

动态对角递归网络在变压器故障诊断中的应用

段慧达, 刘学军, 白晶

(北华大学电气信息学院, 吉林 吉林 132021)

摘要: 介绍了动态对角递归网络, 并针对 BP 算法收敛慢的缺点, 提出了递推预报误差学习算法。利用该算法对神经网络的权值和域值进行训练, 有效地提高神经网络的收敛性及增量学习能力。将动态对角递归网络应用到变压器的故障诊断中, 利用改良三比值方法来实现诊断, 建立了诊断的模型。利用部分数据进行了训练及故障诊断的仿真, 结果表明了利用该方法进行变压器故障诊断的有效性。

关键词: 动态对角递归网络; 递推预报误差; 故障诊断; 气相色谱分析法; BP 算法

Application of diagonal recurrent neural network in power transformer fault diagnosis

DUAN Hui-da, LIU Xue-jun, BAI Jing

(School of Electric and Information Engineering, Beihua University, Jilin 132021, China)

Abstract: A simple recurrent neural network named diagonal recurrent neural network is studied in this paper. To overcome the slow convergence of the BP algorithm, recursive prediction error algorithm is proposed, which can train both the weight and the bias. This algorithm can improve the astringency and increment learning ability of the neural network effectively. In addition, the recurrent neural network trained with RPE algorithm is used in fault diagnosis of power transformer based on improved three-ratio method. A model of fault diagnosis based on DRNN is established. Some data are used to simulate, the simulation diagnosis demonstrates the effectiveness of the proposed algorithm.

Key words: diagonal recurrent neural network; recursive prediction error algorithm; fault diagnosis; dissolved gas analysis; BP algorithm

中图分类号: TM711, TP183

文献标识码: A

文章编号: 1003-4897(2007)04-0011-03

0 引言

变压器是电力系统的重要设备之一, 它的故障给供电可靠性和系统的正常运行带来了严重的影响。随着系统对供电可靠性要求的提高, 以在线监测及故障诊断技术为基础的状态维修体系逐渐取代预防性维修体系已成为变压器故障诊断的一个明确的发展趋势。实测和研究表明, 采用气相色谱分析法来分析变压器的潜伏性故障是监视变压器安全运行的最有效的措施之一, 已成为国内外诊断充油电气设备故障的一种最为有效的手段。目前 DL/T2000 已推荐改良三比值法(原改良电协研法)为变压器内部故障诊断的主要方法^[1]。

BP 网络具有一定的非线性逼近能力, 能进行故障模式识别、故障严重程度评估和故障预测, 应用

很广;但对异常类故障处理能力低, 收敛性差, 不具备增量学习功能。动态对角递归网络^[2,3](Diagonal recurrent neural network)受前馈网络结构的启发, 将部分输入输出信息作为网络的输入, 这样不仅能够有效提高前馈网络的泛化能力, 提高其用于故障处理的增量学习能力, 而且可以有效地提高神经网络的收敛性。本文采用利用递推预报误差(Recursive Prediction Error)算法修正的动态对角递归网络来对变压器进行故障诊断, 取得了良好的效果。

1 动态对角递归网络及其 RPE 算法

多输入多输出 DRNN 的模型如图 1 所示。非线性状态空间表达式如下:

$$S_j(k) = \sum_{i=1}^M W_{ji}^h * X_i(k) + W_j^d O_j(k-1) + b_{j_i}(k)$$

$$O_j(k) = f(S_j(k))$$

$$y_l(k) = \sum_{j=1}^H V_{lj} * O_j(k) + b_{2l}(k) \quad (1)$$

其中: $X_l(k)$ 为网络输入, $y_l(k)$ 为网络输出, $S_j(k), O_j(k)$ 分别为隐层输入和输出, W_{ji}^h 为输入层至隐层的连接权, V_{lj} 为隐层至输出层连接权, W_j^d 为递归神经元连接权, b_{1j} 和 b_{2l} 分别为隐层和输出层阈值。 $f(\cdot)$ 为隐单元的激发函数 (如 sigmoid 函数)。

递推预报误差 (Recursive Prediction Error) 算法是一种通过极小化预报误差来获取参数估计的方法。RPE 算法定义性能指标为

$$E(\Theta) = \frac{1}{2N} \cdot \sum_{k=1}^N [y_d(k) - \hat{y}(k)]^2 = \frac{1}{2N} \cdot \sum_{k=1}^N e^T(k, \Theta) \cdot e(k, \Theta) \quad (2)$$

式中: $e(k, \Theta)$ 为预报误差矢量, Θ 为参数矢量, N 是数据长度。

RPE 算法的基本原理是沿着 $E(\Theta)$ 的 Gauss-Newton 搜索方向修正未知参数矢量, 从而使 $E(\Theta)$ 趋于最小, 参数矢量的修正算式为

$$\Theta(k) = \Theta(k-1) + \alpha(k) \cdot \mu[\Theta(k-1)] \quad (3)$$

式中: $\alpha(k)$ 为学习速率, $\mu(\Theta)$ 为 Gauss-Newton 搜索方向, 定义为

$$\mu(\Theta) = -[H(\Theta)]^{-1} \nabla E(\Theta) \quad (4)$$

式中: $\nabla E(\Theta)$ 是 $E(\Theta)$ 关于 Θ 的梯度, $H(\Theta)$ 是 $E(\Theta)$ 的 Hessian 矩阵, 即

$$\nabla E(\Theta) = -\frac{1}{N} \cdot \sum_{k=1}^N \psi(k, \Theta) \cdot e(k, \Theta) \quad (5)$$

$$H(\Theta) = \sum_{k=1}^N \psi(k, \Theta) \cdot \psi^T(k, \Theta) \quad (6)$$

式中: $\psi(k, \Theta) = [d\hat{y}(k, \Theta)/d\Theta]^T$ 是网络的一步预报值对 Θ 的一阶微分。基于上述原理的 RPE 算法是 $e(k) = y(k) - \hat{y}(k)$

$$P(k) = \frac{1}{\lambda(k)} \cdot \{P(k-1) + P(k-1) \cdot \psi(k) [\lambda(k) + \psi^T(k) P(k-1) \psi(k)]^{-1} \psi^T(k) \cdot P(k-1)\}$$

$$\Theta(k) = \Theta(k-1) + \alpha(k) P(k) \psi(k) e(k)$$

式中: $\lambda(k)$ 是遗忘因子, 迭代初期置 $\lambda(k) < 1$, 从而实现自适应算法, 当 $k \rightarrow \infty$ 时, 取 $\lambda(k) \rightarrow 1$, 按式 (7) 采用变 $\lambda(k)$ 的算法可达到这一目的。

$$\lambda(k) = \lambda_0 \cdot \lambda(k-1) + (1 - \lambda_0) \quad (7)$$

这里 λ_0 和初始遗忘因子 $\lambda(0)$ 根据需要设置。

从以上 RPE 算法的原理可以看出, BP 算法可以认为是 RPE 算法的简化。同 BP 算法相比, RPE 算法增加了每一步训练的计算量, 但它利用二阶梯度有效加快了算法的收敛速度, 缩短了整体的训练时间。RPE 算法改变了算法对学习率和动量因子初值的敏感性, 避免了 BP 算法因不恰当选择学习率和动量因子造成训练效果差的现象^[2]。

2 改良三比值法

改良三比值法是利用油中溶解的不同气体浓度的数据, 按照不同气体组分的比值, 判断电力变压器故障的一种方法。其故障特征及故障类型诊断表如表 1 所示。

表 1 改良三比值故障特征及故障类型诊断

Tab.1 Fault character and fault diagnosis table of improved three-ratio method

故障类型诊断			
C_2H_2/C_2H_4	CH_4/H_2	C_2H_4/C_2H_6	故障类型诊断
$K_1 < 0.1$	$K_2 < 0.1$	$K_3 < 1$	局部放电
	$0.1 < K_2 < 1$	$1 \leq K_3 < 3$	低温过热 (低于 150℃)
	$1 \leq K_2$	$K_3 < 1$	低温过热 (150℃~300℃)
	$1 \leq K_2$	$1 \leq K_3 < 3$	中温过热 (300℃~700℃)
$K_1 \geq 3$	任意	$K_3 \geq 3$	高温过热 (高于 700℃)
	$K_2 < 1$	任意	低能 (火花) 放电
$0.1 \leq K_1 < 3$	$K_2 \geq 1$	任意	低能 (火花) 放电兼过热
	$K_2 < 1$	任意	电弧放电
	$K_2 \geq 1$	任意	电弧放电兼过热

3 故障诊断及仿真实例

利用 DRNN 的进行变压器故障诊断, 根据改良三比值法确定其神经网络模型的输入为 3 个, 分别为不同气体的浓度的比值; 模型输出为 9 个, 分别为 9 种不同的故障类型。输出用 1 或 0 表示故障是否存在, 即输出为 1 时表示存在该类故障, 为 0 时表示不存在该类故障。神经网络用于分类时输出是相应类别的后验概率, 神经元输出与 1 越接近表示变压器属于该类故障的概率越大, 反之越小。

根据实际故障诊断数据, 组织 30 个标准学习样本对所建立的神经网络进行训练。分别利用 BP 算法和 RPE 算法进行训练后, 得到样本训练后的误差平方和变化曲线如图 2 和图 3 所示。

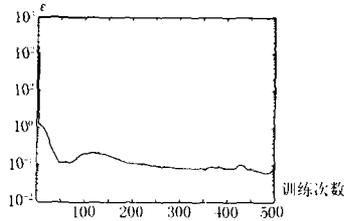


图 2 BP 算法的误差平方和变化曲线

Fig.2 Simulation curve of BP algorithm

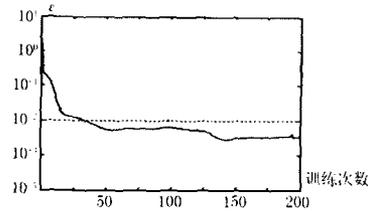


图 3 RPE 算法误差平方和变化曲线

Fig.3 Simulation curve of RPE algorithm

可以看出采用 RPE 算法修正的 DRNN 网络只训练 50 步的精度就远远高于 BP 算法训练 500 步的精度, 说明其具有很好的收敛性。

为进一步研究两种算法的增量学习能力, 另外选取 10 个未经训练的样本进行诊断, 诊断结果如

表 2 两种算法的故障诊断结果

Tab.2 Fault diagnosis results of arithmetic BP algorithm and RPE algorithm

序号	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	CO	CO ₂	BP 诊断结果	RPE 诊断结果
1	73	520	1 230	140	7	410	5 500	高温过热	高温过热
2	259	863	994	393	6	974	7 038	低温过热*	中温过热
3	80	20	20	6	62	190	240	火花放电	火花放电
4	260	130	84	26	92	260	7 400	电弧放电	电弧放电
5	66	86	7	100	8	310	1 800	电弧放电*	电弧放电兼过热
6	2 781	1 293	23	248	84	750	—	低能放电	低能放电
7	170	24	17	7	54	1 100	10 000	火花放电	火花放电
8	58	55	110	10	70	71	9 990	电弧放电兼过热*	电弧放电兼过热*
9	610	1 200	1 800	300	6	180	2 000	中温过热*	高温过热
10	78	28	29	13	110	120	400	低能放电	低能放电

4 结论

本文论述了油浸式变压器故障诊断的神经网络实现方法, 研究了应用 RPE 算法修正的 DRNN 用于变压器故障诊断的方法。结果表明利用该方法进行故障诊断时, 与简单的 BP 网络相比具有更加快速的收敛性, 且具有较好的增量学习功能。

参考文献

[1] 操敦奎. 变压器油中气体分析诊断与故障检查[M]. 北京:中国电力出版社, 2005.
CAO Dun-kui. Gas Analysis and Fault Diagnose of Transformer[M]. Beijing:China Electric Power Press, 2005.

[2] 段慧达, 郑德玲, 等. 基于对角递归神经网络的建模及应用[M]. 北京科技大学学报, 2004, (1): 103.
DUAN Hui-da, ZHENG De-ling, et al. Modeling and Application Based on Diagonal Recurrent Neural Network[M]. Transaction of Beijing Science and Technology University, 2004, (1): 103.

表 2 所示, 其中*表示诊断结果与实际结果不一致。

可见, 利用 RPE 算法修正的神经网络比利用 BP 算法修正的神经网络有更好的故障诊断正确率, 即有较好的增量学习能力。

[3] 宋轶民, 余跃庆, 张策, 等. 动态递归网络及其在机敏机构辨识中的应用[J]. 机械科学与技术, 2001, 20(4): 515.
SONG Yi-min, YU Yue-qing, ZHANG Ce, et al. System Identification of Smart Mechanisms Based on Dynamic Recurrent Neural Networks[J]. Mechanical Science and Technology, 2001, 20(4): 515

[4] GAO Fu-rong, WANG fu-li. A Simple Nonlinear Controller with Diagonal Recurrent Neural Network[J]. Chemical Engineering Science, 2000.

收稿日期: 2006-08-21; 修回日期: 2006-12-12

作者简介:

段慧达(1973-), 女, 硕士, 讲师, 主要从事电力系统自动化和神经网络技术、智能控制的教学和研究; E-mail: huida_duan@163.com

刘学军(1950-), 男, 副教授, 主要从事电力系统自动化及控制;

白晶(1965-), 女, 博士, 教授, 主要从事电力电子及传动、智能控制。