

改进 PSO 的 WNN 模型在短期负荷预测中的应用^①

张 兰

西安航空职业技术学院 基础部, 西安 710089

摘要: 针对电力系统负荷预测中实际的负荷数据往往具有极大的波动性, 模型呈现出极大的非线性, 提出一种改进粒子群优化的的小波神经网络模型, 将其应用于电力系统的负荷预测研究. 首先, 分析和介绍了小波神经网络和改进的粒子群算法的基本原理和优点; 其次, 将改进的 PSO 算法用于优化小波神经网络的参数优化; 最后对改进的 PSO-WNN 负荷预测模型进行仿真分析. 实验结果与传统 PSO-WNN 的实验结果进行对比, 证明改进的 PSO 能够提高模型的运算效率和负荷预测精度.

关 键 词: 改进粒子群; 小波神经网络; 负荷预测模型

中图分类号: TM743

文献标志码: A

文章编号: 1000-5471(2017)06-0100-05

短期电力负荷预测对于改进电力运行效率具有重要的意义, 负荷预测能够影响电力系统的负荷管理、发电调度和电力系统的安全于经济运行等^[1]. 负荷预测的关键是分析影响负荷预测的因素并建立有效的预测模型, 传统的负荷预测方法如专家系统、模糊控制、灰色预测等虽都已经相对成熟, 但预测效果常常差强人意^[2].

20 世纪末负荷预测的问题经常采用神经网络算法来进行预测, 神经网络具有高效的自主学习性和较高的非线性映射能力^[2], 将其用于负荷预测具有很大优越性. 在神经网络实际预测时常选用 BP 算法进行训练网络, 然而 BP 算法具有学习效率低下, 在实际应用中网络结构很难选择等缺点^[3]. 近年来兴起的小波变换理论在构造具有随机波动信号的非线性函数模型^[4]方面具有很大的优越性. 因此, 张清华等人于 1992 年首次提出了小波神经网络(wavelet neural network, WNN), 并在函数学习上取得了成功^[5]. 该算法结合了小波分析和神经网络的优点, 核心主要是用小波函数替代神经网络的激活函数. 小波神经网络广泛应用于模型预测、系统辨识、故障诊断等领域^[6-7].

进化算法是一种基于种群搜索的方法, 具有强大的全局搜索能力和鲁棒性. 粒子群算法(Particle Swarm Optimization)是一种模拟鸟类觅食的智能优化算法, 该优化算法控制参数少, 易于实现, 搜索效率高^[8]. PSO 和小波神经网络相结合比单独的算法能够更好地发挥小波神经网络的泛化能力, 被广泛应用于电力系统负荷预测、模型辨识、能源预测等. 然而 PSO 算法在粒子进行全局寻优方面具有劣势, 收敛速度慢, 一旦提高其收敛速度, 很容易陷入局部最优值.

本文对此做了进一步改进, 参考文献[9-11], 提出一种基于改进粒子群算法的小波神经网络模型, 将其应用于电力系统的负荷预测中. 对实际算例进行仿真分析, 验证了改进的小波神经网络在负荷预测模型上的有效性.

① 收稿日期: 2015-10-22

基金项目: 陕西省教育厅专项科研计划基金资助项目(15JK1381).

作者简介: 张 兰(1985-), 女, 陕西西安人, 讲师, 博士研究生, 主要从事优化算法的研究.

1 小波神经网络结构

小波神经网络是小波分析和神经网络相结合的产物, 因此兼备了小波分析和神经网络的优点, 它具有神经网络的高效的自主学习性和小波变化的局部化特性. 本文中采用 3 层的小波神经网络, 具体的网络结构如图 1 所示.




图 1 小波神经网络的结构

其中: $x_i (i = 1, 2, \dots, N)$ 为输入样本, $y(x)$ 为 WNN 的输出, $w_i (i = 1, 2, \dots, N)$ 代表输入层神经元与隐层神经元之间的连接权值, u_i 代表隐层神经元与输出层神经元间的连接权值, 本文隐含层采用小波 Morlet 为激活函数, 其表达式为

$$\psi \frac{x-b}{a} = \cos\left(1.75 \frac{x-b}{a}\right) \exp\left(-0.5 \left(\frac{x-b}{a}\right)^2\right) \quad (1)$$

2 改进的 PSO 算法优化 WNN

2.1 改进 PSO 算法

粒子群优化算法由 Kennedy 和 Eberhart 提出. 在粒子群算法中, 每个粒子 i 代表一个潜在解, 粒子的位置和速度的矢量分别为 $x_i(t) = (x_{i1}(t), x_{i2}(t), \dots, x_{in}(t))$ 和 $v_i(t) = (v_{i1}(t), v_{i2}(t), \dots, v_{in}(t))$, 粒子状态的更新方程如下:

$$v_{ij}(t+1) = \omega v_{ij}(t) + c_1 \cdot r_1 \cdot (p_{ij}(t) - x_{ij}(t)) + c_2 \cdot r_2 \cdot (p_{gj}(t) - x_{ij}(t)) \quad (2)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad i = 1, 2, \dots, M, j = 1, 2, \dots, n \quad (3)$$

其中, c_1 和 c_2 均是加速因子; r_1, r_2 是 $[0, 1]$ 上均匀分布的随机数; t 代表进化代数; v_i, x_i , 分别表示每个粒子的速度和位置; p_{gj}, p_{ij} 分别代表粒子群的全局最优和个体最优, ω 为惯性权重, 一般线性递减.

衡量一个进化算法性能的因素包括: 全局搜索能力、收敛速度、鲁棒性、精度等. 在 PSO 算法中, 随着粒子迭代次数的增加, 种群的多样性减少, 使得种群的全局搜索能力降低. 尤其在种群搜索寻找最佳位置时, 各个粒子最优位置的适应度差异常被忽略, 因此本文在文献[9-11]的基础上提出一种改进的粒子群优化小波神经网络的模型, 根据粒子的适应度情况不同, 选择不同的权重, 使适应度好的粒子发挥最大优势, 并在搜索过程中发挥导向作用, 增加收敛速度, 粒子的惯性权重系数随着适应度的大小而线性递减. 由于待求目标函数最小值, 因此对个体适应度值按照降序排列标号, 并取 τ_{fitness} 为降序排序标号值, 则惯性权重记为如下形式:

$$\omega = (\omega_{\text{start}} - \omega_{\text{end}}) \cdot \left(\frac{t_{\text{maxg}} - \tau_{\text{fitness}}}{t_{\text{maxg}}}\right)^2 + 2(\omega_{\text{end}} - \omega_{\text{start}}) \cdot \left(\frac{t_{\text{maxg}} - \tau_{\text{fitness}}}{t_{\text{maxg}}}\right) + \omega_{\text{start}} \quad (4)$$

其中 $\omega_{\text{start}} = 0.9$, $\omega_{\text{end}} = 0.3$, t_{max} 为最大的迭代次数, 通过在整个群中的适应值顺序进行惯性权重的计算, 这样使得粒子的变化具有动态适应性.

2.2 改进 PSO 优化 WNN

本文引入改进的 PSO 优化算法训练小波神经网络, 可加快网络训练速度, 有效提高预测精度. 改进的

PSO 用于 WNN 的训练时, 选取 n 个网络训练的样本, 粒子的位置向量代表网络的权值, 粒子初始化后通过速度更新粒子的位置向量, 而粒子的适应度函数采用如下均方误差来表示:

$$fit = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^m (y_{j,i}^d - y_{j,i})^2 \quad (5)$$

其中: m 为神经元的网络输出节点数目; $y_{j,i}^d$ 为第 i 个样本的第 j 个预测输出值; $y_{j,i}$ 为第 i 个样本的第 j 个网络实际输出值.

改进 PSO 算法训练 WNN 的步骤:

Step1: 算法初始化: 确定粒子数为 N , 粒子维数为 D , 最大迭代代数 $t_{\max}$, 惯性权重初始值, WNN 的输入层、隐含层、输出层的节点数目;

Step2: 利用公式(2) 和公式(3) 计算粒子的初始速度和位置;

Step3: 根据公式(5) 进行粒子适应度的计算, 评价每个粒子 i 对应的适应度, 记个体最佳适应度值为全局最优极值, 更新全局最优值;

Step4: 对个体适应度值按照降序排列标号, 由(4) 式更新惯性权重, 并更新粒子 i 的速度和位置;

Step5: 确定 WNN 的最优网络参数, 输入训练参数并进行 WNN 模型的预测;

Step6: 若迭代达到要求, 则停止, 输出预测结果; 否则, 转向步骤 2.

3 数值实验

本实验采用 MATLAB_R2013a, 计算机处理器采用: 1.4 GHz Intel core i5, 内存: 4GB, 1600 MHz DDR3. 为了更好地评价预测结果的好坏, 本文采用绝对误差(Absolute Percentage Error, APE) 和平均绝对误差(Mean Absolute Percentage Error, MAPE) 来检验算法预测的效果. 绝对误差和平均绝对误差分别用 A_{APE} 和 M_{MAPE} 表示

$$A_{APE} = \left| \frac{A_i - P_i}{A_i} \right| \cdot 100\%, i = 1, 2, \dots, n \quad (6)$$

$$M_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - P_i}{A_i} \right| \cdot 100\% \quad (7)$$

其中, A_i 代表实际的负荷值, P_i 代表预测的负荷值, n 代表小时数.

本实验所用数据来源于网站 <http://www.ferc.gov/market-oversight/mkt-electric/overview.asp> 中某城市 2012 年 1 月某工作日 24 整点的负荷数据为样本, 预测第二天工作日的电力负荷值. 本文实验中对该地区预测日前一天的负荷平均每间隔 1 h 进行测量, 得到 24 个数据, 由于负荷数据受到天气等因素的影响, 导致会出现一些缺失和坏的数据, 因此一般先对数据进行预处理.

本文中小波神经网络对负荷进行预测时的网络层数取 3 层, 输入的神经元数为 12, 包括当前时刻和前 3 个时刻的负荷, 当前时刻和前 3 个时刻的温度以及当前时刻和前 3 个时刻的风速; 输出层的神经元个数为 1, 隐藏层的神经元个数经确定采用文献[12] 的方法, 具体通过下面的式子计算:

$$k < \sum_{i=0}^n C_i^h \quad (8)$$

$$h = \sqrt{n + m + a} \quad (9)$$

其中 k 为样本数, n 为输入层节点数, m 为输出层节点数, h 为隐藏层节点数, a 是 1 ~ 10 之间的常数.

本文将改进的粒子群优化小波网络的负荷预测模型分别与传统的粒子群优化小波神经网络的负荷预测模型分别进行比较. 预测结果比较见表 1. 负荷预测曲线图分别如图 2 和图 3 所示, 其中横坐标为时间, 纵坐标为负荷值.

从表 2 可以看出, 改进的 PSO-WNN 模型的最大绝对误差为 8.057%, 最小绝对误差为 0.464%, 而改进后的 PSO-WNN 模型的误差为 6.705%, 最小绝对误差为: 0.977%. 改进后的 PSO-WNN 模型的预测精度要好于 PSO-WNN 模型的预测精度. 两者的平均绝对误差比较, 改进后的 PSO-WNN 模型也好于 PSO-

WNN 模型的预测精度。因此，总体而言改进后的 PSO-WNN 模型具有较好的精度。

表 1 两种模型的负荷预测值与绝对误差对比

时间	PSO-WNN 误差/%	改进 PSO-WNN 误差/%
1	2.014	1.811
2	2.370	1.859
3	3.001	2.990
4	2.112	1.206
5	2.086	1.144
6	3.084	2.110
7	2.830	1.998
8	1.320	0.732
9	2.345	1.339
10	5.930	3.389
11	3.464	1.539
12	2.252	1.142
13	1.955	0.912
14	1.859	0.892
15	1.455	0.464
16	1.151	1.347
17	2.690	2.208
18	1.566	0.671
19	1.784	1.273
20	1.649	1.313
21	0.977	0.649
22	2.296	1.165
23	1.126	0.949
24	8.057	6.705

表 2 两种网络结构模型的迭代时间和平均预测误差的对比

模型结构	平均绝对百分比误差/%
PSO-WNN	2.5011
改进 PSO-WNN	1.6514




图 2 PSO-WNN 预测结果




图 3 改进的 PSO-WNN 预测结果

4 结 论

本文在 PSO 算法的基础上，利用函数的适应度值的大小对惯性权重进行改进，提出改进的 PSO 算法，

并将算法应用于小波神经网络的训练,用修正后的 PSO-WNN 模型进行电力系统的复合预测,结果表明,与传统 PSO 算法相比,改进的 PSO-WNN 模型提高了负荷预测的精度。

参考文献:

- [1] 康重庆,夏清,刘梅. 电力系统负荷预测 [M]. 北京: 中国电力出版社, 2007.
- [2] MOGHRAH I, RAHMAN S. Analysis and Evaluation of Five Short-Term Load Forecasting Techniques [J]. Proceedings of the IEEE Transaction on Power Systems, 1989, 4(4): 1484—1491.
- [3] HIPPERT H S, PEDREIRA E C, SOUZA C R. Neural Networks for Short-Term Load Forecasting: A Review and Evaluation [J]. IEEE Transactions on Power Systems, 2001, 16(1): 44—55.
- [4] CHUI C K. An Introduction to Wavelets [M]. New York: Academic Press, 1992.
- [5] ZHANG Q, BENVENISTE A. Wavelet Networks [J]. IEEE Transactions on Neural Networks, 1992, 3(6): 889—898.
- [6] ZHANG Q. Using Wavelet Network in Nonparametric Estimation [J]. IEEE Transactions on Neural Networks, 1997, 8(2): 227—236.
- [7] SZU H, TELFER B, KADAMBE S. Neural Network Adaptive Wavelets for Signal Representation and Classification [J]. Optical Engineering, 1992, 31(9): 1907—1916.
- [8] KENNEDY J, EBERHART R C. Particle Swarm Optimization [C]. Proceedings of the 1995 IEEE International Conference on Neural Networks. Piscataway, NJ: IEEE Press, 1995: 1942—1948.
- [9] CHEN Z, FENG T J. The Application of Wavelet Neural Network for Time Series Prediction and System Modeling Based on Multi-Resolution Learning [C]. Tokyo, Japan: Proceedings of IEEE 1999 International Conference on System, Man and Cybernetics, 1999: 425—430.
- [10] 陈贵敏,贾建援,韩琪. 粒子群优化算法的惯性权值递减策略研究 [J]. 西安交通大学学报, 2003, 40(1): 53—61.
- [11] 皮倩瑛,叶洪涛. 一种动态调节惯性权重的粒子群算法 [J]. 广西科技大学学报, 2016, 27(3): 26—32.
- [12] 袁曾任. 人工神经网络及其应用 [M]. 北京: 清华大学出版社, 1999: 118—131.

On Application of Improved PSO-WNN to Model Load Forecasting

ZHANG Lan

Department of Basic, Xi'an Aeronautical Polytechnic Institute, Xi'an 710089, China

Abstract: An improved Particle Swarm Optimization algorithm has been proposed in this paper to model the wavelet neuron network, and this model been applied to the application of forecasting load in power system. Firstly, the basic principle of improved PSO-WNN model is presented. Secondly, the improved PSO algorithm is used to optimize the parameters of WNN load forecasting model. Then, the experiment simulations of improved PSO-WNN model are conducted and analyzed. The improved PSO-WNN model is compared with conventional PSO-WNN model. The experiment results show that the proposed model is efficiency in model computing and the precision of the load forecasting.

Key words: improved PSO; WNN; load forecasting model