

基于改进 PSO-BP 神经网络的短期电力负荷预测研究

乔维德

(江苏常州市广播电视大学, 江苏 常州 213001)

摘要: 粒子群优化 (PSO) 算法是基于群智能的全局优化技术, 它通过粒子间的相互作用, 对解空间进行智能搜索, 从而发现最优解。该文对基本粒子群算法进行改进, 并将改进粒子群优化算法与误差反向传播 (BP) 算法结合起来构成的混合算法用于训练人工神经网络, 对短期电力负荷进行预测。实践结果表明: 改进 PSO-BP 算法有效地解决常规 BP 算法学习网络权值和阈值收敛速度慢、易陷入局部极小等问题, 具有较快的收敛速度和较高的预测精度。

关键词: 改进 PSO-BP 算法; 短期电力负荷; 预测

Study of short-term power load forecasting based on improved PSO-BP neural network model

QIAO Wei-de

(Changzhou Radio and TV University, Changzhou 213001, China)

Abstract: Particle Swarm Optimization (PSO) algorithm is a global optimization technology based on the group intelligence, it carries on the intelligent search for the solution space through mutual effect in order to discover the optimal solution. This paper makes the improvement on the basic particle swarm algorithm, and creates a mix algorithm, which combines the improved PSO algorithm with the erroneous reverse dissemination (BP) algorithm. This mixed algorithm can be used for training the artificial neural network, forecasting the short-term power load. The practice result indicates that the improved PSO-BP algorithm solves effectively the problems of the conventional BP algorithm network convergence rate slow and easily falling into partial minimum, it works with quicker convergence rate and the higher forecast precision.

Key words: improved PSO-BP algorithm; short-term power load; forecasting

中图分类号: TM715

文献标识码: A

文章编号: 1003-4897(2007)17-0017-05

0 引言

近年来, 电力负荷预测的研究不断发展, 一些预测方法, 如时间序列法、灰色系统建模预测法、人工神经网络模型预测法等, 已经得到普遍应用。其中在神经网络的学习算法中应用最多的是误差反向传播 (BP) 算法, 它响应快, 具有良好的容错性、强大的自学习能力和非线性映射能力, 但由于 BP 算法本身存在容易陷入局部极小值、收敛速度慢、迭代时间长等一些固有缺陷, 因此影响了 BP 神经网络预测模型的精度。为了提高电力负荷预测的快速性和准确性, 本文提出将改进的粒子群优化算法与 BP 算法相结合的一种新的改进 PSO-BP 混合算法,

来训练短期电力负荷预测的神经网络模型, 有效改善了粒子群算法的“早熟”现象, 具有训练时间短、计算精度高和较强的全局搜索能力等优点, 取得了良好的应用效果。

1 BP 神经网络算法

BP 神经网络一般由输入层、隐含层、输出层组成。对于输入信号, 先向前传播到隐节点, 经过节点作用函数后, 再把隐节点的输出信息传播到输出节点, 最后输出结果。节点的作用函数通常选取 S 型函数 $f(x)=1/(1+e^{-x})$ 。BP 算法的学习过程分为正向传播和反向传播过程。如果正向传播输出的误差达不到预期精度, 则沿误差的负梯度方向反复修改各层神经元的权值和阈值, 直至网络全局误差信号最小。由于传统 BP 算法基于梯度下降法的, 而梯度

基金项目: 江苏广播电视大学学术带头人培养工程资助项目

下降法通常具有收敛速度慢、易陷入局部极小值和振荡等缺点, 所以将 BP 算法进行了改进。本文采用一种基于动量——自适应的改进 BP 学习算法, 加入动量项实质上是相当于阻尼项, 它减小了学习过程的振荡趋势。自适应学习就是使学习率不断调整, 克服了学习率太小或太大、收敛速度太慢和修正过头而导致的振荡甚至发散现象。动量——自适应学习算法表达式为:

$$\omega_{ij}(t+1) = \omega_{ij}(t) + \eta(t+1)\delta(t)O_i(t) + \alpha[\omega_{ij}(t) - \omega_{ij}(t-1)]$$

$$\eta(t+1) = \begin{cases} m\eta(t)[\delta(t)O_i(t)], [\delta(t-1)O_i(t-1)] > 0 \\ n\eta(t)[\eta(t)O_i(t)], [\eta(t-1)O_i(t-1)] < 0 \\ \eta(t)[\delta(t)O_i(t)], [\delta(t-1)O_i(t-1)] = 0 \end{cases} \quad (1)$$

式中: α 为动量因子, 后面与其相乘项为动量项; m 与 n 为常数, $0 < n < m$; η 为变化中的学习率 (步长); δ 为神经元误差; O_i 为神经元的输入。

2 粒子群优化算法及其改进

2.1 粒子群优化算法

粒子群优化算法 PSO (Particle Swarm Optimization) 最早是由美国普渡大学的 Kennedy 博士和 Eberhart 博士于 1995 年提出的一种基于仿生的集群优化算法。PSO 算法来自于对鸟群的捕食行为的模拟和研究, 一群鸟在随机搜寻食物, 如果这个区域里只有一块食物, 所有的鸟都不知道食物在哪里, 那么找到食物的最简单有效策略就是搜寻目前离食物最近鸟的周围区域。PSO 算法正是从这种模型中得到启示并应用于解决优化问题的。在 PSO 算法中, 每个优化问题的解都是搜索空间的一只鸟, 称为“粒子”, 即每个粒子的位置就是一个潜在的解。假设在一个 d 维搜索空间中, 有 m 个粒子组成一个群体, 第 i 个粒子在 d 维空间的位置表示为 $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$ ($i=1, 2, \dots, m$), 第 i 个粒子的“飞翔”速度, 即粒子改变位置的速率记为 $V_i = (v_{i1}, v_{i2}, \dots, v_{id})$, 第 i 个粒子经历过的最优位置 (有最好适应度) 记为 $P_{best} = (P1, P2, \dots, Pd)$, 群体所有粒子经历过的最优位置记为 $G_{best} = (G1, G2, \dots, Gd)$ 。在每一次迭代中, 粒子通过跟踪这两个最优值来更新自己。在找到这两个最优值时, 粒子根据公式 (2)、(3) 分别对自己的速度和位置进行迭代更新, 直至满足迭代终止条件。迭代终止条件根据具体问题, 一般选取为最大迭代次数或者粒

子群迄今为止搜索到的最优位置满足规定的最小误差标准要求为止。

$$V_{ij}(t+1) = \omega V_{ij}(t) + C_1 * R_1 * (P_j(t) - X_{ij}(t)) + C_2 * R_2 * (G_j(t) - X_{ij}(t)) \quad (2)$$

$$X_{ij}(t+1) = X_{ij}(t) + V_{ij}(t+1) \quad (3)$$

式中: $j=1, 2, \dots, d$, t 为迭代次数; $X_{ij}(t)$ 为粒子第 t 代当前位置; $V_{ij}(t)$ 为粒子第 t 代 (循环) 的速度; ω 为惯性权重, 它使粒子保持运动惯性; C_1 、 C_2 为加速因子 (或学习因子), 分别调节向全局最优粒子和个体最优粒子方向飞行的最大步长, 通常取 $C_1=C_2=2$; R_1 、 R_2 为 $[0, 1]$ 区间变化的随机数。

2.2 粒子群优化算法的改进

在标准 PSO 算法中, 惯性权重是控制历史速度对当前速度的影响程度、平衡 PSO 算法的全局搜索和局部搜索能力。当 ω 较大时, 粒子的全局搜索能力强; 当 ω 较小时, 粒子主要在当前解的附近搜索, 局部搜索能力强; 当 $\omega=0$ 时, 粒子就失去记忆性。而且 PSO 算法容易“早熟”, 并且粒子在算法后期容易在全局最优解附近出现振荡现象, 我们通常可采取将 ω 从最大惯性权重到最小惯性权重线性减小的办法, 但这需要通过反复试验才能确定 ω 的最大值 ω_{max} 、 ω_{min} 和最大迭代次数, 而且找到适应于每个问题的最佳值也比较困难。为此本文提出了一种改进非线性动态自适应粒子群优化算法, 以实现 ω 能够随适配值自动改变。惯性权重 ω 的计算公式为:

$$\omega = \begin{cases} \omega_{max} - \frac{(\omega_{max} - \omega_{min})(f - f_{ave})}{f_{max} - f_{ave}} & (f \geq f_{ave}) \\ \omega_{max} & (f < f_{ave}) \end{cases} \quad (4)$$

公式中: f 为粒子的适配值; f_{ave} 为每代粒子的平均适配值; f_{max} 为粒子群中最大的适配值。

3 改进 PSO-BP 神经网络混合算法实现

将改进的 PSO 与 BP 神经网络算法结合起来形成一种混合算法。在混合算法训练网络时, 首先定义粒子群的位置向量 X_i 的元素是 BP 网络的全部连接权值和阈值, 并初始化位置向量 X_i , 然后用混合算法搜索出粒子适应度函数值 (均方误差) 最小时的 BP 网络最佳权值和阈值。

$$J = \frac{1}{n} \sum_{j=1}^n \left| \sum_{k=1}^m (q_{jk} - y_{jk})^2 \right| \quad (5)$$

式中: q_{jk} 为目标期望值, y_{jk} 为网络计算值, m 为输

出节点数, n 为训练集样本数。

改进 PSO 与 BP 神经网络混合算法的流程如下:

①根据神经网络的输入、输出样本集, 建立神经网络的拓扑结构, 将神经元之间所有的连接权值和阈值编码成实数向量表示种群中的个体粒子。

②初始化粒子的初始位置、速度、惯性权重 ω 、加速因子 C_1 、 C_2 , 规定最大迭代次数等。

③根据输入、输出样本, 计算出每个粒子适应度函数值, 并将每个粒子的最好位置作为其历史最佳位置, 开始迭代。

④利用 PSO 算法的 (2)、(3)、(4) 式对粒子的速度和位置进行更新。

⑤检查粒子速度和位置是否越界, 如越界, 排除越界并重新更新粒子速度和位置。

⑥重新计算粒子的适应度值, 并根据适应度自动改变惯性权重, 搜索出粒子最佳位置。

⑦检验是否符合结束条件。如果当前位置或最大迭代次数达到预定的误差要求时, 则停止迭代, 输出神经网络的最终权值和阈值, 否则转至③执行。

4 短期电力负荷预测模型及其应用

4.1 训练样本的数据处理

影响电力负荷预测的因素主要由历史电力负荷以及相应的天气因素、日期类型组成, 为提高预测精度, 避免神经元出现饱和现象, 对网络训练的输入、输出负荷数据必须进行归一化处理, 使输入负荷数据位于 $[0, 1]$ 之间。 t 时刻负荷数据 X_t 采用下面的归一化公式换算:

$$X'_t = \frac{X_t - X_{\min}}{X_{\max} - X_{\min}} \quad (t = 1, 2, \dots, 24) \quad (6)$$

在输出层采用公式重新换回实际的负荷值, 其公式为:

$$X_t = (X_{\max} - X_{\min})X'_t + X_{\min} \quad (7)$$

式中: X_{\max} 、 X_{\min} 分别表示训练样本集中电力负荷的最大值和最小值。

在实际影响日负荷的天气情况、温度情况、日期类型等因素与电力负荷的关系非常复杂, 具有非线性和不确定性, 用传统的数值统计方法很难描述其复杂关系。本文通过模糊推理策略将这些影响因素经过隶属函数转化为模糊量。

(1) 气温的量化。气温的隶属度函数分别按低温、中温和高温采用偏小型、中间型和偏大型梯形分布。

低温的隶属度函数为:

$$u_{t1} = \begin{cases} 0 & (t > 10) \\ \frac{10-t}{10-0} & (0 \leq t \leq 10) \\ 1 & (t < 0) \end{cases} \quad (8)$$

中温的隶属度函数为:

$$u_{t2} = \begin{cases} 0 & (t > 25 \text{ 或 } t < 5) \\ \frac{t-5}{15-5} & (5 \leq t \leq 15) \\ \frac{25-t}{25-15} & (15 < t \leq 25) \end{cases} \quad (9)$$

高温的隶属度函数为:

$$u_{t3} = \begin{cases} 0 & (t < 20) \\ \frac{t-20}{40-20} & (20 \leq t \leq 40) \\ 1 & (t > 40) \end{cases} \quad (10)$$

将同类型日的最高温度 t_h 分别代入以上公式, 计算得到 t_h 对应的低、中、高温三个状态的隶属度。根据隶属度最大原则, 可知 t_h 所属的模糊集。对于最低温度, 可按照同样方法求出相应的三个状态隶属度及其取值。

(2) 天气情况的量化。天气情况可用语言变量“晴、阴、多云、雨”等描述, 对其进行预处理, 即将天气这个模糊量给定量化系数。表 1 中仅列出典型的天气情况, 其中降雨量会对负荷预测产生一定的影响, 具体量化取值见表 2 所示。

表 1 天气情况量化系数

Tab.1 Weather situation quantification coefficient

天气情况	量化系数
晴	0.0
多云	0.2
阴	0.4
雨	随降雨量变化

表 2 降雨量及其相应量化系数

Tab.2 Rain-fall amounts and its quantification coefficient

降雨量/mm	量化系数
0	0
0~15	0.2
15~30	0.3
30~50	0.5
50~80	0.7
80~120	0.9
120~	1.0

(3) 日期类型的量化。日期的量化可分为工作日、双休日、节假日三种类型。前两种日期类型的隶属函数采用半矩形分布。

工作日的隶属度函数表示为：

$$W_{\text{day}} = \begin{cases} 1 & (\text{周一} \sim \text{周五}) \\ 0 & (\text{周六、周日}) \end{cases}$$

双休日的隶属度函数表示为：

$$R_{\text{day}} = \begin{cases} 0 & (\text{周一} \sim \text{周五}) \\ 1 & (\text{周六、周日}) \end{cases}$$

对于五一、国庆、春节等节假日取值可根据具体情况和需求单独建模。

4.2 神经网络系统结构设计

预测日最大、最小负荷受日期类型及天气情况的影响较大，而且还与预测日前几天的最大、最小负荷等直接有关，因而采用表 3 所示的神经网络输入、输出信息表示。

表 3 预测日 t 时刻最高（低）负荷的神经网络输入、输出量

Tab.3 Neural network input and output for t time highest (lowest) load of the forecasting dates

	神经元	相应相应量
输入	1	前一天 t 时刻最高（低）负荷
	2	前一天 t 时刻最高温度
	3	前一天 t 时刻最低温度
	4	前一天 t 时刻天气情况
	5	前一天 t 时刻日期类型
	6	前两天 t 时刻最高（低）负荷
	7	前两天 t 时刻最高温度
	8	前两天 t 时刻最低温度
	9	前两天 t 时刻天气情况
	10	前两天 t 时刻日期类型
	11	预测日 t 时刻最高温度
	12	预测日 t 时刻最低温度
	13	预测日 t 时刻天气情况
	14	预测日 t 时刻日期类型
输出	15	预测日 t 时刻最高（低）负荷

表 3 中，负荷值采用归一化数据表示，其它均采用隶属度函数或量化系数。本网络中有 14 个输入节点和 1 个输出节点，隐层节点数根据经验选取为 6。

4.3 算例分析

为了验证改进 PSO-BP 混合算法训练短期负荷预测神经网络的有效性，本文选取江苏省宝应某地区 2003 年 5 月至 2005 年 10 月的历史电力负荷数据和该地区对应日期、天气数据作为学习样本，借助 Matlab 软件对神经网络进行训练和仿真，再根据训

练好的神经网络来预测 2006 年 8 月的 10 日（星期四）和 13 日（星期日）的负荷，并将其与 BP 神经网络预测结果比较，如表 4、表 5 所示（限于版面，只列出该日的奇数预测值）。从表中可以观察，本文构建的网络模型预测精度明显高于传统 BP 算法，而且学习训练时间只需 1.6 s，测试时间为 22 ms，具有较快的速度和精度，完全可以满足电力系统运行调度的需求。

表 4 2006 年 8 月 10 日（星期四）负荷预测结果
Tab.4 Forecast result on August 10, 2006(Thursday)

时刻	实际负荷 /MW	改进 PSO-BP 网络		BP 神经网络	
		预测值 /MW	误差/(%)	预测值 /MW	误差/(%)
1	635.24	640.38	0.81	649.25	2.21
3	583.55	589.22	0.97	593.3	1.67
5	582.12	585.35	0.55	577.45	-0.80
7	773.26	768.18	-0.66	782.51	1.20
9	994.51	987.25	-0.73	1014.32	1.99
11	1206.8	1193.67	-1.09	1175.08	-2.63
13	905.25	914.63	1.04	932.85	3.05
15	984.32	990.54	0.63	960.27	-2.44
17	999.16	1007.15	0.80	1013.45	1.43
19	1105.35	1098.4	-0.63	1114.42	0.82
21	1024.71	1033.28	0.84	1043.26	1.81
23	883.2	890.04	0.77	900.5	1.96

表 5 2006 年 8 月 13 日（星期日）负荷预测结果
Tab.5 Forecast result on August 13, 2006(Sunday)

时刻	实际负荷 /MW	改进 PSO-BP 网络		BP 神经网络	
		预测值/MW	误差/(%)	预测值 /MW	误差 / (%)
1	608.21	610.32	0.35	612.21	0.66
3	513.54	509.28	-0.83	503.37	-1.98
5	552.13	559.65	1.36	571.41	3.49
7	713.26	720.17	0.97	728.5	2.14
9	894.61	890.2	-0.49	887.72	-0.77
11	1006.24	1003.37	-0.29	1012.04	0.58
13	855.27	859.69	0.52	877.18	2.56
15	894.52	898.52	0.45	903.26	0.98
17	913.16	907.18	-0.65	925.34	1.33
19	999.85	1018.37	1.85	1011.2	1.14
21	1005.76	1006.24	0.05	1012.56	0.68
23	792.14	794.05	0.24	798.33	0.78

5 结语

科学准确的短期电力负荷预测有利于提高电力系统运行的经济性和安全性，对于保证电力工业的

健康发展乃至整个国民经济的发展具有十分重要的意义。由于电力系统负荷的复杂性,存在着多种不确定性和难以解析描述的非线性,因此预测时不仅要求较高的精确性,还要求较强的鲁棒性、实时性和容错性。基于以上考虑,本文运用改进粒子群算法和 BP 算法相结合形成的混合算法(改进 PSO-BP 算法)来训练神经网络,并对某地区短期电力负荷进行预测。实例结果表明,运用该方法能有效提高电力负荷预测的准确性和有效性,具有较好的工程应用价值和实际指导意义。

参考文献

- [1] Vila J P,Wagner V,Neveu P.Bayesian Nonlinear Model Selection and Neural Network:a Conjugate Prior Approach[J].IEEE Trans on Neural Networks,2000,11(2): 265-278.
- [2] Senjyu T,Takara H,Funabashi T.One-hour-ahead Load Forecasting Using Neural Network[J].IEEE Trans on Power Systems,2002,17(1):113-118.
- [3] Kim K H,Youn H S,Kang Y C.Short-term Load Forecasting for Special Days in Anomalous Load Conditions Using Neural Networks and Fuzzy Inference Method[J].IEEE Trans on Power Systems,2000,15(2): 559-565.
- [4] 鲍正江,胡海兵.一种基于神经网络的电力负荷预测方法[J].浙江电力,2004,23(4):10-12.
BAO Zheng-jiang,HU Hai-bing.An Electric Load Forecast Method Based on the Neural Network[J]. Zhejiang Electric Power,2004,23(4):10-13.
- [5] 姚李孝,姚金雄,李宝庆,等.基于竞争分类的神经网络短期电力负荷预测[J].电网技术,2004,28(10):45-48.

- YAO Li-xiao,YAO Jin-xiong,LI Bao-qing,et al.Short-time Load Forecasting Using Neural Network Based on Competitive Learning Classification[J].Power System Technology,2004, 28(10):45-48.
- [6] 卫志农,王丹,孙国强,等.基于级联神经网络的短期负荷概率预测新方法[J].电工技术学报,2005,20(1):95-98.
WEI Zhi-nong,WANG Dan,SUN Guo-qiang,et al.A Novel Method of Short Time Load Probability Forecasting Based on Cascaded Neural Network[J]. Transactions of China Electro Technical Society,2005,20(1):95-98.
 - [7] 张红梅,卫志农,等.基于粒子群支持向量机的短期电力负荷预测[J].继电器, 2006,34(3):28-31.
ZHANG Hong-mei,WEI Zhi-nong,et al. A Short-term Load Forecasting Approach Based on PSO Support Vector Machine[J]. Relay, 2006,34(3):28-31.
 - [8] 康重庆,夏清,张伯明.电力系统负荷预测研究现状与发展方向的探讨[J].电力系统自动化,2004,28(17):1-11.
KANG Chong-qing,XIA Qing,ZHANG Bo-ming.Power System Load Forecasting:Current Status and Future Prospects[J].Automation of Electric Power Systems,2004, 28(17):1-11.
 - [9] 姜勇.电力系统短期负荷预测的模糊神经网络方法[J].继电器,2002,30(7):11-13.
JIANG Yong.Fuzzy Neural Network for Short-term Load Forecasting[J].Relay,2002,30(7):11-13.

收稿日期:2007-02-27; 修回日期:2007-04-02

作者简介:

乔维德(1967-),男,副教授,研究方向为智能控制等。

E-mail:qwd@cztvu.com

(上接第4页 continued from page 4)

- [6] 沈全荣,严伟,梁乾兵,等.异步法电流互感器饱和判别新原理及其应用[J].电力系统自动化,2005, 29(16): 84-86.
SHEN Quan-rong, YAN Wei, LIANG Qian-bing, et al. Asynchronous Method for the Recognition of Current Transformer Saturation and Its Application[J]. Automation of Electric Power Systems, 2005, 29(16): 84-86.

(上接第16页 continued from page 16)

LIU Jian, GOU Xin-peng, XU Jing-qiu, et al. Short-term Load Forecasting of Distribution Networks Based on Partition Loads[J]. Automation of Electric Power Systems, 2003,27(19):34-37.

收稿日期:2007-02-01; 修回日期:2007-06-22

作者简介:

刘玉东(1978-),男,硕士研究生,工程师,主要研究方向为电力系统继电保护及相关领域; E-mail: vip.yudongliu@163.com

王增平(1964-),男,教授,博士生导师,主要从事电力系统自动化微机保护方向的研究与教学工作;

张志梅(1980-),女,硕士,主要从事电力系统继电保护和电网调度工作。

罗滇生(1971-),男,博士,副教授,主要研究领域为电力市场理论研究及应用、电力系统在线监测;E-mail: hhylds@sohu.com

肖伟(1983-),男,硕士研究生,主要研究领域为电力市场理论研究及应用;

何洪英(1976-),女,博士,主要从事智能信号处理技术在电力系统中的应用等方面的研究。

收稿日期:2007-03-03; 修回日期:2007-05-09

作者简介: