

基于加权小波神经网络的油浸式电力变压器故障检测

崔东君¹, 刘念¹, 刘秀兰²

(1. 四川大学电气信息学院, 四川 成都 610065; 2. 北京市电力公司试验研究院, 北京 100067)

摘要: 分析变压器油中溶解气体含量进行变压器故障诊断的关键是找到油中溶解气体含量和故障之间的非线性关系。针对已有检测方法诊断准确性不高的问题, 提出不基于 Fourier 变换, 而是利用细分的方法构造一类新的具有加权性质的小波函数。将小波函数作为前馈神经网络的隐含层函数并优化网络的学习率, 构造出加权小波神经网络处理变压器油中溶解气体含量数据。通过实际故障数据验证, 此方法较已有的诊断方法准确性更高, 在同等计算精度下速度更快, 进而提高了变压器故障诊断的效率。

关键词: 加权小波; 小波神经网络; 油溶解气体; 变压器故障检测

Fault diagnosis of oil-immersed power transformer based on weighted wavelet neural network

CUI Dong-jun¹, LIU Nian¹, LIU Xiu-lan²

(1. School of Electrical Engineering and Information, Sichuan University, Chengdu 610065, China;

2. Test and Research Institute of Beijing Electric Power Corporation, Beijing 100067, China)

Abstract: The key point of analyzing dissolved gas in transformer to diagnose transformer fault is to find out the non-linear relationship between dissolved gas content and the fault type. Using subdivision method, but not based on Fourier transformer to create a new wavelet function is put forward to deal with the problem which diagnosis accuracy is not high using traditional analysis method. The novel wavelet function combines with feed-forward neural network which learning rate is optimized to build a weighted wavelet neural network for fault diagnosis of transformers. Using weighted wavelet neural network to analyze actual fault data proves that novel neural network has higher diagnostic accuracy, and higher calculation speed under the same condition, thus can increase the efficiency of the transformer fault diagnosis.

Key words: weighted wavelet; wavelet neural network; dissolved gas analysis; transformer fault diagnosis

中图分类号: TM771 文献标识码: A 文章编号: 1674-3415(2010)18-0019-05

0 引言

电力变压器是电力系统中非常重要的设备, 关系到用电设备是否能安全可靠地运行^[1]。如何较早地发现变压器故障, 快速准确地判断出故障类型是当今研究的热点问题。其中根据油中溶解气体(DGA)判断变压器故障已被各国普遍接受。此方法是根据变压器内部发生过热、放电等故障时, 故障点附近的绝缘分解, 产生各种能表征故障类型的特征气体溶解在变压器油中^[2]。从变压器油中分离出含量不同的各种气体, 并转换成信号送入工作站软件, 根据气体含量与变压器故障的对应关系判断变压器故障类型。国际电工委员会(IEC)推荐的三比值法诊断变压器故障已被电力行业采用, 但其编码与变压器故障并非一一对应, 存在一定误差。

近年来出现了很多新方法^[3-5]判断变压器故障, 尤其是小波神经网络技术的引入改进了 IEC 三比值法编码过于绝对的问题。但小波神经网络也有其局限性, 一是学习过程不稳定, 二是运算速度慢。

针对上述不足, 本文分两个方面对小波神经网络进行改进: 引入了不基于 Fourier 变换, 而是用一种新的小波合成方法构造出一种加权小波^[6]组成小波神经网络; 运用自适应调整网络学习率的算法。改进后的小波神经网络加强了判断故障的能力, 提高了运算速度, 使之更便于在线监测。

1 新型加权小波神经网络(WWNN)

1.1 构造加权小波函数

常见的小波是通过 Fourier 变换得到的, 其基本思想是用函数的尺度伸缩平移构成 L_2 空间的基。

Fourier 变换增加了计算的复杂度,而且构造出的小波函数有些没有显示表达式,有些没有良好的特性,如紧支撑,高阶消失矩等。目前出现了一些其他形式的小波^[7],它们没有紧支撑性,不适合实际应用。本文不通过 Fourier 变换构造小波,而是利用基于细分方案的平均插值法,通过细分方法构造具有紧支撑和较大消失矩的新型加权小波。

首先定义一个在 L_2 空间中可积的正函数 $\omega(x)$ 作为 L_2 空间中一个加权内积 $\langle f, g \rangle_\omega$ 的权系数。再定义闭子空间 V_j 中的多分辨分析满足空间嵌套性;逼近性 ($\bigcap_{j \rightarrow \infty} V_j$ 在 L_2 空间中稠密且 $\bigcap_{j \rightarrow \infty} V_j = \{0\}$); Riesz 基存在性(尺度函数存在并且 $\{\phi_{j,k}\}_k$ 构成 V_j 的一个 Riesz 基)。以上三点表明每个尺度函数 $\phi_{j,k}$ 具有以下加细关系:

$$\phi_{j,k} = \sum_l h_{j,k,l} \phi_{j+1,2k+l} \quad (1)$$

式中: $h_{j,k,l}$ 为加细关系系数。空间 W_j 是子空间 V_j 在空间 V_{j+1} 中的补空间,其中的一个 Riesz 基为 $\{\psi_{j,k}\}_k$, 则小波函数为

$$\psi_{j,k} = \sum_l g_{j,k,l} \phi_{j+1,2k+l} \quad (2)$$

加权小波 $\psi_{j,k}$ 的 N 阶加权消失矩定义为:

$$\int_{-\infty}^{+\infty} \omega(x) x^p \psi_{j,k} dx = 0 \quad 0 \leq p \leq N-1 \quad (3)$$

$$\int_{-\infty}^{+\infty} \omega(x) x^p \psi_{j,k} dx \neq 0 \quad p = N$$

可以看到加权小波的收敛速率与消失矩有关(若 $f(x) \in C^N$, 则收敛速率为 $\|\Sigma \langle f, \phi_{j,k} \rangle_\omega \phi_{j,k} - f(x)\| = O(h^N)$ ($h=2^{-j}$)。新型加权小波具有紧支性和高阶消失矩,与常规小波相比收敛速度快得多^[8]。

细分的思想是将一定的拓扑规则与几何规则作用于初始信号而产生的新的信号,并且不断重复这一过程直到生成光滑的极限信号的过程。目的是对原始的信号不断加细产生细化的信号,并且细化的信号保持原始信号的特征与结构。经过细分后的函数序列为:

$$f^{(j)} = \sum_k \lambda_{j,k} \bar{\phi}_{j,k} / M_{j,k}^0 \quad (j \geq i) \quad (4)$$

其中: $M^p \leq x^p$, $\phi_{j,k} >_\omega$ ($0 \leq p < N$) 是定义的一个局部矩; λ 为不同细分水平的系数 ($\lambda_{j,k} \leq f, \phi_{j,k} >_\omega$), 具体推导过程见文献[9]。

最后得到由尺度函数细分构成的加权小波函数可以表示为:

$$\psi_{j,k} = \phi_{j+1,ak} - \phi_{j+1,ak+1} + \phi_{j+1,ak+2} + \dots + (-1)^{a-1} \phi_{j+1,ak+a-1} = \sum_{l=ak}^{ak+a-1} (-1)^l \phi_{j+1,l} \quad (5)$$

本文选取在 L_2 空间中一个可积的正函数 $\omega(x)$ 作为加权小波的权系数,如式(16)。

$$w(x) = x(\chi_{(-\infty,a)} + 10^3 \chi_{(a,+\infty)}), \alpha=1.73 \quad (6)$$

由式(5)和加权尺度函数满足的性质可以得到加权小波: $\psi_{0,0} = \phi_{1,0} - \phi_{1,1} + \phi_{1,2} - \phi_{1,3}$, 如图1所示。其中 $j=k=0, \alpha=4$ 。可以看到,即使加权函数有很大的跃变,加权小波还是非常光滑的,而且支撑性良好。

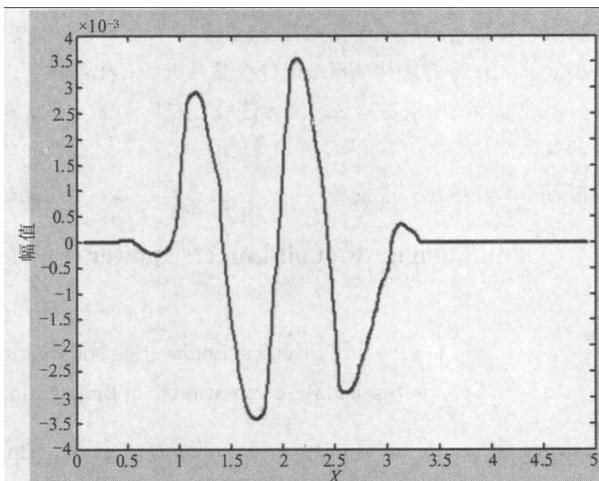


图1 加权小波函数

Fig.1 Function of weighted wavelet

1.2 建立小波神经网络

根据变压器的故障诊断特点,本文采用3层前馈神经网络,如图2所示。它包括输入层,结点个数为 I , 对应的输入向量为 $X=[x_1, x_2, \dots, x_I]$; 隐含层,结点个数为 J , 由小波层和权值层组成,小波层函数为加权小波,隐含层的输出向量为 $\psi=[\psi_1, \psi_2, \dots, \psi_J]$; 输出层,结点个数为 K , 相应的输出向量为 $O=[o_1, o_2, \dots, o_K]$, 期望输出向量为 $T=[t_1, t_2, \dots, t_K]$ 。令输入层任意节点 x_i 到隐含层任一节点间的连接权值为 ω_{ij} ; 隐含层节点 ψ_j 到输出层节点 o_k 间的连接权值为 ω_{jk} ; θ_j 为隐含层第 j 个神经元的阈值, θ_k 为输出层第 k 个神经元的阈值,其中 $i=(1,2,\dots,I); j=(1,2,\dots,J); k=(1,2,\dots,K)$ 。通过前向计算,输出关系式可表示为:

$$o_k = f[\sum_{j=1}^J \omega_{jk} \psi(\sum_{i=1}^I \omega_{ij} x_i - \theta_j) - \theta_k] \quad (7)$$

式中: f 采用 Sigmoid 函数,即 $f(x)=1/(1+e^{-x})$; ψ 为前述的加权小波函数。

实际计算中,网络的实际输出与期望输出不等,则定义二者间的误差函数为:

$$E = 1/2 \sum_{k=1}^K (o_k - t_k)^2 \quad (8)$$

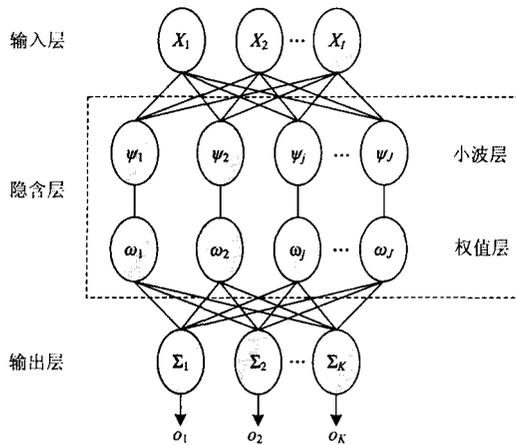


图2 小波神经网络图

Fig.2 Structure diagram of the WWNN

神经网络的学习过程就是不断调整权值的过程,使得误差 E 减小。在普通神经网络的学习算法中,学习率是个常值,值过大则振荡,过小则训练时间太长。因此本文采用自适应调整学习率的算法加以改进。

设调整参数为 y , 当 y 的相邻两次梯度方向不同时说明上一次调整有效,可增大 y 的学习率,使误差函数向极小值靠拢或跳出极小值邻域;当两次梯度方向不同时,说明 y 上一次调整幅度过大,此时应减小 y 的学习率;当相邻两次梯度有一个为零时,此时 y 所处的位置不明确,保持学习率不变。

$$\text{若 } \frac{\partial E}{\partial y}(n) \times \frac{\partial E}{\partial y}(n-1) > 0$$

$$\text{则 } a(n) = a(n-1) \times \mu_1$$

$$\text{若 } \frac{\partial E}{\partial y}(n) \times \frac{\partial E}{\partial y}(n-1) < 0$$

$$\text{则 } a(n) = a(n-1) \times \mu_2,$$

$$\text{其他情况下 } a(n) = a(n-1) \quad (9)$$

其中: μ_1 为增量因子,其值在 1.01~1.3 之间; μ_2 为减量因子,其值在 0.7~0.9 之间。

2 基于 WWNN 的变压器 DGA 故障诊断

为说明加权小波神经网络能够准确、快速地进行变压器故障诊断,本文在众多 DGA 检测法中选取应用较广的 IEC 三比值法;改善了编码过于绝对的智能诊断方法中效果较好的反向传播神经网络法 (BPNN) 与加权小波神经网络法 (WWNN) 进行比较。通过 WWNN 与两种典型的变压器 DGA 故障诊断方法比较,分析故障诊断性能。其中 BPNN 和 WWNN 在检测变压器故障前需要设置神经网络参

数。

2.1 网络参数设置

1) 确定输入向量

统计变压器油中分解出的 H_2 , CO , CO_2 , CH_4 , C_2H_4 , C_2H_6 , C_2H_2 (后面 4 种为总烃), 7 种特征气体含量并用比值表示, BPNN 与 WWNN 输入向量为 4 个, 见表 1。

表 1 输入向量

Tab.1 Input patterns of test case

输入向量的比值表示	故障诊断方法
$C_2H_2/C_2H_4, CH_4/H_2, C_2H_4/C_2H_6$	三比值法
$C_2H_2/C_2H_4, CH_4/H_2, C_2H_6/C_2H_4, C_2H_2/\text{总烃}$	BPNN 和 WWNN

2) 确定输出向量

将变压器故障分成: ①局部放电或受潮; ②低能放电; ③高能放电; ④低温过热 ($<300^\circ\text{C}$); ⑤中温过热 ($300^\circ\text{C} \sim 700^\circ\text{C}$); ⑥高温过热 ($>700^\circ\text{C}$)。这六种故障模式作为输出层的输出值。输出值在 $[0,1]$ 的范围内变化, 表示故障发生的概率, 数值越大表示该类型的故障发生的可能性和严重性越大。实际检验的结果显示, 一般的故障概率大于 60% 时可基本确定发生此类故障。

3) 确定隐含层节点数

神经网络的结构主要由隐含层的节点数决定, 隐含层节点数过多或过少都不能很好地满足需要。节点数少则达不到精度要求, 节点数多则导致学习时间过长, 而且准确率也因达到饱和而有所下降。目前确定隐含层节点数的方法主要是凭经验和试探的办法^[10]。本文选用的 BPNN 节点数为 12, WWNN 的节点数为 9。

2.2 仿真分析变压器故障

设定最大训练次数为 2 000 次, 目标平均误差为 0.01, $\omega_{ji}=0.25$, 权值范围 $[-1,1]$, 仿真采用 Matlab 软件。

选取 2004 年 1 月至 2008 年 1 月之间国内已经确认故障类型的 500 组变压器 DGA 数据作为试验样本。该样本包括了变压器在实际运行中可能出现的各种故障, 且样本数量大, 有一定代表性。通过 IEC 三比值法、BPNN 法和 WWNN 法分别计算这些 DGA 数据, 分析变压器可能的故障类型, 再与每组数据对应的实际故障类型比较, 计算出各种 DGA 诊断方法的准确率。对于 IEC 三比值法可直接通过计算得到诊断结果; 对于 BPNN 和 WWNN 需将 500 组试验样本中的 350 组作为二者的训练样本, 另外 150 组作为故障识别样本, 具体故障分组情况见表 2。

表 2 变压器 DGA 数据
Tab.2 Transformer DGA data

组别	无故障	低	中	高	局部放 电或受 潮	低	高
		温 过 热	温 过 热	温 过 热		能 放 电	能 放 电
学习样本	150	33	33	44	24	32	34
识别样本	30	16	15	30	13	22	24

1) BPNN 与 WWNN 学习速率比较

利用 350 组训练数据对 BPNN 和 WWNN 进行训练, 输出结果和实际故障类别的误差曲线见图 3 和图 4。如图可见两种网络在具有相同的网络输入和期望输出时, 在收敛时间以及平均误差方面有显著的差异。BPNN 经过 1 383 次迭代后误差符合精度要求, 在前 200 次迭代过程中平均误差出现较大幅度振荡, 这样的振荡对学习过程十分不利, 且 230~1200 次迭代学习率几乎无变化, 学习效率不高。WWNN 经过 809 次迭代后平均误差降到目标值之下, 平均误差曲线比较平滑, 下降速度较快, 表现出更优异的故障分类能力。

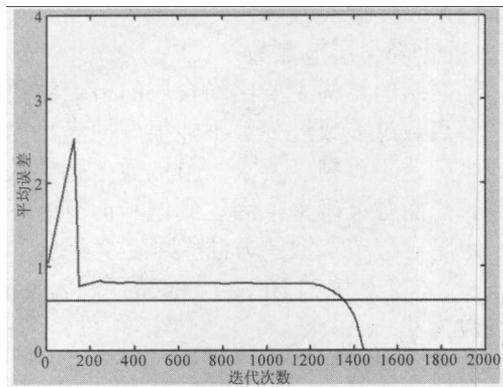


图 3 BPNN 误差曲线
Fig.3 Error curve of BPNN

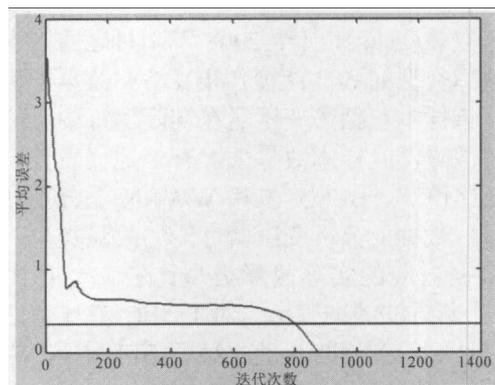


图 4 WWNN 误差曲线
Fig.4 Error curve of WWNN

2) 故障判断性能比较

分别用 IEC 三比值法、BPNN 法、WWNN 法对表 2 中 150 组故障识别样本进行分析, 比较三种故障诊断法的准确性, 结果见表 3。传统的比值法由于编码不全, 编码边界过于绝对, 容易导致故障误判断, 所以在 150 组样本的诊断结论中, 其准确率最低, 有 77%左右。BPNN 的准确率为 83%, 已经体现出神经网络自学习的优势了。WWNN 的准确率为 88%, 比前两者都高。

表 3 故障诊断结果比较

Tab.3 Comparative table of diagnosis results

监测方法	无故障	低	中	高	局 放 或 受 潮	低	高	总 正 判 率
		温 过 热	温 过 热	温 过 热		能 放 电	能 放 电	
IEC 三比值法	73	70	80	74	70	82	87	77
BPNN 法	83	75	88	77	78	87	92	83
WWNN 法	86	80	92	83	83	91	96	88

BPNN 和 WWNN 都是对 IEC 三比值法编码过于绝对这一缺陷的改进, 但 WWNN 较 BPNN 有更好的故障判别能力, 表 4 引入 150 组故障识别样本中的一组典型故障数据, 分析两网络故障识别差异。BPNN 判断此组数据为中温过热故障, WWNN 判断其为低温过热故障, 而实际该组数据为低温过热故障。出现此差异是由于 WWNN 中加权小波函数对传入神经网络隐含层的故障数据有优异的甄别能力和良好的局部化特性。同时又继承了神经网络的自学习能力, 而且计算的复杂度不高, 光滑性好, 故能达到较高的故障识别率。

表 4 典型气体含量数据

Tab.4 A typical gas content data

特征气体	H ₂	CO	CO ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂
气体含量/ μ L	27	166	388	93.3	1.7	623	1642

3 结论与展望

本文构造了一种不基于 Fourier 变换, 而是采用细分的方法构造具有紧支撑和较大消失矩的新型加权小波函数作为前馈神经网络的隐含层, 并优化了神经网络的学习率。新型的小波神经网络有如下特点:

1) 加权小波较之通常由 Fourier 变换得到小波有计算复杂度低、支撑性好、光滑性好的特点, 适

合对大量, 尤其是非线性的数据进行分析。神经网络的自学习特性有效地解决了故障阈值过于绝对的问题。

2) 输入层导入待测变压器的特征气体比值, 隐含层中的加权小波变换对输入样本进行局部化特征提取, 输出层对样本进行模式分类。故 WWNN 有良好的分类能力、收敛性、鲁棒性。

3) 对神经网络的学习率进行优化, 可以减少振荡, 提高网络自学习效率。

文章最后利用 IEC 三比值法、BPNN 法、WWNN 法对变压器油中溶解气体含量实测数据进行仿真分析比较, 尤其比较了 BPNN 和 WWNN 这两种智能诊断的方法。仿真结果说明 WWNN 有较高的故障识别率和神经网络学习速度。

参考文献

- [1] 孙才新, 陈伟根, 李俭, 等. 电气设备油中气体在线监测与故障诊断技术[M]. 北京: 科学出版社, 2003.
SUN Cai-xin, CHEN Wei-gen, LI Jian, et al. Electrical equipment oil dissolved gas on-line monitoring and fault diagnosis technology[M]. Beijing: Science Press, 2003.
- [2] 潘超, 马成廉, 等. 一种结合模糊 TOPSIS 法和 BP 神经网络的变压器故障诊断方法[J]. 电力系统保护与控制, 2009, 37 (9): 20-24.
PAN Chao, MA Cheng-lian, et al. A new method based on fuzzy TOPSIS and BP neural network for power transformer fault diagnosis[J]. Power System Protection and Control, 2009, 37 (9): 20-24.
- [3] 张承彪, 罗运柏, 文习山. 主成分分析在变压器故障诊断中的应用研究[J]. 高电压技术, 2005, 31 (8): 9-11.
ZHANG Cheng-biao, LUO Yun-bai, WEN Xi-shan. Study on fault diagnosis of transformer based on principal component analysis of dissolved gas[J]. High Voltage Engineering, 2005, 31 (8): 9-11.
- [4] 杨启平, 薛五德, 蓝之达. 基于人工神经网络的变压器故障诊断[J]. 变压器, 2000, 37 (3): 33-36.
YANG Qi-ping, XUE Wu-de, LAN Zhi-da. Artificial neural network for transformer fault diagnosis[J]. Transformer, 2000, 37 (3): 33-36.
- [5] 杨海马, 刘瑾, 张菁. BP 神经网络在变压器故障诊断中的应用[J]. 变压器, 2009, 46 (1): 67-70.
YANG Hai-ma, LIU Jin, ZHANG Jing. Application of BP neural network to transformer fault diagnosis[J]. Transformer, 2009, 46 (1): 67-70.
- [6] 侯霞, 胡寿松. 一种新的细分加权小波[J]. 自动化学报, 2004, 30 (6): 17-20.
HOU Xia, HU Shou-song. A novel weighted wavelet with subdivision[J]. Acta Automatica Sinica, 2004 (6): 1017-1020.
- [7] Meyer Y. Ondelettes et operateurs, I: ondelettes, II: operateurs de calderon-zygmund, III: operators multilinear wavelets and operators[M]. Cambridge University Press, 1993.
- [8] Sweldens W, Piessens R. Calculation of the wavelet decomposition using quadrature formula: number 1 in series in approximations and decompositions[J]. World Scientific Singapore, 1993: 139-160.
- [9] 侯霞. 小波神经网络若干关键问题研究[D]. 南京: 南京航空航天大学, 2006.
HOU Xia. Research on key technologies of wavelet neural network[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2006.
- [10] 陈伟根, 潘翀, 等. 利用小波神经网络的电力变压器故障诊断方法[J]. 高电压技术, 2007, 33 (8): 52-55.
CHEN Wei-gen, PAN Chong, et al. Fault diagnostic method using wavelet neural network for power transformers[J]. High Voltage Engineering, 2007, 33 (8): 52-55.

收稿日期: 2009-09-25; 修回日期: 2009-11-18

作者简介:

崔东君 (1984-), 男, 硕士研究生, 主要研究方向为电力设备故障诊断; E-mail: cdj1122@126.com

刘念 (1956-), 男, 教授, 硕士生导师, 主要从事高电压绝缘和电力设备故障监测方面的研究工作;

刘秀兰 (1983-), 女, 助理工程师, 主要从事电力设备运行试验和故障检测工作。