

DOI: 10.7667/PSPC160412

## 基于动态权值相似日选取算法的短期负荷预测

李啸聪, 李春涛, 从兰美, 任子熠, 罗宏亮, 王彧文, 袁辉, 丘浩

(广西大学电气工程学院, 广西 南宁 530004)

**摘要:** 提出了一种基于动态权值优化的相似日选取算法和灰色 GRNN 串联组合模型的短期负荷预测方法。采用动态权值相似日选取算法, 在考虑不同地区和季节对短期负荷的影响时, 引入改进的果蝇优化算法(MFOA), 动态调整各因子的权值, 增强了相似日选取算法的适应性和有效性。选取出相似日后, 采用灰色模型和广义回归神经网络(GRNN)串联组合的短期负荷预测方法, 并通过改进的布谷鸟(MCS)算法对 GRNN 平滑因子进行优化, 组合模型改善了单一模型预测精度的稳定性。实例预测结果验证了该方法的有效性。

**关键词:** 短期负荷预测; 相似日; 改进的果蝇优化算法; 灰色模型; 广义回归神经网络; 改进的布谷鸟算法

### Short-term load forecasting based on dynamic weight similar day selection algorithm

LI Xiaocong, LI Chuntao, CONG Lanmei, REN Ziyi, LUO Hongliang, WANG Yuwen, YUAN Hui, QIU Hao

(College of Electrical Engineering, Guangxi University, Nanning 530004, China)

**Abstract:** A short-term load forecasting method based on similar day algorithm with dynamic weight value and GM-GRNN model is proposed. Traditional ways to select similar days can not effectively identify the dominant factors. Aiming at this problem, the dynamic weight similarity day selection algorithm based on modified fruit fly optimization algorithm (MFOA) is proposed, which is based on the optimization algorithm of different regions and seasons. The method improves adaptability and effectiveness of the algorithm. Moreover, the accuracy of load forecasting is enhanced. After the selection of similar days, the short-term load forecasting method of grey model and generalized regression neural network (GRNN) is proposed, which improves the stability of the single model forecasting accuracy. In order to further optimize the prediction model, the GRNN smoothing factor is optimized by the modified cuckoo search (MCS) algorithm. Simulation results verify the validity of the proposed method.

This work is supported by National Natural Science Foundation of China (No. 51267001), Guangxi Scientific Research and Technological Development Program (No. 14122006-29), and Natural Science Foundation of Guangxi Province (No. 2014GXNSFAA118338).

**Key words:** short-term load forecasting; similar day; fruit fly algorithm; grey model; general regression neural network; modified cuckoo search

## 0 引言

长期以来, 国内外学者对短期负荷预测<sup>[1-3]</sup>做了大量研究, 主要方法有: 时间序列法<sup>[4]</sup>、线性外推法、灰色理论<sup>[5-8]</sup>、专家系统法、人工神经网络<sup>[9]</sup>、模糊预测法、支持向量机等。

基于相似日的短期负荷预测方法<sup>[10-12]</sup>, 原理上

跟调度部门的人工预测方法相似, 能够减少预测模型输入数据的维数, 利用较少的训练数据可以达到较高的预测精度。如何通过已有的相关数据快速找到有效的相似日是相似日选取算法的关键。传统方法在选取相似日时, 各因子的影响大小一般采用固定权系数, 不能有效识别主导因素的影响, 选取出的相似日可能会对短期负荷预测精度产生不利影响。文献[10-11]提出的相似日选取算法, 虽然考虑到气象等各种因素对短期负荷的影响, 但是在计算相似度时, 只是将各因素的相似度系数简单的相乘, 并没有考虑到这些因素对短期负荷影响比重

**基金项目:** 国家自然科学基金资助项目(51267001); 广西科学研究与技术开发计划项目(14122006-29); 广西自然科学基金资助项目(2014GXNSFAA118338)

的动态变化。因此,针对这些方法的不足,本文在相似日选取时,充分考虑到了几种主要常规因子对短期负荷的影响,并提出把实时气象数据序列相似系数作为一个新的影响因子增加到相似日选取算法中;针对各影响因子在不同时期和地区对负荷影响程度的变化,提出一种基于改进果蝇优化算法<sup>[13]</sup>的相似日选取方法,该方法选取的相似日具有适应性强的优点,能自动识别主导因素的影响,使得相似日的选取更为准确。

组合预测模型可以综合各个模型的优点,提供精度更为稳定的预测结果。因此,本文在提取出相似日负荷序列的基础上,以灰色模型的输出作为GRNN<sup>[14]</sup>的输入,提出一种基于相似日和灰色GRNN串联组合的预测模型,该模型利用改进的布谷鸟优化算法<sup>[15]</sup>优化GRNN的平滑因子,使得模型的预测精度显著提高。由于布谷鸟算法属于智能算法,容易陷入局部最优,本文在自适应的步长的基础上,引入逐维指数扰动因子,以提高搜索速度和避免进入陷入局部最优。

## 1 基于改进果蝇优化算法的相似日选取

### 1.1 短期负荷特性主要影响因素的相似度计算

#### 1.1.1 气象因子相似度计算

影响短期负荷的气象因素有很多,从中选取对负荷特性影响比较大的因素:温度、湿度、降雨量和天气状况,把它们作为研究对象,并计算预测日与历史日气象因素相似度。

(1) 日特征气象因素相似度计算<sup>[10]</sup>。先将气象因素量化取值并归一化到[0, 1]区间,设 $x_i(i=1, \dots, L)$ ,  $x_0$ 分别为历史日和预测日的日气象因素特征向量,其中,  $L$ 表示预测日前 $L$ 天内的历史日,第 $i$ 个历史日气象因素日特征向量为 $x_i=(x_i(1), \dots, x_i(m))$ ,依次为日最高温度、最低温度、平均温度、最大湿度、降雨量和天气状况,  $m$ 为日特征因素个数,  $x_0=(x_0(1), \dots, x_0(m))$ 。用灰色关联度计算序列 $x_0$ 与 $x_i$ 相似度,则

$$\zeta_i(k) = \frac{\min_i \min_k |x_0(k) - x_i(k)| + \rho \max_i \max_k |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \max_i \max_k |x_0(k) - x_i(k)|} \quad (1)$$

式中:  $\zeta_i(k)$ 为 $x_0$ 与 $x_i$ 序列在 $k$ 点的灰色关联系数;  $\min_i \min_k |x_0(k) - x_i(k)|$ 为2级最小差;  $\max_i \max_k |x_0(k) - x_i(k)|$ 为2级最大差;  $\rho \in (0, 1)$ ,通常取为0.5。联合上述各个因子的关联系数,可得第 $i$ 个历史日与预测日的关联度计算公式<sup>[16]</sup>为

$$\mu_i = \frac{1}{m} \sum_{k=1}^m \zeta_i(k) \quad (2)$$

(2) 实时温度相似度计算。将实时温度数据归一化,设 $y_i(i=1, \dots, L)$ ,  $y_0$ 分别表示第 $i$ 个历史日和预测日的实时温度特征向量,  $y_i=(y_i(1), \dots, y_i(n))$ ,  $y_0=(y_0(1), \dots, y_0(n))$ ,  $n$ 取值为96,表示一天96个时刻点,用相似系数公式计算序列 $y_0$ 和 $y_i$ 的相似系数,计算式如式(3)。

$$S_i = \frac{\sum_{k=1}^n y_i(k)y_0(k)}{\sqrt{\sum_{k=1}^n y_i^2(k) \sum_{k=1}^n y_0^2(k)}} \quad (3)$$

式中:  $S_i$ 表示相似系数;  $k$ 表示序列号( $k=1, 2, \dots, 96$ )。

(3) 实时湿度相似度计算。因其与实时温度相似系数计算相似,故同理可得到第 $i$ 个历史日与预测日的实时湿度相似系数为 $M_i$ 。

#### 1.1.2 星期因子相似度计算

电力负荷特性在星期类型上有明显的规律性,星期类型越相近,负荷特性越相似。

星期因子相似度计算公式<sup>[10]</sup>如式(4)。

$$\gamma_i = 1 - |g(x_i) - g(x_0)| \quad (4)$$

式中,  $x_0$ 与 $x_i$ 分别表示为预测日与历史日的星期类型,其映射后的值分别为 $g(x_0)$ 和 $g(x_i)$ 。

#### 1.1.3 时间因子相似度计算

时间因子是指预测日距历史日的天数,表现为“近大远小”原则,即预测日距历史日越近,负荷特性相似度越大。又考虑到负荷变化的周期性,其计算式<sup>[10]</sup>如式(5)。

$$\varepsilon_i = \begin{cases} \theta_1^{\text{mod}(t, K_1)} \theta_2^{\text{int}(t/K_2)} & \theta_1^{\text{mod}(t, K_1)} \theta_2^{\text{int}(t/K_2)} \geq b \\ b & \theta_1^{\text{mod}(t, K_1)} \theta_2^{\text{int}(t/K_2)} < b \end{cases} \quad (5)$$

式中:  $t$ 为预测日距离第 $i$ 个历史日的天数;  $\text{mod}$ 为取余函数;  $\text{int}$ 为取整运算;  $K_1$ 、 $K_2$ 取值为7,表示一周的天数;  $\theta_1$ 和 $\theta_2$ 分别为日衰减系数和周衰减系数,取值范围在0.90~0.98,本文取为0.95;  $b$ 为相似度下限。

## 1.2 基于果蝇优化算法的综合因子相似日选取

### 1.2.1 算法基本设计

上述各因子相似度计算分别量化了历史日与预测日在各主要影响因素的相似程度。然而,每一种影响因素对负荷特性的影响大小并不是一成不变的,会随外部条件改变。因此,为了能更好地适应这种动态变化,本文引入综合因子相似度,采用各因子相似度带权相加方法计算综合因子相似度,引入权重系数来反映这种变化,其计算式可以表示如式(6)。

$$\sigma_i = f_1\mu_i + f_2S_i + f_3M + f_4\gamma_i + f_5\varepsilon_i \quad (6)$$

式中:  $\sigma_i$  为第  $i$  个历史日与预测日的综合因子相似度;  $f_1, f_2, f_3, f_4, f_5$  分别为日特征气象因子、实时温度、实时湿度、星期因子和时间因子的相似度权重系数。

为了让权重系数  $f_1, f_2, f_3, f_4, f_5$  能够动态适应地区和季节的变化, 引入改进的果蝇优化算法, 动态优化权重系数, 从而达到参数的自适应。

得到综合因子计算公式后, 分别计算历史日与预测日综合相似度, 并将其按数值大小排序, 从历史日中选取部分综合因子相似度较高的日期作为相似日。

### 1.2.2 改进的果蝇算法优化权重参数

本文采用改进的果蝇优化算法(MFOA)<sup>[13]</sup>搜寻最优权重参数, 算法步骤如下:

(1) 初始化权重参数  $f_1^0, f_2^0, f_3^0, f_4^0, f_5^0$ , 其和值为1, 由于参数个数是5个, 因此要设置5个坐标位置。种群数量15个, 终止迭代次数为100。对每个参数随机生成果蝇初始群体位置  $(x_i^0, y_i^0, z_i^0)$ ,  $i = 1, \dots, 5$ 。

(2) 设置个体搜寻食物的距离与方向, 设参数  $m = 1, \dots, 100$ , 表示迭代次数。

$$\begin{cases} x_i^m = x_i^{m-1} + \text{random} \\ y_i^m = y_i^{m-1} + \text{random} \\ z_i^m = z_i^{m-1} + \text{random} \end{cases} \quad (7)$$

(3) 引入味道浓度判定值  $S(i)$ , 即果蝇个体与原三维距离之倒数并加上一个逃脱参数  $\Delta$ 。

$$\begin{cases} \text{Dist}(i) = \sqrt{x_i^2 + y_i^2 + z_i^2} \\ S(i) = \frac{1}{\text{Dist}(i)} + \Delta \\ f_i^m = S(i) \end{cases} \quad (8)$$

(4) 将参数归一化, 始终保持参数之和为1。求取果蝇个体的味道浓度值  $\text{Smell}(m)$ , 将味道浓度判定值代入味道浓度判定值函数得到浓度值。

$$\text{Smell}(m) = \text{Funcion}(f_1^m, \dots, f_5^m) \quad (9)$$

(5) 锁定果蝇群体中味道浓度最高的个体, 即求出极大值。

(6) 保留最佳味道浓度值与对应的位置坐标。此时, 群体中的其他个体都会飞向此位置。

(7) 迭代寻优, 重复步骤(2)至(5), 并判断味道浓度是否优于前一代值, 若是则执行步骤(6)。

基于改进果蝇算法优化的相似日选取方法基本步骤如下:

(1) 读取气象、星期类型和时间等负荷特性影响

因子数据以及历史负荷数据。

(2) 将各影响因子数据量化和归一化处理。

(3) 计算历史日和预测日各影响因子相似度。

(4) 采用改进的果蝇优化算法优化式(6)中的权重系数  $f_1, f_2, f_3, f_4, f_5$ 。

(5) 将最优权值系数组代入式(6)中, 计算各个历史日与预测日综合因子相似度值。

(6) 将计算出的历史日与预测的综合因子相似度值按照从大到小的顺序排序。

(7) 选取排序靠前的若干综合因子相似度较大的日期作为预测日的相似日。

相似日选取算法流程图如图1所示。

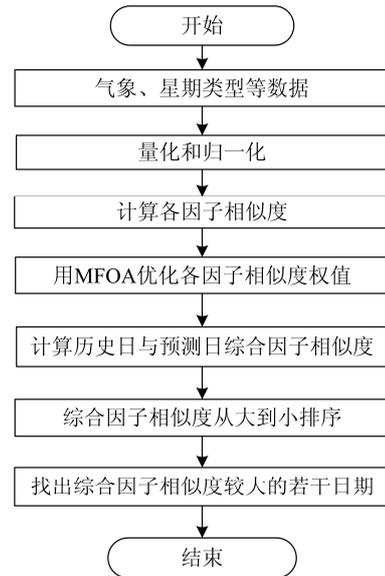


图1 相似日选取算法流程图

Fig. 1 Flow chart of similar day selection algorithm

## 2 基本概念

### 2.1 灰色模型 G(1, 1)

灰色系统理论主要针对信息不完全的系统进行研究, 将原始序列进行某种生成方式而得到新的序列, 将新数据序列建成微分方程模型, 最后反生成化, 其核心是灰色模型, 本文采用 GM(1,1)模型。

### 2.2 改进的布谷鸟优化算法

布谷鸟(Cuckoo Search, CS)优化算法<sup>[17]</sup>采用莱维飞行(Levy Flights)随机搜索机制搜索全局最优解。然而采用莱维飞行搜索方式, 步长时长短, 随机性比较大, 从而造成寻优精度低。文献[15]采用自适应步长, 并且增加高斯扰动。而本文则采用在自适应步长的基础上增加逐维指数扰动因子, 增强其跳出局部最优的能力。自适应步长公式如下:

$$step_i = step_{min} + (step_{max} - step_{min}) \cdot \frac{\|X_i^t - X_{best}^t\|}{\max\|X_i^t - X_{best}^t\|} \quad (10)$$

式中,  $X_i^t$  和  $X_{best}^t$  表示第  $i$  个寄生巢第  $t$  次迭代位置和当前最佳位置。

宿主发现布谷鸟蛋后, 对鸟巢位置施加逐维指数扰动因子, 如式(11)。

$$X_i^{t+1} = \omega \cdot X_i^t + \varphi \cdot \text{exprnd}(\theta) \quad (11)$$

式中:  $\omega$  和  $\varphi$  为权重系数, 分别取为 0.38 和 0.62;  $\text{exprnd}(\theta)$  为指数分布随机数。

### 2.3 广义回归神经网络

广义回归神经网络(GRNN)<sup>[14]</sup>是一种监督式的学习方式网络, 具有训练速度快, 逼近和分类能力突出, 网络可收敛于集聚较多的优化回归面等优点。其网络结构如图2所示。

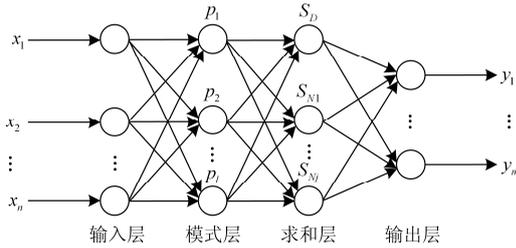


图2 GRNN 模型

Fig. 2 Model of GRNN

### 2.4 GRNN 参数优化

GRNN的理论基础是非线性核回归分析, 其基函数是径向对称的, 具有良好的非线性逼近能力, 通常情况下, 假设训练样本中每一维数据都呈高斯分布, 需要优化的主要参数是隐含层神经元中基函数的光滑因子<sup>[18]</sup>。针对参数光滑因子的优化问题, 很多学者都进行了深入探索研究, 引入了很多种优化算法, 取得了不错的效果。

平滑因子就是  $spread$  值, 取值范围是0到1, 越靠近0, 函数逼近越准确, 越靠近1, 拟合越平滑, 逼近误差也越大。本文采用改进的布谷鸟算法对GRNN的平滑因子进行优化。MCS算法的适应度值为训练样本的输出值与实际值的均方根误差, 表达式如式(12)。

$$y_{error} = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (y_i' - y_i)^2} \quad (12)$$

式中:  $y_i'$  为样本输出值;  $y_i$  为实际值。选出最优位置鸟巢, 作为GRNN模型的平滑因子值。

基于改进的布谷鸟算法(MCS)优化GRNN的具体流程图如图3所示。

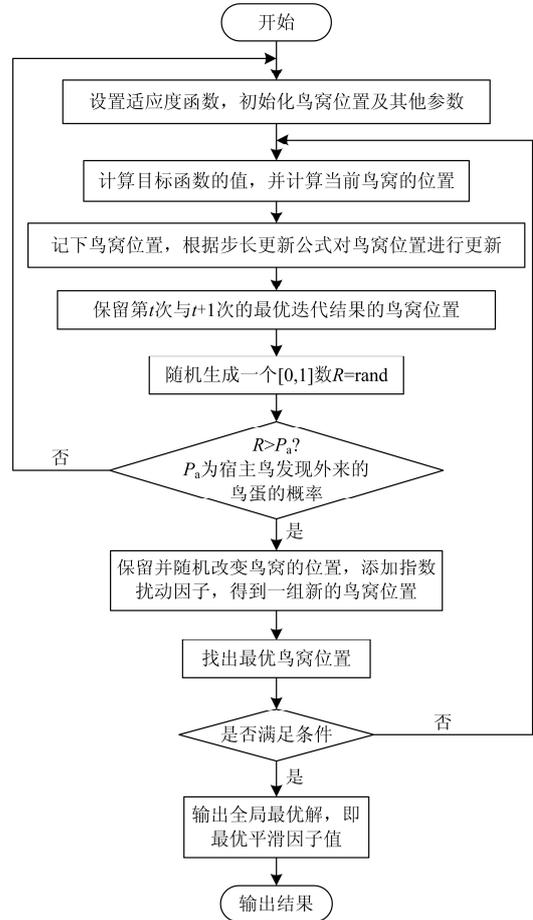


图3 基于MCS的GRNN参数优化流程图

Fig. 3 Flow chart of parameter optimization of GRNN based on MCS

## 3 GM-GRNN 串联组合预测模型

### 3.1 基于相似日和灰色预测模型的建立

从预测日前 60 个历史日中, 用基于改进果蝇优化算法相似日选取方法, 挑选出综合因子相似度最高的 10 天作为预测日的相似日。提取出这 10 个相似日的负荷数据, 对 96 个时段负荷序列分别建立灰色预测模型。

### 3.2 串联组合模型的建立

经过灰色模型拟合出来的预测值在一定精度上已经反映了当天的实测值, 即预测值与实测值本身存在很强的相关性<sup>[19]</sup>, 因此, 为了进一步提高预测精度和可靠性, 我们需要对预测值和实测值的关系做进一步的研究, 研究方法步骤如下:

(1) 用上述提出的相似日选取算法选出与预测日相似度最高的 10 个相似日。并将这 10 个相似日依次作为研究对象, 选出每个相似日相似度最高的日期, 即, 相似日的最高相似日。

(2) 用基于相似日和灰色模型方法计算出相似

日中每个时刻点负荷的拟合值和预测日每个时刻的预测值。

(3) 将这 10 个相似日中每个时刻的拟合值、日特征气象数据、每个时刻点的实时气象数和每个相似日的最高相似日中每个时刻的实测值、日特征气象数据、每个时刻点的实时气象数据作为训练样本的输入, 这 10 个相似日中每个时刻的实测值作为训练样本的期望值, 建立广义回归神经网络, GRNN 平滑因子采用改进的布谷鸟算法进行优化。

(4) 然后将步骤(2)中预测模型计算出的预测日每个时刻的预测值、预测日的日特征气象数据和每个时刻点的实时气象数据作为广义神经网络的测试样本, 得到预测日的最终预测值。

简而言之, 这种灰色和 GRNN 组合预测就是用灰色模型预测出来的具有一定精度的预测值作为 GRNN 的训练样本来进行预测。串联组合模型的预测流程图如图 4 所示。

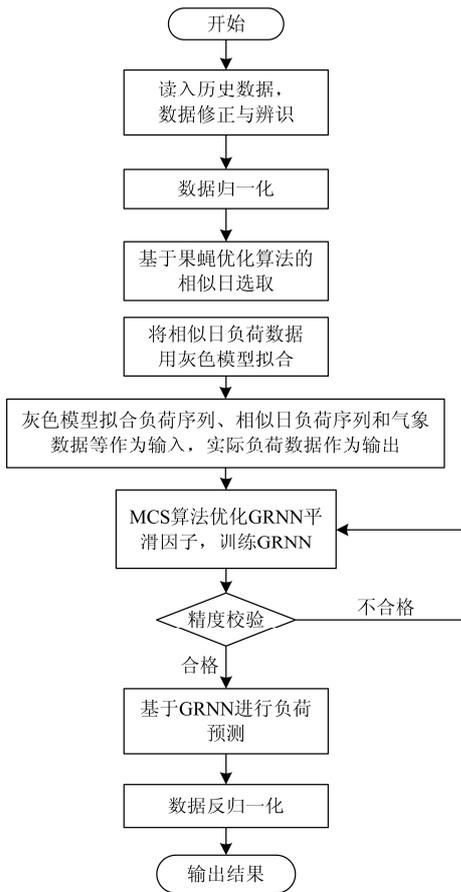


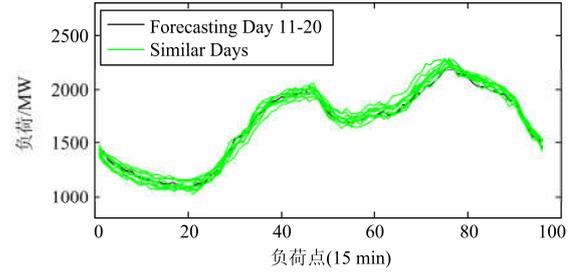
图 4 基于相似日和 GM-GRNN 组合的预测模型

Fig. 4 Forecasting model based on the combination of similar day and GM-GRNN

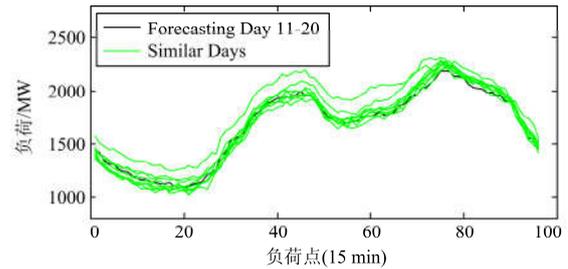
## 4 算例分析

### 4.1 相似日选取

以南方某地区 2014 年 11 月 20 日至 23 日为例, 分别利用基于改进果蝇优化算法的相似日选取算法(MFOA-SD)和文献[10]提出的因子相乘相似日选取算法(FM-SD), 在预测日的前两个月中, 选出 10 个相似日。图 5 至图 8 分别为 20 日至 23 日两种方法的相似日选择结果对比。



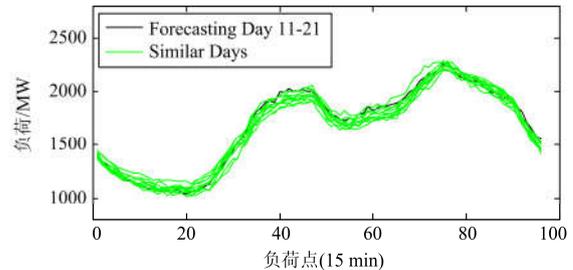
(a) MFOA-SD



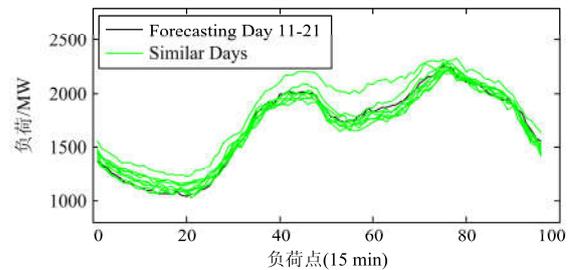
(b) FM-SD

图 5 11 月 20 日及其 10 个相似日负荷曲线

Fig. 5 Nov. 20th and its 10 similar daily load curves



(a) MFOA-SD



(b) FM-SD

图 6 11 月 21 日及其 10 个相似日负荷曲线

Fig. 6 Nov. 21th and its 10 similar daily load curves

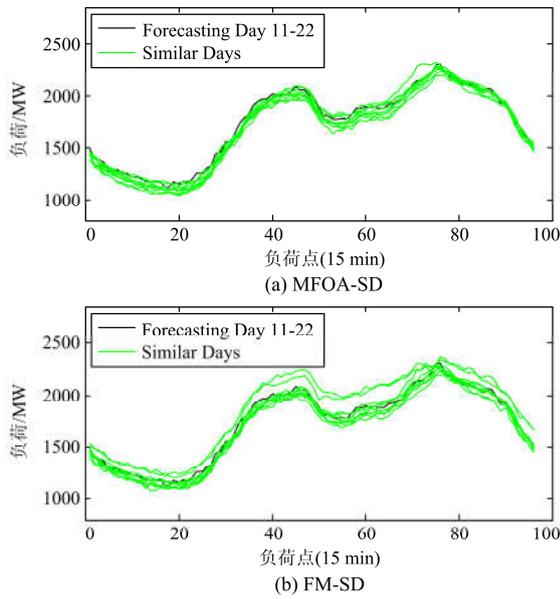


图 7 11 月 22 日及其 10 个相似日负荷曲线  
Fig. 7 Nov. 22th and its 10 similar daily load curves

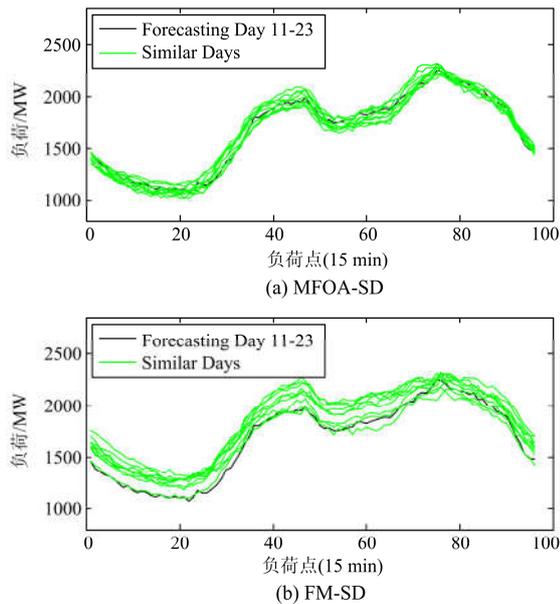


图 8 11 月 23 日及其 10 个相似日负荷曲线  
Fig. 8 Nov. 23th and its 10 similar daily load curves

根据图 5、图 6、图 7 和图 8 的算例结果，我们可以看出，本文的 MFOA-SD 方法选取的相似日负荷曲线与预测日负荷曲线非常相似，较优于 FM-SD，说明本文相似日选取算法的有效性。利用 FM-SD 方法选取的相似日曲线，在 11 月 20 至 22 日有一定的使用价值，但在 11 月 23 日，选取的相似日负荷曲线与预测日出现较大的偏差。而本文的 MFOA-SD 方法选出的相似日曲线与预测日仍拥有

较高的相似性，自适应能力较强。

#### 4.2 预测模型对比

为了验证本文提出的预测模型对于短期负荷预测的有效性，本文以南方某地区 2014 年 9 月份到 11 月份的电力负荷和气象历史数据作为原始数据序列，分别对 96 个时刻点建立预测模型。

预测模型 I：选取相似日时，采用文献[10]提出的因子相乘法，建立灰色模型和 GRNN 组合预测方法(GM-GRNN)，GRNN 平滑因子采用改进的布谷鸟算法进行优化。

预测模型 II：选取相似日时，采用改进的果蝇优化算法对权重系数进行优化，建立 GRNN 单一预测方法，GRNN 平滑因子采用改进的布谷鸟算法进行优化。

预测模型 III：选取相似日时，采用改进的果蝇优化算法对权重系数进行优化，建立基于灰色模型和 GRNN 组合预测方法，GRNN 平滑因子采用改进的布谷鸟算法进行优化。

预测模型 IV：选取相似日时，采用改进的果蝇优化算法对权重系数进行优化，建立基于灰色模型和 BP 神经网络组合预测方法(GM-BP)，并用 Levenberg-Marquardt(L-M)算法对 BP 神经网络进行优化<sup>[20]</sup>，BP 网络的隐层神经元个数设置为 3。

分别采用上述 4 种模型对 2014 年 11 月 17 日到 23 日每天 96 时刻点负荷值进行预测，结果如表 1。

表 1 四种模型预测结果比较

日期	模型 I	模型 II	模型 III	模型 IV
	MAPE	MAPE	MAPE	MAPE
11.17	1.58	1.43	1.38	3.02
11.18	1.72	1.57	1.66	2.36
11.19	1.74	1.71	1.52	2.38
11.20	1.53	1.81	1.45	2.54
11.21	2.82	1.63	1.70	2.77
11.22	2.17	2.09	2.08	3.05
11.23	6.57	1.67	1.73	3.21
平均值	2.59	1.70	1.65	2.76

表 1 中的 MAPE 指的是平均相对误差百分比，

$$MAPE = \frac{1}{96} \sum_{i=1}^{96} \left| \frac{L_i - \hat{L}_i}{L_i} \right| \times 100\%$$

其公式为： $L_i$  表示某时刻点的负荷实际值， $\hat{L}_i$  为某时刻负荷预测值。从表 1 可以看出，预测模型 III 比预测模型 I 平均误差小，说明本文提出的基于改进的果蝇算法优化的相似日方法优于因子相乘相似日方法，改善了模型预测精度。预测模型 III 比预测模型 II 虽然不是每一

天误差都小, 但平均误差小, 说明本文采用的组合预测方法比单一的神经网络预测精度稳定性要高。预测模型III比预测模型VI平均误差小, 说明本文的GM-GRNN 串联组合模型优于 GM-BP 神经网络组合模型。总之, 预测模型III相比于所用的其他 3 种方法具有更高的、可靠的预测精度和预测效果。

## 5 结论

(1) 准确的相似日选取, 是改善短期负荷预测精度的有效途径。本文提出基于改进果蝇优化算法的相似日选取方法, 综合考虑了各种因素对负荷特性的影响大小, 能够有效识别主导因素, 具有一定的自适应能力, 可以选出较为有效的相似日, 对提高短期负荷预测水平具有较大的价值。

(2) 本文提出的基于相似日和灰色 GRNN 组合预测模型, 结合了灰色模型和 GRNN 的优点, 相比于单一 GRNN 模型具有更稳定的预测效果。

## 参考文献

- [1] 刘思捷, 张海鹏, 林舜江, 等. 夏季日最大降温负荷的估算和预测方法[J]. 电力系统保护与控制, 2016, 44(5): 75-81.  
LIU Sijie, ZHANG Haipeng, LIN Shunjiang, et al. An estimating and forecasting method for daily maximum cooling load in summer[J]. Power System Protection and Control, 2016, 44(5): 75-81.
- [2] 刘念, 张清鑫, 刘海涛, 等. 基于核函数极限学习机的微电网短期负荷预测方法[J]. 电工技术学报, 2015, 30(8): 218-224.  
LIU Nian, ZHANG Qingxin, LIU Haitao, et al. Online short-term load forecasting based on ELM with kernel algorithm in micro-grid environment[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 218-224.
- [3] 高赐威, 李倩玉, 苏卫华, 等. 短期负荷预测中考虑积温效应的温度修正模型研究[J]. 电工技术学报, 2015, 30(4): 242-248.  
GAO Ciwei, LI Qianyu, SU Weihua, et al. Temperature correction model research considering temperature cumulative effect in short-term load forecasting[J]. Transactions of China Electrotechnical Society, 2015, 30(4): 242-248.
- [4] 崔和瑞, 彭旭. 基于 ARIMAX 模型的夏季短期电力负荷预测[J]. 电力系统保护与控制, 2015, 43(4): 108-114.  
CUI Herui, PENG Xu. Summer short-term load forecasting based on ARIMAX model[J]. Power System Protection and Control, 2015, 43(4): 108-114.
- [5] 邓聚龙. 灰色理论基础[M]. 武汉: 华中科技大学出版社, 2002.
- [6] 刘洪涛, 肖广明, 刘俊涛. 基于粒子群优化灰色模型的电力系统负荷预测[J]. 东北电力大学学报, 2009, 23(2): 69-72.  
LIU Hongtao, XIAO Guangming, LIU Juntao. Power load forecasting based on particle swarm optimization grey model[J]. Journal of Northeast Dianli University, 2009, 23(2): 69-72.
- [7] 魏伟, 牛东晓, 常征. 负荷预测技术的新进展[J]. 华北电力大学学报, 2002, 29(1): 10-15.  
WEI Wei, NIU Dongxiao, CHANG Zheng. New development of load forecasting technology[J]. Journal of North China Electric Power University, 2002, 29(1): 10-15.
- [8] LI Xiacong, WANG Le, LI Qiuwen, et al. The short-term load forecasting based on grey theory and RBF neural network[C] // APPEEC, 2011: 1-4.
- [9] 李龙, 魏靖, 黎灿兵, 等. 基于人工神经网络的负荷模型预测[J]. 电工技术学报, 2015, 30(8): 225-230.  
LI Long, WEI Jing, LI Canbing, et al. Prediction of load model based on artificial neural network[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 225-230.
- [10] 刘晶. 基于相似日和支持向量机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.
- [11] 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.
- [12] 周海锋, 徐伟, 鲍颜红, 等. 基于相似日选择的调度计划安全校核潮流数据生成[J]. 电力系统保护与控制, 2015, 43(18): 87-93.  
ZHOU Haifeng, XU Wei, BAO Yanhong, et al. Power flow data generation of security check for scheduling plans based on similar day selection[J]. Power System Protection and Control, 2015, 43(18): 87-93.
- [13] 王英博, 聂娜娜, 王铭泽, 等. 修正型果蝇算法优化 GRNN 网络的尾矿库安全预测[J]. 计算机工程, 2015, 41(4): 267-272.  
WANG Yingbo, NIE Nana, WANG Mingze, et al. Mine tailings facilities safety evaluation of GRNN optimized

- by modified fruit fly algorithm[J]. Computer Engineering, 2015, 41(4): 267-272.
- [14] 谷志红, 牛东晓, 王会青. 广义回归神经网络模型在短期电力负荷预测中的应用研究[J]. 中国电力, 2006, 39(4): 11-14.  
GU Zhihong, NIU Dongxiao, WANG Huiqing. Research on application of general regression neural network in short-term load forecasting[J]. Electric Power, 2006, 39(4): 11-14.
- [15] 屈迟文, 傅彦铭, 戴俊. 基于改进 CS 优化算法的灰色神经网络预测模型[J]. 西南师范大学学报, 2014, 39(1): 131-136.  
QU Chiwen, FU Yanming, DAI Jun. On a forecasting model of grey neural network based on improved cuckoo search optimal algorithm[J]. Journal of Southwest China Normal University, 2014, 39(1): 131-136.
- [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] 薛浩然, 张珂珩, 李斌, 等. 基于布谷鸟算法和支持向量机的变压器故障诊断[J]. 电力系统保护与控制, 2015, 43(8): 8-13.  
XUE Haoran, ZHANG Keheng, LI Bin, et al. Fault diagnosis of transformer based on the cuckoo search and support vector machine[J]. Power System Protection and Control, 2015, 43(8): 8-13.
- [18] 黄金杰, 夏静, 满春涛, 等. 一种参数优化旋转广义回归神经网络模型[J]. 电机与控制学报, 2009, 13(3): 442-447.  
HUANG Jinjie, XIA Jing, MAN Chuntao, et al. Parameter-optimized rotated general regression neural network model[J]. Electric Machines and Control, 2009, 13(3): 442-447.
- [19] 王守相, 张娜. 基于灰色神经网络组合模型的光伏短期出力预测[J]. 电力系统自动化, 2012, 36(19): 37-41.  
WANG Shouxiang, ZHANG Na. Short-term output power forecast of photovoltaic based on a grey and neural network hybrid model[J]. Automation of Electric Power Systems, 2012, 36(19): 37-41.
- [20] 秦毓毅, 凌亮, 宋永华, 等. 基于灰色模型和神经网络组合的短期负荷预测方法[J]. 现代电力, 2009, 26(2): 1-4.  
QIN Yuyi, LING Liang, SONG Yonghua, et al. Short-term load forecasting based on grey model[J]. Modern Electric Power, 2009, 26(2): 1-4.

收稿日期: 2016-03-24; 修回日期: 2016-05-17

作者简介:

李啸聪(1959-), 男, 博士, 教授, 博士生导师, 研究方向为控制系统计算机辅助设计、电力系统动态仿真及计算机实时控制、电力系统分析与控制、电力系统非线性控制; E-mail: lhtlht@gxu.edu.cn

李春涛(1989-), 男, 通信作者, 硕士研究生, 研究方向为电力系统非线性控制、电力负荷预测。E-mail: lctmmeda@163.com

(编辑 张爱琴)