

电网供电系统短期电力负荷预测优化仿真^①

王惠中¹, 杨世亮¹, 卢玉飞²

¹(兰州理工大学 电气工程与信息工程学院, 兰州 730050)

²(国家电网平高集团有限公司, 平顶山 467001)

摘要: 对电网供电系统短期电力负荷预测模型进行优化, 能提升预测结果的准确性和鲁棒性. 虽然现有预测模型可以满足预测速度的要求, 但预测结果的精确性和稳定性却无法保证. 为了得到更加准确和稳定的预测结果, 提出了细菌觅食算法优化极限学习机预测模型. 首先在电力负荷样本数据中形成训练样本和预测样本集, 利用细菌觅食优化算法对极限学习机预测模型中的不确定参数进行优化, 然后利用改进后的模型进行电力负荷预测. 新模型的优化仿真结果显示, 利用细菌觅食算法优化极限学习机预测模型的预测精度和稳定性均优于传统预测模型的预测结果, 该算法具有很好地实用性.

关键词: 负荷预测; 极限学习机; 细菌觅食; 模型

引用格式: 王惠中, 杨世亮, 卢玉飞. 电网供电系统短期电力负荷预测优化仿真. 计算机系统应用, 2017, 26(8): 147-151. <http://www.c-s-a.org.cn/1003-3254/5890.html>

Grid Power System Short-Term Load Forecasting Simulation Optimization

WANG Hui-Zhong¹, YANG Shi-Liang¹, LU Yu-Fei²

¹(Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

²(Pinggao Group Co. Ltd., State Grid, Pingdingshan 467001, China)

Abstract: The optimization of short-term load forecasting simulation for the Grid power system can improve prediction accuracy and robustness of the results. Although the existing prediction models can meet the requirements of prediction speed, the accuracy and stability of the predicted results are always difficult to guarantee. In order to get more accurate and stable forecast results, this paper puts forward the bacterial foraging algorithm to optimize the new predicting model of the extreme learning machine. First, the training sample and forecast sample set are formed in the power load sampling data set. The bacteria foraging optimization algorithm is used to optimize the uncertain parameters in the prediction model of extreme learning machine algorithm. Then, the improved model for power load forecasting is used. Through the optimization of the new model simulation, the results show that the use of bacterial foraging algorithm optimization model to predict extreme learning machine precision and stability are superior to the traditional forecasting model prediction results, and the algorithm has good practicability.

Key words: load forecasting; extreme learning machine; bacteria foraging; model

当前全球经济发展迅速、电力市场不断放开, 短期负荷预测结果的准确性和稳定性对电力系统的发展更加重要^[1]. 新世纪以来, 科技工作者对负荷预测方法的探索从未停止. 文献^[2]采用支持向量回归机(SVR)进

行负荷预测, 结果表明该方法具有良好的泛化能力. 但由于其收敛速度慢、效率低, 预测结果的准确性依赖于训练样本的内在规律, 而电力负荷的发展是一个随机变化过程, 受各种自然条件的影响很大, 所以用该算

① 基金项目: 甘肃省自然科学基金(1308RJZA117)

收稿时间: 2016-08-17; 采用时间: 2016-12-26

法进行准确预测有较大困难. 文献[3]运用广义回归神经网络(GRNN), 建立超短期负荷的预测模型, 在一定程度上提高了预测精度, 但该方法在预测过程中有不变的结构和参数, 使模型的泛化能力不足. 文献[4]运用支持向量机(SVM)回归算法的预测模型, 该方法的实质为线性不等式的二次规划问题, 这种方法当训练样本数量较大的时候, 二次规划问题将束手无策. 文献[5]运用遗传算法优化极限学习机(GA-ELM)预测模型, 通过对模型参数优化, 提高算法的收敛速度和全局搜索能力, 但遗传算法的编程实现比较困难, 初始种群的选择对预测过程影响很大, 搜索结果充满不确定性.

针对 SVR、GRNN、SVM、GA-ELM 等传统算法的不足, 提出细菌觅食算法优化极限学习机(BFO-ELM)预测模型. 将细菌觅食优化算法(BFO)用于极限学习机(ELM)预测模型的参数优化中^[6]. 该算法结构简单清晰、计算速度快、全局搜索能力强^[7]. 仿真结果表明, BFO-ELM 明显提高预测模型的准确性和鲁棒性, 有更强的实用性.

1 极限学习机预测模型

ELM 算法与 BP 神经网络的最大区别在于它是基于广义逆矩阵理论得到的单隐层前馈神经网络^[8]. 该方法把训练误差最小化作为学习标准, 无需迭代隐含层, 隐含层输入权值和偏置值可任意选择, 待输出权值确定之后就得到学习算法^[9]. ELM 模型如图 1.

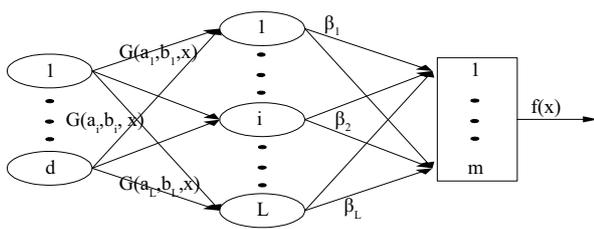


图 1 ELM 算法模型

现将极限学习机训练步骤简介如下:

(1) 样本输入: 输入训练负荷样本数据集 $\{x_i, t_i\}_{i=1}^N \in R^n \times R^m$, 测试负荷数据样本 $\{y_i\}_{i=1}^M$, 隐含层激活函数 $G(X)$ 及其节点数 L .

(2) 对单隐含层各个节点的参数(输入权值 a_i 、隐含层偏差 b_i)赋值.

(3) 得到隐含层输出矩阵 H :

$$H(a_1, \dots, a_L, b_1, \dots, b_L, x_1, \dots, x_N) = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (1)$$

(4) 根据输出矩阵得到输出权值 $\beta: \beta = H^+T$.

(5) 计算输出权值 $\beta: \beta = H^+T$. 其中, 在 H 为列满秩阵时:

$$H^+ = (H^T H)^{-1} H^T, \beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (2)$$

若 H 为非奇异矩阵, 那么 β 可以按下式求得: $\beta = H^+T$.

(6) 得到预测值: 根据输出权值得到 ELM 预测模型:

$$y = \sum_{i=1}^L \beta_i f(\alpha_i x + \beta_i) \quad (3)$$

ELM 预测模型的训练过程其实就是使误差减小的最优化分析, 通过对其中的各个参数赋值, 得到所需要的输出权值.

虽然与传统神经网络计算方法相比, ELM 的学习速度、预测精度都有所提高, 并且参数调整更加简单, 但是在实际应用过程中, 为了得到准确地预测结果, ELM 通常需要大量的隐含层节点. 并且每个节点的输入权值 a_i 和隐含层节点偏差 b_i 的确定变得困难, 成为影响该模型实际应用效果的关键问题^[10].

2 BFO-ELM 负荷预测模型

电力负荷受到各种各样自然和社会因素的影响, 同时 ELM 隐含层节点数、延迟时间、嵌入维数共同影响着电力负荷预测的准确性^[11]. BFO 是根据大肠杆菌在寻找食物过程中的生理特征得出的一种优化算法, 能够控制局部搜索和全局搜索间的动态转换, 具有很好地收敛性, 因此提出 BFO-ELM 的改进负荷预测方法. BFO-ELM 工作流程如下:

(1) 记录收集某一地区的实测电力负荷数据, 并且将其进行归一化处理, 归一化公式计算如下:

$$\chi'(i) = \frac{\chi(i) - E_x}{\sigma_x} \quad (4)$$

其中, $\chi(i)$ 归一化之前的数据, $\chi'(i)$ 为归一化之后的负荷数据, E_x 为期望值, σ_x 为标准差.

(2) 设置模型各个参数: 细菌的趋化数 N_c ; 细菌的繁殖数 N_{re} 、迁移数 N_{ed} ; 迁移的概率 P_e ; 细菌数 S ; 细菌的游动次数 N_s .

(3) 根据所需优化参数 a_i 、 b_i 、 L 的选择区域对细菌的位置赋初始值 X , 且 X 为区间 $[0, 1]$ 的任意值, 之后根据预测模型的预测精度计算得到每个位置的细菌的适应度 J_0 .

(4) 任意细菌 i 在空间的位置为 $P(i, j, k, l)$. 其中 j 为趋化循环数: $1:N_c$, k 为繁殖循环数: $1:N_{re}$, l 迁移循环数 $1:N_{ed}$.

(5) 根据细菌在各个被优化参数的解空间中的位置, 得到的各个当前参数下的预测模型的预测误差, 也就是细菌在参数解空间中各个寻优位置的适应度值 J_i , 比较相邻两个寻优解 J_{i+1} 与 J_i 的大小. 若出现最小值 J_{min} , 使得 $J_{i+m} > J_{min} (m=1, 2, 3, \dots)$, 则 J_{min} 就是细菌的最优适应度值或者该参数的最优解; 若 $J_{i+1} < J_i$, 则继续重复步骤(2)~(5), 直到完成设置的趋化循环次数 N_c 、繁殖循环次数 N_{re} 以及迁移循环次数 N_{ed} .

(6) 分析所有细菌适应度值, 并找出当前最优解.

(7) 由于细菌觅食算法中每个细菌的适应度代表极限学习机中需要优化的各个参数值, 因此根据适应度的最优值可得到极限学习机中被优化参数 a_i 、 b_i 、 L 的最优解. 进而得到最优极限学习机负荷预测模型.

3 仿真实验

3.1 实验准备

为证实 BFO-ELM 预测模型的可行性, 在 Windows 7 操作系统, Intel(R)Core(TM)cpu M380@2.53 GHz, 2 G 内存, 500 G 硬盘, 的 PC 机上, 采用 C++ 语言编程仿真. 训练集和预测集电力负荷数据来自浙江某地 1464 个真实负荷数据, 数据集中不但有正常负荷数据, 也存在一定的非正常数据. 具体如图 2.

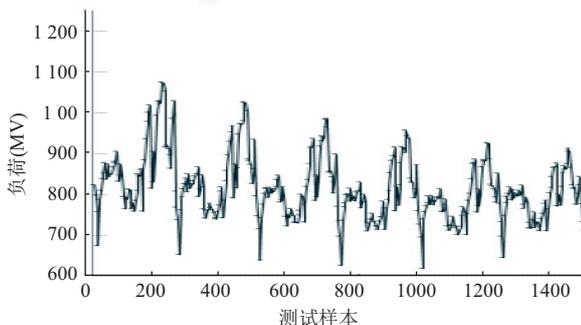


图2 训练和预测数据集

3.2 优化流程

BFO 是根据概率型得到最优化结果的仿生算法, 通过建模从而得到最优解. 实验过程如图 3.

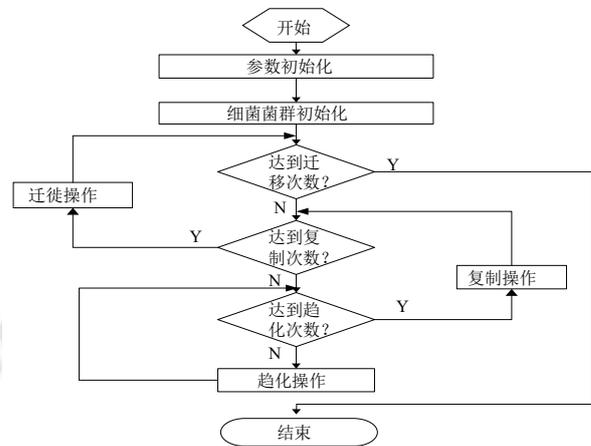


图3 细菌觅食优化算法流程图

将收集到的训练样本数据集和预测样本数据集用于电网供电系统短期电力负荷预测模型的建立过程中, 对于细菌觅食算法优化模型, 以训练样本的输出值与实际值的均方根误差作为适应度函数寻找最优平滑参数(输入权值 a_i 、隐含层偏差 b_i 以及隐含层节点数 L), 如果适应度函数输出值达到设定的误差要求, 则输出预测模型结果, 如果误差未达到预测要求, 则继续重复上述优化过程, 直到要求满足要求为止.

3.3 实验结果分析

通过采用 BFO 优化 ELM 的输入权值、节点偏置以及节点数量, 建立起 BFO-ELM 预测模型, 并在预测样本集中进行仿真预测. 本次试验从相对平均误差 (MAPE%) 与均方根误差 (RMSE) 两个方面进行对比衡量, 与遗传算法优化极限学习机 (GA-ELM)、粒子群算法优化极限学习机 (PSO-ELM)、蝙蝠算法优化极限学习机 (BA-ELM) 负荷预测模型的预测误差结果进行对比. 结果显示 BFO-ELM 预测结果的优越性. BFO-ELM 模型的预测结果以及预测误差如图 4、图 5.

结果显示, BFO-ELM 可以预测该地区电力负荷的变化趋势, 预测相对稳定. 将 BFO-ELM 预测模型的单步预测结果 MAPE、RMSE 与 GA-ELM、PSO-ELM、BA-ELM 预测模型的相应数据进行对比见表 1.

从上表可以看出, 相对于 PSO-ELM、GA-ELM、BA-ELM, BFO-ELM 预测模型的预测结果最为准确,

预测稳定性有了明显提升,这主要是因为细菌觅食算法可以以较快的速度搜寻到极限学习机的最优 a_i 、 b_i 、 L ,从而建立起更加合理的预测模型。

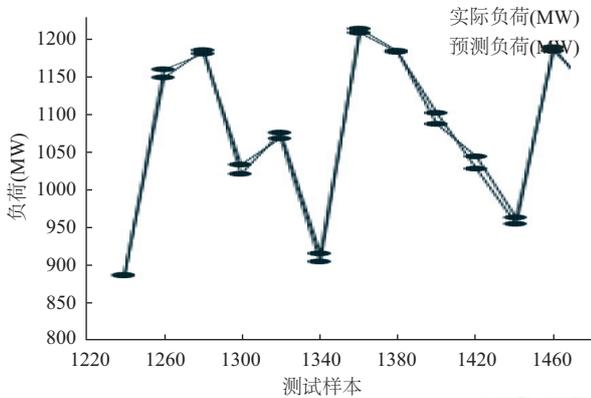


图4 BFO-ELM 的单步预测结果

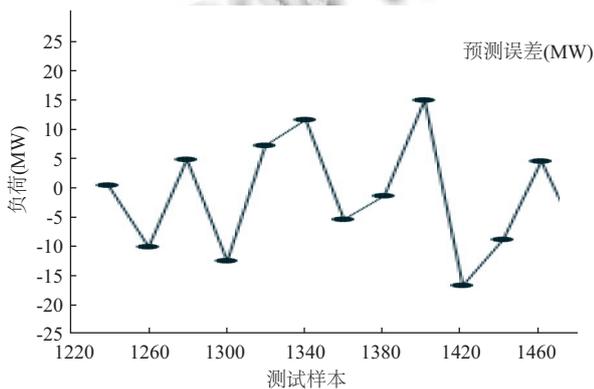


图5 BFO-ELM 的单步预测误差

表1 各个预测模型的单步预测结果分析

模型	相对平均误差(%)	均方根误差
GA-ELM	1.72	20.88
PSO-ELM	1.54	18.83
BA-ELM	1.27	17.23
BFO-ELM	1.16	16.19

由于短期电力负荷预测需要对未来一段时间的负荷趋势进行描述,因此但不预测结果不能很好地满足这一需求,为了更好地服务于调度部门工作人员的工作需求,需要进行多步预测,并分析该模型多步预测的稳定性. BFO-ELM 预测模型的5步负荷预测结果和预测误差如图6、图7。

结果显示,由于预测步数的不断增加,该模型的预测误差明显增加,显然预测能力随之下降,然而,根据

电力调度部门短期电力负荷预测的实际应用要求来讲,改进之后的预测模型仍然能够很好地得到未来一段时间内负荷的发展趋势,很好地将预测误差控制在10%以内,可以较好地服务于当地的预测工作。

将 BFO-ELM 预测模型的5步预测结果 MAPE、RMSE 与 GA-ELM、PSO-ELM、BA-ELM 预测模型的相应数据进行对比见表2。

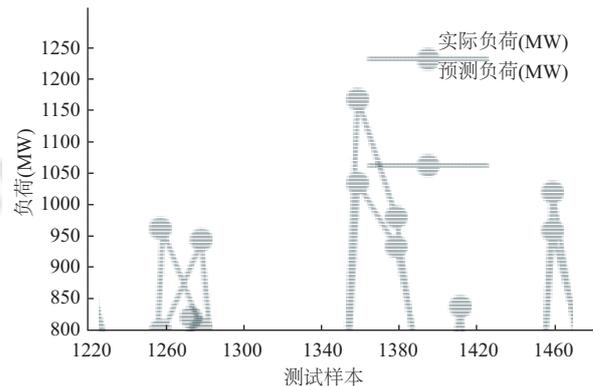


图6 BFO-ELM 的5步预测结果

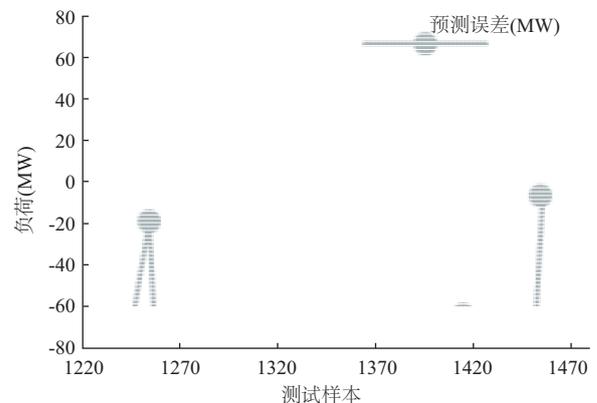


图7 BFO-ELM 的5步预测误差

表2 各个负荷预测模型的5步预测性能对比

模型	相对平均误差(%)	均方根误差
GA-ELM	12.23	80.29
PSO-ELM	11.80	79.73
BA-ELM	7.81	51.25
BFO-ELM	6.98	45.18

综上所述,相对于 GA-ELM、PSO-ELM、BA-ELM, BFO-ELM 预测方法的预测结果相对稳定,预测误差变化幅度小,准确地刻画了电力负荷的实变特性和周期特性,预测误差比较小,采用该模型进行负荷预测是可行的。

4 结束语

针对 ELM 算法在短期负荷预测中的特征,将细菌觅食优化算法引入预测模型的参数优化中,建立起 BFO-ELM 电力负荷预测模型.并在相同的训练样本和数据样本中,将其与 GA-ELM、PSO-ELM、BA-ELM 预测结果进行分析对比.分析结果显示,BFO-ELM 预测模型的预测精度明显高于其他预测方法,很好地降低了建模的难度和预测的效率,为该方法在电力系统短期负荷预测领域的应用前景开创了广阔的天地.

参考文献

- 1 王晓丹,王积勤.支持向量机研究与应用.空军工程大学学报(自然科学版),2004,5(3):49-55.
- 2 李云飞.支持向量机在电力系统短期负荷预测中的应用及改进[硕士学位论文].成都:西南交通大学,2006.
- 3 张庆宝,程浩忠,刘青山,等.基于粗糙集属性约简算法和支持向量机的短期负荷预测.电网技术,2006,30(8):56-59,70.
- 4 贾东梨,孟晓丽,宋晓辉.基于超短期负荷预测的智能配电网状态估计.电力建设,2013,34(1):31-35.
- 5 杨廷志,文小飞,万俊,等.改进神经网络的短期负荷预测模型及仿真.计算机仿真,2014,31(10):145-150,176.
- 6 Kouh S, Keynia F. A new cascade NN based method to short-term load forecast in deregulated electricity market. Energy Conversion and Management, 2013, 71: 76-83. [doi: 10.1016/j.enconman.2013.03.014]
- 7 Grant JL. Short-term peak demand forecasting using an artificial neural network with controlled peak demand through intelligent electrical loading[Ph. D. thesis]. Miami: University of Miami, 2014: 54-61.
- 8 Sudheer G, Suseelatha A. A wavelet-nearest neighbor model for short-term load forecasting. Energy Science & Engineering, 2015, 3(1): 51-59.
- 9 Sudheer G, Suseelatha A. Short term load forecasting using wavelet transform combined with Holt-Winters and weighted nearest neighbor models. International Journal of Electrical Power & Energy Systems, 2015, (64): 340-346.
- 10 Huang GB, Zhu QY, Siew CK. Extreme learning machine: A new learning scheme of feedforward neural networks. Proc. of 2004 IEEE International Joint Conference on Neural Networks. Budapest, Hungary. 2004. 985-990.
- 11 刘晓娟,方建安.基于双修正因子的模糊时间序列日最大负荷预测.中国电力,2013,46(10):115-118.