

基于粒子群优化算法的神经网络在配电网线损计算中的应用

盛四清, 王献志

(华北电力大学电气工程学院, 河北 保定 071003)

摘要: 提出了一种将粒子群优化算法 (PSO) 训练神经网络用于配电网线损计算的方法。该方法使用由 PSO 训练的 BP 模型来拟合影响线损的特征参数与线损之间的复杂关系。实例计算表明, 与 BP 算法及 BP 与 GA 结合算法比较, 该方法在提高误差精度的同时可以加快训练收敛的速度。

关键词: 配电网; 线损计算; 粒子群优化算法; 神经网络; BP 模型

中图分类号: TM744 **文献标识码:** A **文章编号:** 1003-4897(2006)10-0073-04

0 引言

电力网电能损失率 (线损率) 是电力企业的一项重要重要的综合性技术经济指标, 准确简便的线损计算有利于拟定出合理的降损措施并考察措施的实际效果, 也便于制定适当的线损考核指标和规划, 从而对线损管理工作起指导和促进作用。

配电网线损的理论计算目前有许多各种各样的方法, 如: 牛顿法、P-Q 分解法等潮流计算的方法, 等值电阻法、形状系数法等简化方法, 线性回归分析法^[1]等等。文献 [1] 以有代表性的配电同线损与特征参数数据为基础, 得到回归方程, 而后用回归方程快速计算线损。但是不同的配电网需采用不同形式的回归方法。近年来随着神经网络 (ANN) 的不断发展, 提出了基于神经网络模型计算配电网线损的方法。文献 [2] 先用分群算法将样本数据分类, 再用 BP 型神经网络映射 (拟和) 各个群的样本数据, 然后计算配电网线损; 文献 [3] 采用函数型神经网络, 将输入特征参数映射到高维空间, 用无隐层的单层网络精确地拟和特征参数与线损之间的关系, 来计算配电网线损; 文献 [4] 先利用精确线损计算模型获得神经网络所需的样本, 再采用函数型神经网络计算配电网线损, 此方法更为实用。但是基于梯度下降的 BP 算法依赖于初始权值的选择, 收敛速度缓慢且容易陷入局部最优。为了解决这个矛盾, 有人引入遗传算法与 BP 算法相结合来计算配电网线损。文献 [5] 利用遗传算法来优化神经网络的权值, 再用训练好的 BP 型神经网络拟和特征参数与线损之间的关系, 来计算配电网线损; 文献 [6] 首先通过 GA 来确定 ANN 的三个参数 (隐含层中神经元个数、学习速率和动量因子)。然后应用 BP 型神经网络来拟合影响线损的特征参数与线损之间的

复杂关系, 在此基础上计算配电网线损。通过实验证明, 与 BP 算法比较, 遗传算法训练的神经网络在提高误差精度的同时可以加快训练的收敛速度。但是, 遗传算法复杂的遗传操作如选择、复制、交叉、变异使神经网络的训练时间随问题的规模及复杂程度呈指数级增长。而且, 由于缺乏有效的局部区域搜索机制, 算法在接近最优解时收敛缓慢甚至出现收敛停滞现象^[7]。

粒子群优化算法 (PSO) 是基于群体智能理论的优化算法, 通过种群中粒子间的合作与竞争产生的群体智能指导优化搜索。与进化算法比较, PSO 保留了基于种群的全局搜索策略, 其采用的速度一位移模型操作简单, 避免了复杂的遗传操作。本文提出了基于粒子群优化的神经网络训练算法。用粒子群优化算法优化神经网络的连接权值和阈值, 实验结果证明了该算法的准确性和高效性。

1 粒子群优化算法

粒子群优化算法的提出受鸟群觅食行为的启发, 并用于解决优化问题。算法采用速度一位移搜索模型。每个粒子代表解空间的一个候选解, 解的优劣程度由适应函数决定。速度 $v_i = (v_{i1}, v_{i2}, \dots, v_{im})$ 决定粒子在搜索空间单位迭代次数的位移, 适应函数根据优化目标定义。PSO 随机初始化一群粒子, 其中第 i 个粒子在 n 维解空间的位置表示为 $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$ 。每一次迭代, 粒子通过动态跟踪两个极值来更新其速度和位置。第一个是粒子从初始到当前迭代次数搜索产生的最优解: 个体极值 $p_i = (p_{i1}, p_{i2}, \dots, p_{in})$ 。第二个是粒子种群目前的最优解: 全局极值 $g_i = (g_1, g_2, \dots, g_n)$ 。粒子根据以下公式来更新其速度和位置:

$$v_{id}(t+1) = W * v_i(t) + c_1 * rand() * (p_{id}(t) -$$

$$x_{id}(t) + c_2 * rand() * (g_d(t) - x_{id}(t)) \quad (1)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (2)$$

其中 $d=1, 2, 3, \dots, n$, n 为粒子搜索空间的维数; $i=1, 2, 3, \dots, s$, s 为种群规模; w 为惯性权重; $rand()$ 是均匀分布在 $(0, 1)$ 区间的随机数; c_1, c_2 为加速因子, 一般取 $c_1 = c_2 = 2^{1.8}$ 。

粒子在解空间内不断跟踪个体极值与全局极值进行搜索, 直到达到规定的迭代次数或满足规定的误差标准为止。粒子在每一维飞行的速度不能超过算法设定的最大速度 v_{max} , 即当式 (1) 的 $|v_{id}| > v_{max}$ 时, 取 $|v_{id}| = v_{max}$ 。设置较大 v_{max} 的可以保证粒子种群的全局搜索能力, v_{max} 较小则粒子种群的局部搜索能力加强。 v_{max} 通常设定为每维动态变化范围的 10% ~ 20%。

确定权重的一般做法将 w 初始为 0.9 并使其随迭代次数的增加线性递减至 0.4, 但是 PSO 实际搜索过程是非线性且高度复杂的, 使用惯性权重线性搜索策略往往不能反映实际优化搜索。鉴于此本文使用了一种随机惯性权 (RW) 策略^[9]。这种随机惯性权策略意在改变线性搜索策略的单一的调节模式, 使之较好地适应复杂的实际环境。为此, 先定义最优适应值变化率 k , 如式 (3) 所示。

$$k = \frac{f(t) - f(t-10)}{f(t)} \quad (3)$$

其中: $f(t)$ 为种群在第 t 代时的最优适应值; $f(t-10)$ 为种群在第 $(t-10)$ 代时的最优适应值。

由式 (3) 可见, k 表示在进化 10 代内最优适应值的相对变化率。惯性权重 w 将按式 (4) 取随机值, 且其数学期望值将随 k 而变。

$$\begin{cases} w = w_1 + r/2 & 0 < k < 0.05 \\ w = w_2 + r/2 & 0 < k < 0.05 \end{cases} \quad (4)$$

其中: r 为均匀分布于 $[0, 1]$ 之间的随机数, 当 $0 < k < 0.05$ 时, 期望值 $E(w) = w_1 + 0.25$; 当 $k < 0.05$ 时, $E(w) = w_2 + 0.25$, 且令 $w_1 > w_2$ 。 w_1, w_2 分别是最优适应值变化率 k 取不同范围时所对应的最小权重值。

该选择策略有两个特点: 其一, 随机地选取 w 值, 由式 (1) 可见, 这将使粒子历史速度对当前速度的影响为随机的; 其二, w 的数学期望值将随最优适应值的变化率自适应地调整, 从而可以更灵活地调节全局搜索与局部搜索能力。另外, 惯性权取值的随机性, 在一定程度上与遗传算法的变异算子较为相似, 这将有助于保持种群的多样性。

2 BP神经网络优化

2.1 BP神经网络学习过程

BP模型是一种多层前馈网络, 如图 1 所示。除输入节点层和输出节点层外, 还有一个或多个隐藏层。神经元节点函数常取 S 型函数:

$$F(x) = 1 / [1 + \exp(-x)] \quad (5)$$

式中: x 为节点输入向量, θ 为阈值。

BP算法分为两个阶段: 第一阶段 (正向过程) 输入信息从输入层经隐含层逐层计算各单元的输出值; 第二阶段 (反向传播过程) 输出误差逐层向前算出隐含层各单元的误差, 并用此误差修正前层权值和阈值。

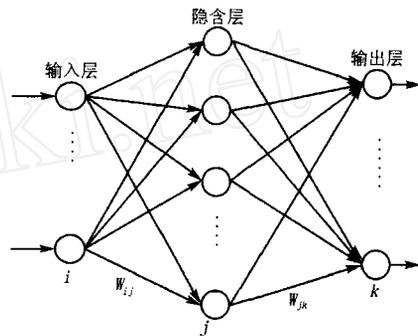


图 1 BP模型图

Fig 1 Model of BP network

BP网络训练时, 对确定的输入样本向量而言其实际输出可以认为是以权重和阈值为自变量的函数。设定该函数为 BP 网络的“黑箱函数” F , 则 $a = F(w, b)$ 。 a 为实际输出向量, b 为阈值所构成的向量, w 为权重矩阵集, 第 i 个输入样本有相应的实际输出 a_i , 其第 j 个分量为 a_{ij} ; 对每个确定的输入样本向量有相应的期望输出 t_i , 其第 j 个分量 t_{ij} 为从而最小均方差 MSE 为:

$$MSE = \frac{1}{SN} \sum_{i=1}^{SN} \sum_{j=1}^N (a_{ij} - t_{ij})^2 \quad (6)$$

其中: N 为输出向量的维度, SN 为样本总数, MSE 仍然是权重和阈值为自变量的函数。

2.2 PSO训练 BP型神经网络

设计 BP 神经网络基于 PSO 的学习算法, 首先必须建立合理的粒子模型并确定适应函数和搜索空间。从本文的 2.1 分析可知, 神经网络学习过程主要是权重和阈值的更新过程, PSO 搜索过程主要是其不同维度上的速度和位置的改变。因而神经网络学习算法中的权重和阈值应与粒子的位置相对应。先依次按行扫描神经网络的权重矩阵, 后扫描所有偏置量。从而得到 N 维向量, 每个向量 x 对应一个 PSO 中的一个粒子, PSO 中的适应函数可定义为

MSE,这样,神经网络的学习过程实质是粒子在 N 维空间中搜索最佳位置。图 2 为粒子群优化算法优化神经网络流程图。

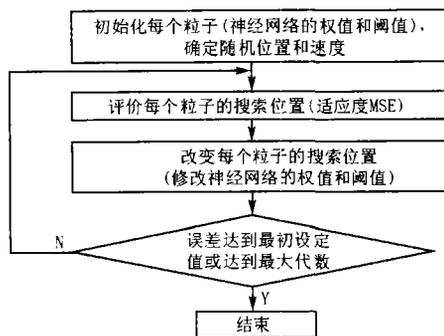


图 2 粒子群训练神经网络流程图

Fig 2 Diagram of PSO training ANN

设粒子群个数为 30,随机产生 $[-1, 1]$ 区间的初始权值和阈值做为粒子的初始位置,取样本中输出值和神经网络训练的实际输出值的误差平方和 MSE 作为粒子的适应度来评价每个粒子的搜索位置,用式 (1)、式 (2) 改变每个粒子的搜索位置,当误差达到最初设定值或达到最大的循环次数时,循环停止。

2.3 对神经网络训练样本的处理

由式 (5) 可看出, BP 模型的神经元节点 (包括输出节点) 的输出值的取值范围为 $[0, 1]$, 很难达到 0 和 1, 而且当神经元节点的输入的绝对值太大时会导致神经元节点饱和。因而当用 BP 模型映射函数关系 (用其自变量作输入, 因变量作输出) 时, 自变量的绝对值不可太大, 因变量的值应在 $[0, 1]$ 内。否则应先对原始数据进行处理, 满足这些要求后再用 BP 模型进行训练。

考虑到以下原因, 我们要对样本进行分群处理:

原因 1 样本较多时, 用 ANN 模型模拟自变量和因变量的关系时要求的隐节点较多, 训练时间较长。而将样本分成几个群, 训练相应的 ANN 模型时, 由于各群的样本较少, 信息量小, 隐节点可选得少一些, 从而节约总的训练时间。

原因 2 当因变量的数值比较分散时, ANN 模型训练不到高精度。将因变量数据相差不大的样本

分为一群, 可提高 ANN 模型的训练精度。

2.4 神经网络结构的确定

本文采用三层 BP 模型神经网络, 有 4 个输入端和 1 个输出端, 分别与 4 个特征参数和配电线路线损相对应。根据经验规则, 网络中权重总数应等于或小于样本容量, 所得数学模型才比较稳定。由此, 在文中隐层结点为 5 比较合适, 网络结构为 4 - 5 - 1, 共 25 个权值和 6 个阈值。即粒子群算法中每个粒子的搜索空间为 31 维。

3 实例计算及结果分析

一定时段内配电线路线损与很多特征参数有关, 如配电线路的有功供电量、无功供电量、配电变压器的容量、配电线路长度、配电变压器的台数、配电线路总截段数等。本文只研究了前四个特征参数与线损的关系, 但考虑更多特征参数时本文的方法同样适用。本文对某地区配电线路中精确计算的 68 条线路进行训练, 并寻找其统计规律以用于其余配电线路的计算。算例具体数据见文献 [10] 中的表 6 - 5。

首先给出算法的参数设置。基于粒子群优化的训练算法种群规模 $s=30$, 惯性权重 w 按式 (4) 取随机值, 式 (4) 中 $w_1=0.5$, $w_2=0.4$, 加速因子 $c_1=c_2=2$, 权值为 $[-1, 1]$ 区间变量, 由经验公式确定神经网络隐含层节点数为 5, 算法停止条件为最大迭代次数 (4 000) 或误差精度为 0.000 1。

表 1 列出了分别用 PSO 优化后的 ANN 和 GA 优化后的 ANN 参数以及用 BP 模型训练后的计算结果的误差。

表 1 不同算法的计算结果误差比较

Tab 1 Error comparison of result among different algorithms

误差百分比范围		1%以下	1% ~ 5%	5% ~ 10%	10%以上
路 条 数	BP算法 (文 [2])	51	14	0	3
	GA与BP结合算法 (文 [5])	52	12	3	1
	PSO与BP结合算法	60	5	2	1

表 2 列出了分别用 PSO 优化后的 ANN 和 GA 优化后的 ANN 参数以及用 BP 模型训练后的分群误差平方和。

表 2 不同算法的误差平方和的比较

Tab 2 ES comparison among different algorithms

误差平方和	第一群	第二群	第三群	第四群	第五群	合计
BP算法 (文 [2])	0.001 17	0.014 12	0.049 33	0.039 33	0.088 40	0.192 35
GA与BP结合算法 (文 [6])	0.000 96	0.004 60	0.022 70	0.001 10	0.030 60	0.059 96
PSO与BP结合算法	0.000 18	0.001 44	0.000 86	0.001 40	0.020 18	0.024 06

由表 2 可以看到。本文结果较文献 [6] 结果精度提高 0.059 96/0.024 06 2.5 倍, 较文献 [2] 结果精度提高 0.192 35/0.024 06 8 倍, 较文献 [10] 中提到的回归分析法结果精度提高了 1.028 75/0.024 06 42.8 倍。

4 结论

粒子群优化算法的速度——位移搜索模型操作简单, 计算复杂度低, 并通过惯性权重协调全局搜索与局部搜索, 既能以较大的概率保证最优解, 克服 BP 算法局部最优的缺陷, 又可以提高局部区域的收敛速度, 避免 GA 在局部区域搜索过程中的收敛停滞现象。计算结果表明: PSO 与 BP 结合的算法对于实际的配电网线损计算研究是可行的, 其训练神经网络的精度快于 BP 算法和 BP 与 GA 结合算法, 且该算法更易编程实现。

参考文献:

- [1] 郭晓君. 回归分析法在线损计算中的应用 [J]. 继电器, 2002, 30(8): 50-51, 54.
GUO Xiao-jun The Application of Regressive in Line-loss Calculation [J]. Relay, 2002, 30(8): 50-51, 54.
- [2] 文福栓, 韩桢祥. 基于分群算法和人工神经网络的配电网线损计算 [J]. 中国电机工程学报, 1993, 13(8): 41-50.
WEN Fu-shuan, HAN Zhen-xiang The Calculation of Energy Losses in Distribution Systems Based upon a Clustering Algorithm and an Artificial Network Model [J]. Proceedings of the CSEE, 1993, 13(8): 41-50.
- [3] 陈天恩, 于鹏. 用函数型神经网络计算配电网的线损 [J]. 甘肃电力, 1996, 4(1): 40-41.
CHEN Tian-en, YU Peng The Calculation of Energy Losses on Distribution Systems Based upon a Functional Neural Network Model [J]. Gansu Power System, 1996, 4(1): 40-41.
- [4] Hsu C T, Tzang Y M, Chen C Z, et al Distribution Feeder Loss Analysis by Using an Artificial Neural Network [J]. Electric Power Systems Research, 1995, 34(2): 85-90.
- [5] 辛开远, 杨玉华, 陈富. 计算配电网线损的 GA 与 BP 结合的新方法 [J]. 中国电机工程学报, 2002, 22(2): 79-82.
XIN Kai-yuan, YANG Yu-hua, CHEN Fu An Advanced Algorithm Based on Combination of GA with BP to Energy Loss of Distribution System [J]. Proceedings of the CSEE, 2002, 22(2): 79-82.
- [6] 袁慧梅, 郭喜庆. 用遗传算法辅助设计的人工神经网络计算配电网线损 [J]. 电网技术, 1998, 22(12): 17-19.
YUAN Huimei, GUO Xi-qing Calculation of Line Losses in Distribution Systems Using Algorithm Neural Network Aided by GA [J]. Power System Technology, 1998, 22(12): 17-19.
- [7] Yang J M, Kao C Y. A Robust Evolutionary Algorithm for Training Neural Networks [J]. Neural Computing and Application, 2001, 10(3): 214-230.
- [8] Shi Y H, Eberhart R C. Parameter Selection in Particle Swarm Optimization [A]. Annual 1998.
- [9] 张丽平, 俞欢军, 陈德钊, 等. 粒子群优化算法的分析与改进 [J]. 信息与控制, 2004, 33(5): 513-517.
ZHANG Li-ping, YU Huan-jun, CHEN De-zhao, et al Analysis and Improvement of Particle Swarm Optimization Algorithm [J]. Information and Control, 2004, 33(5): 513-517.
- [10] 杨秀台. 电力网线损的理论计算和分析 [M]. 北京: 水利电力出版社, 1985.
YANG Xiu-tai The Theoretical Calculation and Analysis of Energy Losses in Distribution Systems [M]. Beijing: China Water Power Press, 1985.

收稿日期: 2005-10-31; 修回日期: 2005-11-28

作者简介:

盛四清 (1965 -), 男, 副教授, 博士, 主要从事电力系统故障诊断和处理、专家系统和人工神经网络在电力系统中的应用等方面的研究工作;

王献志 (1980 -), 男, 硕士研究生, 研究方向: 智能技术在电力系统中的应用。研究课题: 基于数据仓库的线损统计与分析。E-mail: wangxzh472@163.com

Loss calculation of distribution system based on particle swarm optimization algorithm in ANN

SHENG Si-qing, WANG Xian-zhi

(School of Electrical Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: In this paper, a new method is presented for calculating the energy losses in distribution systems based on particle swarm optimization (PSO) algorithm in multi-layer artificial neural network. The method uses BP model trained by PSO to map the complicated relationship between the energy losses and the feature parameters which have influenced the line loss. Simulation results of practical example show that the method can improve the calculation accuracy and the speed of the convergence process compared with BP and BP trained by GA.

Key words: distribution system; line loss calculation; particle swarm optimization (PSO); neural network; BP model