

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

吴云¹, 雷建文¹, 鲍丽山², 李春哲³

(1. 东北电力大学信息工程学院, 吉林省吉林市 132012;

2. 国网江苏省电力有限公司信息通信分公司, 江苏省南京市 221000;

3. 国网吉林省电力有限公司辽源供电公司, 吉林省辽源市 136200)

摘要: 针对短期负荷预测的精度问题,文中提出基于改进灰色关联与蝙蝠优化神经网络的短期负荷预测方法。在传统的灰色关联分析方法基础上,引入以距离相似性和形状相近性相关联的综合灰色关联度选取更高相似度的相似日。为缩小训练样本的差异程度,提高预测精度,利用相似日集合中的样本来训练蝙蝠优化的反向传播(BP)神经网络预测模型。以中国南方某城市的历史数据作为实际算例,将文中提出的基于改进灰色关联与蝙蝠优化神经网络的短期负荷预测方法与单纯的BP神经网络法、蝙蝠优化BP神经网络法、传统灰色关联与蝙蝠优化的BP神经网络组合法的预测结果相比,结果表明文中方法的预测精度较高。

关键词: 负荷预测; 神经网络; 蝙蝠算法; 灰色关联; 相似日

0 引言

短期电力负荷预测是电网运行调度、生产规划的重要组成部分,它主要是对未来几时、一天甚至几天的电力负荷进行预测,其主要用于安排短期调度计划、应对紧急情况,是电力系统安全稳定和经济运行的基础^[1-2]。

随着影响负荷预测因素的数量、种类的增多,随机性以及分布特点变得复杂,传统的负荷预测方法的速度与精度已经不能满足大数据环境下的要求^[3]。越来越多的算法应用到负荷预测领域之中,使得负荷预测的精度不断提高^[4]。文献[5]把灰色模型与神经网络的优点相互结合,并采用遗传算法对神经网络进行优化,以此完成对短期电力负荷的预测,预测精度较单一的神经网络方法有所提高。然而该方法的训练样本中有很多异于待测日特征的样本,这不仅造成神经网络训练时间较长,而且收敛速度较慢。文献[6]把改进的随机森林算法与灰色投影相结合对电网短期负荷预测。该方法虽然通过灰色关联投影法能够找到与待测日具有相似特征的历史日,但是找到的相似日只具备良好的负荷趋势相似性,而不具备良好的负荷曲线形状相似性^[7],因此预测精度也有待提高。

为弥补传统灰色关联分析法在选择相似日时只考虑负荷特征曲线的几何相似程度而忽略了数值接近程度的缺陷,克服反向传播(BP)神经网络泛化能力差、易陷入局部最优^[8]等不足,本文提出了一种基于改进灰色关联与蝙蝠优化神经网络的短期负荷预测(IGRA-BA-BP)方法,并结合实际案例对该方法进行了验证。结果表明,相比现有的短期负荷预测方法,本文方法的预测结果有所提高。

1 选取相似日

1.1 负荷影响因素的分析

短期电力负荷预测是依据电力负荷和其影响因素的历史数据,建立相关的预测模型,对未来的电力负荷进行科学的预测。气象因素是影响负荷变化的重要因素,它对负荷的影响主要体现在气象因素的突变会导致电力负荷随之突然变化^[9-10]。日期类型对电力负荷的影响主要体现在工作日与休息日(周末和节假日)之间的用电量差距^[11]。因而本文选取气象因素和日期类型作为负荷的主要影响因素,来对电力负荷进行预测。

1.2 选取相似日粗集

把影响负荷的主要影响因素作为选取相似日粗集指标,通过下述相似日粗集选取规则选取相似日粗集。由天气预报得知待测日的气象数据,从历史日中选出最高温度与待测日相差 $\pm 3\text{ }^{\circ}\text{C}$ 以内的样

本组成集合 A;从集合 A 中选出最低温度与待测日相差 ±3 °C 以内的样本组成集合 B;从集合 B 中的选出平均温度与待测日相差 ±3 °C 以内的样本组成集合 C;从集合 C 中选出降雨量与待测日相差 ±3 mm 以内的样本组成集合 D;从集合 D 中选出日期类型(工作日、节假日、周末)与待测日一致的样本组成集合 E,则集合 E 为相似日粗集。

此过程只是选取出了与待测日具有粗糙相似的历史日期类型和气象特征的历史日,为了提高预测精度,再运用灰色关联分析方法^[12],在相似日粗集中进一步抽取与待测日具有高度关联的若干历史日,以这些历史日作为下一步预测模型的训练样本,无疑将会较大地提高负荷预测的精度^[13]。

1.3 量化影响因素

温度和降雨量以及日期类型的数量级和单位都不相同,不能做进一步计算,如要进一步计算各相似日粗集中的样本与待测日的灰色关联度,需要对各影响因素进行量化,从而方便相似度的计算。本文参考文献^[14]对日期类型的与气象数据进行量化来定性描述日期类型与气象因素对短期电力负荷预测的影响。因其只对降雨类型做了量化,这样量化不够精细,因此本文参照其方法对降雨量根据区间进行量化,如表 1 所示。

表 1 降雨量区间及其量化值
Table 1 Rainfall interval and its quantified value

降雨量/mm	量化取值
0	1.0
0~10	1.5
10~25	2.0
25~50	2.5
50~100	3.0
100~250	5.0

1.4 改进灰色关联分析方法

关联分析的基本思想是根据数据序列的相似程度来判断关联程度^[7,12],是灰色系统理论提出的一种分析系统中各因素关联程度的方法。传统灰色关联分析法使用两个数据序列之差的绝对值计算关联度,只考虑了数据序列之间的几何相似程度,而忽略了数值接近程度。如果两条曲线平行,以传统灰色关联分析法计算出二者关联度为 1,实则两条曲线的关联度不为 1,计算出的关联度与实际不符。

本文从两个角度分析两条特征曲线的关联度,两条特征曲线各点的差越接近 0 或者商越接近 1,则两条特征曲线越接近。提出一种融合差方式和除方式的灰色关联分析方法,从形状和距离上定义综合灰色关联度。改进灰色关联度步骤如下。

1)构造特征矩阵

由各影响因素的值组成特征向量 X,待测日特征向量以 $X_0 = [x_0(1), x_0(2), \dots, x_0(m)]$ 表示。相似日粗集中的每日的特征向量以 X_1, X_2, \dots, X_n 表示,这 n+1 个序列构成一个 $m \times (n+1)$ 阶的特征矩阵如式(1)所示。

$$[X_0 \quad X_1 \quad X_2 \quad \dots \quad X_n] = \begin{bmatrix} x_0(1) & \dots & x_n(1) \\ \vdots & x_i(k) & \vdots \\ x_0(m) & \dots & x_n(m) \end{bmatrix} \quad (1)$$

式中:m 为特征向量的维数;n 为相似日粗集中样本个数; $x_i(k)$ 表示相似日粗集中第 i 个样本的第 k 个特征; $x_0(k)$ 表示待测日的第 k 个特征;下标 $i=1, 2, \dots, n, k=1, 2, \dots, m$ (下同)。

2)计算差矩阵

求待测日序列与相似日粗集中样本序列各分量的差值,组成差值矩阵,如式(2)所示。

$$\Delta x_i^0(k) = |x_0(k) - x_i(k)| \quad (2)$$

式中: $\Delta x_i^0(k)$ 表示待测日的第 k 个特征值与相似日粗集中第 i 个样本的第 k 个特征值的差。

将 Δx_i^0 引入下式构成形状相似性灰色关联度:

$$\gamma_1(x_0(k), x_i(k)) = \frac{1}{e^{\Delta x_i^0(k)}} \quad (3)$$

3)计算商矩阵

求待测日序列与相似日粗集中样本序列各分量的商,组成商矩阵,如式(4)所示。

$$\Delta x_i^0'(k) = \frac{x_i(k)}{x_0(k)} \quad (4)$$

式中: $\Delta x_i^0'(k)$ 表示待测日的第 k 个特征值与相似日粗集中第 i 个样本的第 k 个特征值的商。

将 $\Delta x_i^0'(k)$ 引入下式构成距离相近性灰色关联度:

$$\gamma_2(x_0(k), x_i(k)) = \frac{1}{e^{|\ln \Delta x_i^0'(k)|}} \quad (5)$$

4)计算综合灰色关联度

求得相似日粗集中每个历史日与待测日的综合灰色关联度。综合灰色关联度计算公式如下:

$$\gamma_i^0 = \frac{1}{m} \sum_{k=1}^m \sqrt{\gamma_1(x_0(k), x_i(k)) \gamma_2(x_0(k), x_i(k))} \quad (6)$$

按照求取的综合灰色关联度,选择相似日粗集中综合关联度大于 0.85 的所有样本组成相似日集。

2 建立预测模型

2.1 BP 神经网络

BP 神经网络是一种按照误差逆向传播,反复修

正各层之间的连接权值和阈值,使得误差函数值达到最小的多层前馈神经网络,相邻层之间通过不同的权值实现连接^[15]。本文采用单隐含层的三层神经网络,输入层节点数为8个,其中包含待测日的负荷影响因素与待测日前一天 t 时刻、 $t-1$ 时刻、 $t-2$ 时刻的负荷值。输出层节点为一个,代表待测日 t 时刻的负荷值,隐含层节点数根据经验式(7)来确定^[16]。

$$h = \sqrt{m' + n'} + a \quad (7)$$

式中: m' 和 n' 分别为输入层、输出层节点的个数; h 为隐含层节点个数; a 为1~10之间的调节常数,最终选定隐含层的节点数为4。隐含层和输出层的激活函数采用sigmoid函数^[17]

2.2 蝙蝠算法

蝙蝠算法(bat algorithm, BA)^[18]是一种全局搜索优化算法,其基本思想是将每个种群个体映射为空间中的可行解,把搜索过程和优化过程模拟成蝙蝠个体搜寻猎物和移动的过程,蝙蝠所处位置的优劣以求解问题的适应度函数来衡量,将寻优过程类比为个体的优胜劣汰过程。

蝙蝠在搜索寻优的过程中每个个体的位置、速度以及回声频率按如下公式进行变化:

$$f_i = f_{\min} + (f_{\max} - f_{\min})\beta \quad (8)$$

$$v_i^{t+1} = v_i^t + (p_i^t - p_{\text{best}})f_i \quad (9)$$

$$p_i^{t+1} = p_i^t + v_i^{t+1} \quad (10)$$

式中: p_i^{t+1} 和 p_i^t 分别表示蝙蝠个体 i 在 $t+1$ 和 t 时刻的位置; p_{best} 表示当前所有蝙蝠个体的最优位置; β 为均匀分布在 $[0, 1]$ 上的随机数; f_i 为蝙蝠个体的回声频率, $f_i \in [f_{\min}, f_{\max}]$; v_i^t 和 v_i^{t+1} 分别为蝙蝠 i 在 t 和 $t+1$ 时刻的速度。

对于局部搜索,一旦从现有的最优解中选出一个解,每只蝙蝠的下一个解 p_{new} 就在随机游走中就近产生,即

$$p_{\text{new}} = p_{\text{old}} + \theta A^t \quad (11)$$

式中: θ 为 $[0, 1]$ 区间内的随机数; $A^t = \langle A_i^t \rangle$ 为所有蝙蝠在这个时刻的平均响度; p_{old} 为每个蝙蝠个体当前最优解中的任何一个解。

在初始时个体保持较强的响度和较低的脉冲发射率,在搜寻到食物后,则不断减小响度,增大脉冲发射率,蝙蝠在搜寻猎物过程中,脉冲发射率和响度表示公式如下:

$$r_i^{t+1} = r_i^0 (1 - e^{-\mu t}) \quad (12)$$

$$A_i^{t+1} = \alpha A_i^t \quad (13)$$

式中: α 为脉冲响度衰减系数, μ 为脉冲发射率增加系数, α 和 μ 为常量,通常都取0.9; r_i^0 为最大脉冲发

射率; r_i^{t+1} 为 $t+1$ 时刻的脉冲发射率。响度和脉冲发射率只有在解进化的时候更新,这意味着蝙蝠算法只朝着最优解方向进行^[19]。

2.3 BA优化BP神经网络

由于神经网络训练过程缓慢,容易陷入局部小值,甚至还有可能无法收敛^[20],所以对BP神经网络的初始参数进行优化。蝙蝠算法因具备并行性、分布式和收敛速度快等特点,被广泛应用到各个领域。它比粒子群优化算法^[21]和遗传算法更具发展潜力,BA算法结合这些算法的主要优点,在优化神经网络方面性能优越^[22]。

采用BA对BP神经网络的初始权值和阈值进行优化,使其不易陷入局部极小值,还可以增强泛化性能,提高预测精度和收敛速度。BA优化的适应度函数为:

$$\text{Fitness}(i) = \frac{1}{g} \sum_{i=1}^g \sum_{j=1}^{n'} (y_{i,j}^d - y_{i,j})^2 \quad (14)$$

式中: g 为样本个数; $y_{i,j}^d$ 为第 i 个样本的第 j 个输出节点的预测值; $y_{i,j}$ 为第 i 个样本的第 j 个输出节点对应的实际值。

BA优化BP神经网络的步骤如下。

步骤1:初始化神经网络结构,即初始化输入层、隐含层、输出层的节点个数,导入训练数据。

步骤2:初始化蝙蝠种群,即初始化种群规模 N ,脉冲频率的范围为 $f_{\min} \sim f_{\max}$,第 i 只蝙蝠个体的位置 p_i^t 和速度 v_i^t ($i=1, 2, \dots, N$),脉冲响度 A_i^t 和脉冲发射率 r_i^t ,脉冲响度衰减系数 α ,最大迭代次数 g' 和搜索精度 ϵ 。

步骤3:计算适应度 $\text{Fitness}(i)$ 当前最优适应度 F_{best} ,当前最优位置 p_{best} 。

步骤4:按照式(8)至式(10)产生新解。

步骤5:若随机数 η_{rand} 大于脉冲发射率 r_i^t ,则在当前所有个体中选择一个个体的位置为全局最优个体位置 p_{best} ,利用式(11)在 p_{best} 附近随机产生一个局部个体,并计算这个局部个体的适应度值 F_{new} 。

步骤6:若步骤5中 F_{new} 优于 F_{best} ,且 η_{rand} 小于响度 A_i^t ,则把该新解设为当前最优全局个体,保存其适应度值,利用式(12)和式(13)增大 r_i^t 和减小 A_i^t 。

步骤7:判断算法是否达到终止条件,若达到终止条件,输出结果,得到神经网络的最优权值和阈值。否则,返回步骤4继续迭代。

步骤8:将蝙蝠全局最优位置对应的权值和阈值作为BP神经网络参数,建立最优的负荷预测模型。BA优化BP神经网络流程图见附录A图A1。

3 预测实例及结果分析

3.1 预测实例

算例 1:采用中国南方某地区 2014 年 6 月 1 日到 9 月 23 日的历史数据,对 2014 年 9 月 24 日全天 24 h 的电力负荷进行预测。首先利用本文第 1 节所述规则从历史数据中选出相似日粗集,共有 28 个样本被选入相似日粗集。再利用本文改进的灰色关联方法计算相似日粗集中样本与待测日的综合灰色关联度,计算结果见图 1。选取综合灰色关联度大于 0.85 的样本作为待测日的最终相似日集,用来训练神经网络。

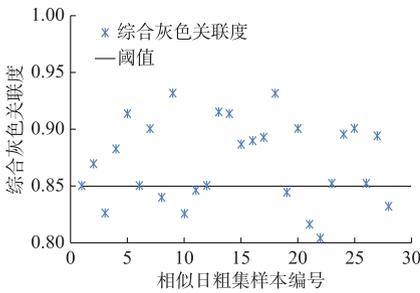


图 1 综合灰色关联度
Fig.1 Comprehensive grey relational degree

把预处理后的原始数据 y 经式(15)归一化后与量化之后的影响因素组成神经网络的输入向量。预测结果的反归一化如式(16)所示。

$$y_{input} = \frac{y - \min(y)}{\max(y) - \min(y)} \quad (15)$$

$$\hat{y}(t) = \min(y) + y_{output} (\max(y) - \min(y)) \quad (16)$$

式中: y_{input} 为归一化后的负荷数据; $\hat{y}(t)$ 为反归一化后的输出负荷数据,即为预测值; y_{output} 为神经网络输出结果。

相关参数设置:BP 神经网络为 3 层网络结构,隐含层和输出层之间采用 sigmoid 函数,学习率为 0.01,输入节点为 8 个,隐含层节点为 4 个,输出节点为 1 个,需要优化的权值和阈值为 $8 \times 4 + 4 \times 1 + 4 + 1 = 41$ 个,其中权值为 36 个,阈值为 5 个。所以蝙蝠个体维数为 41,个体中各分量的范围为 $[-1, 1]$,种群规模为 20,脉冲响度为 0.3,脉冲发射率为 0.5,脉冲响度衰减系数和脉冲发射率增加系数都为 0.9,回声频率范围 $[f_{min}, f_{max}]$ 为 $[0, 3]$,最大迭代次数为 5 000 次,期望误差为 0.001。

使用全部历史数据分别通过单一的 BP 神经网络预测方法、蝙蝠优化 BP 神经网络组合预测(BA-BP)方法、传统灰色关联与蝙蝠优化 BP 神经网络组

合预测(GRA-BA-BP)方法以及本文所提 IGRA-BA-BP 方法对 2014 年 9 月 24 日电力负荷进行预测,预测结果如图 2 所示。

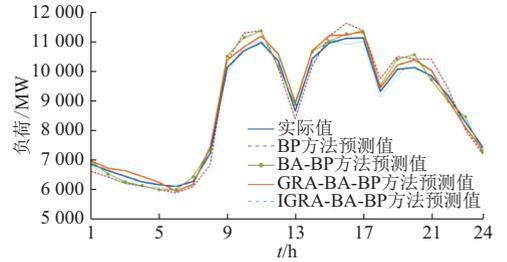


图 2 预测负荷曲线与实际负荷曲线
Fig.2 Prediction load curves and actual load curve

3.2 误差分析

通常将误差的评价指标选为绝对值平均误差 E_{MRE} 和均方根误差 E_{RMSE} [23]。设 $y(t)$ 和 $\hat{y}(t)$ 分别表示 t 时刻的实际负荷值和预测值,相对误差如式(17)所示。

$$E_{RE} = \frac{y(t) - \hat{y}(t)}{y(t)} \times 100\% \quad (17)$$

由于相对误差 E_{RE} 有正负,为了避免正负相抵消,计算平均相对误差的时候取相对误差的绝对值。平均相对误差如式(18)所示,均方根误差如式(19)所示。

$$E_{MRE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y(t) - \hat{y}(t)}{y(t)} \right| \times 100\% \quad (18)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left| \frac{y(t) - \hat{y}(t)}{y(t)} \right|^2} \times 100\% \quad (19)$$

均方根误差指标加强了数值大的误差的作用,提高了该指标的灵活性。

为方便分析,把相对误差去绝对值,做出对比如图 3 所示。

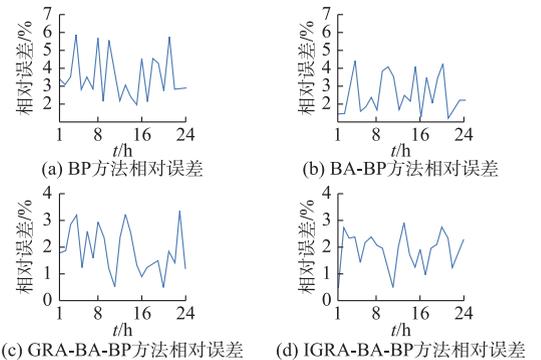


图 3 相对误差对比
Fig.3 Comparison of relative error

4 种方法的平均相对误差和均方根误差如表 2 所示。

表 2 平均相对误差与均方根误差
Table 2 Mean relative error and root mean square error

方法	$E_{MRE}/\%$	$E_{RMSE}/\%$
BP	3.38	3.56
BA-BP	2.31	2.50
GRA-BA-BP	2.02	2.13
IGRA-BA-BP	1.95	2.08

由图 3 和表 2 可以看出:采用优化过的神经网络来预测短期电力负荷,误差比单一的神经网络预测要小;BA-BP 方法预测结果的平均相对误差和均方根误差比单一的 BP 神经网络分别减小 1.07% 和 1.06%;采用灰色关联选取相似日和优化的神经网络相结合的预测方法,预测效果相比没有采用相似日法的预测效果也有明显的提升;GRA-BA-BP 方法预测结果的平均相对误差和均方根误差比 BA-BP 方法分别减小 0.29% 和 0.37%;而预测效果最好的是 IGRA-BA-BP 方法,其预测结果比 GRA-BA-BP 方法预测结果的平均相对误差和均方根误差分别降低了 0.07% 和 0.05%;IGRA-BA-BP 方法的预测效果比 BA-BP 和 BP 方法的预测效果都有了大幅的提高,其中平均相对误差与均方根误差比 BP 方法分别减小了 1.43% 和 1.48%。

算例 2:为充分证明本文方法的优越性,随机选择一组数据对其中一天的负荷进行预测,以 2014 年 3 月 1 日到 5 月 20 日的历史数据,对 2014 年 5 月 21 日全天 24 h 的电力负荷进行预测。并分别与算例 1 另外三种方法的预测结果对比,预测负荷曲线和实际负荷曲线图见附录 A 图 A2,具体的预测误差见附录 A 表 A1。

4 结语

针对短期电力负荷预测中选择相似日的问题,本文首先通过相似日粗集选取规则从历史日中选取与待测日具有相似性的样本,在常规灰色关联分析的基础之上引入形状相似性和距离相近性,选取综合灰色关联度大于 0.85 的样本组成相似日集,利用相似日集作为神经网络预测模型的训练样本,减少了训练样本的数量和差异程度。在 BP 神经网络预测的基础上,对其初始权值和阈值进一步优化,使得 BP 神经网络很快速地收敛到一个较好的解。通过把本文方法的预测的结果分别和没有经过相似日选择的两种方法以及利用传统灰色关联方法选取相似日的预测方法相比较可得,改进的灰色关联方法与蝙蝠优化的神经网络结合,可以有效提高短期电力负荷预测的预测精度,为电网发电、调度等环节提供可靠支持。但是随着电力系统数据量的增加,文中

方法在大数据环境下的应用还有一定的局限性。未来可以将本文方法和大数据平台结合,进一步提高该方法的训练效率、应用范围及数据处理能力。

附录见本刊网络版 (<http://www.aeps-info.com/aeps/ch/index.aspx>)。

参考文献

- [1] 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].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]. Automation of Electric Power Systems, 2011, 39(1): 147-152.
- [2] RAZA M Q, KHOSRAVI A. A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings[J]. Renewable & Sustainable Energy Reviews, 2015, 50: 1352-1372.
- [3] 吴倩红,高军,侯广松,等.实现影响因素多源异构融合的短期负荷预测支持向量机算法[J].电力系统自动化,2016,40(15): 67-72. DOI:10.7500/AEPS20160229012.
WU Qianhong, GAO Jun, HOU Guangsong, et al. Short-term load forecasting support vector machine algorithm based on multi-source heterogeneous fusion of load factors [J]. Automation of Electric Power Systems, 2016, 40(15): 67-72. DOI: 10.7500/AEPS20160229012.
- [4] KUSTER C, REZGUI Y, MOURSHED M. Electrical load forecasting models: a critical systematic review[J]. Sustainable Cities and Society, 2017, 35: 257-270.
- [5] 葛少云,贾鸣莎,刘洪.基于遗传灰色神经网络模型的实时电价条件下短期电力负荷预测[J].电网技术,2012,36(1):224-229.
GE Shaoyun, JIA Ousha, LIU Hong. A gray neural network model improved by genetic algorithm for short-term load forecasting in price-sensitive environment [J]. Power System Technology, 2012, 36(1): 224-229.
- [6] 吴潇雨,和敬涵,张沛,等.基于灰色投影改进随机森林算法的电力系统短期负荷预测[J].电力系统自动化,2015,39(12):50-55. DOI:10.7500/AEPS20140916005.
WU Xiaoyu, HE Jinghan, ZHANG Pei, et al. Power system short term load forecasting based on improved random forest with grey relation projection[J]. Automation of Electric Power Systems, 2015, 39(12): 50-55. DOI: 10.7500/AEPS20140916005.
- [7] 莫维仁,张伯明,孙宏斌,等.短期负荷预测中选取相似日的探讨[J].清华大学学报(自然科学版),2004,44(1):106-109.
MO Weiren, ZHANG Boming, SUN Hongbin, et al. In the short-term load forecasting a similar day is selected[J]. Journal of Tsinghua University (Natural Science), 2004, 44(1): 106-109.
- [8] 孔祥玉,郑锋,鄂志君,等.基于深度信念网络的短期负荷预测方法[J].电力系统自动化,2018,42(5):133-139. DOI:10.7500/AEPS20170826002.
KONG Xiangyu, ZHENG Feng, E Zhijun, et al. Short-term load forecasting based on deep belief network[J]. Automation of Electric Power Systems, 2018, 42(5): 133-139. DOI: 10.7500/AEPS20170826002.
- [9] LUSIS P, KHALILPOUR K R, ANDREW L, et al. Short-term residential load forecasting: impact of calendar effects and

- forecast granularity[J]. *Applied Energy*, 2017, 205: 654-669.
- [10] CAO X, DONG S, WU Z, et al. A data-driven hybrid optimization model for short-term residential load forecasting [C]// *IEEE International Conference on Computer and Information Technology*, October 26-28, 2015, Liverpool, UK: 283-287.
- [11] 随惠惠. 基于 BP 神经网络的短期电力负荷预测的研究[D]. 哈尔滨: 哈尔滨工业大学, 2015.
SUI Huihui. Research on short-term electric load forecasting based on BP neural network[D]. Harbin: Harbin Institute of Technology, 2015.
- [12] 曹明霞. 灰色关联分析模型及其应用的研究[D]. 南京: 南京航空航天大学, 2007.
CAO Mingxia. Research on grey incidence analysis model and its application[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2007.
- [13] ZHANG Xiaoyu, WANG Rui, LIAO Tianjun, et al. Short-term forecasting of wind power generation based on the similar day and Elman neural network[C]// *IEEE Symposium Series on Computational Intelligence*, December 7-10, 2015, Cape Town, South Africa: 647-650.
- [14] 于龙. 基于模糊聚类选取相似日的短期电力负荷预测[D]. 上海: 上海交通大学, 2013.
YU Long. Short-term power load forecasting based on fuzzy clustering similar days [D]. Shanghai: Shanghai Jiao Tong University, 2013.
- [15] PIAN Zhaoyu, LI Shengzhu, ZHANG Hong, et al. The application of the PSO based BP network in short-term load forecasting[J]. *Physics Procedia*, 2012, 24: 626-632.
- [16] 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): 36-42.
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(Supplement 1): 36-42.
- [17] KYURKCHIEV N, MARKOV S. On the approximation of the step function by some sigmoid functions[J]. *Mathematics and Computers in Simulation*, 2017, 133: 223-234.
- [18] YANG Xinshe. A new metaheuristic bat-inspired algorithm[J]. *Nature Inspired Cooperative Strategies for Optimization*, 2010, 284: 65-74.
- [19] 谢健, 周永权, 陈欢. 一种基于 Lévy 飞行轨迹的蝙蝠算法[J]. *模式识别与人工智能*, 2013, 26(9): 830-837.
XIE Jian, ZHOU Yongquan, CHEN Huan. A bat algorithm based on Lévy flights trajectory[J]. *Pattern Recognition and Artificial Intelligence*, 2013, 26(9): 830-837.
- [20] WANG Jian, WEN Yanqing, YE Zhenyun, et al. Convergence analysis of BP neural networks via sparse response regularization [J]. *Applied Soft Computing*, 2017, 61: 354-363.
- [21] 史冬琳, 邵思阳. 基于粒子群算法的火电厂锅炉燃烧模糊解耦控制[J]. *东北电力大学学报*, 2017, 37(1): 60-65.
SHI Donglin, SHAO Siyang. Fuzzy decouple control of boiler combustion system for the thermal power plant based on PSO [J]. *Journal of Northeast Electric Power University*, 2017, 37(1): 60-65.
- [22] KHAN K, SAHAI A. A comparison of BA, GA, PSO, BP, and LM for training feed forward neural networks in e-learning context[J]. *Intelligent Systems and Applications*, 2012, 7(4): 23-29.
- [23] 杨茂, 张强. 风电功率超短期预测误差的非参数估计分布研究[J]. *东北电力大学学报*, 2018, 38(1): 15-20.
YANG Mao, ZHANG Qiang. The research of ultra short-term wind power prediction error distribution based on nonparametric estimation [J]. *Journal of Northeast Electric Power University*, 2018, 38(1): 15-20.

吴云(1976—), 女, 硕士, 副教授, 主要研究方向: 智能信息处理。E-mail: 838558160@qq.com
雷建文(1993—), 男, 通信作者, 硕士研究生, 主要研究方向: 电力负荷预测。E-mail: 254846210@qq.com
鲍丽山(1976—), 男, 硕士, 高级工程师, 主要研究方向: 电网运行。E-mail: 138013800@qq.com

(编辑 孔丽蓓)

Short-term Load Forecasting Based on Improved Grey Relational Analysis and Neural Network Optimized by Bat Algorithm

WU Yun¹, LEI Jianwen¹, BAO Lishan², LI Chunzhe³

(1. School of Information Engineering, Northeast Electric Power University, Jilin 132012, China;

2. Information and Communication Branch of State Grid Jiangsu Electric Power Co. Ltd., Nanjing 221000, China;

3. Liaoyuan Power Supply Company of State Grid Jilin Electric Power Company, Liaoyuan 136200, China)

Abstract: In view of the accuracy of short-term load forecasting, a short-term load forecasting method based on improved grey relational analysis and back propagation (BP) neural network optimized by bat algorithm (IGRA-BA-BP) is proposed. On the basis of traditional grey relational analysis, comprehensive grey correlation degree associated with distance proximity and shape similarity is introduced to select the similar days of higher similarity. In order to reduce the difference of training samples and improve the accuracy of prediction, the samples of similar day set are used to train BP neural network prediction model which is optimized by bat algorithm. Taking historical data in a region of southern China as an actual example, the prediction results of simple BP neural network, BP neural network optimized by bat algorithm (BA-BP) and the traditional grey relational analysis and BP neural network optimized bat algorithm (GRA-BA-BP) are compared with the short-term load forecasting method based on the improved grey relational analysis and BP neural network optimized by bat algorithm, the results show that the prediction accuracy of the proposed method is better.

Key words: load forecasting; neural network; bat algorithm; grey correlation; similar day