

涡流检测中的组合神经网络模型

幸玲玲¹, 王东进²

(1. 南京师范大学电气工程系, 江苏南京 210042; 2. 中国科学技术大学电子工程系, 安徽合肥 230072)

摘要: 针对使用单一神经网络在缺陷识别中存在的输入矢量维数高, 结构复杂及训练时间长等问题, 本文提出了组合神经网络模型, 这一模型采用逐级判别的方法, 每级判断均采用独立的神经网络子模块, 各模块采用随机学习算法分别进行训练。裂缝识别的计算实例表明, 这一组合模型使神经网络输入变量的维数从 N^2 降低到 N , 网络结构大为简化, 训练速度很快, 同时具有较高的缺陷识别率, 可推广应用于实时涡流检测中。

关键词: 涡流检测; 裂缝识别; 组合神经网络模型

中图分类号: TM 13 **文献标识码:** A **文章编号:** 0372-2112 (2002) 05-0734-04

A Composite Neural Network Model for Eddy Current Testing

XING Ling ling¹, WANG Dong jin²

(1. Department of Electrical Engineering, Nanjing Normal University, Nanjing, Jiangsu 210042, China;

2. Department of Electronic Engineering, University of Science and Technology of China, Hefei, Anhui 230027, China)

Abstract: A composite neural network model with many sub-network stages is presented. The flaw identification is accomplished stage by stage. Each stage consists of different sub-networks and is trained by a stochastic learning algorithm independently. Numerical simulations of crack identification have shown that the composite neural network model decreases the input vector dimensions of neural network from N^2 to N , simplifies the structure of network, saves the learning time, and has a better generalization ability. It can be used effectively in eddy current testing.

Key words: eddy current testing; flaw identification; composite neural network model

1 引言

涡流无损检测中缺陷或裂缝的位置、大小和形状的识别本质上属于电磁场逆问题。目前电磁场逆问题的求解方法有两大类, 一类是用数值方法反复求解电磁场微积分方程, 另一类是模式识别方法。

最近十几年发展起来的人工神经网络方法是一种唯象的处理逆问题的方法。神经网络可以通过学习大量的实际范例来分类和识别目标, 其学习过程实际上就是一种逆问题的优化求解过程。前向多层神经网络已开始应用于涡流检测的电导率分布重建及缺陷识别中^[1, 2]。

涡流检测中传统的阻抗分析方法在测量中每次只能得到一个阻抗值, 对缺陷判断的准确性受仪器使用者的经验限制。九十年代提出的微型环磁传感器阵列探头^[3]可以一次检测出缺陷上方的空间磁场分布, 提高了检测速度和灵敏度。但如何根据这一空间磁场分布快速准确地重构缺陷仍然是有待解决的难点问题。若以缺陷上方磁场测量值的两维数据直接作为神经网络的输入矢量, 势必使网络输入维数过大, 使网络结构复杂, 训练时间加长, 降低网络的训练精度和推广能力。另一方面, 要用一个神经网络同时识别出缺陷的位置、形状及大小

将是十分困难的。为此, 本文提出了组合神经网络模型。这一模型采用分级判别的方法, 从初始有无缺陷, 到确定缺陷的位置及形状, 最后给出缺陷的尺寸。这一模型克服了单一神经网络模型在输入矢量维数高, 结构复杂及训练时间长等方面的不足, 具有较高的缺陷识别率和实用价值。

Wits 等人基于随机优化思想提出了前向网络的随机学习算法^[4]。本文结合涡流检测中缺陷识别的问题特征, 采用一种新型的随机学习算法, 缺陷识别的计算结果表明, 该随机学习算法具有较快的学习速度和较高的拟合精度, 并能够以较大概率避免学习过程陷入局部极小点, 可推广应用于实时涡流检测中。

2 组合神经网络模型

从磁传感器阵列探头, 可以得到平板导体中存在缺陷时其上方的空间磁场分布 B^m , 将这一磁场减去激励线圈在空气中产生的磁场 B^p , 即可得到缺陷引起的涡流磁场分布 $B^e = B^m - B^p$ 。理论计算和实测结果均表明^[5, 6], 涡流磁场的 x 分量和 y 分量幅值和垂直分量 B_z^e 相比小得多, 并且目前涡流检测水平主要检测 B_z^e 分量。因此本文神经网络的学习主要采

用 B_z^e 分量. 为了简便, 省略下标“z”.

图 1 表示检测平面上各测量点的分布 (图中用“×”表示), 共 $N \times N$ 个, 激励线圈、导电板、及裂缝等参数见表 1.

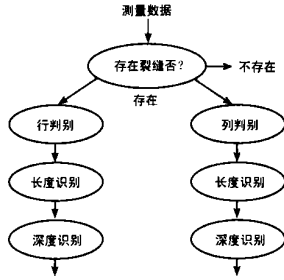



图 1 xoy 平面上测量点分布 图 2 组合神经网络功能模型

表 1 基本模型各参数

激励线圈	
内半径 r_1	(0.6 ± 0.01) mm
外半径 r_2	(1.6 ± 0.01) mm
线圈高 Δz	(0.8 ± 0.01) mm
匝数 n	140
提高 h	(1.0 ± 0.01) mm
检测面 z	(0.5 ± 0.01) mm
频率 f	150kHz
导电板	
板厚 d	(1.25 ± 0.01) mm
电导率 σ	(1.0 × 10 ⁶) S/m
裂缝	
长 l	(10.0 ± 0.02) mm
宽 w	(0.1 ± 0.01) mm
深 b	(1.0 ± 0.01) mm

如果以检测面上得到的全部测量值作为神经网络的输入, 势必使网络输入维数过大, 网络结构复杂, 训练时间加长. 为了有效地识别缺陷, 我们采用逐级判别的方法, 首先判断是否存在缺陷(裂缝), 其次判断裂缝的走向是横向、纵向还是斜向的, 再判断裂缝的长度, 最后对裂缝的深度进行识别. 每级判断均采用独立的神经网络模块, 各模块采用随机学习算法独立地进行训练, 最后各模块根据一定的逻辑推理规则构成组合神经网络系统模型, 其结构如图 2 所示.

在组合神经网络模型中, 判别由粗至细, 逐级进行, 根据上一级神经网络模型的输出来选择下一级神经网络模块, 进一步判断, 直至将裂缝的全部参数确定. 各子模块的输入参量和训练样本集互不相同.

第一级, 判断是否存在裂缝. 这一级只用单个神经元即可, 该神经元设二个输入, 一个输出. 输入矢量中的一个分量为各测量点涡流磁场归一化值的平方和, 即:

$$x_1 = \sum_{j=1}^N \sum_{i=1}^N \frac{B_{ij}^e}{B_{\max}^e}$$

其中 B_{\max}^e 为平板导体中无缺陷时检测面上涡流磁场的最大值, B_{ij}^e 为各测量点上的涡流磁场. 另一分量为涡流磁场归一化值的最大值, 即:

$$x_2 = \left| \frac{B_{ij}^e}{B_{\max}^e} \right|_{\max} \quad (2)$$

输出变量为 1 时表示存在裂缝, 需要进行下一级判断, 输出为 0 时, 表示导体板中无裂缝.

第二级, 判别裂缝是横向的, 还是纵向的. 更细致的话还可增加斜向裂缝, 这里暂时不考虑斜向裂缝. 首先求出整个平面上涡流磁场的最大值 B_{\max}^e , 再将各点 B_{ij}^e 归一化. 对于行判别, 将某一行各数据平方求和, 即:

$$x_i = \sum_{j=1}^N \left(\frac{B_{ij}^e}{B_{\max}^e} \right)^2, \quad i = 1, \dots, N \quad (3)$$

将其作为第二级神经网络的输入矢量, 输入矢量的维数即为测量点的行数 N . 神经网络的输出矢量也为 N 个, 输出为 0 时, 表示此行附近无裂缝, 输出为 1 时, 表示存在横向裂缝, 如 $Y = \{0, 0, 1, 0\}$ 表示第三行存在裂缝.

对于列, 可以进行类似判别. 因此这一级神经网络可以确定裂缝的位置, 并判断缝是横向的还是纵向的, 或者横向和纵向都存在, 或者存在多条裂缝.

第三级, 裂缝长度的识别. 若上一级某行(或某列)输出为 1, 则对该行继续判别. 首先求出该行(设第 i 行)的最大值 B_{\max}^e , 将该行各点 B_{ij}^e 归一化, 再平方, 即:

$$x_j = \left(\frac{B_{ij}^e}{B_{\max}^e} \right)^2, \quad j = 1, \dots, N \quad (4)$$

将其作为第三级神经网络的输入, 神经网络的输出对应裂缝的实际长度, 输出矢量的维数取决于待识别裂缝的分辨率.

第四级: 裂缝深度的识别. 对给出了长度的裂缝, 再选择与其对应的下一级子网络进行深度识别. 先求出对对应行或列穿透裂缝上方的涡流磁场最大值 $B_{\max T}^e$, 再将该行各点 B_{ij}^e 归一化, 子网络的输入为:

$$x_j = \left(\frac{B_{ij}^e}{B_{\max T}^e} \right)^2, \quad j = 1, \dots, N \quad (5)$$

子网络的输出对应裂缝深度占导体板厚度的百分比. 例如 10%, 20%, ..., 100% 等.

这种逐级识别裂缝的方法, 使神经网络输入变量的维数从 N^2 降低到 N , 网络结构大为简化, 训练时间极大地减少. 一方面各子网络可以独立地分别训练. 另一方面, 网络结构参数的调整可在各子网络部分进行, 如要细分裂缝的长度, 可增加长度识别子网络的输出节点, 只需对长度识别的子网络重新训练即可.

3 前向三层网络的随机学习算法

研究证明, 一个仅含有隐层非线性连续变换函数的前向三层网络可以用来逼近有界闭区域上的任一连续函数. 涡流检测中缺陷的识别问题也即非线性最优拟合问题. 给定样本集合 $\{X(k), Y(k), k = 1, 2, \dots, K\}$, 求最优拟合函数集 $Y(X) = \{\hat{y}_1(k), \hat{y}_2(k), \dots, \hat{y}_L(k)\}^T$, 使

$$J = \frac{1}{K} \sum_{k=1}^K \|Y(k) - \hat{Y}(k)\|^2 \quad (6)$$

最小化, 其中 k 为样本数.

网络结构如图 3 所示, 由输入层、隐层及输出层构成, 各

层节点数分别用 N 、 M 、 L 表示, 隐层神经元采用非线性 Sigmoid 函数, 输出层神经元采用线性函数。

以 $W = \{w_{ij} | i = 1, \dots, M, j = 0, 1, \dots, N\}$ 表示隐层权系数阵, w_{i0} 为

隐层各神经元的阈值。 $V = \{v_{li} | l = 1, \dots, L, i = 0, 1, \dots, M\}$ 表示输出层权系数阵, v_{l0} 对应各神经元的阈值。 $h_i(k)$, $z_i(k)$ 分别为隐层第 i 个节点的输入与输出。 $g(x)$ 为 Sigmoid 函数

$$g(x) = \frac{1}{1 + \exp(-x)}$$

网络的训练方法为: 隐层权系数 $\{w_{ij}\}$ 采用随机寻优方法获得, 而输出层权系数 $\{v_{ij}\}$ 采用递推线性最小二乘法求得。首先对 $\{w_{ij}\}$ 设置一组初值, 计算隐层单元输出 $z_i(k)$ 。再用递推最小二乘法计算输出层权系数 $\{v_{ij}\}$, 从而计算网络实际输出 $\hat{y}_l(k)$, 并与样本输出值进行比较, 若满足误差要求, 则迭代过程结束。否则, 按随机优化方法修改 $\{w_{ij}\}$, 并进行第二轮迭代, 直至输出向量与样本向量的均方误差满足误差要求为止。

在组合神经网络模型中, 各子模块均采用上述随机学习算法独立地进行训练。

4 裂缝识别实例

对组合神经网络的每一级进行训练, 需要大量的样本数据, 若用实验方法来获取样本集, 不但消耗大量的时间和资金, 而且样本裂缝的尺寸不易做得准确, 为网络的训练和应用造成误差。我们采用数值计算方法建立样本集合。用 FEM-BEM 组合法程序对平板导体中的各种不同裂缝进行计算, 该 FEM-BEM 组合法程序经过多个研究小组验证, 并且其阻抗的计算结果与实验测量值相符^[5]。样本集合中, 激励线圈和导电板的各参数保持不变(见表 1), 只改变各裂缝的位置、长度和深度。

首先假定裂缝位于 y 轴上, 长度分别为 2, 4, ..., 24, 30, 36mm, 深度分别为板厚的 20%、40%、60%、80%、100% 共 65 种情况, 再依次假设各裂缝位于 $x = 2, 4, 6$ mm 处, 最后假设各裂缝位于 $y = 0, 2, 4, 6$ mm 处, 共得到 520 组样本, 以其中的 320 组构成训练样本集, 200 组构成检测样本集, 检测面上每隔 2mm 取一个点, 测量点共取 9×9 个。

第一级, 只判断是否存在裂缝, 采用单个 Sigmoid 函数神经元。用随机寻优方法找权值, 经过 352 次学习, 找到了网络权值。检测结果表明, 主要是 2mm 和 4mm 长的几个较浅裂缝不能正确识别, 其余裂缝均判别正确, 识别正确率为 95%。

第二级, 主要判别裂缝是横向的, 还是纵向的, 并确定其位置。这一级采用两个前向三层子网络, 并用随机学习算法分别对子网络进行训练, 网络输入输出矢量的维数为测量点的行数或列数。

一般来说, 神经网络输入和输出矢量的维数可根据实际




图3 前向三层神经网络结构图

问题来确定, 对网络结构参数选择的困难在于隐层神经元数目的确定, 一般情况下, 研究者需凭直觉和经验来确定隐单元数目^[7]。我们比较了隐层单元数分别为 3 和 6 的两个三层网络 9-3-9 和 9-6-9, 网络 9-6-9 训练时间较长, 但网络的训练误差小, 推广能力强, 因此, 综合性能较好。

以 320 组样本作为训练样本集, 200 组构成检测样本集, 网络经过 2894 次迭代, 找到了合适的权重, 检验准确率为 90.5%。误差主要来自对较短较浅的裂缝及离激励线圈中心较远裂缝的判别, 如长 2mm、4mm, 深度为 20%、40% 的裂缝和位于 $x = 6$ mm 处的几个较短裂缝出现误判。

第三级, 裂缝长度的确定, 神经网络的输入对应某行或某列各点 B^e 归一化值的平方, 网络的输出对应裂缝的长度。从工程角度看, 当裂缝长度大于某个值时, 则工件必须被替换, 而不再确定裂缝究竟有多长, 这里假定这一临界值为 20mm。因此, 对于裂缝长度大于 20mm 的情况, 均识别为 20mm, 网络输出从 2mm 到 20mm, 每 2 个毫米对应一个节点, 共 10 个输出节点, 子网络结构为 9-6-10。网络训练经过 2781 次迭代收敛。为了检验网络对未学样本的判别, 我们将裂缝长为 3, 5, ..., 19mm 的样本增加到检验样本集中。检测结果表明, 网络不但能识别已学的不同长度裂缝, 而且对相近长度的裂缝也能寻找到最接近的已学样本。

裂缝的位置和长度均已确定后, 再对裂缝的深度进一步识别。对不同长度的裂缝, 采用不同的子网络识别其深度, 根据对长度划分粗细的不同, 确定子网络的个数。

我们用一个长 12mm 的裂缝在不同位置和深度时的涡流磁场值训练一个子网络, 训练后的网络就只能用于判断 12mm 或相近长度裂缝的深度。利用前面已有的 12mm 长裂缝的样本集 40 组, 再计算对应的裂缝深为 10%、30%、50%、70%、90% 等样本, 共 80 组样本, 以 50 组构成训练样本集, 30 组为检测样本集, 子网络输入为 9 个节点, 网络输出为板厚的 10%、20%, ..., 100% 共 10 个节点, 设计一个 9-6-9 的子网络, 网络训练后检测结果的准确率达 90%。在裂缝深度较小时, 有时会误判。

对于其他长度的裂缝深度判别, 可采用类似的网络训练方法。对于划分的一个长度, 采用一个子网络判别其深度。

各级子网络训练与识别典型数据列于表 2 中。

表 2 各级子网络训练与识别结果

级别	迭代次数	计算时间	检验准确率
第一级	352	1'27"	95.0%
第二级	2894	2'35"	90.5%
第三级	2781	2'015"	92.8%
第四级	2147	1'12"	90.0%

5 小结

根据缺陷或裂缝上方的空间磁场测量值来识别缺陷是涡流检测发展的必然趋势, 但若以检测面上的两维数据作为单一神经网络的输入, 将使网络输入维数过大, 结构复杂, 训练困难。本文提出的组合神经网络模型有效地解决了这一问题。这一模型采用分级判别的方法, 从初始的有无缺陷, 到确定缺

陷的位置及形状,最后给出缺陷的尺寸.组合模型中各子网络结构设计灵活,可独立地进行训练和修改,裂缝识别的计算结果表明,这一模型具有较高的识别率和实用价值.

组合神经网络模型中各子网络的训练采用随机学习算法,这一学习算法与 BP 算法相比,具有较快的学习速度和较好的推广能力,并且学习过程陷入局部极小点的可能性很小.

参考文献:

- [1] G Katragadda, J Wallace, J Lee, S Nair. Neural network inversion for thickness measurements and conductivity profiling [A]. Review of Progress in Quantitative Nondestructive Evaluation [C]. Plenum, New York: 1997.
- [2] K Zgonc, J D Achenbach. A neural network for crack sizing trained by finite element calculations [J]. NDT&E International, 1996, 29(3): 147- 155.
- [3] M Uesaka, K Hakuta, K Miya, et al. Eddy current testing by flexible microloop magnetic sensor array [J]. IEEE Trans Magn, 1998, 34(4): 2287- 2297.
- [4] M J Wits, et al. Artificial neural networks in process engineering [J]. IEEE Processings D. 1991, 138: 256- 266.

- [5] T Takagi, M Hashimoto, H Fukutomi, et al. Benchmark models of eddy current testing for steam generator tube: experiment and numerical analysis [J]. Int J of Applied Electromagnetics in Materials, 1994, 5(3): 149- 162.
- [6] 幸玲玲. 涡流无损检测中数值模拟与缺陷重构的研究 [D]. 西安: 西安交通大学, 1999.
- [7] S Geva, J Site. A constructive method for multivariate function approximation by multilayer perceptrons [J]. IEEE Trans Neural Network. 1992, 3(4): 621- 624.

作者简介:



幸玲玲 女, 1959 年生于江西省高安市, 2000 年在西安交通大学获博士学位, 目前主要研究方向为电磁场数值计算及其逆问题的求解, 涡流无损检测, 神经网络的应用等.

王东进 教授, 电磁场与微波技术专业, 目前主在研究方向为电磁散射与逆散射, 微波系统等.