

基于 BP 的配电系统网络重构算法的研究

陈中孝, 张晓斌, 李 雷

(西安工业大学 电子信息工程学院, 陕西 西安 710032)

摘 要: 为了有效地缩短配电网络重构的时间, 首先对 BP 神经网络从学习速度和局部收敛方面改进, 以提高 BP 算法的速度, 然后根据配电网的数学模型, 在 BP 神经网络的误差函数和约束条件的分析中运用图论知识, 从而准确并快速地实现配电网络重构。

关键词: 配电网; 网络重构; 图论; BP 神经网络

中图分类号: TP183

文献标识码: A

文章编号: 1000-7180(2012)01-0143-05

Study of Reconfiguration Alogrithm in Distribution System Based on BP Network

CHEN Zhong-xiao, ZHANG Xiao-bin, LI Lei

(School of Electronics and Information Engineering, Xi'an Technological University, Xi'an 710032, China)

Abstract: In order to shorten the time of distribution network reconfiguration effectively, firstly the improvements from learning speed and local convergence of BP neural network enhance the speed of BP algorithm, and according to the mathematical model of distribution network, in the BP neural network error function and constraints analysis using graph theory, which accurately and quickly to achieve distribution network reconfiguration.

Key words: distribution network; network reconfiguration; graph theory; BP neural network

1 引言

配电网络重构在提高电网运行效率、供电可靠性和供电质量上具有重要的作用。随着配电网节点数的增多, 与用户生活生产息息相关, 所以配电网络变的庞大并且复杂, 数学模型非常复杂, 导致网络重构用时长, 并且网损不是网络重构单一的目标函数, 网络重构是实现多个目标最优的问题。如何实现配电网快速而准确的重构, 一直是国内外学者研究的问题。随着人工智能理论和计算机技术的发展, 神经网络因其具有实时性和鲁棒性等优点, 使得它在配电网络重构算法中起到了重要的作用^[1-2]。

2 BP 神经网络及其改进

BP(Back Propagation)神经网络是一种前馈神经网络, 其学习的类型是示例学习, 是非逻辑性归

纳。它是由多个非线性变换单元组成的前馈网络, 是实现映射变换较常使用的一种网络。学习是神经网络最重要、最令人注目的特点。BP 算法的基本原理是: 已知输入向量和期望的输出, 输入向量经过连接权、阈值和变换函数计算后, 获得一个输出, 然后让它与期望的输出比较, 如果有偏差, 则通过输出端反向传播偏差, 进行连接权和阈值的调整, 使实际输出与期望输出相同。

BP 神经网络实质是由许多具有简单处理能力的神经元构成的, 是对任意非线性映射关系的一种逼近, 由于采用的是全局逼近的方法, 因而 BP 神经网络具有较好的泛化能力。对于给定的 BP 神经网络的样本集, 其目标函数是全部连接权系数的函数, 所以要寻优的连接权系数比较多, 这就给寻优带来许多问题。其中最大的一个问题就是收敛速度慢, 因为需要寻优的参数非常多; BP 神经网络存

在陷入局部极小值的可能;还有网络停止收敛的问题^[3].

BP 神经网络可以进行如下方面改进,以克服自身的不足.

(1) 提高学习速度

① 学习样本的批处理

在以往的 BP 算法学习中,每提供一个学习样本给神经网络,都需计算误差函数并对连接权值进行连续调整. BP 算法训练神经网络有顺序和批处理两种方法,学习样本的批处理是神经网络接收到所有的学习样本后,根据输出误差的平均值,统一调整一次网络.这样,不仅神经网络学习的时间减少了,还避免了因每个学习样本变化而产生的连接权值过调,从而神经网络的学习速度提高了.当有足够多的学习样本时,批处理方法还体现了学习样本的统计规律性.

② 加入动量项

为了加速算法收敛,可以加入动量项,即

$$w(k+1) = w(k) + \alpha[(1-\eta)D(k) + \eta D(k-1)]$$

式中 $w(k)$ 不但可以是单个的连接权系数,也可以是连接权向量(其中元素为连接权系数). $D(k) = -\partial E / \partial w(k)$ 为 k 时刻的负梯度, E 为拟合误差的代价函数. $D(k-1)$ 是 $k-1$ 时刻的负梯度. α 为学习率, $\alpha > 0$. η 为动量项因子, $0 \leq \eta < 1$. 加入动量项减小了学习过程的振荡趋势,改善了收敛性,这种改进算法的应用目前比较广泛.

③ 变步长法

使用固定长梯度下降法求解连接权系数容易出现收敛震荡甚至发散、收敛速度慢两个问题.这里可以考虑采用变步长法改变这种现象.

变步长法首先设一初始学习速率 α , 若连续两次迭代的梯度方向相反,则表明下降太快,学习速率乘以 β ($\beta < 1$);若连续两次迭代的梯度方向相同,则表明下降太慢,学习速率乘以 λ ($\lambda > 1$),即

$$\begin{cases} \alpha = \beta \alpha, & \beta < 1, \text{sgn}[D(k)D(k-1)] = 1 \\ \alpha = \lambda \alpha, & \lambda > 1, \text{sgn}[D(k)D(k-1)] = -1 \end{cases}$$

这种计算量小的处理方法特别适用于批处理 BP 算法.

(2) 防止收敛局部最小

BP 网络隐含节点的数目不够和设置了不合适的初始权值都可以引起 BP 算法收敛到局部最小. 可以从如下方法防止收敛局部最小:

① 根据确定 BP 网络隐含层节点数的经验公式

和实际验证,进而确定具体实例的最优隐含层节点数.

② 设置合适的初始权值. BP 算法存在过早饱和(加权值在饱和区)的问题,如果一个单元有许多输入时,其初始权值设置应该比较小,这时加权值不会离零太远.因而,在设置具有 n 个输入的单元的初始权值时,其实际范围应该保持在 $[-2/n, 2/n]$ 区间内.合适初始权值的设置,就有效地防止了 BP 网络收敛到局部最小.

③ 改进 BP 算法的误差函数,使它适合具体的配电网重构模型.

3 BP 神经网络基于图论数学模型的改进

现实中的配电网结构已经确定,并且配电网重构时需要达到网损最小等要求^[4],还要求配电网是不具有环网和孤立顶点的树形网络.这样,我们可以在 BP 神经网络的约束条件和误差函数中运用图论知识,将能很好地防止 BP 神经网络收敛到局部最小并达到配电网重构网损最小等要求^[5].

3.1 误差函数对权值修正的改进

图 1 为隐节点和输出节点都使用 Sigmoid 函数 ($y = f(s) = \frac{1}{1+e^{-s}}$) 的三层 BP 网络(网络中没有各神经元的阈值).




图 1 三层 BP 网络

图中对 BP 网络各节点的计算,有

$$s_j = \sum_{i=1}^n w_{ij} x_i - \theta_j$$

$$y_j = f(s_j) = \frac{1}{1+e^{-s_j}}$$

BP 算法的学习规则是运用最小均方误差准则.

当给网络输入一个样本(设为第 p 个样本)时,均方误差应该为输入产生的各个输出单元的误差平方之和,即

$$E_s^{(p)} = \frac{1}{2} \sum_{j=1}^m (d_j^{(p)} - y_j^{(p)})^2$$

根据图论知识,配电网重构后应该是树形网络.针对配电网的具体结构,运用树形结构模型的

理论加一个全局约束条件给输出单元的误差,使其输出闭合开关数(树枝数目)必须符合拓扑要求.这样可以有效地防止 BP 神经网络收敛到局部最小点,所以得到新的误差函数:

$$E^{(p)} = \frac{1}{2} \sum_{j=1}^m (d_j^{(p)} - y_j^{(p)})^2 + \frac{A}{2} \left(\sum_{j=1}^m y_j^{(p)} - D \right)^2$$

式中, A 为常数; D 为配电网中合闸开关的具体数,即树枝数,它是配电网的开关数减去配电网中的连枝数;上式前一项是均方误差,后一项是全局约束,它对配电网中的合闸数目和配电网中应该断开的连枝数形成具体的约束.

所有样本输入一次后,总误差是:

$$E_A = \sum_{p=1}^P E^{(p)} = \frac{1}{2} \sum_{p=1}^P \left[\sum_{j=1}^m (d_j^{(p)} - y_j^{(p)})^2 + A \left(\sum_{j=1}^m y_j^{(p)} - D \right)^2 \right]$$

根据梯度下降法,配电网中的连接权值 w_{ij} 经过批处理后,其权值修正量应该是:

$$\Delta w_{ij} = -\alpha \frac{\partial E_A}{\partial w_{ij}}$$

式中 α 为学习速率.

(1) 对输出层

$$w_{ij}(n+1) = w_{ij}(n) - \alpha \frac{\partial E_A}{\partial w_{ij}}$$

式中, n 为迭代次数. $\frac{\partial E_A}{\partial w_{ij}}$ 的求解过程为:

$$\begin{aligned} \frac{\partial E_A}{\partial w_{ij}} &= \sum_{p=1}^P \frac{\partial E^{(p)}}{\partial w_{ij}} \\ &= \sum_{p=1}^P \frac{\partial E^{(p)}}{\partial y_j^{(p)}} \frac{\partial y_j^{(p)}}{\partial s_j^{(p)}} \frac{\partial s_j^{(p)}}{\partial w_{ij}} \\ &= - \sum_{p=1}^P \left[(d_j^{(p)} - y_j^{(p)}) - A \left(\sum_{j=1}^m y_j^{(p)} - D \right) \right] f \cdot (s_j^{(p)}) x_i^{(p)} \\ &= - \sum_{p=1}^P \left[(d_j^{(p)} - y_j^{(p)}) - A \left(\sum_{j=1}^m y_j^{(p)} - D \right) \right] \mu y_j^{(p)} (1 - y_j^{(p)}) x_i^{(p)} \\ &= - \sum_{p=1}^P \delta_{ij}^{(p)} x_i^{(p)} \end{aligned}$$

式中此时的反传误差为

$$\delta_{ij}^{(p)} = \mu \left[(d_j^{(p)} - y_j^{(p)}) - A \left(\sum_{j=1}^m y_j^{(p)} - D \right) \right] y_j^{(p)} (1 - y_j^{(p)})$$

所以有

$$w_{ij}(n+1) = w_{ij}(n) + \alpha \sum_{p=1}^P \delta_{ij}^{(p)} x_i^{(p)}$$

(2) 对中间隐层

$$w_{hi}(n+1) = w_{hi}(n) - \alpha \frac{\partial E_A}{\partial w_{hi}}$$

式中

$$\begin{aligned} \frac{\partial E_A}{\partial w_{hi}} &= \sum_{p=1}^P \frac{\partial E^{(p)}}{\partial w_{hi}} \\ &= \sum_{p=1}^P \sum_{j=1}^m \frac{\partial E^{(p)}}{\partial y_j^{(p)}} \frac{\partial y_j^{(p)}}{\partial s_j^{(p)}} \frac{\partial s_j^{(p)}}{\partial x_i^{(p)}} \frac{\partial x_i^{(p)}}{\partial s_i^{(p)}} \frac{\partial s_i^{(p)}}{\partial w_{hi}} \\ &= - \sum_{p=1}^P \sum_{j=1}^m \left[(d_j^{(p)} - y_j^{(p)}) - A \left(\sum_{j=1}^m y_j^{(p)} - D \right) \right] f \\ &\quad \cdot (s_j^{(p)}) w_{ij} \mu x_i^{(p)} (1 - x_i^{(p)}) x_h^{(p)} \\ &= - \sum_{p=1}^P \sum_{j=1}^m \delta_{ij}^{(p)} w_{ij} \mu x_i^{(p)} (1 - x_i^{(p)}) x_h^{(p)} \\ &= - \sum_{p=1}^P \delta_{hi}^{(p)} x_h^{(p)} \end{aligned}$$

式中此时的反传误差为

$$\delta_{hi}^{(p)} = \sum_{j=1}^m \delta_{ij}^{(p)} w_{ij} \mu x_i^{(p)} (1 - x_i^{(p)})$$

所以有

$$w_{hi}(n+1) = w_{hi}(n) + \alpha \sum_{p=1}^P \delta_{hi}^{(p)} x_h^{(p)}$$

可以看出 BP 网络学习分为两个阶段:各隐层和输出层的输出从前向后的计算;权值通过误差从后向前反向传播进行修正.

3.2 图形拓扑结构对配电网的具体约束

通常在 BP 神经网络的训练过程中,如果网络满足 $E_A < \epsilon$ 或者网络达到最大学习次数时,其停止学习.但在进行配电网的 BP 训练时,根据重构后的配电网要符合网络没有环网和孤立顶点的树形结构的拓扑要求,用其判断和约束 BP 神经网络的输出结果,从而使网络工作在正常状态.

(1) 判断树形网络

根据树形结构约束的数学模型,用树形网络对具体配电网的输出进行约束,可以构造

$$E_F = \frac{A}{2} \left(\sum_{j=1}^m y_j - D \right)^2 + \frac{B}{2} \sum_{x=0}^{K-1} \sum_{\substack{y \neq x \\ y=0}}^{K-1} \sum_{j=1}^m y_{jx} y_{jy}$$

如果 $E_F < \epsilon$,则可以认为配电网输出满足树形网络的约束条件.式中, A 和 B 为常数;式中前一项是总体约束,表明输出值中处于合闸状态的顶点有 D 个;后一项是行约束,表明每行最多只能有一

个1,顶点可以划分为 $K-1$ 个树集合和 1 个连枝集合.

(2) 判断环网

通过图论的知识可以写出输出层各顶点(输出层神经元)的弧结构矩阵 C . 在网形结构模型中搜索 $t_k=1$ 的输出层神经元,即搜索到的这个顶点处于合闸状态. 如果该顶点的入度 $id_G = \sum_{i=1}^N v_{ik} > 1$, 则表明该网形中存在环网现象,与配电网的拓扑要求不符,必须对配电网再次重构输出.

由于具体配电网的形状结构是已知的,可以直接用树枝加连枝构成该配电网的所有环网,并且列举出来. 在配电网中,如果第 i 个环网差函数的误差平方用 $E_i(\text{ring})$ 表示;第 i 个环网的神经元的输出用 $y_j(i)$ 表示;第 i 个环网用 $loop_i$ 表示;第 i 个环路所包含的所有支路数用 Bra_i 表示. 就可得出下式:

$$E_i(\text{ring}) = \left(\sum_{loop_i} y_j(i) - Bra_i \right)^2$$

如果 $E_i(\text{ring}) < \epsilon$, 则表明配电网中存在环网现象,此时必须再次重构该配电网.

(3) 判断孤立顶点

通过图论知识可以对输出层各神经元写出弧结构矩阵 C , 根据矩阵判断网形中各顶点的度,如果网形中存在度为 $d_G(v_k) = ad_G(v_k) + id_G(v_k) = \sum_{i=1}^N v_{ki} + \sum_{i=1}^N v_{ik} < \epsilon$ 的顶点 v_k , 则认为顶点 v_k 的度为 0, 可以判断 v_k 是孤立顶点. 此时必须再次重构该配电网.

因为配电网是一个整体,所以网络重构的各个判断条件之间是相互联系的,大多数配电网经过上面的一两个约束条件后,实际网形的配电网也能满足其他约束条件. 一个条件不等式就可以满足其中几个约束条件,像 $E = \sum_i \left(\sum_{loop_i} y_j(i) - Bra_i + 1 \right)^2$ 就可以满足上述的环网判断和孤立顶点判断二个条件. 上式要求每个环路通过断开一个连枝形成树,然后求配电网所有 i 个环网的平方和. 如果在每个环网只断开一个连枝的情况下并且 $E < \epsilon$, 则认为该配电网就没有环网和孤立顶点.

根据具体配电网的结构情况,如果把式 $E = \sum_i \left(\sum_{loop_i} y_j(i) - Bra_i + 1 \right)^2$ 作为基础,并加上式

$E_{all} = \frac{A}{2} \left(\sum_{j=1}^m y_j - D \right)^2$ 作为全局约束条件,在 BP 标准样本的训练下,具体配电网的输出一定能满足树形网络.

4 改进 BP 神经网络的应用

BP 神经网络经过改进后,BP 网络本身训练速度慢和存在收敛到局部最小的缺点得到了改善. 将改进的 BP 神经网络应用到配电网重构中,发现其具有直观、简单、理论成熟和易编程等优点;最重要的是 BP 神经网络的自学习能力,它把配电网实际运行的负荷模式 and 对应开关状态作为样本进行训练,经过配电网长期运行后,BP 网络的输出越来越准确表达配电网的状态^[6-7]. 下述网络结构是实际配电网采用的结构:

(1) 总体 BP 网络采用 3 层网络结构.

(2) 根据具体配电网的情况,将输入母线节点的负荷模式设定为输入层神经元数目和输出开关支路数设定为输出层神经元的数目.

(3) 设定隐含层神经元个数. 主要根据经验公式,还要经过实际训练结果的验证,进而确定实例最佳的具体隐含层神经元个数.

文中可以按一下几个步骤对实际案例算法进行程序设计:

(1) 网络的所有样本进行归一化处理,并对其采用批处理样本学习方法.

(2) 根据输入神经元的数目 n , 设定初始权值在 $[-2/n, 2/n]$ 区间范围内.

(3) 将加入动量项算法和变步长算法相结合运用于网络,进而加快算法收敛.

(4) 用改进后的误差函数推导权值修正量.

(5) 误差平方和也就是推导权值修正量的误差函数. 经过全局树枝数目约束条件改进的误差函数,不但使最后输出的误差满足要求,而且使其输出也满足配电网拓扑树枝数目的要求,配电网中那些不符合实际情况的 BP 神经网络局部最小点输出也被极大的限制.

(6) 神经网络迭代结束条件,不但要求误差平方和小于目标值,而且对输出还要进行环网和孤立顶点判断,如果不满足约束条件,必须重新生成初值并训练. 全部条件满足,迭代才能结束.

(7) 根据实际情况,输出层神经元的输出值经过 0-1 处理后,我们就能方便直观地观察开关分合闸的状态.

程序设计流程如图2所示。




图2 配电网络重构BP训练流程图

5 结束语

将BP神经网络应用到配电网络重构算法的研究中,配电网络根据图论知识的具体拓扑结构要求,有效地改进与约束了配电网络,BP神经网络经过改

进后,其网络学习速度慢和收敛到局部最小等缺点得到了极大的改善。BP神经网络经过训练后,能针对具体配电网的负荷模式,输出最优的配电网开关状态,实现配电网最优重构,表现出BP神经网络输出速度快,能全局逼近的优点。进而实现了配电网故障定位,网络重构等,提高了供电的可靠性。

参考文献:

- [1] 刘健. 配电网理论及应用[M]. 北京:中国水利水电出版社,2007.
- [2] 孙红辉,王红霞,田涛. 一种基于不变距和BP网络的目标识别方法[J]. 微电子学与计算机,2011,28(3): 63-65.
- [3] 孙增圻. 智能控制理论与技术[M]. 北京:清华大学出版社,2003.
- [4] Fan Ji-Yuan, Zhang Lan, McDonald JD. Distribution network reconfiguration: single loop optimization[J]. IEEE Trans on Power Systems, 1996, 11(3): 1643-1647.
- [5] 徐俊明. 图论及其应用[M]. 北京:中国科学技术大学出版社,2010.
- [6] 闫志忠. BP神经网络模型的改进及其应用研究[D]. 长春:吉林大学,2003.
- [7] 戚涌,李千目,刘凤玉. 基于BP神经网络的网络智能诊断系统[J]. 微电子学与计算机,2004,21(10):10-13.

作者简介:

陈中孝 男,(1963—),副教授.研究方向为智能信息处理与智能控制.


张晓斌 男,(1987—),硕士研究生.研究方向为检测技术与自动化装置.

李雷 男,(1985—),硕士研究生.研究方向为控制工程与控制理论.

(上接第142页)

- [4] 潘显志,李向丽,邱保志. 基于优先级的MPLS重路由转发机制[J]. 微电子学与计算机,2008(03):149-151.
- [5] Ivan Pepelnjak, Jim Guichard 著,赵斌,陈文飞,徐鸿文译. MPLS和VPN体系结构[M]. 北京:人民邮电出版社,2003.
- [6] Andersson L, Doolan P, Feldman N, A. Fredette, B. Thomas. LDP Specification. RfC 3036, [S]. 2001.
- [7] 康银婵,汤小春. SSL VPN系统中自主签发证书的设计与实现[J]. 微电子学与计算机,2009(04):121-124.

作者简介:



李海华 男,(1965—),副教授.研究方向为网络协议与信息安全.

冯卫华 男,(1980—),讲师.研究方向为计算机软件与网络.