

5.1 三维漏磁信号特征量值

参照国家标准 GB/T 27699—2011 中给出的分类标准,按照缺陷的长度及宽度特征,将金属损失型缺陷分为以下 6 种:针孔、水平凹槽、水平凹沟、切向凹槽、切向凹沟和坑状缺陷。以漏磁检测器扫查方向(同时是磁化方向)作为缺陷的长度方向,垂直该方向作为缺陷的宽度方向,以 t 作为被测件的厚度,则得到缺陷的分类标准如图 5.1 所示。

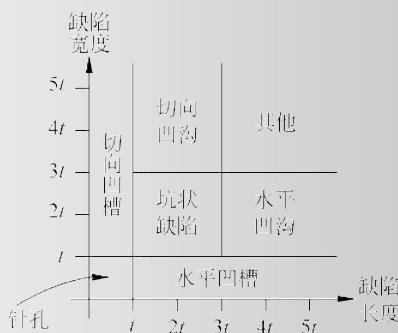


图 5.1 金属损失型缺陷分类标准

令 L 表示缺陷长度, W 表示缺陷宽度, 则从图中看出, 针孔缺陷的定义为 $L < t, W < t$; 坑状缺陷的定义为 $t < L < 3t, t < W < 3t$; 水平凹槽缺陷的定义为 $L > t, W < t$; 水平凹沟缺陷的定义为 $L > 3t, t < W < 3t$; 切向凹槽缺陷的定义为 $L < t, W > t$; 切向凹沟缺陷的定义为 $t < L < 3t, W > 3t$ 。

针孔缺陷与坑状缺陷在水平方向与切向方向的尺寸相近(相等), 其缺陷三维漏磁信号的峰值区域、谷值区域均呈现相似的形状, 本书将这两种缺陷归为一类, 统称为凹坑缺陷; 水平凹槽缺陷与水平凹沟缺陷的三维漏磁信号特征相近, 因此, 将这两种缺陷归为一类, 统称为水平沟槽缺陷; 切向凹槽缺陷与切向凹沟缺陷三维漏磁信号特征也相近, 因此将这两种缺陷也归为一类, 统称为切向沟槽缺陷。

为了获取更多的缺陷尺寸信息, 提高缺陷的量化精度, 分别对三种类型缺陷的三维漏磁信号进行分析, 并分别定义能够反映缺陷三维漏磁信号特征的信号参数。

5.1.1 凹坑缺陷的参数定义

图 5.2 为 $24\text{mm} \times 24\text{mm} \times 2.4\text{mm}$ 凹坑缺陷三维漏磁信号的三维立体图。基于缺陷三维漏磁信号水平分量、切向分量和法向分量的不同特征,对凹坑缺陷三维漏磁信号的参数进行定义,信号三个分量的参数分别以 P_h 、 P_t 和 P_v 表示。

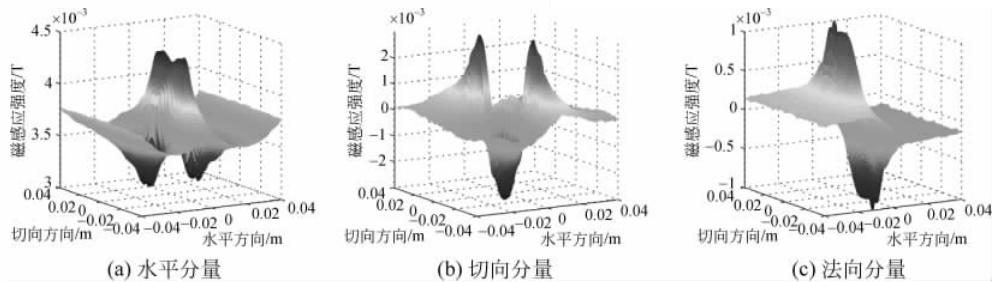


图 5.2 $24\text{mm} \times 24\text{mm} \times 2.4\text{mm}$ 凹坑缺陷三维漏磁信号三维立体图

由图 5.2(a)可知,凹坑缺陷漏磁信号的水平分量包括一个峰值区域和两个谷值区域,其峰值区域具有两个极大值与一个极小值;每个谷值区域包含有一个极小值,即为该信号的谷值。该信号切向坐标为 0 的曲线(记作水平轴线)的峰值即为该信号峰值区域的极小值点,也即缺陷的中心位置。同理,该信号水平方向坐标为 0 的曲线(记作切向轴线)的峰值即为该信号峰值区域的极大值点,也是该信号的峰值。从图 5.2 (a)可知,该峰值位置可以在一定程度上反映凹坑缺陷切向方向的延伸,即反映凹坑缺陷的直径信息。此外,由于对磁化是沿水平方向的,漏磁信号的水平分量会在缺陷处发生突变,该突变点的位置可以很好地表征缺陷在水平方向的延伸,因此需要提取水平轴线一阶微分信号的峰值坐标。

根据以上分析,针对漏磁信号的水平分量,共定义 15 个信号参数,如表 5.1 所示。

表 5.1 凹坑缺陷漏磁信号水平分量参数定义

参数	定义	单位	参数	定义	单位
P_{h1}	信号峰值	T	P_{h9}	信号梯度峰值水平坐标	mm
P_{h2}	信号峰值切向坐标	mm	P_{h10}	信号梯度峰值切向坐标	mm
P_{h3}	信号谷值	T	P_{h11}	信号强度积分	$\text{T} \times \text{mm}^2$
P_{h4}	信号谷值水平坐标	mm	P_{h12}	信号强度平方的积分	$\text{T}^2 \times \text{mm}^2$
P_{h5}	信号峰谷值	T	P_{h13}	水平轴线峰值	T
P_{h6}	信号峰值区域内点数	个	P_{h14}	水平轴线微分信号峰值	T/m
P_{h7}	信号谷值区域内点数	个	P_{h15}	水平轴线一阶微分信号	
P_{h8}	信号梯度峰值	T/mm		峰值水平坐标	mm

由图 5.2(b)可知,凹坑缺陷漏磁信号的切向分量包括两个峰值区域和两个谷值区域。其中,每个峰值区域包含一个极大值,每个谷值区域包含一个极小值,均反映了缺陷深度的信息。从图 5.2(b)可知,该峰值位置可以在一定程度上反映缺陷的轮廓位置。除此之外,由于漏磁信号会在缺陷边界处发生突变,突变点的位置可以表征缺陷轮廓的直径,因此,提取了梯度最大点的坐标。针对漏凹坑缺陷磁信号的切向分量,共定义 9 个信号参数,如表 5.2 所示。

表 5.2 凹坑缺陷漏磁信号切向分量的参数定义

信号参数	定 义	单位
P_{t1}	信号峰值	T
P_{t2}	信号峰值水平坐标	mm
P_{t3}	信号峰值切向坐标	mm
P_{t4}	信号峰值半径	mm
P_{t5}	信号梯度峰值	T/mm
P_{t6}	信号梯度峰值水平坐标	mm
P_{t7}	信号梯度峰值切向坐标	mm
P_{t8}	信号强度积分	$T \times mm^2$
P_{t9}	信号强度平方的积分	$T^2 \times mm^2$

由图 5.2(c)可知,凹坑缺陷的漏磁信号的法向分量包括一个峰值区域和一个谷值区域,反映了凹坑缺陷的深度信息。同时,信号的峰、谷值位置在一定程度上反映了凹坑缺陷的轮廓位置。此外,信号突变点的位置表征了凹坑缺陷的直径,且该突变点位于水平轴线上,因此,提取了水平轴线一阶微分信号的峰值坐标。针对凹坑缺陷漏磁信号的法向分量,共定义 8 个信号参数,如表 5.3 所示。

表 5.3 凹坑缺陷漏磁信号法向分量的参数定义

信号参数	定 义	单位
P_{v1}	信号峰值	T
P_{v2}	信号峰值水平坐标	mm
P_{v3}	信号峰值区域内点数	个
P_{v4}	信号谷值区域内点数	个
P_{v5}	信号强度积分	$T \times mm^2$
P_{v6}	信号强度平方的积分	$T^2 \times mm^2$
P_{v7}	水平轴线一阶微分信号峰值	T/m
P_{v8}	水平轴线一阶微分信号峰值水平坐标	mm

5.1.2 水平沟槽缺陷的参数定义

图 5.3 为 $48mm \times 24mm \times 1.2mm$ 水平沟槽缺陷三维漏磁信号的三维立体图。针对缺陷三维漏磁信号水平分量、切向分量和法向分量的不同特征,仿照对凹坑缺陷的分析方法,这里对水平沟槽缺陷三维漏磁信号的参数进行定义,信号三个分量的参数分别以 H_h 、 H_t 和 H_v 表示。

由图 5.3(a)可知,与凹坑缺陷相比,水平沟槽缺陷三维漏磁信号水平分量的不同之处在于,该信号具有两个峰值区域,且两个峰值区域之间的跨度可表征缺陷在水平方向的延伸。此外,该信号水平方向坐标为 0 的曲线(记作切向轴线)在缺陷切向边沿处发生突变,与缺陷宽度关系密切。据此,在进行特征量值提取时,增加了信号峰值区域跨度、切向轴线一阶微分信号峰值水平坐标等信号参数。针对水平槽缺陷漏磁信号的水平分量,共定义 16 个信号参数,如表 5.4 所示。

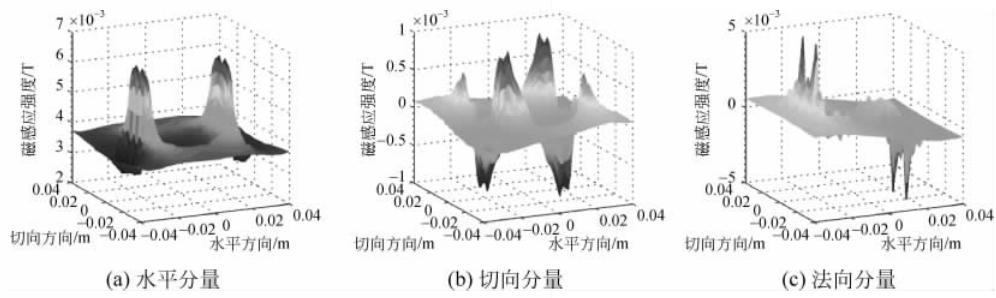


图 5.3 48mm×24mm×1.2mm 水平沟槽缺陷三维漏磁信号三维立体图

表 5.4 水平沟槽缺陷漏磁信号水平分量的参数定义

信号参数	定 义	单位
H_{h1}	信号峰值	T
H_{h2}	信号峰值水平坐标	mm
H_{h3}	信号谷值	T
H_{h4}	信号谷值水平坐标	mm
H_{h5}	信号峰谷值	T
H_{h6}	信号中间极小值	T
H_{h7}	信号峰值区域跨度	mm
H_{h8}	信号谷值区域跨度	mm
H_{h9}	信号强度积分	$T \times mm^2$
H_{h10}	信号强度平方的积分	$T^2 \times mm^2$
H_{h11}	水平轴线峰值	T
H_{h12}	水平轴线峰值水平坐标	mm
H_{h13}	水平轴线一阶微分信号峰值	T/m
H_{h14}	水平轴线一阶微分信号峰值水平坐标	mm
H_{h15}	切向轴线一阶微分信号峰值	T/m
H_{h16}	切向轴线一阶微分信号峰值水平坐标	mm

由图 5.3(b)可知,不同于凹坑缺陷,水平沟槽缺陷三维漏磁信号的切向分量除了包含两个峰值,还包含两个极大值。该极大值的水平坐标与切向坐标分别反映了缺陷的长度信息与宽度信息,因此,在选取水平沟槽缺陷三维漏磁信号切向分量的信号参数时,增加了与极大值相关的参数。此外,水平沟槽缺陷的长度与宽度差别较大,导致其三维漏磁信号切向分量的峰值半径不再反映缺陷几何参数信息,在进行信号参数定义时,不再选用此参数。针对水平槽缺陷漏磁信号的切向分量,共定义 12 个信号参数,如表 5.5 所示。

表 5.5 水平沟槽缺陷漏磁信号切向分量的参数定义

信号参数	定 义	单位
H_{t1}	信号峰值	T
H_{t2}	信号峰值水平坐标	mm
H_{t3}	信号峰值切向坐标	mm
H_{t4}	信号极大值	T
H_{t5}	信号极大值水平坐标	mm

续表

信号参数	定 义	单位
H_{t6}	信号极大值切向坐标	mm
H_{t7}	信号极大值半径	mm
H_{t8}	信号梯度峰值	T/mm
H_{t9}	信号梯度峰值水平坐标	mm
H_{t10}	信号梯度峰值切向坐标	mm
H_{t11}	信号强度积分	$T \times mm^2$
H_{t12}	信号强度平方的积分	$T^2 \times mm^2$

由图 5.3(c)可知,相较于凹坑缺陷,水平沟槽缺陷三维漏磁信号的法向分量不再包含峰值区域,而是具有两个明显的峰值点。在进行信号参数定义时,不再选用信号峰值区域内点数,而是根据信号特征,提取信号峰值的水平坐标与切向坐标作为信号参数。针对水平槽缺陷漏磁信号的法向分量,共定义 7 个信号参数,如表 5.6 所示。

表 5.6 水平沟槽缺陷漏磁信号法向分量的参数定义

信号参数	定 义	单位
H_{v1}	信号峰值	T
H_{v2}	信号峰值水平坐标	mm
H_{v3}	信号峰值切向坐标	mm
H_{v4}	信号强度积分	$T \times mm^2$
H_{v5}	信号强度平方的积分	$T^2 \times mm^2$
H_{v6}	水平轴线一阶微分信号峰值	T/m
H_{v7}	水平轴线一阶微分信号峰值水平坐标	mm

5.1.3 切向沟槽缺陷的参数定义

图 5.4 为 24mm×48mm×1.2mm 切向沟槽缺陷三维漏磁信号的三维立体图。针对缺陷三维漏磁信号水平分量、切向分量和法向分量的不同特征,按照之前给出的对凹坑缺陷与水平沟槽缺陷的分析方法,这里对切向沟槽缺陷三维漏磁信号的参数进行定义,信号三个分量的参数分别以 T_h 、 T_t 和 T_v 表示,选取结果分别在表 5.7、表 5.8 和表 5.9 中给出。

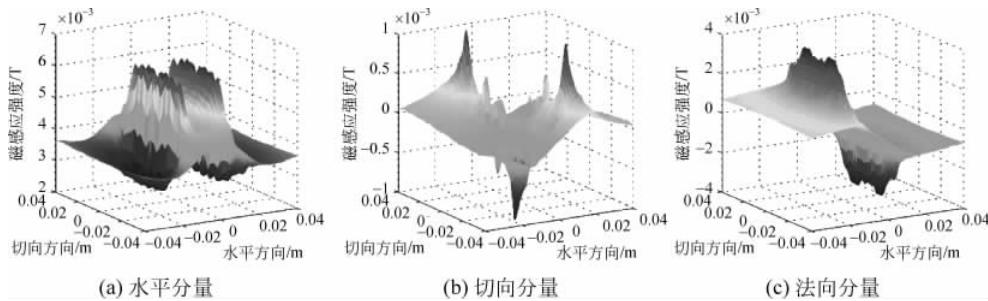


图 5.4 24mm×48mm×1.2mm 切向沟槽缺陷三维漏磁信号三维立体图

表 5.7 切向沟槽缺陷漏磁信号水平分量的参数定义

信号参数	定 义	单位
T_{h1}	信号峰值	T
T_{h2}	信号峰值水平坐标	mm
T_{h3}	信号谷值	T
T_{h4}	信号谷值水平坐标	mm
T_{h5}	信号峰谷值	T
T_{h6}	信号中间极小值	T
T_{h7}	信号峰值区域跨度	mm
T_{h8}	信号谷值区域跨度	mm
T_{h9}	信号峰值区域间距	mm
T_{h10}	信号强度积分	$T \times mm^2$
T_{h11}	信号强度平方的积分	$T^2 \times mm^2$
T_{h12}	水平轴线一阶微分信号峰值	T/m
T_{h13}	水平轴线一阶微分信号峰值水平坐标	mm

表 5.8 切向沟槽缺陷漏磁信号切向分量的参数定义

信号参数	定 义	单位
T_{t1}	信号峰值	T
T_{t2}	信号峰值水平坐标	mm
T_{t3}	信号峰值切向坐标	mm
T_{t4}	信号峰值半径	mm
T_{t5}	信号极大值	T
T_{t6}	信号梯度峰值	T/mm
T_{t7}	信号梯度峰值水平坐标	mm
T_{t8}	信号梯度峰值切向坐标	mm
T_{t9}	信号强度积分	$T \times mm^2$
T_{t10}	信号强度平方的积分	$T^2 \times mm^2$

表 5.9 切向沟槽缺陷漏磁信号法向分量的参数定义

信号参数	定 义	单位
T_{v1}	信号峰值	T
T_{v2}	信号峰值水平坐标	mm
T_{v3}	信号峰值区域跨度	mm
T_{v4}	信号峰值区域与谷值区域间距	mm
T_{v5}	信号强度积分	$T \times mm^2$
T_{v6}	信号强度平方的积分	$T^2 \times mm^2$
T_{v7}	水平轴线峰值	T
T_{v8}	水平轴线峰值水平坐标	mm
T_{v9}	水平轴线一阶微分信号峰值	T/m
T_{v10}	水平轴线一阶微分信号峰值水平坐标	mm

5.2 完整信号下的缺陷分类量化方法

以神经网络对缺陷进行量化通常采用统一的网络进行缺陷参数预测,并未考虑不同形状缺陷的漏磁检测信号之间的差异,结果导致缺陷的量化误差较大。为了提高缺陷的量化精度,首先基于三维漏磁信号对缺陷进行分类,再针对不同类型的缺陷,分别训练相应的神经网络以用于相应类别缺陷的量化。

首先,针对凹坑、水平沟槽和切向沟槽这三种类型的缺陷,建立用于缺陷分类的 RBF 神经网络。由于不同种类缺陷三维漏磁信号之间的差异较大,通过提取特征量值的方法,难以得到合适的缺陷分类神经网络的输入信号。为此,提出缺陷漏磁信号水平分量的网格平均处理方法,用于获取 RBF 分类网络的输入信号。并通过缺陷分类实验,验证所建立的 RBF 分类网络的分类准确度。

其次,针对凹坑、水平沟槽和切向沟槽三类缺陷,分别构建用于缺陷几何尺寸量化的 BP 神经网络。为了控制所构建 BP 神经网络的复杂度,以节约对所构建 BP 神经网络的训练时间,在网络训练过程中引入贝叶斯(Bayesian)算法,在修正各层间连接权值的同时自动修正网络的超参数。

最后,通过缺陷量化实验,对所提出的量化神经网络的训练时间、缺陷量化精度以及抗干扰能力等性能进行验证。

5.2.1 基于 RBF 神经网络的缺陷分类方法

在神经网络模型中,单个神经元只能实现从输入信号到输出信号的线性变换。在基于神经网络对缺陷进行分类时,为了实现输入数据与输出数据之间的非线性映射,采用了径向基神经网络(radial-basis function neural networks)。径向基神经网络以径向基函数作为传递函数,完成输入数据从非线性空间到线性空间的映射,再根据权值进行线性变换,得到最终的输出数据。在隐含层神经元足够多的前提下,这种将数据从非线性空间转换到线性空间的变换,可实现对漏磁检测缺陷的分类。

在 RBF 神经网络的结构中,输入层与隐含层之间不存在权值连接,仅通过径向基函数进行信息传递,而隐含层与输出层之间依靠权值进行信息传递。设 $\mathbf{I} = (I_1, \dots, I_m)$ 为该神经网络的输入向量, \mathbf{O} 为输出信号, $\boldsymbol{\varphi} = (\varphi_1, \dots, \varphi_m)$ 为连接输入层与隐含层的径向基函数, $\mathbf{c} = (c_1, \dots, c_m)$ 为径向基函数的中心, $\mathbf{w} = (w_1, \dots, w_n)$ 为连接该神经网络隐含层与输出层的权值, n 为隐含层所包含的神经元个数, θ 为常数,则可计算得到 RBF 神经网络的输出函数为

$$\hat{\mathbf{O}} = \sum_{i=1}^n w_i \varphi_i(\|\mathbf{I} - \mathbf{c}_i\|) + \theta \quad (5-1)$$

选择式(5-2)所示的高斯函数作为径向基函数:

$$\varphi(\|\mathbf{I} - \mathbf{c}\|) = \exp\left(-\frac{\|\mathbf{I} - \mathbf{c}\|^2}{2\sigma^2}\right) \quad (5-2)$$

其中, σ 为高斯函数的标准差。所选的高斯函数具有如下特点: 在节点中心处的函数值很

大,在远离中心处的函数值迅速下降。

在对 RBF 神经网络进行训练时,通过调整权值 w 、径向基函数的中心 c 和标准差 σ 来减小该神经网络实际输出值与目标输出值之间的差距。以均方误差作为神经网络训练过程中的目标函数,即

$$E = \sum_{j=1}^N \frac{1}{N} (\hat{O}_j - O_j)^2 = \sum_{j=1}^N \frac{1}{N} \left(\sum_{i=1}^n w_{i,j} \varphi_i(\|I - c_i\|) + \theta - O_j \right)^2 \quad (5-3)$$

在 RBF 神经网络的训练过程中,基于最速下降算法对权值、径向基函数的中心与标准差进行修正。由此得到神经网络训练过程中第 L 个输出信号所对应的网络参数的改变量为

$$\Delta w_{i,L} = -\eta_w \frac{\partial E}{\partial w_{i,L}} = -\frac{2\eta_w}{N} \left(\sum_{i=1}^n w_{i,L} \varphi_i(\|I - c_i\|) + \theta - O_L \right) \varphi_i(\|I - c_i\|) \quad (5-4)$$

$$\begin{aligned} \Delta c_i &= -\eta_c \frac{\partial E}{\partial c_i} \\ &= -\frac{2\eta_c}{N\sigma^2} \sum_{j=1}^N \left[w_{i,j} \left(\sum_{i=1}^n w_{i,j} \varphi_i(\|I - c_i\|) + \theta - O_L \right) \varphi_i(\|I - c_i\|) \|I - c_i\| \right] \end{aligned} \quad (5-5)$$

$$\begin{aligned} \Delta \sigma_i &= -\eta_\sigma \frac{\partial E}{\partial \sigma_i} \\ &= -\frac{2\eta_\sigma}{N\sigma_i^3} \sum_{j=1}^N \left[w_{i,j} \left(\sum_{i=1}^n w_{i,j} \varphi_i(\|I - c_i\|) + \theta - O_L \right) \varphi_i(\|I - c_i\|) \|I - c_i\|^2 \right] \end{aligned} \quad (5-6)$$

其中, η_w 、 η_c 、 η_σ 为该神经网络中各个参数的学习速率,用于自适应地调整网络参数、修正算法的步长。学习速率过小,会导致网络的收敛速度慢,且网络的训练时间过长;学习速率过大,网络训练过程中可能产生震荡,导致网络的稳定性较差。

根据前述缺陷分类标准,所训练 RBF 神经网络的分类对象包含凹坑、水平沟槽和切向沟槽缺陷三种。图 5.5 给出了这三类缺陷的三维漏磁信号水平分量的示例。在 5.1 节中已指出,三类缺陷水平方向漏磁信号的特征具有明显的差异,因此,在对这三类缺陷进行分类时,可以只采用其水平方向漏磁信号的特征作为神经网络的输入信号。

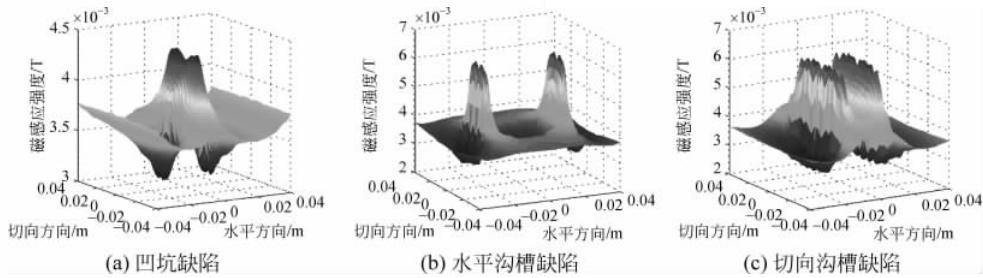


图 5.5 缺陷三维漏磁信号水平分量

由图 5.5 可以看出,凹坑、水平沟槽和切向沟槽三种类型缺陷的水平方向漏磁信号之间存在较大的差异。在选择 RBF 神经网络的输入信号时,通过提取特征量值的方法,难以获得统一的、能够准确地反映缺陷种类的特征量值。因此,针对水平方向的漏磁信号,提出了

一种网格平均处理方法,用于提取 RBF 分类网络的输入信号。

按照所提出的网格平均处理方法,需要对待处理的信号进行网格划分,并计算各网格内的信号平均值作为该网格的值。图 5.6 给出了凹坑、水平沟槽和切向沟槽三类缺陷的水平方向漏磁信号在进行网格平均处理后的结果。

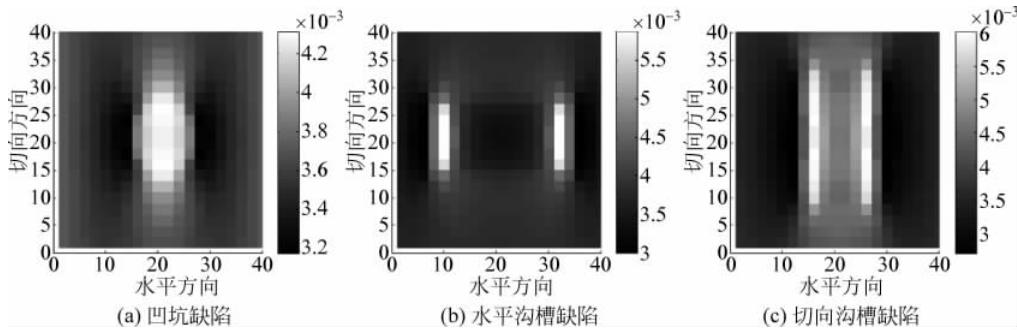


图 5.6 水平方向漏磁信号的网格平均处理结果

采用所提出的网格处理方法对缺陷的水平方向漏磁信号进行处理,可在保留信号主要特征的前提下,降低信号中的数据量。由图 5.6 可以看出,三种类型缺陷网格峰值集中区域之间的差异较大。因此,按照网格值的大小,提取网格值最大的 20 个网格位置,作为 RBF 神经网络的输入信号。

建立包含 90 个凹坑缺陷、150 个水平沟槽缺陷和 150 个切向沟槽缺陷的缺陷样本库,分别选取 70 个凹坑缺陷、70 个水平沟槽缺陷和 70 个切向沟槽缺陷作为神经网络的训练样本。另外,分别选取 20 个凹坑缺陷、20 个水平沟槽缺陷和 20 个切向沟槽缺陷作为测试样本,用于对分类神经网络的分类准确度进行测试。

以提取的网格位置作为 RBF 神经网络的输入信号,以 $[1,0,0]$ 、 $[0,1,0]$ 和 $[0,0,1]$ 代表凹坑缺陷、水平沟槽缺陷和切向沟槽缺陷,并将其作为所构建 RBF 神经网络的输出信号。将 RBF 神经网络训练的目标误差设置为 0.001,当训练结果满足预先设定好的目标误差时,即完成对 RBF 神经网络的训练。

图 5.7 给出了 RBF 神经网络的训练过程曲线。由图可知,经过 4556 次训练,所构建的 RBF 神经网络达到了预先设定的精度要求。

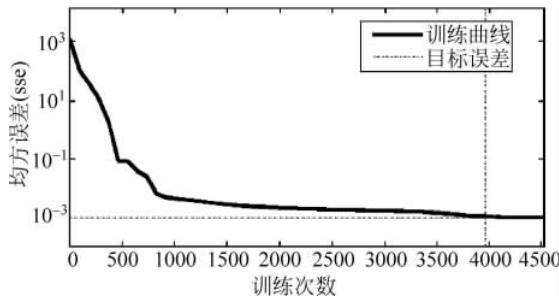


图 5.7 RBF 神经网络训练过程曲线

以 60 个缺陷测试样本对所训练的分类网络进行验证,表 5.10 给出了其中 6 个测试样本的缺陷分类结果(包含测试样本中 3 个分类错误的样本)。

表 5.10 6 个测试样本的缺陷分类结果

缺陷编号	实际缺陷种类	理想输出参数	实际输出参数	判断缺陷种类
1	凹坑缺陷	[1,0,0]	[0.8267,0.1280,0.0454]	凹坑缺陷
3	凹坑缺陷	[1,0,0]	[-0.1329,1.0390,0.0938]	水平沟槽缺陷
21	水平沟槽缺陷	[0,1,0]	[-0.0771,0.9951,0.0821]	水平沟槽缺陷
28	水平沟槽缺陷	[0,1,0]	[0.8012,0.0526,0.1462]	凹坑缺陷
41	切向沟槽缺陷	[0,1,0]	[0.1385,-0.0332,0.8947]	切向沟槽缺陷
52	切向沟槽缺陷	[0,1,0]	[0.8650,0.0276,0.1074]	凹坑缺陷

以测试样本 1 的缺陷分类结果为例, RBF 神经网络的实际输出为 [0.8267, 0.1280, 0.0454], 对其进行四舍五入后, 得到缺陷分类的近似结果 [1,0,0], 据此, 该缺陷的分类为凹坑缺陷。对测试样本 28 进行同样的分类判断, 该缺陷实际为水平沟槽缺陷, 然而其缺陷分类的结果为凹坑缺陷, 说明网络分类出现了错误。

图 5.8 为全部 60 个测试样本的缺陷分类结果。由图可知, 在 60 个测试样本缺陷中, 共有 5 个样本的分类结果错误, 分类的正确率为 91.7%。这表明, 训练得到的 RBF 神经网络可实现对三类缺陷的分类。

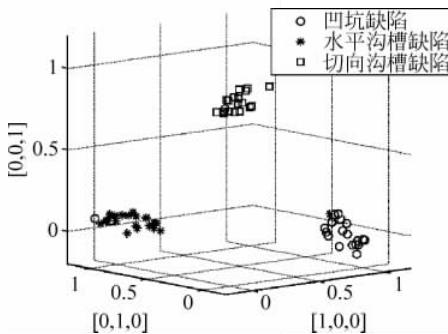


图 5.8 60 个测试样本的缺陷分类结果

5.2.2 基于 BP 神经网络的缺陷量化方法

BP 神经网络具有较强的非线性映射能力, 在具有足够多神经元的前提下, BP 神经网络可以无限逼近于任意的非线性函数, 因而, 可用于建立缺陷三维漏磁信号特征量值与缺陷几何尺寸之间的非线性映射关系。

在 BP 神经网络中, 以 $\mathbf{I} = (I_1, \dots, I_m)$ 表示输入信号, 以 $\mathbf{O} = (O_1, \dots, O_n)$ 表示输出信号, 用 $\mathbf{D} = (\mathbf{I}, \mathbf{O})$ 代表训练样本集, 以 w_1 表示连接输入层与隐含层的权值, 用 w_2 表示连接隐含层与输出层的权值, 以 $\mathbf{W} = (w_1, w_2)$ 表示整体权值, 并以 p 表示隐含层所包含的神经元个数, 则可计算得到 BP 神经网络的输出函数, 即

$$\hat{O}_n = \sum_{i=1}^p w_2(i) \tanh \left(\sum_{j=1}^m w_1(j) I_j + \theta_1(j) \right) + \theta_2 \quad (5-7)$$

基于误差最小原则对 BP 神经网络进行训练, 即通过减小实际输出值与目标输出值之间的误差, 对其中的权值进行调整。据此, 可得到 BP 神经网络训练过程中的目标函数, 即

$$\begin{aligned} E_D &= \sum_{n=1}^N \frac{1}{N} (\hat{O}_n - O_n)^2 \\ &= \sum_{n=1}^N \frac{1}{N} \left\{ \left[\sum_{i=1}^p w_{2,n}(i) \tanh \left(\sum_{j=1}^m w_{1,n}(j) I_j + \theta_1(j) \right) + \theta_2 \right] - O_n \right\}^2 \end{aligned} \quad (5-8)$$

在 BP 神经网络的训练过程中, 常用最速下降法来优化权值, 即求取式(5-8)的极小值。由此得到训练过程中第 L 个输出信号所对应权值的改变量, 即

$$\begin{aligned} \Delta w_{1,L}(j) &= -\eta \frac{\partial E_D}{\partial w_{1,L}(j)} \\ &= -\frac{2\eta}{N} \left[\sum_{i=1}^p w_{2,L}(i) \sec^2 \left(\sum_{j=1}^m w_{1,L}(j) I_j + \theta_1(j) \right) I_j \right] \\ &\quad \times \left\{ \left[\sum_{i=1}^p w_{2,L}(i) \tanh \left(\sum_{j=1}^m w_{1,L}(j) I_j + \theta_1(j) \right) + \theta_2 \right] - O_L \right\} \end{aligned} \quad (5-9)$$

$$\begin{aligned} \Delta w_2(i) &= -\eta \frac{\partial E_D}{\partial w_2(i)} \\ &= -\frac{2\eta}{N} \tanh \left(\sum_{j=1}^m w_1(j) I_j + \theta_1(j) \right) \\ &\quad \times \left\{ \left[w_2(i) \tanh \left(\sum_{j=1}^m w_1(j) I_j + \theta_1(j) \right) + \theta_2 \right] - O_L \right\} \end{aligned} \quad (5-10)$$

其中, η 为权值修正过程的学习速率, 用于在梯度下降算法中调整权值的修正步长。

采用以上模型对 BP 神经网络的权值进行修正时, 需要预先设定隐含层神经元的数目。如果神经元数目过多, 会导致该神经网络复杂度高、泛化能力差。但如果神经元数目过少, 则会导致该神经网络的非线性拟合度较差。为了将神经元数目调整到合适的值, 从而减少其对该神经网络造成的影响, 在该神经网络的训练中, 在目标函数的基础上增加了衰减函数, 即

$$E_w = \sum_m \frac{1}{2} w_1^2 + \sum_p \frac{1}{2} w_2^2 \quad (5-11)$$

通过控制式(5-11)的取值大小, 可有效地控制该神经网络的复杂度。因此可得到该神经网络训练的最终目标函数, 即

$$E = \alpha E_w + \beta E_D = \alpha \left(\sum_m \frac{1}{2} w_1^2 + \sum_p \frac{1}{2} w_2^2 \right) + \beta \sum_n \frac{1}{N} (\hat{O}_n - O_n)^2 \quad (5-12)$$

其中, α 和 β 为超参数, 用于对网络的复杂度进行调整。

若 $\alpha \gg \beta$, 说明训练目标为尽可能减小实际输出与目标输出之间的误差, 对网络规模的控制较少, 导致该神经网络出现了过度拟合; 若 $\alpha \ll \beta$, 说明训练目标为尽可能减小网络的复杂度, 会导致该神经网络的非线性拟合能力较差。

采用最速下降算法对该神经网络进行优化时, 无法实现对超参数 α, β 的调整。因此, 将贝叶斯算法引入 BP 神经网络的优化过程, 在训练过程中实现超参数的自适应调整, 从而在该神经网络的误差与该神经网络的规模之间取得平衡。

贝叶斯算法是一种常用的对参数范围进行估计的方法, 其本质是利用事件在过去的出现概率, 对事件在未来的出现概率进行预测, 即利用先验概率分布来求解后验概率分布。依据贝叶斯定理, 任意待求量均可被看作随机变量, 能通过概率分布对其进行描述。贝叶斯定

理通过贝叶斯公式进行表达,即

$$p(\theta | x) = \frac{p(x | \theta)p(\theta)}{p(x)} = \frac{p(x | \theta)p(\theta)}{\int p(x | \theta)p(\theta) d\theta} \quad (5-13)$$

其中, θ 为待求的随机变量; x 为样本; $p(\theta | x)$ 为 θ 的后验分布信息,即待求随机变量的分布信息; $p(\theta)$ 代表 θ 的先验分布信息,即待求随机变量所拥有的初始概率; $p(x)$ 是样本 x 的边缘分布,通常被视为不依赖于变量 θ 的归一化因子。

由式(5-13)可知,贝叶斯算法是通过待求随机变量的先验分布信息与样本的分布概率对变量的后验分布信息进行求解的。由于 $p(x)$ 为归一化因子,故贝叶斯定理的公式可等价为

$$p(\theta | x) \propto p(x | \theta)p(\theta) \quad (5-14)$$

由上式可知,待求量 θ 的后验分布,反映了抽样以后对随机变量 θ 的认识,即抽样信息对先验分布产生影响后的结果。

基于贝叶斯算法的BP神经网络,通过贝叶斯算法对神经网络的权值进行调整。其具体操作流程为将神经网络中的所有参数看作随机变量,基于目标参数的先验概率分布与实际输入、输出信号的样本数据,对神经网络的权值范围做进一步修正,并通过BP神经网络模型复杂度的控制,节约神经网络的训练时间,降低神经网络过度拟合的可能性并提高BP神经网络的泛化能力。

以 A 表示神经网络,根据贝叶斯定理,采用无样本数据时神经网络权值的先验分布 $p(w | A)$,对有样本 $D = (I_m, O_n)$ 后神经网络权值的后验分布 $p(w | D, \alpha, \beta, A)$ 进行估计。得到神经网络权值的后验概率分布函数,即

$$p(w | D, \alpha, \beta, A) = \frac{p(D | w, \beta, A)p(w | \alpha, A)}{p(D | \alpha, \beta, A)} \quad (5-15)$$

其中, $p(D | w, \beta, A)$ 为似然函数,即样本的联合分布。

$p(D | \alpha, \beta, A)$ 为归一化因子,有

$$p(D | \alpha, \beta, A) = \int_{-\infty}^{\infty} p(D | \alpha, \beta, A)p(w | \alpha, H) dw \quad (5-16)$$

将神经网络样本的分布看作一个均值为0、方差 $\sigma^2 = \frac{1}{\beta}$ 的高斯分布,则可得到似然函数

$$p(D | w, \beta, A) = \frac{1}{Z_p(\beta)} \exp(-\beta E_D) \quad (5-17)$$

在上式中, $Z_p(\beta)$ 为归一化因子,可写为

$$Z_p(\beta) = \left(\frac{2\pi}{\beta}\right)^{\frac{m}{2}} \quad (5-18)$$

同理,假设神经网络权值的分布是一个均值为0、方差 $\sigma^2 = \frac{1}{\alpha}$ 的高斯分布,则可得到神经网络权值的先验分布,即

$$p(w | \alpha, A) = \frac{1}{Z_w(\alpha)} \exp(-\alpha E_w) \quad (5-19)$$

在上式中, $Z_w(\alpha)$ 为归一化因子,可写为

$$Z_w(\alpha) = \left(\frac{2\pi}{\alpha}\right)^{\frac{m}{2}} \quad (5-20)$$

根据式(5-15)、式(5-17)和式(5-19),可得到神经网络权值的后验概率分布函数为

$$p(w | D, \alpha, \beta, A) = \frac{\frac{1}{Z_p(\beta)} \exp(-\beta E_D) \times \frac{1}{Z_w(\alpha)} \exp(-\alpha E_w)}{p(D | \alpha, \beta, A)} = \frac{\exp(-E)}{Z_F(\alpha, \beta)} \quad (5-21)$$

在以上框架下,对目标函数 E 做最小化处理,即可得到最可能的神经网络权值参数 w 。

在神经网络权值 w 给定的前提下,可以对神经网络的超参数 α, β 的后验概率分布进行估计。根据贝叶斯定理,得到超参数的后验概率分布,即

$$p(\alpha, \beta | D, A) = \frac{p(D | \alpha, \beta, A) p(\alpha, \beta | A)}{p(D | A)} \quad (5-22)$$

根据式(5-12)和式(5-21),归一化因子 $p(D | \alpha, \beta, A)$ 可写为

$$p(D | \alpha, \beta, A) = \frac{Z_F(\alpha, \beta)}{Z_w(\alpha) Z_p(\beta)} \quad (5-23)$$

目标函数 E 在网络参数 w 处进行泰勒展开,并以此对目标函数进行最小化,从而得到使目标函数最小的神经网络权值 w_{MP} ,并基于此,求得可能性最大的超参数 α, β ,即

$$\alpha_{MP} = \frac{\gamma}{2E_w(w_{MP})} \quad (5-24)$$

$$\beta_{MP} = \frac{m - \gamma}{2E_D(w_{MP})} \quad (5-25)$$

其中, γ 可通过神经网络的有效参数来表示。

综合以上分析,得到基于贝叶斯算法的 BP 神经网络的训练流程,如图 5.9 所示。

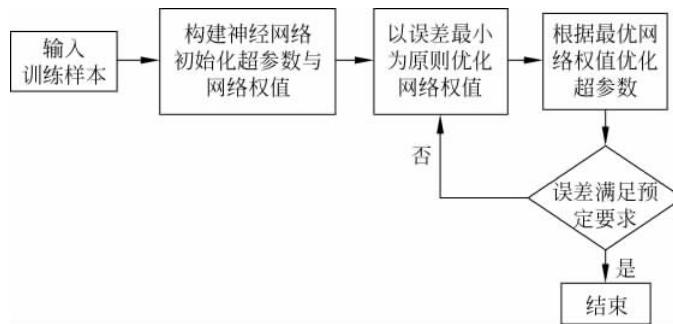


图 5.9 基于贝叶斯算法的 BP 神经网络训练流程

具体的 BP 神经网络训练过程如下:

- (1) 将训练样本 $D = (I_m, O_n)$ 输入到神经网络中;
- (2) 给定初始神经网络结构, 初始化神经网络的超参数 α, β , 初始化 BP 神经网络的权值 w ;
- (3) 以误差最小为原则, 最小化神经网络目标函数 E , 计算得到最优的 BP 神经网络权值 w ;
- (4) 在最优网络权值 w 的基础上, 计算最优的网络超参数 α, β ;
- (5) 若 BP 神经网络优化函数 E 满足设定的误差要求, 则结束神经网络的训练过程, 得到训练好的神经网络; 若优化函数 E 不满足设定的误差要求, 且神经网络训练次数仍未达

到上限,则重复步骤(3),直至优化函数 E 满足要求,得到符合期望的神经网络;若神经网络训练次数达到上限时,优化函数 E 仍不满足误差要求,则表明当前的神经网络不收敛。

根据以上的 BP 神经网络训练流程,可以构建缺陷几何尺寸信息与缺陷三维漏磁信号特征量值之间的非线性映射关系。

为了验证基于贝叶斯算法的 BP 神经网络在减少神经网络训练时间上的有效性,以及其用于缺陷量化时的量化精度,需要进行对应的缺陷量化实验。首先,构建基于贝叶斯算法的 BP 神经网络,采用缺陷三维漏信号关键特征量值作为 BP 神经网络的输入信号,采用缺陷几何尺寸作为 BP 神经网络的输出信号,得到缺陷三维漏磁信号关键特征量值与缺陷几何尺寸之间的映射关系。进而比较引入贝叶斯算法对网络进行优化前后的网络训练时间,并采用测试数据验证所训练神经网络的量化精度与抗干扰能力。

针对凹坑缺陷,利用包含 90 个缺陷的缺陷样本库,提取样本库内缺陷三维漏磁信号的关键特征量值。从这些缺陷样本中,选择 79 组用于神经网络的训练,剩余 11 组样本将作为测试数据,用于对训练好的神经网络的量化精度进行验证。

以 0.001 作为神经网络训练的目标均方误差,图 5.10 和图 5.11 分别给出了对凹坑缺陷直径进行量化的神经网络训练过程,以及对凹坑缺陷深度进行量化的神经网络训练过程。其中,图 5.10(a)与图 5.11(a)基于传统的 BP 神经网络,采用缺陷三维漏磁信号的关键特征量值对缺陷的直径、深度进行量化。图 5.10(b)与图 5.11(b)是基于贝叶斯算法的 BP 神经网络,采用缺陷一维漏磁信号的关键特征量值对缺陷直径、深度进行量化。图 5.10(c)与图 5.11(c)则给出了基于贝叶斯算法的 BP 神经网络,采用缺陷三维漏磁信号特征量值对缺陷直径、深度进行量化的网络训练过程。在各个训练过程图中,均用虚线标识了神经网络训练的目标误差。

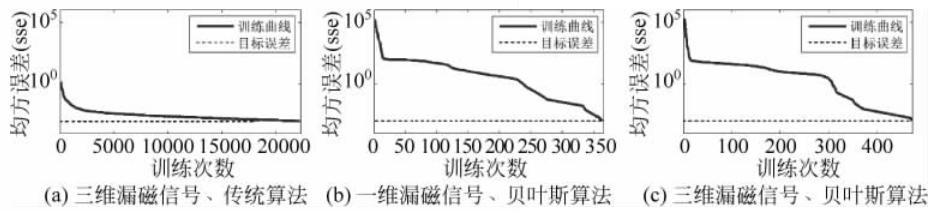


图 5.10 凹坑缺陷直径量化神经网络的训练过程

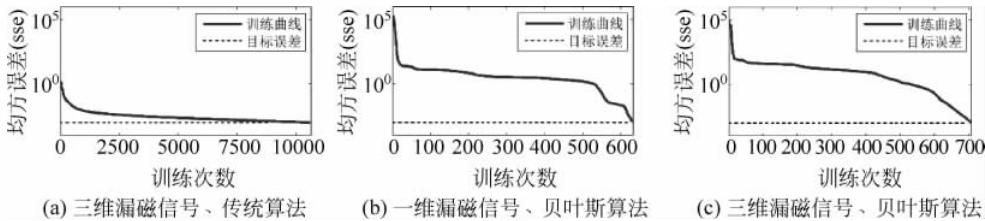


图 5.11 凹坑缺陷深度量化神经网络训练过程比较

对比图 5.10(a)与图 5.10(c)可以看出,在采用缺陷三维漏磁信号特征量值对神经网络进行训练时,传统 BP 神经网络经过 22 598 次训练达到了预期目标,而基于贝叶斯算法的 BP 神经网络只需 473 次训练就达到了预期目标,其收敛速度更快,可有效地减少训练时间。

而对比图 5.10(b)与图 5.10(c)可以看出,采用缺陷一维漏磁信号特征量值对神经网络进行训练时,经过 365 次训练达到了预期目标,比采用缺陷三维漏磁信号特征量值进行训练的次数要少,这与神经网络输入变量的减少是一致的。比较图 5.11(a)与图 5.11(c)、图 5.11(b)与图 5.11(c),也可得到相同的结论。以上结果表明,基于贝叶斯算法的 BP 神经网络,相比于传统的 BP 神经网络,具有收敛速度快、训练时间短的优点。

针对凹坑缺陷,统计 11 个测试样本的缺陷直径与深度的量化结果,如图 5.12 所示。其中,横坐标代表 11 个缺陷样本的编号,纵坐标代表该缺陷尺寸的量化结果与缺陷实际几何尺寸的相对比例。表 5.11 给出了不同情况下针对凹坑缺陷量化结果的最大相对误差。

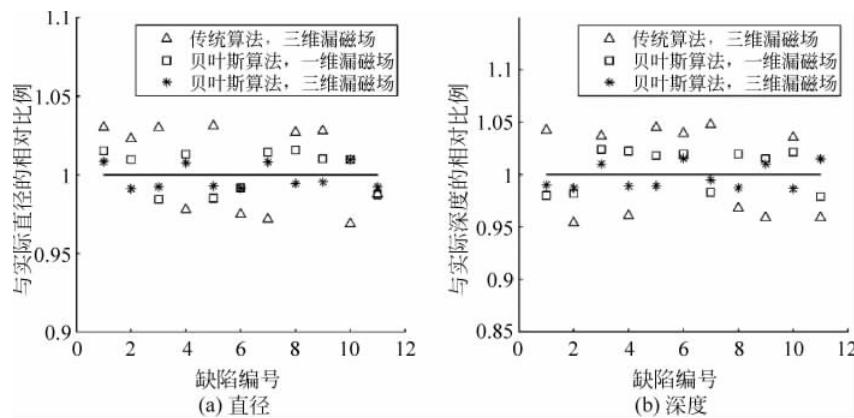


图 5.12 凹坑缺陷量化结果与实际尺寸的相对比例

表 5.11 凹坑缺陷量化的最大相对误差

缺陷参数	传统 BP 神经网络 三维漏磁信号	贝叶斯算法 一维漏磁信号	贝叶斯算法 三维漏磁信号
直径	3.12%	1.59%	0.97%
深度	4.78%	2.26%	1.54%

从表 5.11 中给出的量化结果可以看出,在采用三维漏磁信号特征量值对缺陷进行量化时,使用传统 BP 神经网络对缺陷直径、深度量化的最大相对误差要大于基于贝叶斯算法的 BP 神经网络量化的最大相对误差。从图 5.12 中也可以看出,在各测试样本的量化结果中,传统 BP 神经网络的量化误差普遍高于基于贝叶斯算法的 BP 神经网络的量化误差。以上结果表明,基于贝叶斯算法的 BP 神经网络,可在缺陷三维漏磁信号的特征量值与缺陷几何尺寸之间建立更好的映射关系,能提高对凹坑缺陷的量化精度。

除此之外,在采用基于贝叶斯算法的 BP 神经网络对缺陷进行量化时,使用三维漏磁信号对缺陷直径、深度量化的最大相对误差要小于使用一维漏磁信号进行量化的最大相对误差。在各测试样本的量化结果中,也可看出,采用缺陷三维漏磁信号量化的相对误差普遍低于采用一维漏磁信号的量化误差。以上结果表明,缺陷三维漏磁信号包含有更多的缺陷信息,采用三维漏磁信号对储罐底板缺陷进行量化能有效提高缺陷的量化精度。

针对水平沟槽缺陷,利用其包含 150 个缺陷的样本库,提取样本库内缺陷的三维漏磁信号的关键特征量值。在这些缺陷样本中,选择 130 组缺陷样本用于神经网络的训练,剩余

20组样本用于对训练好的神经网络进行量化精度的验证。

以0.001作为网络训练的目标误差,图5.13、图5.14与图5.15分别给出了对水平沟槽缺陷长度、宽度、深度进行量化的神经网络的训练过程。图5.13(a)、图5.14(a)与图5.15(a)为基于传统BP神经网络、采用缺陷三维漏磁信号特征量值进行量化的网络训练过程。图5.13(b)、图5.14(b)与图5.15(b)为基于贝叶斯算法的BP神经网络,采用缺陷一维漏磁信号特征量值进行量化的网络训练过程。图5.13(c)、图5.14(c)与图5.15(c)为基于贝叶斯算法的BP神经网络,采用缺陷三维漏磁信号特征量值进行量化的网络训练过程。图中,用虚线标识了网络训练的目标误差,即0.001。

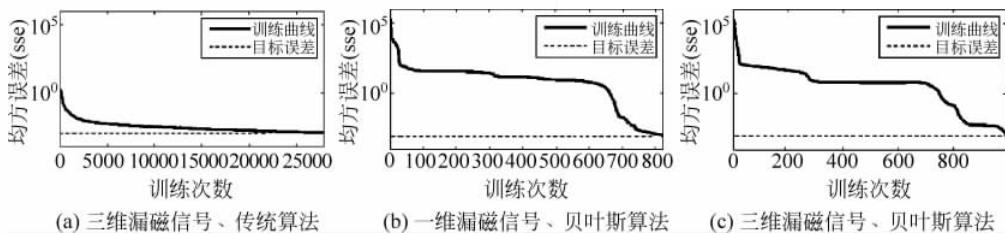


图5.13 水平沟槽缺陷长度量化神经网络训练过程比较

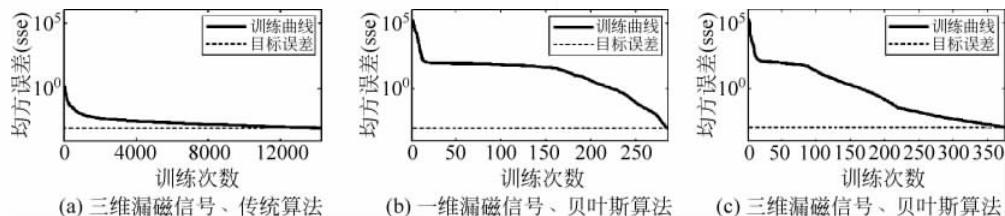


图5.14 水平沟槽缺陷宽度量化神经网络训练过程比较

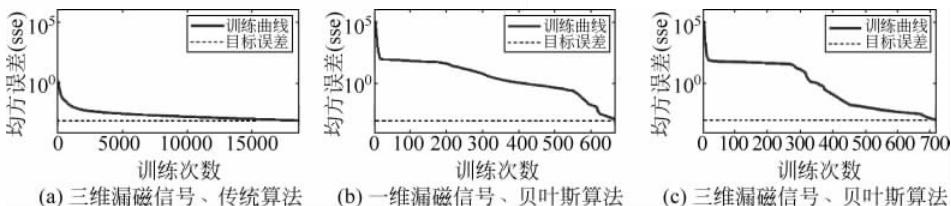


图5.15 水平沟槽缺陷深度量化神经网络训练过程比较

通过图5.13(a)与图5.13(c)、图5.14(a)与图5.14(c)、图5.15(a)与图5.15(c),可以对比采用传统BP神经网络与基于贝叶斯算法的BP神经网络的训练过程。在对缺陷长度、宽度和深度进行量化的神经网络的训练过程中,传统BP神经网络分别经过28 931、14 305、19 625次训练可达到预期目标,基于贝叶斯算法的BP神经网络只经过994、375、717次训练就达到了预期目标。这一结果,验证了基于贝叶斯算法的BP神经网络的收敛速度更快。

通过图5.13(b)与图5.13(c)、图5.14(b)与图5.14(c)、图5.15(b)与图5.15(c),可以对比使用基于贝叶斯算法的BP神经网络时,采用缺陷一维漏磁信号特征量值与采用缺陷三维漏磁信号特征量值的网络训练过程。可以看出,在对缺陷长度、宽度和深度进行量化的神经网络的训练过程中,采用缺陷一维漏磁信号特征量值的神经网络分别经过824、286、

666 次训练达到了预期目标,比采用缺陷三维漏磁信号特征量值进行训练的次数略少,与其采用了较少的漏磁信号特征量值相符。

针对水平沟槽缺陷,统计 20 个测试缺陷样本的长度、宽度、深度的量化结果,如图 5.16 所示。表 5.12 给出了水平沟槽缺陷尺寸量化结果的最大相对误差。

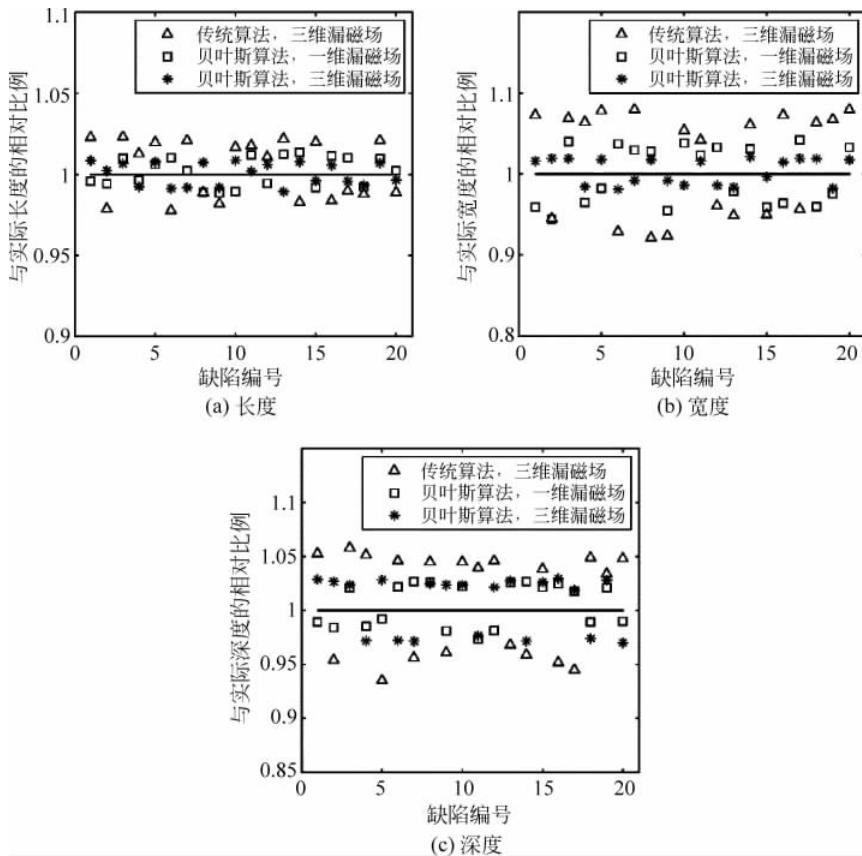


图 5.16 水平沟槽缺陷量化结果与实际尺寸相对比例

表 5.12 水平沟槽缺陷量化的最大相对误差

缺陷参数	传统 BP 神经网络	贝叶斯算法	贝叶斯算法
	三维漏磁信号	一维漏磁信号	三维漏磁信号
长度	2.32%	1.07%	0.86%
宽度	7.98%	4.52%	2.13%
深度	5.98%	2.69%	3.03%

从表 5.12 中给出的量化结果可以看出,在采用三维漏磁信号对水平沟槽缺陷进行量化时,使用传统 BP 神经网络对缺陷长度、宽度、深度量化的最大相对误差要大于基于贝叶斯算法的 BP 神经网络量化的最大相对误差。从图 5.16 中同样可以看出,在 20 个测试样本的量化结果中,传统 BP 神经网络的量化误差普遍高于基于贝叶斯算法的 BP 神经网络的量化误差。由此可知,采用基于贝叶斯算法的 BP 神经网络能有效地提高对储罐底板水平沟槽缺陷的量化精度。

由表 5.12 可知,在采用基于贝叶斯算法的 BP 神经网络对水平沟槽缺陷进行量化时,使用缺陷三维漏磁信号进行量化的最大相对误差要小于使用一维漏磁信号进行量化的最大相对误差。且在图 5.16 所示的量化结果中,采用三维漏磁信号对缺陷进行量化的相对误差普遍低于采用一维漏磁信号的量化误差。这是由于,缺陷三维漏磁信号包含有更多缺陷信息,因而,采用三维漏磁信号对储罐底板水平沟槽缺陷长度、宽度进行量化,能有效提高缺陷的量化精度。

在 150 个切向沟槽缺陷样本中,选择 130 组用于神经网络的训练,剩余 20 组用于验证训练好的神经网络的量化精度。

图 5.17、图 5.18 与图 5.19 分别给出了针对切向沟槽缺陷长度、宽度和深度量化的网络的训练过程。其中,图 5.17(a)、图 5.18(a)与图 5.19 (a)为基于传统 BP 神经网络、采用缺陷三维漏磁信号特征量值对缺陷进行量化的神经网络训练过程;图 5.17 (b)、图 5.18(b)与图 5.19 (b)为基于贝叶斯算法的 BP 神经网络,采用缺陷一维漏磁信号特征量值对缺陷进行量化的神经网络训练过程;图 5.17 (c)、图 5.18(c)与图 5.19(c)为基于贝叶斯算法的 BP 神经网络,采用缺陷三维漏磁信号特征量值对缺陷进行量化的神经网络训练过程。

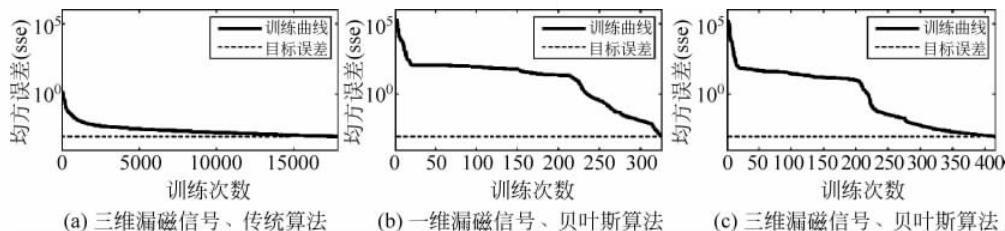


图 5.17 切向沟槽缺陷长度量化神经网络训练过程比较

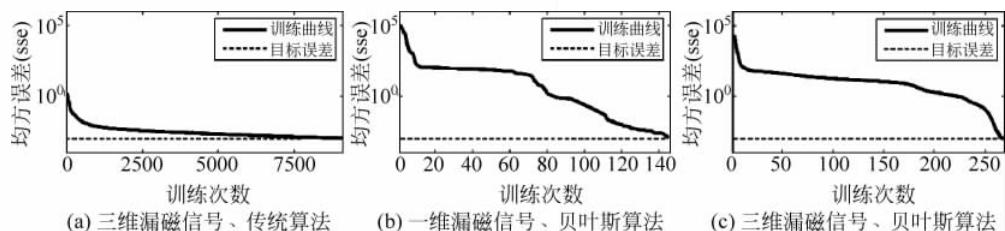


图 5.18 切向沟槽缺陷宽度量化神经网络训练过程比较

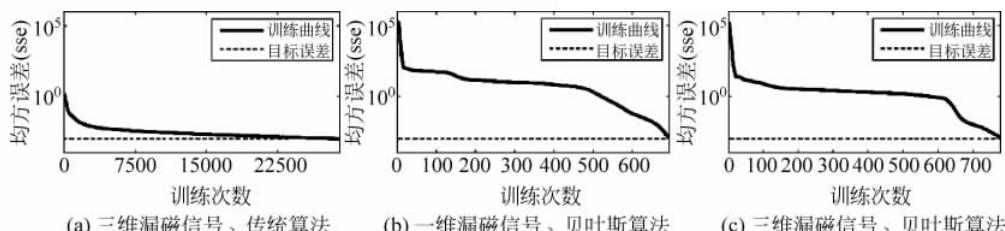


图 5.19 切向沟槽缺陷深度量化神经网络训练过程比较

基于图 5.17 (a)与图 5.17 (c)、图 5.18 (a)与图 5.18(c)、图 5.19(a)与图 5.19(c),可以对比采用缺陷三维漏磁信号特征量值时,分别使用传统 BP 神经网络与基于贝叶斯算法

的 BP 神经网络的网络训练次数。传统 BP 神经网络分别经过 17 882、9185、28 652 次训练达到了预期目标,而基于贝叶斯算法的 BP 神经网络只经过 416、269、779 次训练就达到了预期目标,这进一步验证了基于贝叶斯算法的 BP 神经网络的较快的收敛速度。此外,从图 5.17(b)、图 5.18(b)与图 5.19(b)中可以看出,在切向沟槽缺陷的长度、宽度和深度量化神经网络的训练过程中,采用缺陷一维漏磁信号特征量值的神经网络训练,分别经过 326、146、694 次迭代后达到了预期目标,略少于图 5.17(c)、图 5.18(c)与图 5.19(c)中采用缺陷三维漏磁信号特征量值时的训练次数。这也是由于缺陷三维漏磁信号的特征量值多于一维漏磁信号的特征量值,增加了网络的输入变量。

图 5.20 给出了切向沟槽缺陷的 20 个测试样本的长度、宽度和深度量化结果,其中,横坐标代表 20 个缺陷的编号,纵坐标代表该缺陷长度、宽度和深度量化结果与缺陷实际几何尺寸的相对比例。表 5.13 统计了几种情况下切向沟槽缺陷量化结果的最大相对误差。

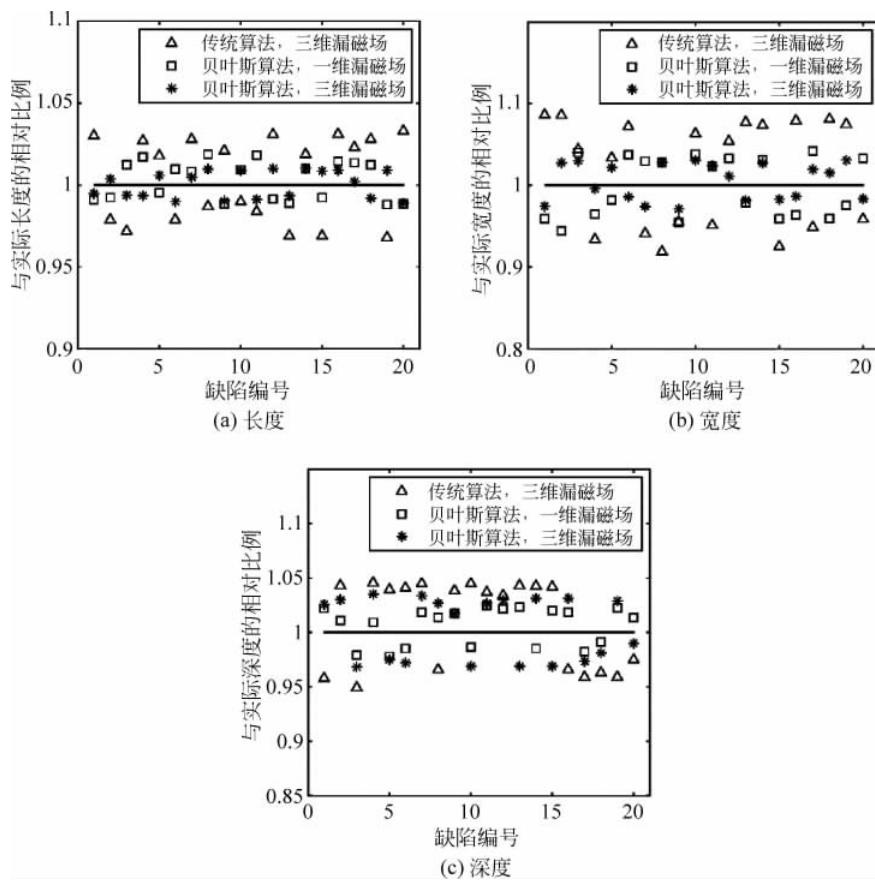


图 5.20 切向沟槽缺陷量化结果与实际尺寸相对比例

从图 5.20 与表 5.13 中给出的量化结果可以看出,与凹坑缺陷、水平沟槽缺陷的量化结果相似,采用传统 BP 神经网络对切向沟槽缺陷几何尺寸量化的误差要普遍高于基于贝叶斯算法的 BP 神经网络量化的误差。验证基于贝叶斯算法的 BP 神经网络能有效地提高对切向沟槽缺陷的量化精度。

在采用基于贝叶斯算法的 BP 神经网络对切向沟槽缺陷进行量化时,使用一维漏磁信

号对缺陷长度、宽度的量化误差要高于采用三维漏磁信号的量化误差,验证了缺陷三维漏磁信号包含有更多缺陷信息,可有效提高缺陷的量化精度。

表 5.13 切向沟槽缺陷量化的最大相对误差

缺陷参数	传统 BP 神经网络	贝叶斯算法	贝叶斯算法
	三维漏磁信号	一维漏磁信号	三维漏磁信号
长度	3.32%	1.86%	1.02%
宽度	8.65%	5.49%	3.01%
深度	4.48%	2.45%	3.51%

5.3 不完整信号下的缺陷量化与显示方法

本节将利用检测到的缺陷三维漏磁信号,反演得到缺陷的几何尺寸,从而实现对缺陷轮廓的实时显示。

在缺陷的检测过程中,存在以下问题:数据处理区域内不包含完整的缺陷三维漏磁信号,也就无法准确地实现缺陷的分类与量化。为了解决这一问题,将在已获得的不完整的缺陷三维漏磁信号的情况下,提出一种快速的缺陷轮廓显示方法。通过对缺陷边缘的识别与对缺陷深度的估计,在一定的允许误差前提下,实现基于不完整三维漏磁信号下的缺陷实时显示。

首先,为了识别不完整三维漏磁信号下的缺陷边缘,提出基于索贝尔离散性差分算子的缺陷边缘识别方法。采用索贝尔算子,求解缺陷三维漏磁信号的梯度。进而,采用阈值截取的方法,获取基于三维漏磁信号的缺陷边缘点,并据此进行边缘点的合成。对于合成后的边缘点进行曲线拟合,以获得最终的缺陷边缘。

其次,为了实现不完整三维漏磁信号下对缺陷深度的估计,提出基于信号等效处理的缺陷深度快速估计方法。提出缺陷不完整三维漏磁信号的等效处理方法,得到等价的缺陷完整三维漏磁信号,进而提取其关键特征量值,并以此作为深度量化神经网络的输入信号,对缺陷深度进行快速估计。最终,通过缺陷深度估计实验,验证所提出的不完整三维漏磁信号下缺陷深度快速估计方法的有效性。

最后,基于不完整三维漏磁信号下估计得到的缺陷边缘与深度,总结归纳出缺陷的实时显示方法。总结对缺陷种类进行判断的具体流程,并针对凹坑、水平沟槽和切向沟槽这三类缺陷,给出用于缺陷实时显示的缺陷轮廓求取方法。通过缺陷实时显示实验,对所提出的缺陷实时显示方法的可行性进行验证。

5.3.1 缺陷边缘识别

在不完整的缺陷三维漏磁信号下,数据处理区域内仅包含部分的缺陷漏磁信号。同时,检测器每完成一次扫查,数据处理区域内数据就进行一次队列更新。在缺陷反演过程中,仍然对每次扫查后数据处理区域内的静态漏磁场的数据进行处理。对每次扫查后的处理结果进行实时更新,即可得到实时显示的缺陷结果。

在漏磁检测过程中,磁力线在缺陷边缘处会发生突变。因此,缺陷三维漏磁检测信号的突变点即可反映被检出缺陷的边缘信息。据此,可采用缺陷三维漏磁信号的梯度值来对缺陷边缘进行检测。

鉴于数据处理区域内的信号具有不连续性,采用索贝尔离散性差分算子,对数据处理区域内每一点的梯度值进行计算。首先,针对数据处理区域内的信号点 (x, y) ,分别沿水平方向与切向方向,求得索贝尔边缘识别梯度值 $G_x(x, y)$ 与 $G_y(x, y)$ 。其中,水平方向的边缘识别梯度值 G_x 由该点沿水平方向上左列信号点 $(x-1, y-1)$ 、 $(x-1, y)$ 、 $(x-1, y+1)$ 与右列信号点 $(x+1, y-1)$ 、 $(x+1, y)$ 、 $(x+1, y+1)$ 的加权差值求得,可采用差分运算代替一阶偏导数运算;切向方向的边缘识别梯度值 G_y 由该点沿切向方向上左列信号点 $(x-1, y-1)$ 、 $(x, y-1)$ 、 $(x+1, y-1)$ 与右列信号点 $(x-1, y+1)$ 、 $(x, y+1)$ 、 $(x+1, y+1)$ 的加权差值求得。由此,可以求出

$$\begin{aligned} G_x(x, y) = & (-1) \times f(x-1, y-1) + 0 \times f(x, y-1) + 1 \times f(x+1, y-1) \\ & + (-2) \times f(x-1, y) + 0 \times f(x, y) + 1 \times f(x+1, y) \\ & + (-1) \times f(x-1, y+1) + 0 \times f(x, y+1) \\ & + 1 \times f(x+1, y+1) \end{aligned} \quad (5-26)$$

$$\begin{aligned} G_y(x, y) = & 1 \times f(x-1, y-1) + 2 \times f(x, y-1) + 1 \times f(x+1, y-1) \\ & + 0 \times f(x-1, y) + 0 \times f(x, y) + 0 \times f(x+1, y) \\ & + (-1) \times f(x-1, y+1) + (-2) \times f(x, y+1) \\ & + (-1) \times f(x+1, y+1) \end{aligned} \quad (5-27)$$

根据信号点 (x, y) 的水平方向与切向方向的梯度值 $G_x(x, y)$ 与 $G_y(x, y)$,可计算得到信号点 (x, y) 的梯度 $G(x, y)$ 与梯度方向 $\theta(x, y)$,即

$$G(x, y) = \sqrt{G_x(x, y)^2 + G_y(x, y)^2} \quad (5-28)$$

$$\theta(x, y) = \arctan(G_y(x, y)/G_x(x, y)) \quad (5-29)$$

在对数据处理区域内全部信号点 \mathbf{A} 进行处理时,以索贝尔卷积因子 \mathbf{G}_x 、 \mathbf{G}_y 对 \mathbf{A} 沿水平方向与切向方向进行卷积来实现水平方向与切向方向的差分运算,有

$$\mathbf{G}_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix}, \quad \mathbf{G}_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (5-30)$$

$$\mathbf{G}_x(\mathbf{A}) = \mathbf{G}_x * \mathbf{A} = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix} * \mathbf{A} \quad (5-31)$$

$$\mathbf{G}_y(\mathbf{A}) = \mathbf{A} * \mathbf{G}_y = \mathbf{A} * \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (5-32)$$

由此,可计算得到数据处理区域内全部信号点的梯度 $\mathbf{G}(\mathbf{A})$ 与梯度方向 $\theta(\mathbf{A})$,有

$$\mathbf{G}(\mathbf{A}) = \sqrt{\mathbf{G}_x(\mathbf{A})^2 + \mathbf{G}_y(\mathbf{A})^2} \quad (5-33)$$

$$\theta(\mathbf{A}) = \arctan\left(\frac{\mathbf{G}_y(\mathbf{A})}{\mathbf{G}_x(\mathbf{A})}\right) \quad (5-34)$$

采用以上方法,对凹坑缺陷、水平沟槽缺陷与切向沟槽缺陷的三维漏磁信号进行梯度求

解。图 5.21、图 5.22 和图 5.23 分别给出了三类缺陷三维漏磁信号的梯度分布强度图。

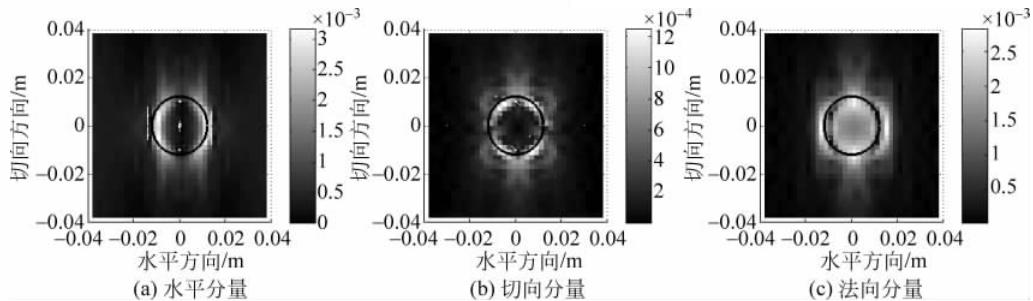


图 5.21 $24\text{mm} \times 24\text{mm} \times 2.4\text{mm}$ 凹坑缺陷三维漏磁信号梯度分布强度图

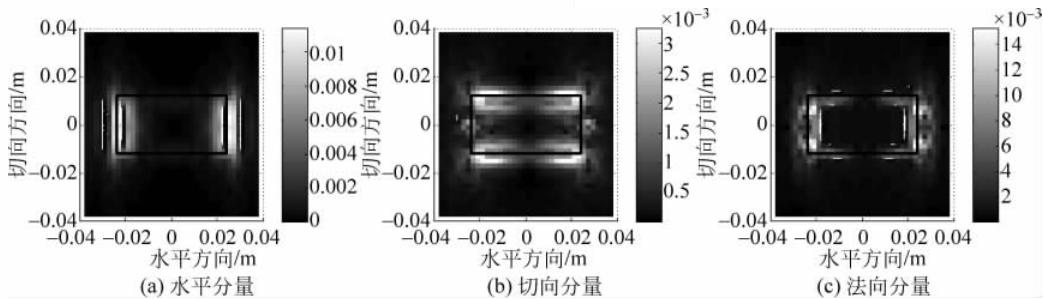


图 5.22 $48\text{mm} \times 24\text{mm} \times 1.2\text{mm}$ 水平沟槽缺陷三维漏磁信号梯度分布强度图

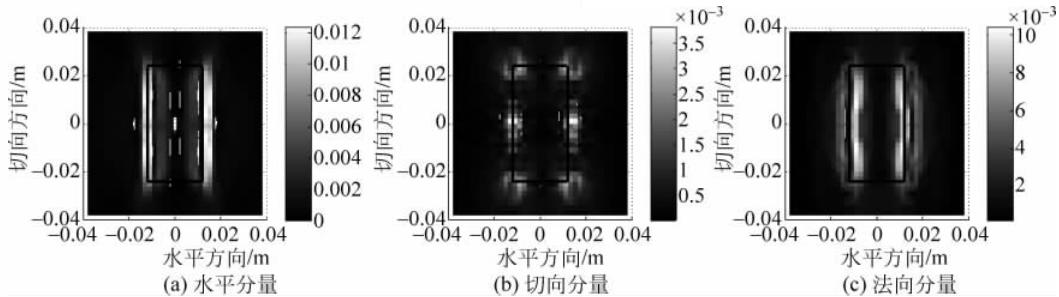


图 5.23 $24\text{mm} \times 48\text{mm} \times 1.2\text{mm}$ 切向沟槽缺陷三维漏磁信号梯度分布强度图

图 5.21、图 5.22 和图 5.23 中黑线为缺陷的实际边缘。可以看出,缺陷三维漏磁信号梯度的峰值分布区域均与缺陷的边缘吻合较好,但水平、切向、法向信号的吻合点存在一定的差异。

为了获取最终的缺陷边缘,针对水平、切向和法向这三个方向的漏磁信号,分别提取梯度的峰值区域分布。经调整,设定梯度信号峰谷值的 80%、65% 和 75% 作为截取阈值,得到凹坑缺陷、水平沟槽缺陷和切向沟槽缺陷的基于水平、切向和法向三个方向漏磁信号的边缘识别结果。进而将得到的三维边缘点进行合成,得到缺陷边缘点识别的合成结果,如图 5.24、图 5.25 和图 5.26 所示。

可以看出,水平、切向和法向三个方向的边缘点识别结果基本位于实际边缘左右,且各方向边缘点覆盖实际边缘的位置各有不同。因此,将三维边缘点合成,得到合成后的边缘点

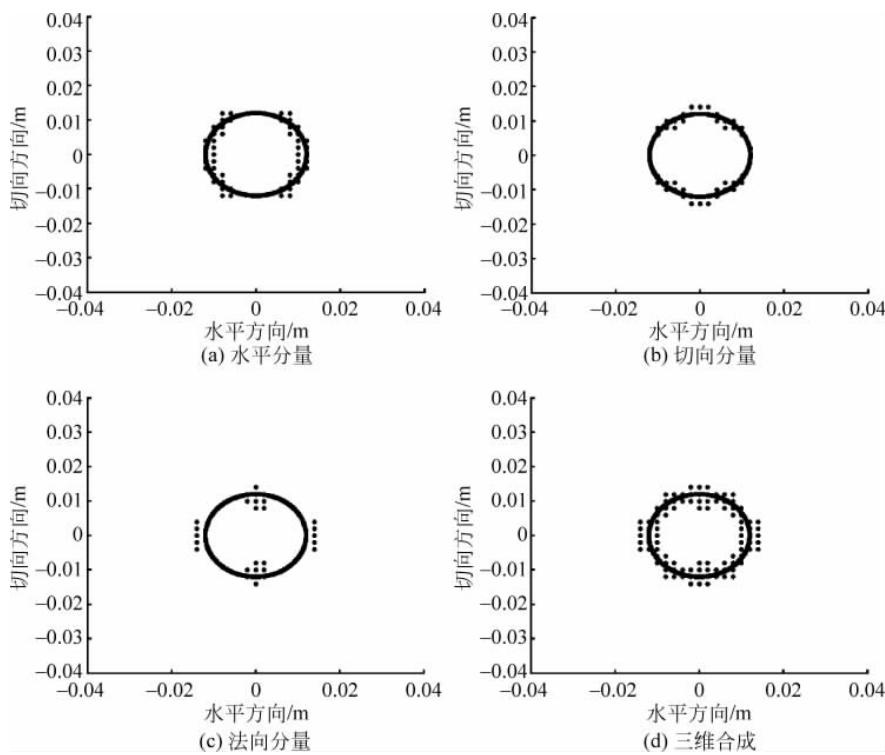


图 5.24 24mm×24mm×2.4mm 凹坑缺陷边缘点识别结果

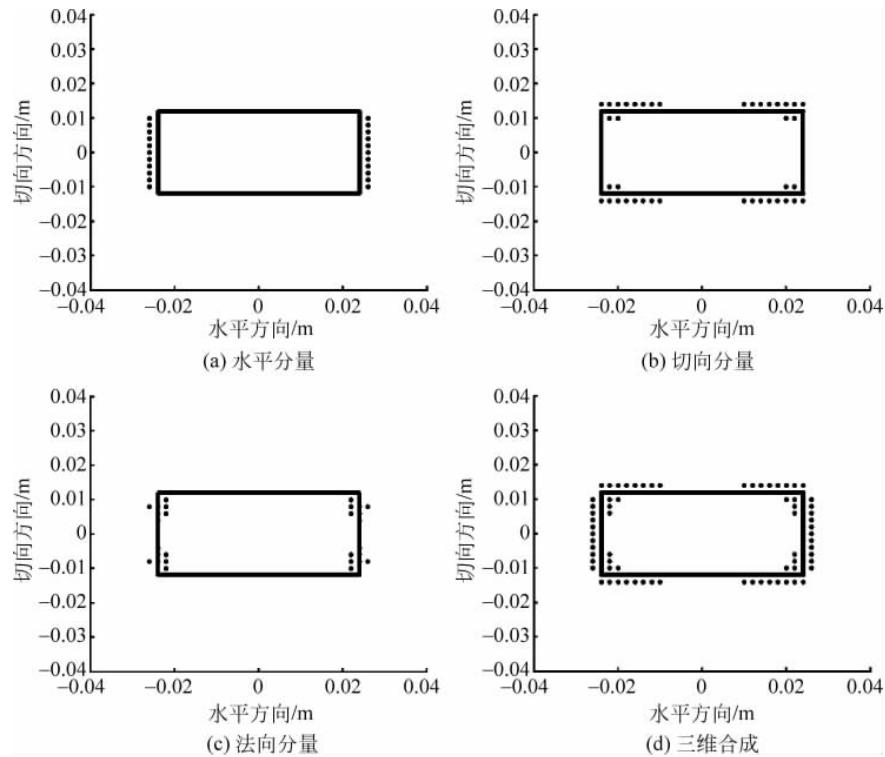


图 5.25 48mm×24mm×1.2mm 水平沟槽缺陷边缘点识别结果

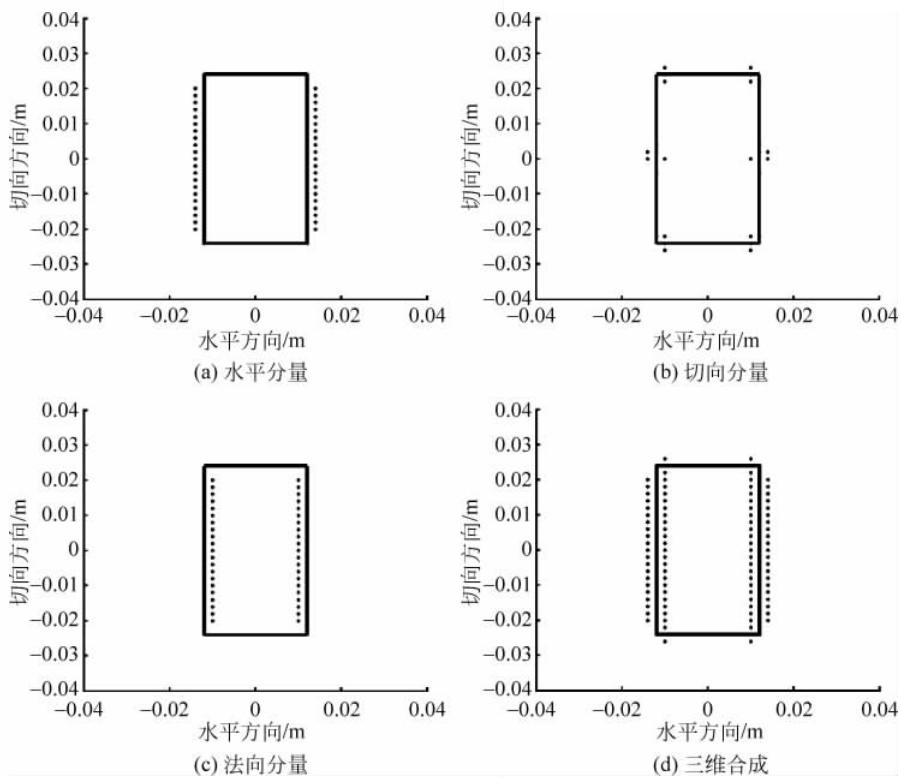


图 5.26 24mm×48mm×1.2mm 切向沟槽缺陷边缘点识别结果

的覆盖范围要大于实际的缺陷边缘。从图 5.24(d)、图 5.25(d)和图 5.26(d)中也可以看出,合成边缘点对缺陷沿切向方向的边缘的识别更加准确。这是由于,磁化方向是沿水平方向进行的,在该方向上的磁场变化更加明显,与之相切方向的边缘识别也就会更加清楚。

为了获取缺陷边缘的完整信息,以三维合成边缘点识别结果中的最外边缘点为基础进行曲线拟合,获取其中的封闭区域作为识别得到的缺陷,如图 5.27(a)、图 5.28 (a) 和图 5.29 (a)中蓝色区域所示。图 5.27(b)、图 5.28(b)和图 5.29(b)则为所识别的缺陷边缘与实际缺陷边缘的对比图。

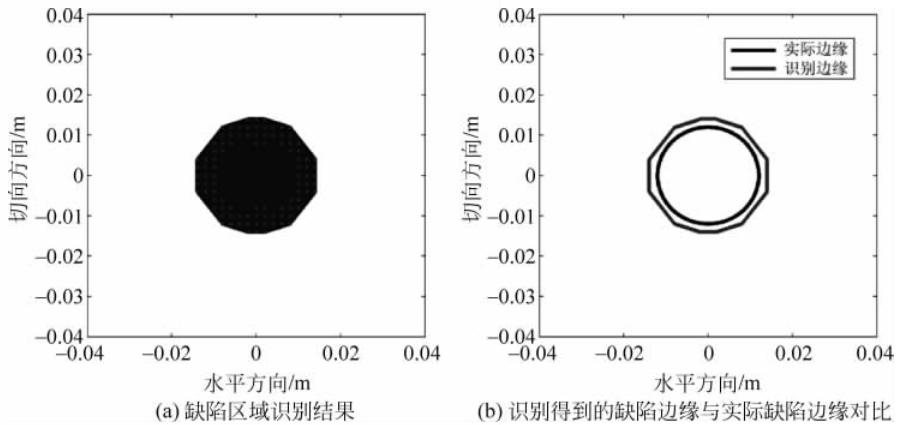
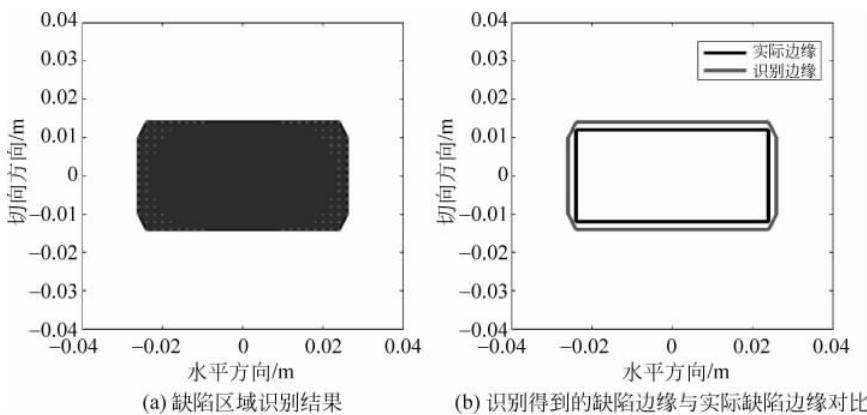
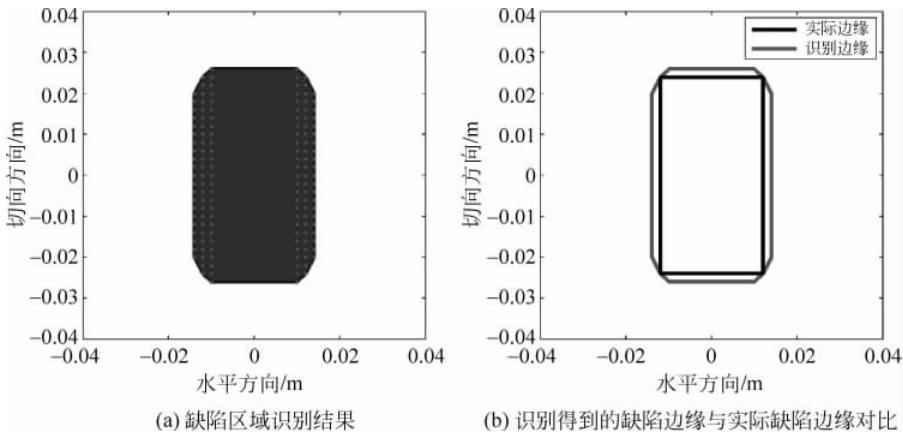


图 5.27 24mm×24mm×2.4mm 凹坑缺陷边缘识别结果

图 5.28 $48\text{mm} \times 24\text{mm} \times 1.2\text{mm}$ 水平沟槽缺陷边缘点识别结果图 5.29 $24\text{mm} \times 48\text{mm} \times 1.2\text{mm}$ 切向沟槽缺陷边缘点识别结果

对比识别得到的缺陷边缘与实际的缺陷边缘可知,基于三维信号梯度的缺陷边缘识别结果与实际的缺陷边缘非常相近,且其很好地包含了缺陷的实际边缘。除此之外,由图 5.27~图 5.29 可以看出,识别得到的缺陷边缘,最大仅超出实际边缘 1 个格点(2mm),相比于检测器的 5mm 采点间隔,该误差可以忽略不计。

为了验证所提出缺陷边缘识别方法对不完整信号下的缺陷相应部分的边缘识别的效果,分别对凹坑、水平沟槽和切向沟槽三类缺陷,进行不完整信号下的缺陷边缘识别实验。对每一类缺陷,分别在数据处理区域内包含 10%、30%、60%、90% 的缺陷三维漏磁信号条件下,进行缺陷的边缘识别。图 5.30 给出了 $30\text{mm} \times 30\text{mm} \times 2\text{mm}$ 凹坑缺陷在 10%、30%、60%、90% 的缺陷三维漏磁信号时的缺陷区域识别结果,图 5.31 则为识别边缘与实际边缘的对比结果。

由图 5.30 和图 5.31 可以看出,当数据处理区域内包含 10%、30%、60%、90% 的缺陷不完整三维漏磁信号时,识别得到的缺陷边缘与缺陷的实际边缘基本吻合。这表明,该边缘识别方法可以在不完整三维漏磁信号下对缺陷相应部分的边缘进行准确的识别。

值得注意的是,在将完整信号下的缺陷边缘识别方法用于不完整信号下的缺陷边缘识别时,存在两个问题。

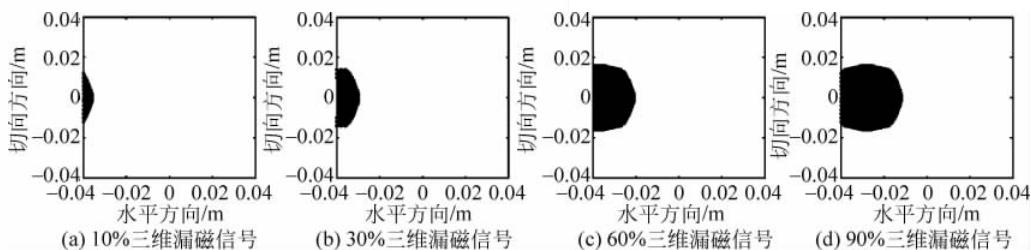


图 5.30 30mm×30mm×2mm 凹坑缺陷的缺陷区域识别结果

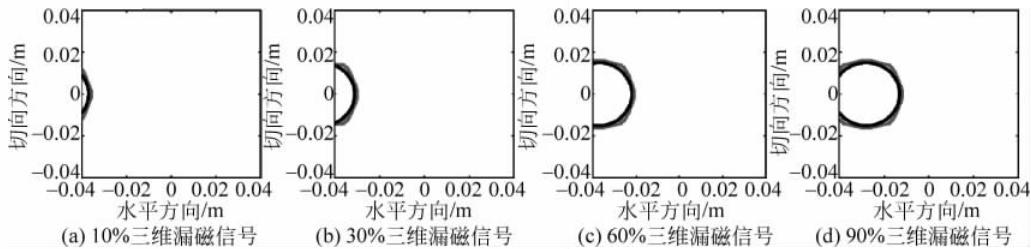


图 5.31 30mm×30mm×2mm 凹坑缺陷识别边缘与实际边缘对比

首先,当梯度信号在边沿处未达到峰值时,无法通过峰谷值的百分比作为截取阈值,如直接采用截取阈值,会将非缺陷的位置识别作缺陷。针对这一问题的解决办法是,在梯度信号中,设定用于判断缺陷起始的梯度阈值,当梯度信号达到这一梯度阈值时,再采用截取阈值的方法对边缘进行识别。由于缺陷三维漏磁信号在缺陷边缘处的变化很快,梯度信号会在短时间内达到峰值。实验表明,该方法在边缘识别初期可能造成不超出实际边缘 2 个格点(4mm)的误差,与检测器 5mm 的采点间隔相比,还是可以忽略不计的。

其次,当数据处理区域内包含少于 50% 的缺陷三维漏磁信号时,无法通过缺陷沿水平方向的两条边界的点共同确定缺陷区域。针对这一问题的解决办法为:以 50% 缺陷三维漏磁信号内的缺陷边缘约束缺陷宽度,并与数据处理区域内约束了缺陷宽度的后边缘点共同确定缺陷的区域。

为了识别 50% 缺陷三维漏磁信号这一状态点,对缺陷三维漏磁信号水平分量进行判断。取数据处理区域内最后 6 列数据点,以沿切向方向的中线为对称轴,比较对称轴两端对应数据点的相对误差。若 90% 以上数据点的相对误差小于 10%,则认为识别到 50% 缺陷三维漏磁信号状态点。

图 5.32、图 5.33、图 5.34 和图 5.35 给出了 40mm×20mm×2mm 水平沟槽缺陷、

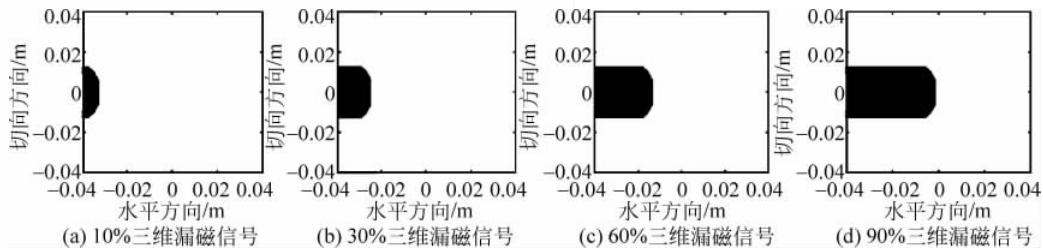


图 5.32 40mm×20mm×2mm 水平沟槽缺陷的缺陷区域识别结果

$20\text{mm} \times 40\text{mm} \times 2\text{mm}$ 切向沟槽缺陷在不完整三维漏磁信号时的缺陷区域识别结果以及识别边缘与实际边缘的对比结果。由图 5.32~图 5.35 可以看出, 在不同百分比的缺陷三维漏磁信号下, 识别的缺陷相应部分的边缘与实际缺陷边缘的吻合度均较高。

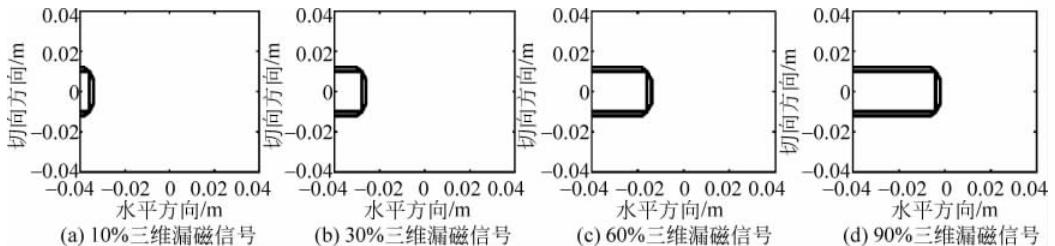


图 5.33 $40\text{mm} \times 20\text{mm} \times 2\text{mm}$ 水平沟槽缺陷识别边缘与实际边缘对比

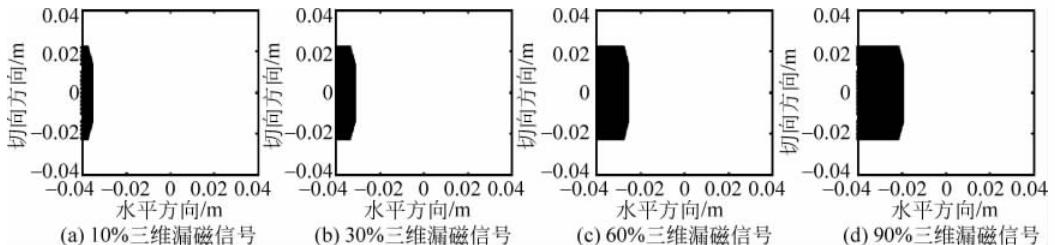


图 5.34 $20\text{mm} \times 40\text{mm} \times 2\text{mm}$ 切向沟槽缺陷区域识别结果

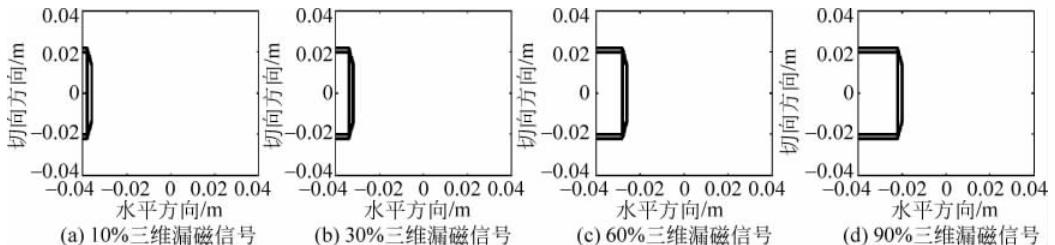


图 5.35 $20\text{mm} \times 40\text{mm} \times 2\text{mm}$ 切向沟槽缺陷识别边缘与实际边缘对比

5.3.2 缺陷深度估计

在已知缺陷边缘的前提下, 为了实现不完整信号下对缺陷相应部分的实时显示, 需要利用数据处理区域内不完整的缺陷三维漏磁信号对缺陷的深度进行估计。由于信号的不完整性, 对缺陷深度的估计不可避免地会存在一定误差。

在 2.2 节给出的完整三维漏磁信号的缺陷深度量化过程中, 采用神经网络方法, 训练并获得了以较高精度计算缺陷深度的神经网络。对不完整信号下要实现缺陷相应部分的显示, 仍利用神经网络来估算缺陷深度, 旨在满足实时显示缺陷的实际要求。然而, 采用神经网络进行缺陷的深度估计, 通常需要缺陷完整的三维漏磁信号。为了利用神经网络的快速特性, 提出一种缺陷不完整三维漏磁信号的等效处理方法, 从而得到等价的完整信号, 用于对缺陷深度进行快速估计。

在对信号进行等效处理前,首先对凹坑、水平沟槽、切向沟槽这三类缺陷深度量化中使用的完整三维漏磁信号关键特征量值进行分析。

在对凹坑缺陷的深度进行量化时,神经网络的输入信号为缺陷完整三维漏磁信号水平分量的信号峰值 P_{h1} 、信号谷值 P_{h3} 、切向分量的信号强度积分 P_{t8} 和法向分量的信号强度积分 P_{v5} 。在水平沟槽缺陷的深度的量化过程中,神经网络的输入信号为缺陷完整三维漏磁信号水平分量的信号峰值 H_{h1} 、信号强度积分 H_{h9} 、切向分量的信号极大值 H_{t4} 、法向分量的信号强度积分 H_{v4} 和水平轴线一阶微分信号峰值 H_{v6} 。在对切向沟槽缺陷的深度进行量化时,则将缺陷完整三维漏磁信号水平分量的信号峰谷值 T_{h5} 、信号强度积分 T_{h10} 、切向分量的信号峰值 T_{t1} 、法向分量的信号强度积分 T_{v5} 和水平轴线号峰值 T_{v7} 作为神经网络的输入。

以上用于深度量化的神经网络输入信号的共同点在于,当缺陷的直径、长度或宽度不变时,除了凹坑缺陷深度量化中的关键特征量值 P_{h3} 外,所有关键特征量值都随着缺陷深度的增加而逐渐增加。凹坑缺陷深度量化中的关键特征量值 P_{h3} 是随着缺陷深度的增加而逐渐减小的。据此,为了保证在缺陷三维漏磁信号信息量增加时,缺陷深度的估算准确度不断增加,在对不完整信号下缺陷三维漏磁信号进行等效处理时,处理后的信号应该满足:随着获取缺陷三维漏磁信号信息量的增加,凹坑缺陷深度量化中的关键特征量值 P_{h3} 逐渐减小,而除此之外的所有关键特征量值均应逐渐增大。

根据以上分析,在对缺陷不完整三维漏磁信号进行等效处理时,当已知的缺陷三维漏磁信号少于完整缺陷信号的 50% 时,将已有的缺陷不完整三维漏磁信号的水平分量沿切向平面进行偶对称处理;将切向分量沿切向平面进行偶对称处理后,再沿水平平面进行偶对称;将法向分量沿切向平面进行奇对称处理。

以 $24\text{mm} \times 24\text{mm} \times 2.4\text{mm}$ 凹坑缺陷为例,对数据处理区域内分别包含 10%、25%、40% 缺陷三维漏磁信号的水平、切向、法向信号,进行信号的等效处理,得到图 5.36、图 5.37 和图 5.38 所示的处理结果。

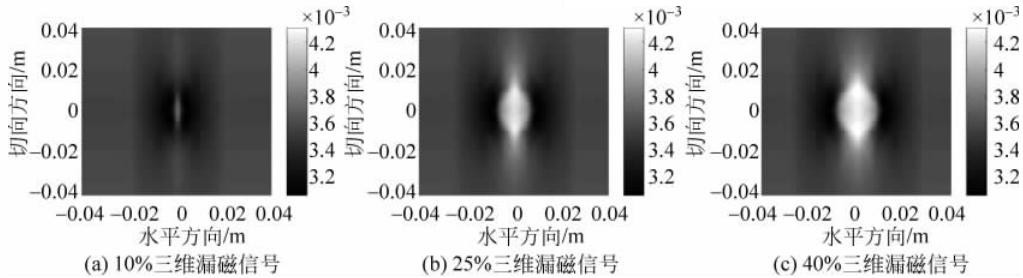
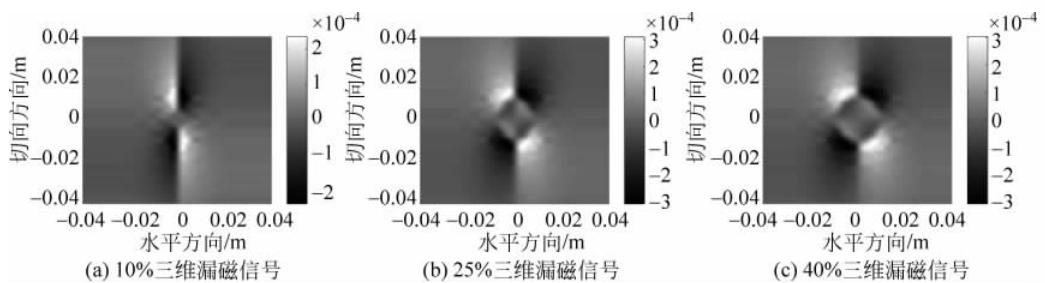
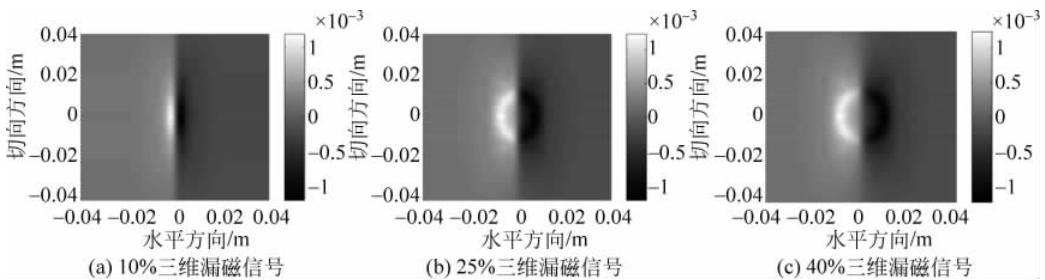


图 5.36 $24\text{mm} \times 24\text{mm} \times 2.4\text{mm}$ 凹坑缺陷不完整三维漏磁信号水平分量等效处理结果

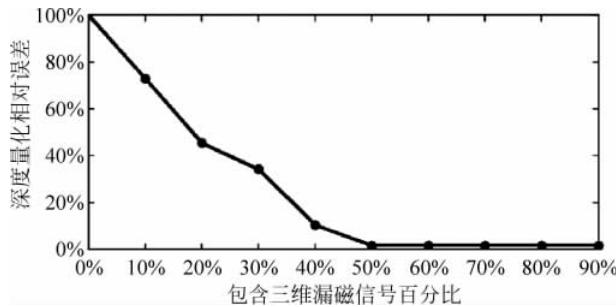
以上结果显示,对于等效处理后的缺陷三维漏磁信号,随着缺陷三维漏磁信号信息量的增加,提取的缺陷三维漏磁信号各关键特征量值的准确度也在不断增加。当数据处理区域内包含 10% 的缺陷三维漏磁信号时,信号切向分量、法向分量的峰值与谷值已经与缺陷完整三维漏磁信号下的对应数值相等。随着数据处理区域内缺陷三维漏磁信号比重的逐渐加大,水平分量、切向分量和法向分量的信号强度积分等关键特征量值不断增加。由此可见,采用信号等效处理方法,在缺陷深度的估算过程中,估算精度会随着信息量的增加而逐渐提升,完全满足预期的要求。

图 5.37 $24\text{mm} \times 24\text{mm} \times 2.4\text{mm}$ 凹坑缺陷不完整三维漏磁信号切向分量等效处理结果图 5.38 $24\text{mm} \times 24\text{mm} \times 2.4\text{mm}$ 凹坑缺陷不完整三维漏磁信号法向分量等效处理结果

最后,在已知的缺陷三维漏磁信号多于完整缺陷信号的 50% 时,仅需对 50% 缺陷不完整三维漏磁信号的水平分量、切向分量和法向分量进行与之前相同的对称处理,即可得到完整的缺陷三维漏磁信号。

在对缺陷不完整三维漏磁信号进行等效处理后,针对凹坑、水平沟槽和切向沟槽三类缺陷的等价三维漏磁信号,分别提取其关键特征量值,进而代入用于缺陷深度量化的神经网络中,得到对应的缺陷深度。

为了验证所提出基于三维漏磁信号等效处理的缺陷深度估计方法的有效性,以 $30\text{mm} \times 30\text{mm} \times 2\text{mm}$ 凹坑缺陷为例,当其数据处理区域包含不同比例的缺陷三维漏磁信号时,对信号进行等效处理,并利用神经网络,求得各阶段的缺陷深度,统计得到实时扫查过程中对缺陷深度估计的误差变化曲线如图 5.39 所示。

图 5.39 $30\text{mm} \times 30\text{mm} \times 2\text{mm}$ 凹坑缺陷包含不同比例三维漏磁信号的深度量化误差

从图 5.39 可以看出,随着获取漏磁信号比例的逐渐增加,量化得到缺陷深度的误差逐渐减小。当信号获取比例达到 50% 后,可以利用已知信号获取全部的缺陷三维漏磁信号关

键特征量值,深度量化的误差也不再改变。以上结果表明,当获取到 50% 的缺陷漏磁信号时,缺陷深度估计已达到较高的精度,即该方法可用于对不完整信号下凹坑缺陷的深度进行有效的估计。

图 5.40 和图 5.41 分别给出了 $40\text{mm} \times 20\text{mm} \times 2\text{mm}$ 水平沟槽缺陷、 $20\text{mm} \times 40\text{mm} \times 2\text{mm}$ 切向沟槽缺陷,在数据处理区域包含不同比例的缺陷三维漏磁信号时,采用等效的缺陷完整三维漏磁信号得到的实时显示过程中缺陷深度估计的误差变化曲线。

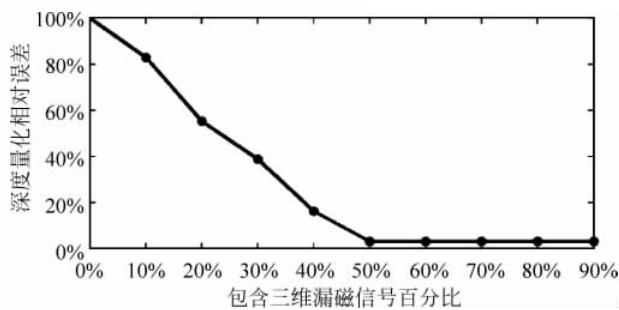


图 5.40 $40\text{mm} \times 20\text{mm} \times 2\text{mm}$ 水平沟槽缺陷包含不同比例三维漏磁信号的深度量化误差

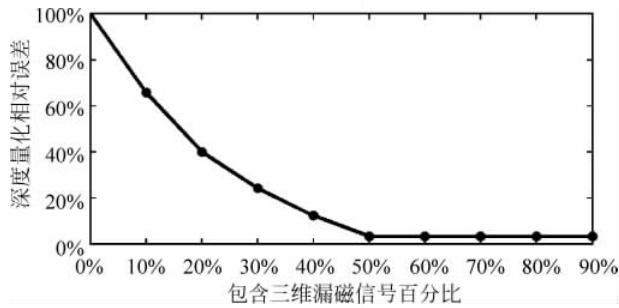


图 5.41 $20\text{mm} \times 40\text{mm} \times 2\text{mm}$ 切向沟槽缺陷包含不同比例三维漏磁信号的深度量化误差

由图 5.40 和图 5.41 中给出的特性曲线可知,与凹坑缺陷相似,针对水平沟槽缺陷与切向沟槽缺陷的不完整三维漏磁信号进行等效处理后,量化得到的缺陷深度误差,随着采集到信号比例的增加而逐渐减小。当信号比例达到 50%,即获得了较高准确度的缺陷深度量化结果。验证了基于信号等效处理的缺陷深度估计方法,在用于水平沟槽缺陷与切向沟槽缺陷的深度量化同样可行。

5.3.3 不完整信号下的缺陷实时显示

在得到不完整信号的缺陷边缘识别结果与深度估计结果后,针对三种不同的缺陷,给出具体的缺陷实时显示方法。

由于对凹坑、水平沟槽和切向沟槽这三种缺陷所采用深度估计的神经网络并不相同,在对缺陷深度进行估计时,首先应对缺陷的种类进行判断。由于在获取缺陷三维漏磁信息较少的情况下,存在不能通过已知信号对缺陷种类进行判断的情况,提出一种在不同的缺陷三维漏磁信号信息量时对缺陷进行判断并显示的方法。

对于缺陷种类的判断,是随着检测器的行进而不断更新的,图 5.42 给出了具体的缺陷判断显示流程图。当数据处理区域内第一次出现识别到的缺陷边缘,即数据处理区域内仅有最后一列数据包含缺陷边缘时,开始以凹坑缺陷对缺陷深度进行估计并进行缺陷显示。随着数据处理区域内边缘点的增加,当有连续三列缺陷的边缘信息不在切向方向上扩展后,则认定该缺陷不是凹坑缺陷,转而以切向沟槽缺陷对缺陷深度进行估计并对缺陷进行显示。直到缺陷边缘在水平方向的延伸大于其在切向方向上延伸的二分之一后,认定该缺陷为水平沟槽缺陷,转而以水平沟槽缺陷对缺陷深度进行估计并对缺陷进行显示。

在已知缺陷边缘与缺陷深度后,按照不同的缺陷类型分别求取缺陷的轮廓。

1. 凹坑缺陷的轮廓

对于凹坑缺陷,在获得了缺陷边缘与深度值后,通过求解缺陷所在的球面,得到缺陷的轮廓。图 5.43 为求解缺陷所在球面的相关参数示意图,其中, h 为缺陷的深度, a 为缺陷边缘曲线两端点之间的距离, b 为边缘曲线中心到其两端点中心的距离。基于以上参数,可以求出边缘曲线所在的圆的半径 r ,即

$$r = \frac{b}{2} + \frac{a^2}{8b} \quad (5-35)$$

进而,求出缺陷所在球面的圆心位置 O 与半径 R ,即

$$R = \sqrt{r^2 + \left(\frac{rb}{h} - \frac{b^2}{2h} - \frac{h}{2}\right)^2} = \sqrt{\left(\frac{b}{2} + \frac{a^2}{8b}\right)^2 + \left(\frac{a^2}{bh} - \frac{h}{2}\right)^2} \quad (5-36)$$

由圆心位置 O 与半径 R 即可求出球面,进而求得缺陷的轮廓。

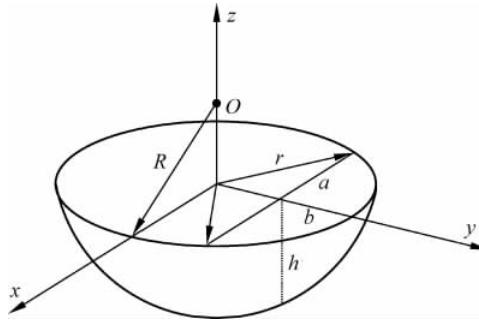


图 5.43 凹坑缺陷所在球面相关参数求解示意

图 5.44 给出了凹坑缺陷的显示结果示意图,其中,图 5.44 (a) 为缺陷三维漏磁信号少于 50% 时的显示结果,图 5.44 (b) 为缺陷三维漏磁信号多于 50% 时的显示结果。

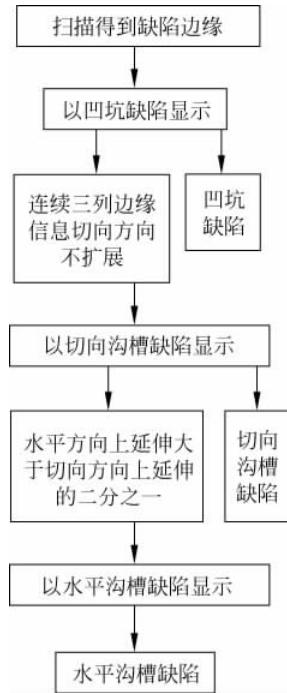


图 5.42 不完整信号下缺陷实时显示过程中的判断显示流程

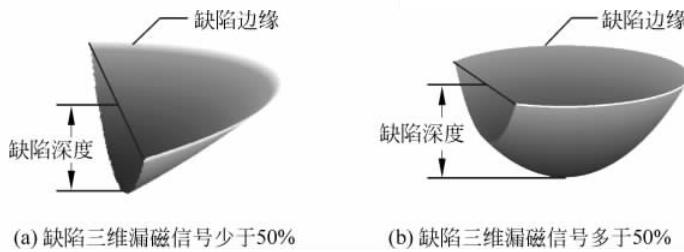


图 5.44 凹坑缺陷实时显示结果示意图

2. 水平沟槽和切向沟槽缺陷的轮廓

对于水平沟槽与切向沟槽缺陷,在获得了缺陷边缘与深度值后,直接按矩形缺陷进行显示。图 5.45(a)与图 5.45(b)分别给出了水平沟槽缺陷与切向沟槽缺陷的显示结果示意图。

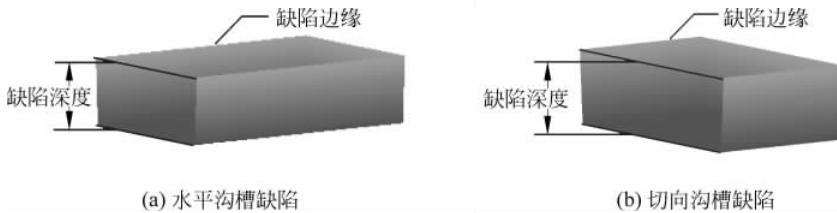
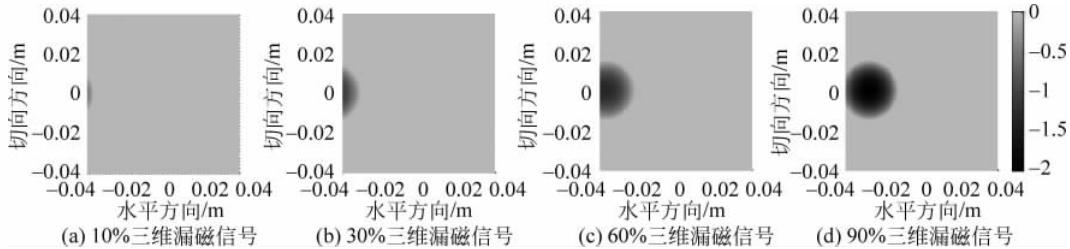


图 5.45 水平沟槽缺陷与切向沟槽缺陷实时显示结果示意图

采用本书提出的显示方法,在求解得到的缺陷边缘与深度的基础上,对不完整凹坑、水平沟槽和切向沟槽缺陷进行实时显示。

为了验证所提出的不完整信号下凹坑缺陷显示方法的可行性,图 5.46 与图 5.47 针对 $30\text{mm} \times 30\text{mm} \times 2\text{mm}$ 凹坑缺陷,给出了已知 10%、30%、60%、90% 缺陷三维漏磁信号时的实际缺陷图与缺陷实时显示结果。

图 5.46 实际的 $30\text{mm} \times 30\text{mm} \times 2\text{mm}$ 凹坑缺陷

以上结果表明,采用不完整信号下凹坑缺陷显示方法,可以在已知不同比例的缺陷三维漏磁信号时,对缺陷的相应部分进行实时显示。同时,比较实际缺陷与实时显示的缺陷可知,各比例缺陷三维漏磁信号下实际缺陷轮廓结果与实时显示的缺陷轮廓结果基本一致,验证了不完整三维漏磁信号下缺陷的量化与实时显示方法的可行性。

图 5.48 与图 5.49 分别给出了 $40\text{mm} \times 20\text{mm} \times 2\text{mm}$ 水平沟槽缺陷在已知 10%、30%、

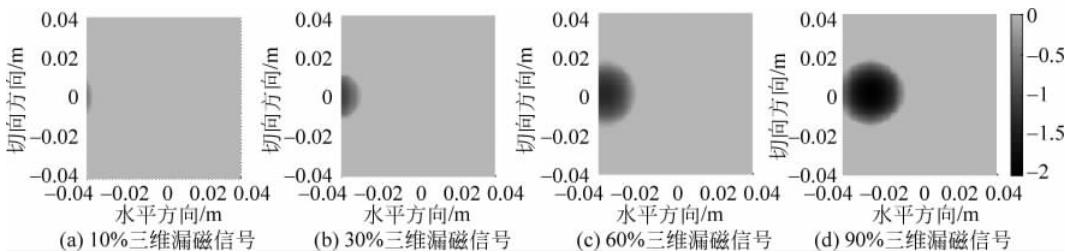


图 5.47 30mm×30mm×2mm 凹坑缺陷实时显示结果

60%、90% 缺陷三维漏磁信号情况下的实际缺陷图与缺陷实时显示结果, 图 5.50 与图 5.51 则给出了 20mm×40mm×2mm 切向沟槽缺陷在已知 10%、30%、60%、90% 缺陷三维漏磁信号情况下的实际缺陷图与缺陷实时显示结果。

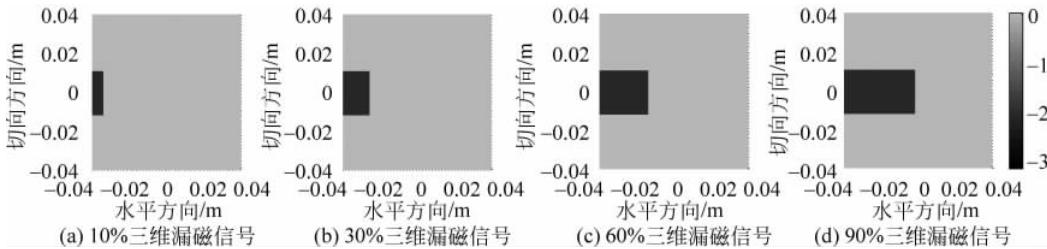


图 5.48 实际的 40mm×20mm×2mm 水平沟槽缺陷

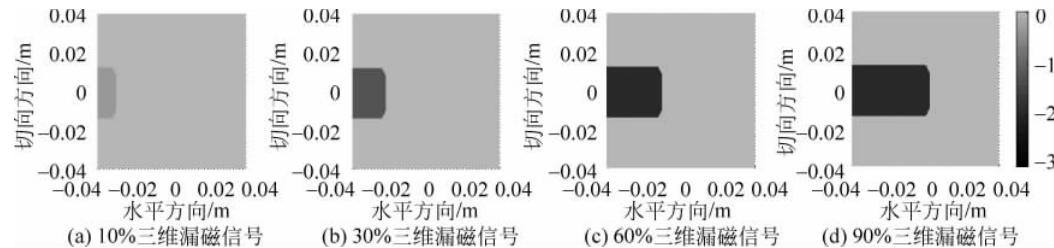


图 5.49 40mm×20mm×2mm 水平沟槽缺陷实时显示结果

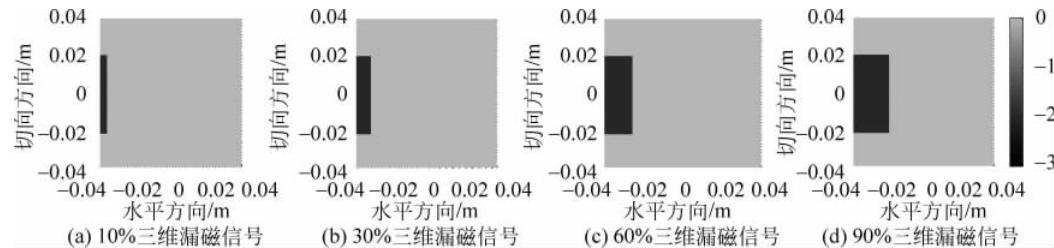


图 5.50 实际的 20mm×40mm×2mm 切向沟槽缺陷

以上结果表明,采用所提出的显示方法,可根据检测得到的缺陷边缘与深度,实现水平沟槽与切向沟槽缺陷的实时显示,结果达到了预期的目标。且对比实际缺陷与缺陷实时显示结果可知,不同缺少比例缺陷三维漏磁信号下的实际缺陷轮廓与实时显示的缺陷轮廓吻合度均较高。

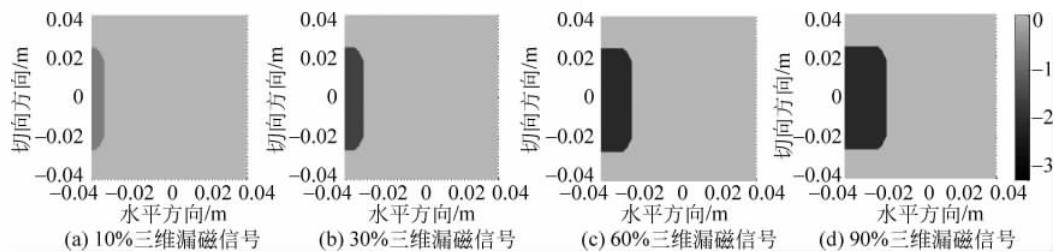


图 5.51 $20\text{mm} \times 40\text{mm} \times 2\text{mm}$ 切向沟槽缺陷实时显示结果