

DOI: 10.19783/j.cnki.pspc.190760

基于 IFOA-GRNN 的短期电力负荷预测方法研究

祝学昌

(河南建筑职业技术学院设备工程系, 河南 郑州 450064)

摘要: 针对智能用电环境下负荷随机性强、短期电力负荷预测精度差、计算时间长等问题, 提出了一种结合改进果蝇优化算法 IFOA 和广义回归神经网络 GRNN 的预测方法。模型的输入因子为负荷数据和气象信息等。通过改进果蝇优化算法的搜索距离, 增强其搜索能力, 优化广义回归神经网络 GRNN 的平滑因数, 提高预测的网络性能和精度。通过仿真验证预测方法的准确性和有效性。结果表明, 改进后的方法可以减小预测误差, 提高算法的稳定性。该研究为我国电力负荷预测的发展提供了参考和借鉴。

关键词: 电力负荷预测; 果蝇优化算法; 广义回归神经网络; 平滑因数

Research on short-term power load forecasting method based on IFOA-GRNN

ZHU Xuechang

(Department of Equipment Engineering, Henan Technical College of Construction, Zhengzhou 450064, China)

Abstract: Examining the problems of strong load randomness, poor short-term load forecasting accuracy and long calculation time in intelligent power environment, a forecasting method combining the improved Drosophila optimization algorithm IFOA and generalized regression neural network GRNN is proposed. The input factors of the model are load data and meteorological information. By improving the search distance of the fruit fly optimization algorithm, the model can be used to optimize the smooth factor of the generalized regression neural network GRNN, thereby improving the performance and prediction accuracy of the network. The accuracy and validity of the proposed prediction method are verified by simulation. The results show that the improved method can reduce prediction error and increase the stability of the algorithm. This study provides a reference for the development of a short-term power load forecasting system in China.

This work is supported by National "Thirteen-Five Year" Research and Development Program of China (No. 2017YFB0602500).

Key words: power load forecasting; fruit fly optimization algorithm; generalized regression neural network; smoothing factor

0 引言

随着科学技术的飞速发展, 电网通过集成先进技术实现智能化, 从而实现电网的经济高效运行。电力负荷预测作为电力系统规划和调度的基础, 可以提高电力系统运行的稳定性, 具有较高的社会效益和经济效益^[1]。短期负荷预测是电力负荷预测系统的重要组成部分之一, 利用历史数据预测未来 1-7 天的负荷^[2], 可用于发电厂发电能力规划和电网调度, 是电网安全管理的基础。因此, 短期负荷预测已成

为智能电网运行和管理的重要研究课题。

目前, 国内外学者对短期负荷预测方法进行了大量研究。在文献[3]中, 电力负荷的历史数据根据两两数据之间的距离进行聚类, 采用组合法将类别分为三类。把同一类数据作为神经网络的输入进行负荷预测, 提高了负荷预测的精度。在文献[4]中, 提出了一组预测点的分位数回归平均方法来预测概率, 充分利用了点预测的能力。在文献[5]中, 提出了一种基于负荷聚类划分、RBF 神经网络共轭梯度学习和相似性加权综合的大用户电力负荷预测方法, 取得了较好的预测效果。在文献[6]中, 提出了一种基于 BP-RBF 的级联神经网络来预测电力负

基金项目: 国家十三五重点研发项目资助(2017YFB0602500)

荷, 使用无负荷因素作为前级 BP 网络的输入, 输出为预测日的峰谷负荷, 取得了较好的预测效果。这些研究为解决电力系统短期预测方法提供了理论依据。

在上述背景的基础上, 本文提出了一种结合改进果蝇优化算法 IFOA 和广义回归神经网络 GRNN 的预测方法, 用于短期负荷预测。该模型以负荷数据和气象信息为输入因子, 通过改进果蝇优化算法优化广义回归神经网络的平滑因数, 提高预测的网络性能和精度。并通过仿真验证预测方法的准确性和有效性。

1 系统架构

电力负荷预测系统具有负荷数据采集、数据分析、数据管理等功能。结合云计算技术实现科学的电力负荷预测, 为用户决策提供依据。电力负荷预测系统遵循标准化、可靠性、可用性、安全性、可扩展性和复杂性的原则。整个系统架构分为数据采集层、云数据中心和数据可视化层^[7]。

数据可视化在数据分析、数据统计、负荷预测等基础上, 为用户提供系统展示。云平台为系统核心, 根据采集数据性质, 分别存储在数据库或分布式文件中, 是数据交互的中心节点。数据采集通过终端设备、互联网等采集数据, 并把这些数据上传到云平台。如图 1 所示系统总体框架。

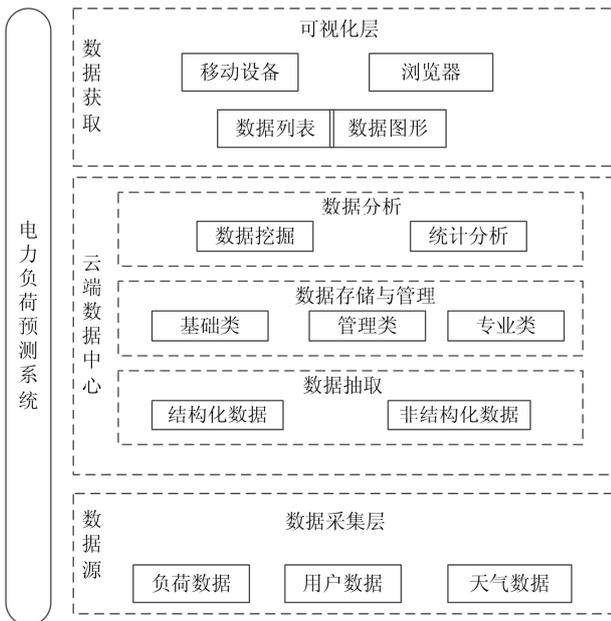


图 1 系统总体架构

Fig. 1 Overall system architecture

2 预测模型

2.1 评价指标

由于电力负荷预测的高随机性和不确定性, 预测误差的存在是不可避免的。但这些误差并非一无是处, 可以让我们更好地了解预测模型, 不断优化预测方法。评价的指标有很多, 常见指标如下:

(1) 绝对误差(Absolute Errors, AE)如式(1)所示^[8]。

$$AE = x'_i - x_i \quad (1)$$

(2) 均方根误差(Root Mean Square Error, RMSE)如式(2)所示^[9]。

$$RMSE = \sqrt{\frac{1}{M} \sum_{i=1}^M (x_i - x'_i)^2} \quad (2)$$

(3) 平均相对误差(Mean Relative Error, MRE)如式(3)所示^[10]。

$$MRE = \frac{1}{M} \sum_{i=1}^M \frac{|x_i - x'_i|}{x_i} \quad (3)$$

(4) 相对误差(Relative Errors, RE)如式(4)所示^[11]。

$$RE = \frac{x'_i - x_i}{x_i} \times 100\% \quad (4)$$

式中: x_i 和 x'_i 分别为 i 时刻的实际值和预测值; M 为预测样本总数。电力调度部门进行短期负荷预测的误差要求是: RE 的绝对值不大于 3%, MRE 也不大于 3%。

2.2 GRNN 基本结构

图 2 为广义回归神经网络(Generalized Regression Neural Network, GRNN)的基本结构。由输入层、模式层、求和层和输出层组成。输入样本为 $X = [x_1, x_2, \dots, x_m]^T$, 输出样本为 $Y = [y_1, y_2, \dots, y_n]^T$ 。

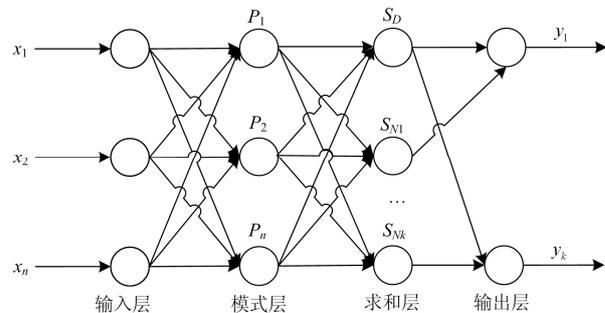


图 2 GRNN 基本结构

Fig. 2 GRNN basic structure

(1) 输入层

输入层神经元的数量等于输入向量的维数 m 。

每个神经元都是一个简单的分布。可将输入直接传输到模式层^[12]。

(2) 模式层

模式层神经元的数量等于训练样本的数量 n 。每个神经元对应于不同的样本，第 i 个神经元的传递函数如式(5)所示^[13]。

$$P_i = \exp\left[\frac{-(X - X_i)^T (X - X_i)}{2\sigma^2}\right], \quad i = 1, 2, \dots, n \quad (5)$$

式中： X 为 GRNN 输入样本； X_i 为第 i 个神经元所对应的训练样本； σ 为平滑因数；第 i 个神经元输出为 X 和 X_i 之间 Euclid 距离平方，如式(6)所示^[14]。

$$D_i^2 = (X - X_i)^T (X - X_i) \quad (6)$$

(3) 求和层

在求和层有两种类型的神经元。一类神经元的传递函数如式(7)所示^[15]。

$$S_D = \sum_{i=1}^n P_i \quad (7)$$

对模式层中各神经元的输出算术求和。另一个神经元传递函数如式(8)所示^[16]。

$$S_{Nj} = \sum_{i=1}^n y_{ij} P_i, \quad j = 1, 2, \dots, k \quad (8)$$

对模式层中的每个神经元的输出进行加权求和， y_{ij} 为模式层中第 i 个神经元与求和层第 j 个神经元的权重，即第 i 个输出样本 Y_i 的第 j 个元素。

(4) 输出层

输出层神经元数据等于训练样本的输出维数 k ，并且每个神经元输出是求和层两类神经元输出之商，如式(9)所示^[17]。

$$Y_j = \frac{S_{Nj}}{S_D}, \quad j = 1, 2, \dots, n \quad (9)$$

由于 GRNN 人工调整因素相对较少，训练完全依赖于输入样本，因此可以防止假定对输出的影响。

2.3 IFOA-GRNN 模型

FOA (Fruit fly optimization algorithm) 是基于果蝇寻找食物的行为得出的全局优化。本文针对 FOA 易陷入局部最优提出改进算法 IFOA，将迭代开始到某一迭代过程中，增加搜索距离 l ，实现种群多样性，使更多的个体跳出局部极值^[18]。在某一次迭代到迭代结束，减少搜索距离 l ，提高收敛精度，如式(10)所示^[19]。

$$l = \begin{cases} l_0 \cdot \left(1 + \frac{t}{T}\right), & \text{若 } 0 \leq \frac{t}{T} \leq R \\ l_0 \cdot \left(1 - \frac{t-1}{T}\right), & \text{若 } R < \frac{t}{T} \leq 1 \end{cases} \quad (10)$$

式中： t 为当前迭代次数； R 为特定迭代次数与总迭代次数之比； T 为总迭代次数。

如果输入样本已知，则 GRNN 结构和重量为常量，网络学习的本质是优化平滑因数 σ ^[20]。因此，为了使测量结果更接近实际值，有必要对参数进行连续优化。基于改进的果蝇优化算法 IFOA 优化方法，利用 IFOA 强大的寻优能力对 GRNN 平滑因数进行优化，提高预测的网络性能和精度。它的主要的思想是通过果蝇嗅觉寻找食物和视觉进行群体位置确认^[21]。找到最优的 σ ，使 GRNN 预测值和实际值的 RMSE 最小，IFOA-GRNN 基本步骤如下。

步骤一：果蝇规模 G 和总迭代次数 T 进行预设，并随机给出群体位置 (x, y) 。

步骤二：个体位置计算如式(11)所示，通过嗅觉寻找食物^[22]。

$$\begin{cases} x_i = x + l \\ y_i = y + l \end{cases} \quad (11)$$

式中： l 为搜索距离，可以在搜索区间 $[-l_0, l_0]$ 中随机形成， $l = l_0 \cdot \frac{1}{t}$ ， t 为当前迭代次数。

步骤三：用式(12)估算个体与 $(0, 0)$ 之间的位移 D_i ，然后计算气味浓度的判别值 S_i ，即为 σ 。如式(13)所示，如果 $\sigma < 0.001$ ，则令 $\sigma = 1$ ^[23]。

$$D_i = \sqrt{x_i^2 + y_i^2} \quad (12)$$

$$\sigma = S_i = \frac{1}{D_i} \quad (13)$$

步骤四：将 σ 带入 GRNN 中，将 RMSE 作为气体浓度判别函数，从而得到个体的气味浓度 f_i 。如式(14)所示。

$$f_i = \text{RMSE} \quad (14)$$

步骤五：在群体中找出气味浓度最低的个体，即 RMSE 最小值，如式(15)所示。

$$[\text{BC}, \text{BN}] = \min(\text{RMSE}) \quad (15)$$

式中： BC 是最高气味的浓度； BN 是拥有最佳气味的个体编号。

步骤六：开始迭代优化，以确定气味浓度是否达到最佳水平，达到执行下一步，否则跳转到第二步。

步骤七：使用式(16)和式(17)分别存储最佳气味

浓度 BC_p 和最佳个别位置 x_b 、 y_b ，此时群体飞往该位置。

$$BC_p = BC \quad (16)$$

$$\begin{cases} x_b = x(BN) \\ y_b = y(BN) \end{cases} \quad (17)$$

步骤八：如果 RMSE 函数或迭代总数满足终止条件，则将 σ 最优解引入 GRNN 进行仿真预测并输出结果，否则继续迭代优化。流程图如图 3 所示。

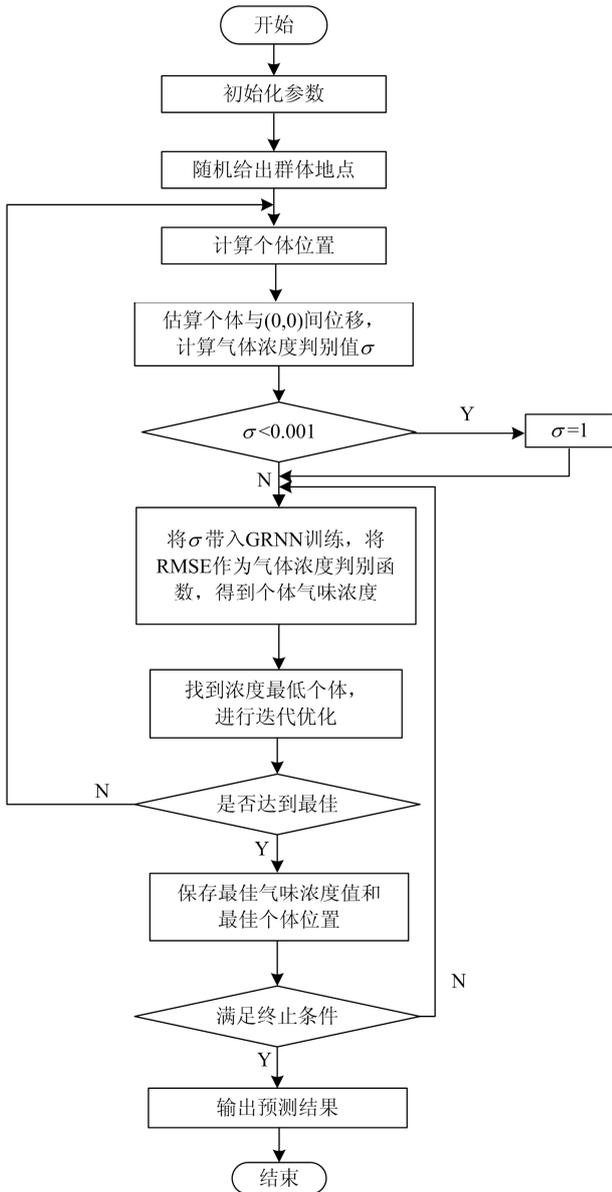


图 3 IFOA-GRNN 流程图

Fig. 3 Flow chart of IFOA-GRNN

3 算例分析

为了更好地评价 IFOA - GRNN 预测性能，对某

地区 2018 年 8 月 9 日(星期四)、8 月 11 日(星期六)、8 月 13 日(星期一)进行了短期负荷预测，并与当地调控中心预测结果进行了比较。本节采用果蝇优化算法和改进的果蝇优化算法对 GRNN 进行短期电力负荷预测优化。采用多输入单输出模型，合理选择多个输入变量。输出变量是预测某一天某一小时的负荷值，通过建立 24 个模型来逐个地进行预测。历史数据的预处理分为两个部分。一是异常数据的处理，二是样品数据的归一化。输入样本为负荷数据和气象信息等 32 维，输出为 1 维。预测数据为预测日时刻和左右相邻时刻前 3 天的负荷数据、气象数据等。负荷预测属于在线预测，即在规定的时间内对结果进行计算，设总迭代次数 T 为 100，种群大小 G 为 20，连续运行 20 次。具体评估结果见表 1—表 3 和图 4—图 6 所示。

表 1 8 月 9 日预测模型预测值与实际值

Table 1 Predicted value and actual value of the prediction model on August 9

预测模型 时刻	实际值/ MW	FOA-GRNN		IFOA-GRNN	
		预测值/ MW	预测 RE/%	预测值/ MW	预测 RE/%
01:00	1 080.83	1 100.12	1.78	1 090.23	0.87
02:00	1 087.15	1 082.61	-0.42	1 083.30	-0.35
03:00	1 092.55	1 112.79	1.85	1 112.59	1.83
04:00	1 099.24	1 116.48	1.57	1 110.89	1.06
05:00	1 077.95	1 110.04	2.98	1 109.60	2.94
06:00	1 124.65	1 158.79	3.05	1 120.46	-0.37
07:00	1 108.97	1 147.35	3.46	1 139.74	2.77
08:00	1 103.40	1 162.20	5.33	1 120.51	1.55
09:00	1 115.57	1 145.46	2.68	1 120.57	0.45
10:00	1 088.79	1 100.84	1.11	1 093.79	0.46
11:00	1 146.09	1 170.51	2.13	1 160.09	1.22
12:00	1 111.56	1 154.71	3.88	1 142.20	2.76
13:00	1 108.56	1 110.92	0.21	1 110.92	0.21
14:00	1 184.61	1 031.19	4.29	1 100.61	1.48
15:00	1 122.20	1 104.33	-1.59	1 147.92	2.29
16:00	1 121.37	1 107.48	-1.24	1 140.51	1.71
17:00	1 195.55	1 166.12	-2.46	1 212.75	1.44
18:00	1 155.88	1 205.33	4.28	1 180.46	2.13
19:00	1 146.60	1 160.53	1.39	1 160.53	1.39
20:00	1 153.77	1 140.78	-1.13	1 164.39	0.92
21:00	1 161.19	1 160.74	-0.04	1 161.95	0.07
22:00	1 137.43	1 175.45	3.34	1 165.16	2.44
23:00	1 164.77	1 149.40	-1.32	1 154.05	-0.92
24:00	1 142.64	1 134.18	-0.74	1 144.36	0.15

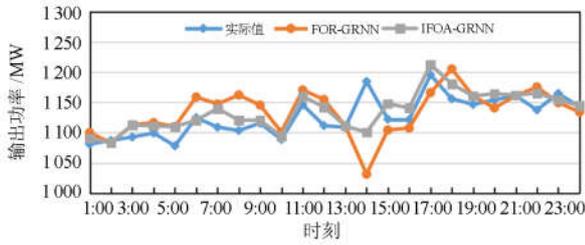


图 4 8 月 9 日预测值与实际值对比图

Fig. 4 Comparison between predicted value and actual value on August 9

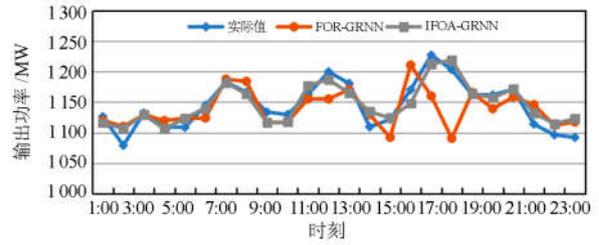


图 5 8 月 11 日预测值与实际值对比图

Fig. 5 Comparison between predicted value and actual value on August 11

表 2 8 月 11 日预测模型预测值与真实值

Table 2 Predicted value and the true value of the prediction model on August 11

预测模型	FOA-GRNN			IFOA-GRNN	
	实际值/ MW	预测值/ MW	预测 RE/%	预测值/ MW	预测 RE/%
01:00	1 126.32	1 119.97	-0.56	1 116.06	-0.91
02:00	1 078.89	1 110.07	2.89	1 106.64	2.57
03:00	1 132.06	1 129.24	-0.25	1 129.24	-0.25
04:00	1 108.95	1 119.76	0.97	1 106.12	-0.26
05:00	1 108.40	1 123.53	1.37	1 123.53	1.37
06:00	1 144.44	1 123.97	-1.79	1 139.96	-0.39
07:00	1 183.01	1 187.62	0.39	1 182.01	-0.08
08:00	1 166.21	1 184.08	1.53	1 163.36	-0.24
09:00	1 133.67	1 116.66	-1.5	1 116.66	-1.5
10:00	1 129.55	1 117.71	-1.05	1 117.71	-1.05
11:00	1 162.53	1 155.31	-0.62	1 177.09	1.25
12:00	1 199.82	1 155.22	-3.72	1 187.00	-1.07
13:00	1 180.62	1 170.71	-0.84	1 164.83	-1.34
14:00	1 109.39	1 129.58	1.82	1 134.46	2.26
15:00	1 121.65	1 092.18	-2.63	1 124.01	0.21
16:00	1 170.31	1 210.71	3.45	1 148.00	-1.91
17:00	1 227.21	1 160.17	-5.47	1 212.75	-1.18
18:00	1 203.41	1 090.60	-1.06	1 219.06	1.3
19:00	1 162.02	1 165.77	0.32	1 164.25	0.19
20:00	1 161.72	1 139.33	-1.93	1 157.02	-0.40
21:00	1 171.31	1 158.30	-1.11	1 171.83	0.04
22:00	1 113.90	1 145.78	2.86	1 132.26	1.65
23:00	1 096.30	1 111.79	1.41	1 114.25	1.64
24:00	1 092.00	1 117.51	2.34	1 123.04	2.84

表 3 8 月 13 日预测模型预测值与真实值

Table 3 Predicted value and actual value of the prediction model on August 13

预测模型	FOA-GRNN			IFOA-GRNN	
	实际值/ MW	预测值/ MW	预测 RE/%	预测值/ MW	预测 RE/%
01:00	1 067.59	1 142.10	6.98	1 110.37	-0.91
02:00	1 107.90	1 118.75	0.98	1 108.43	0.05
03:00	1 116.75	1 184.07	-2.93	1 109.80	-0.62
04:00	1 181.02	1 060.26	-1.92	1 068.49	-1.16
05:00	1 182.41	1 054.00	-2.62	1 080.12	-0.21
06:00	1 138.56	1 110.82	-2.44	1 127.25	-0.99
07:00	1 160.83	1 183.00	1.91	1 163.53	0.23
08:00	1 139.89	1 150.44	0.93	1 155.75	1.39
09:00	1 095.11	1 111.90	1.53	1 113.28	1.66
10:00	1 156.33	1 137.42	-1.64	1 144.04	-1.06
11:00	1 147.51	1 175.26	2.42	1 168.82	1.86
12:00	1 164.54	1 151.13	-1.15	1 174.31	-0.84
13:00	1 157.80	1 129.27	-2.46	1 144.78	-1.12
14:00	1 148.24	1 124.38	-2.08	1 131.68	-1.44
15:00	1 128.01	1 122.88	-0.45	1 126.75	-0.11
16:00	1 102.00	1 111.20	0.83	1 113.33	1.03
17:00	1 140.48	1 165.60	2.2	1 165.60	2.2
18:00	1 155.78	1 219.72	5.53	1 180.78	2.16
19:00	1 174.75	1 175.35	0.05	1 189.55	1.26
20:00	1 173.23	1 183.81	0.90	1 162.69	-0.90
21:00	1 167.43	1 168.20	0.07	1 166.87	-0.05
22:00	1 156.23	1 177.27	1.82	1 170.28	1.22
23:00	1 145.36	1 157.49	1.06	1 144.49	-0.08
24:00	1 145.68	1 154.39	0.76	1 143.91	-0.15

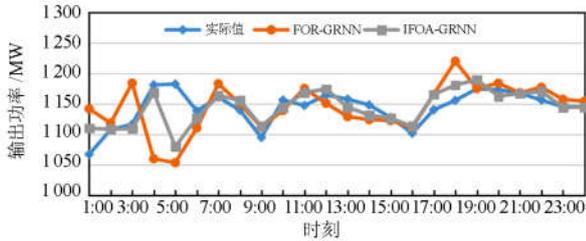


图 6 8月13日预测值与实际值对比图

Fig. 6 Comparison between predicted value and actual value on August 13

统计表 1—表 3 预测时刻的 $|RE|$ 超过 3% 的数量如表 4 所示。每日 $|RE|$ 的最小值和最大值如表 5 所示。每日预测的 MRE 如表 6 所示。

表 4 $|RE|$ 统计超过 3%

Table 4 $|RE|$ statistics are more than 3%

日期	FOA-GRNN	IFOA-GRNN
8月9日	5	0
8月11日	2	0
8月13日	2	0

从表 4 可以看出，在短期负荷预测中，改进前的日不合格 $|RE|$ 基本上小于 5 个。经过改进，IFOA-GRNN 预测满足电力行业的要求。

表 5 $|RE|$ 统计最大值和最小值

Table 5 $|RE|$ statistics maximum and minimum values

日期	FOA-GRNN		IFOA-GRNN	
	最小值	最大值	最小值	最大值
8月9日	-0.04	5.33	0.07	2.94
8月11日	-0.25	-5.47	0.04	2.84
8月13日	0.05	6.98	0.05	2.2

从表 5 可以看出，从 $|RE|$ 的最小值来看，改进前后的模型预测都得到了非常满意的结果，小于 0.3%。对 $|RE|$ 最大值的分析表明，FOA-GRNN 基本上在 5% 到 7% 之间，但 IFOA-GRNN 在 2% 到 3% 之间。这也表明改进后 FOA 精度和稳定性得到了提高。

表 6 每日 MRE

Table 6 Daily MRE

日期	FOA-GRNN	IFOA-GRNN
8月9日	2.05	1.33
8月11日	1.75	1.08
8月13日	1.9	0.92

由表 6 可知，两种预测误差都小于 3%，满足电力系统短期预测要求。进一步分析表明，FOA-GRNN 预测误差一般在 1.5% 至 2.1% 之间，而 IFOA-GRNN 的预测误差在 0.9% 至 1.4% 之间，8月13日最低为 0.92%。另外，从表 1—表 3 和图 4—6 可以看出，FOA-GRNN 预测误差基本都是最小，波

动少。改进的 FOA 算法不仅提高了稳定性，还进一步降低了 IFOA-GRNN 的预测误差。它在负荷预测领域具有很好的应用价值。

4 结论

基于调度中心提供的历史负荷数据和气象数据等，本文提出了一种结合改进果蝇优化算法 IFOA 和广义回归神经网络 GRNN 的预测方法。通过对果蝇优化算法的搜索距离进行改进，增强其搜索能力，用于优化广义回归神经网络 GRNN 的平滑因数，提高预测的网络性能和精度。并通过仿真验证预测方法的准确性和有效性，结果表明，改进后的方法具有减少误差，提高算法稳定性的作用。在当前实验室硬件条件和实验数据规模的影响下，系统仍处于试验阶段，在此基础上，逐步改进和完善将成为下一研究的重点。

参考文献

- [1] 宋人杰, 丁江林, 白丽, 等. 基于合作博弈法和梯形云模型的配电网模糊综合评价[J]. 电力系统保护与控制, 2017, 45(14): 1-8.
SONG Renjie, DING Jianglin, BAI Li, et al. Fuzzy comprehensive evaluation of distribution network based on cooperative game theory and trapezoidal cloud model[J]. Power System Protection and Control, 2017, 45(14): 1-8.
- [2] 宋亚奇, 周国亮, 朱永利, 等. 云平台下输变电设备状态监测大数据存储优化与并行处理[J]. 中国电机工程学报, 2015, 35(2): 255-267.
SONG Yaqi, ZHOU Guoliang, ZHU Yongli, et al. Storage optimization and parallel processing of condition monitoring big data of transmission and transforming equipment based on cloud platform[J]. Proceedings of the CSEE, 2015, 35(2): 255-267.
- [3] 石玉恒, 赵娜, 王凌, 等. 北京地区日最大电力负荷预测模型初探[J]. 中国电力, 2019, 41(1): 112-118.
SHI Yuheng, ZHAO Na, WANG Ling, et al. Preliminary study on daily maximum load forecasting model for Beijing area[J]. Electric Power, 2019, 41(1): 112-118.
- [4] 苏运, 卜凡鹏, 郭乃网, 等. 基于低秩表示的多任务短期电力负荷预测的研究[J]. 现代电力, 2019, 36(3): 58-65.
SU Yun, BU Fanpeng, GUO Naiwang, et al. Study on multi-task short-term load forecasting based on low rank representation[J]. Modern Electric Power, 2019, 36(3): 58-65.
- [5] 李廷顺, 王伟, 刘泽三. 考虑不确定区间的电力负荷 GELM-WNN 预测[J]. 计算机工程, 2019, 36(1): 231-238.
LI Tingshun, WANG Wei, LIU Zesan. GELM-WNN forecasting of electric load considering uncertain interval[J].

- Computer Engineering, 2019, 36(1): 231-238.
- [6] 谷云东, 马冬芬, 程红超. 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学报, 2018, 30(23): 1234-1239.
GU Yundong, MA Dongfen, CHENG Hongchao. Power load forecasting based on improved gradient lifting decision tree[J]. Proceedings of the CSU-EPSC, 2018, 30(23): 1234-1239.
- [7] 陶仁峰, 李凤婷, 李永东, 等. 基于云层分布规律与太阳光跟踪的光伏电站 MPPT 策略[J]. 电力系统自动化, 2018, 29(5): 113-116.
TAO Renfeng, LI Fengting, LI Yongdong, et al. Photovoltaic power plant MPPT strategy based on cloud distribution law and solar tracking[J]. Automation of Electric Power Systems, 2018, 29(5): 113-116.
- [8] 文旭, 郭琳, 王俊梅. 面向节能减排的电力系统发购电计划研究述评[J]. 电力系统保护与控制, 2015, 43(9): 136-144.
WEN Xu, GUO Lin, WANG Junmei. Overview of power dispatch and purchasing plan in power system from energy-saving and emission-reducing[J]. Power System Protection and Control, 2015, 43(9): 136-144.
- [9] 常安, 宋云海, 张晗, 等. 考虑参量有效性的输电线路状态评估方法研究及应用[J]. 高压电器, 2017, 53(6): 72-78.
CHANG An, SONG Yunhai, ZHANG Han, et al. Research and application of transmission line condition assessment method considering parameter validity[J]. High Voltage Apparatus, 2017, 53(6): 72-78.
- [10] 王艳松, 孙明鸿. 含微网配电网的综合优化规划研究[J]. 中国电力, 2018, 51(2): 118-124.
WANG Yansong, SUN Minghong. Research on integrated optimal planning of distribution network containing microgrid[J]. Electric Power, 2018, 51(2): 118-124.
- [11] NAHMAN J, SALAMON D. Mutual interference of neighboring grounding systems and approximate formulation[J]. Electric Power Systems Research, 2017, 41(12): 151-156.
- [12] MOSES V, HATHERLEY R, BISHOP Ö T. Bioinformatic characterization of type-specific sequence and structural features in auxiliary activity family proteins[J]. Biotechnology for Biofuels, 2016, 9(1): 88-94.
- [13] HOU Kaiyuan, SHAO Guanghui, WANG Haiming, et al. Research on practical power system stability analysis algorithm based on modified SVM[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 119-125. DOI: 10.1186/s41601-018-0086-0.
- [14] PATEL G K, DABHI V K, PRAJAPATI H B. Clustering using a combination of particle swarm optimization and K-means[J]. Journal of Intelligent Systems, 2017, 12(3): 457-469.
- [15] GAUTAM J V, PRAJAPATI H B, DABHI V K, et al. Empirical study of job scheduling algorithms in Hadoop MapReduce[J]. Cybernetics and Information Technologies, 2017, 21(1): 146-163.
- [16] CAETANO C E F, LIMA A B, PAULINO J O S, et al. A conductor arrangement that overcomes the effective length issue in transmission line grounding[J]. Electric Power Systems Research, 2018, 46(5): 159-162.
- [17] HU Jianjiang, FICHTNER M, BARICCO M. Preparation of Li-Mg-N-H hydrogen storage materials for an auxiliary power unit[J]. International Journal of Hydrogen Energy, 2017, 42(27): 17144-17148.
- [18] JIA Zhiwei, WANG Lijun, ZHANG Jinchuan, et al. High efficiency, low power-consumption DFB quantum cascade lasers without lateral regrowth[J]. Nanoscale Research Letters, 2017, 12(1): 88-95.
- [19] AZUMAYA C M, DAYS E L, VINSON P N, et al. Screening for AMPA receptor auxiliary subunit specific modulators[J]. PLOS ONE, 2017, 12(3): 1523-1538.
- [20] FAN Chengli. Hybrid artificial bee colony algorithm with variable neighborhood search and memory mechanism[J]. Journal of Systems Engineering and Electronics, 2018, 29(2): 405-414.
- [21] 王月月, 陈民铀, 姜振超, 等. 基于云理论的智能变电站二次设备状态评估[J]. 电力系统保护与控制, 2018, 46(1): 71-77.
WANG Yueyue, CHEN Minyou, JIANG Zhenchao, et al. A state assessment method for secondary equipment in intelligent substation based on cloud model[J]. Power System Protection and Control, 2018, 46(1): 71-77.
- [22] 靳现林, 赵迎春, 吴刚. 考虑分布式光伏和电动汽车接入的配电网空间负荷预测方法[J]. 电力系统保护与控制, 2019, 47(14): 10-19.
JIN Jinlin, ZHAO Yingchun, WU Gang. Spatial load forecasting method for distribution network considering distributed photovoltaic and electric vehicle access[J]. Power System Protection and Control, 2019, 47(14): 10-19.
- [23] 刘科研, 盛万兴, 张东霞, 等. 智能配电网大数据应用需求和场景分析研究[J]. 中国电机工程学报, 2015, 35(2): 287-293.
LIU Keyan, SHENG Wanxing, ZHANG Dongxia, et al. Big data application requirements and scenario analysis in smart distribution network[J]. Proceedings of the CSEE, 2015, 35(2): 287-293.

收稿日期: 2019-07-01; 修回日期: 2019-08-12

作者简介:

祝学昌(1980—), 男, 讲师, 主要研究方向为电气自动化控制。E-mail: srfsgv546@163.com

(编辑 张爱琴)