·农林智能装备与技术 Intelligent Equipment and Technology for Agriculture and Forestry·

基于改进磁偶极子模型的林业装备钢制构件缺陷正反演量化评估方法

张锡武，唐健强，白智轶，邢文婷，徐凯宏*
（东北林业大学 控制与信息工程学院，哈尔滨 150040）

摘 要：为提升林业装备钢制构件在高湿、泥水冲刷与温差循环工况下腐蚀减薄、坑蚀及边界突变缺陷的三维定量评估精度，提出改进的离散化磁偶极子正演模型与两阶段反演的量化框架。正演引入二阶响应驱动自适应网格细化与面元三点求积，提高坑缘与突变带建模并控制节点；反演第1阶段采用主成分分析（principal component analysis，PCA）降维约束搜索空间，通过牛顿-拉夫逊优化算法优化径向基函数（radial basis function，RBF）超参数得到稳健反演初值，反演第2阶段利用协方差矩阵自适应进化策略在低维空间耦合正演模型进行精修。仿真结果表明，正演精度接近有限元模型且耗时显著降低，反演在多形貌下重建更稳定。该方法可嵌入智慧林业状态感知与预测性维护，为林业装备风险评估、检修优先级排序与安全管控提供量化依据。

关键词：智慧林业；腐蚀缺陷；磁偶极子模型；缺陷反演；牛顿-拉夫逊算法；协方差矩阵自适应进化策略；有限元模型；主成分分析

中图分类号：S776.2 **文献标识码：**A **DOI：**10.7525/j.issn.1006-8023.2026.05.012

Quantitative Evaluation Method for Forward and Inverse Modeling of Improved Magnetic Dipole for Defects in Steel Components of Forestry Equipment

ZHANG Xiwu，TANG Jianqiang，BAI Zhiyi，XING Wenting，XU Kaihong*
（College of Control and Information Engineering，Northeast Forestry University，Harbin 150040，China）

Abstract：To improve the accuracy of three-dimensional quantitative evaluation for corrosion thinning，pitting，and boundary-discontinuity defects in steel components of forestry equipment under service conditions involving high humidity，mud-water erosion，and cyclic temperature variations，an improved discretized magnetic dipole forward model and a two-stage inversion-based quantification framework are proposed. In the forward modeling stage，a second-order response-driven adaptive mesh refinement strategy and a three-point surface-element quadrature scheme are introduced to enhance the characterization of pit edges and discontinuity zones while controlling the number of nodes. In the inversion stage，principal component analysis（PCA）is first employed to reduce the dimensionality of the defect description and constrain the search space，while the Newton - Raphson optimizer is used to optimize the hyperparameters of the radial basis function（RBF）model to obtain robust initial estimates. In the second stage，the covariance matrix adaptation evolution strategy is adopted to further refine the solution in the low-dimensional space by coupling it with the forward model. Simulation results demonstrate that the proposed forward model achieves accuracy close to that of the finite element model while significantly reducing computational time，and that the inversion framework provides more stable reconstructions for defects with diverse morphologies. The proposed method can be embedded into intelligent forestry con-

收稿日期：2025-12-23

基金项目：黑龙江省重点研发计划基金资助项目（GZ20210017；GZ20210018；GZ20210019）；东北林业大学2025年高教强省专项-产教融合研究生联合培养基地建设资助项目。

第一作者简介：张锡武，硕士研究生。研究方向为智能检测技术。E-mail：zxw15847741680@163. com

***通信作者：**徐凯宏，博士，教授。研究方向为智能控制与信息技术。Email：13936548825@126. com

引文格式：张锡武，唐健强，白智轶，等. 基于改进磁偶极子模型的林业装备钢制构件缺陷正反演量化评估方法[J]. 森林工程，2026，42(5)：1011-1021.

Zhang Xiwu，Tang Jianqiang，Bai Zhiyi，et al. Quantitative evaluation method for forward and inverse modeling of improved magnetic dipole for defects in steel components of forestry equipment[J]. Forest Engineering，2026，42(5)：1011-1021.

dition monitoring and predictive maintenance systems, thereby providing a quantitative basis for risk assessment, maintenance prioritization, and safety management of forestry equipment.

Keywords: Smart forestry; corrosion defects; magnetic dipole model; defect inversion; Newton-Raphson-based optimizer; covariance matrix adaptation evolution strategy; finite element model; principal component analysis

0 引言

智慧林业的高效运行需要林业装备与林区基础设施的可靠服役[1-2]。林区环境高湿、泥水冲刷与温差循环显著，且维护资源分散，钢制构件一旦腐蚀减薄或坑蚀易引发停机与安全风险。基于传感器与数据融合的状态监测可提升维护决策效率[3-4]，而林道桥梁等钢结构构件是典型铁磁对象[5-6]。面向此类构件，磁场机理无损评估具有工程适配性，但需兼顾效率与定量精度。

现有缺陷漏磁检测的量化方法主要分为前向模型法与非前向模型法。前向模型基于物理原理建立数学模型，通过调整参数以匹配实测信号；非前向模型则通过数据驱动技术，直接从磁场信号中学习缺陷特征。前向模型中，有限元模型精度高但计算成本大[7]；磁偶极子模型（magnetic dipole model，MDM）计算效率突出，却难以表征不规则缺陷。针对这些局限，王雨菲等[8]提出坐标偏移 MDM；Zhong 等[9]引入动态因素构建动态磁偶极子模型；Wang 等[10]融合物理理论与数据驱动构建机器学习偶极子模型。现有方法虽在不同方面取得进展，仍普遍存在适用范围有限、对复杂缺陷表征能力不足或模型泛化性较弱等局限。在缺陷反演方面，Li 等[11]利用磁场扰动与多方向信号进行三维重建，但轮廓误差会直接影响深度重建；缪立恒等[12]探究漏磁信号平均值与缺陷深度的近似线性关系，为反演提供物理约束与适用边界；Hou 等[13]通过改进甲虫群优化算法及变目标函数策略，提升缺陷轮廓重构的收敛速度与重构精度。随机森林等数据驱动方法虽能通过特征学习提升反演精度，然而依赖大量标注样本，缺乏物理约束[14-15]。尽管已有研究在正演与反演方面取得诸多进展，但缺陷漏磁检测的精准计算与仿真仍是核心挑战。

针对上述问题，本研究提出一种融合改进正演模型与低维子空间物理精修的协同反演框架。正演部分在离散化磁偶极子模型（discrete magnetic dipole model，DMDM）基础上引入二阶响应驱动自适应网格细化提高复杂边界与深度突变区的计算可信度，为反演部分提供可靠的物理约束。反演部分采用主成分分析（principal component analysis，PCA）降低计算维度，利用牛顿-拉夫逊优化算法（Newton-Raphson-based optimizer，NRBO）对径向基函数神经网络（radial basis function，RBF）的超参数进行自适应寻优以提升反演初值质量，并以协方差矩阵自适应进化策略（covariance matrix adaptation evolution strategy，CMA-ES）在低维空间耦合物理正演精修，通过算法组合的协同效应实现可解释、高精度且计算可控的林业装备缺陷三维反演评估。

1 二阶响应驱动自适应网格细化的 DMDM

磁偶极子模型是漏磁检测中计算缺陷漏磁场的经典解析模型[16]。为突破传统模型的限制，有学者提出离散化磁偶极子模型（DMDM）[17]。针对复杂缺陷边界及深度突变区域的网格划分问题，在 DMDM 离散求解框架中引入了曲率驱动的自适应网格细化策略，见图 1，图中：(x_m, y_m)为三角形单元任一边端点的中点坐标；$(\boldsymbol{x}_{e,1}, \boldsymbol{x}_{e,2}, \boldsymbol{x}_{e,3})$为面元内 3 个不同的积分点坐标；$\boldsymbol{r}_{e,k}$为从积分点 $\boldsymbol{x}_{e,k}$ 到场点 P 的向量；M 为磁场磁化方向。该策略在控制节点规模的同时，可提高正演计算的精度与稳定性。

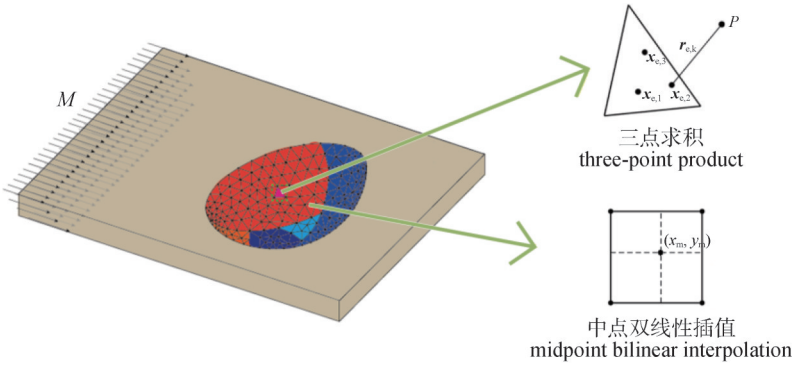


图 1 改进 DMDM 前向模型示意图

Fig. 1 Improved DMDM forward model schematic diagram

在单个离散化后三角形单元中,其内部任意位置的法向量相同,单元表面的磁荷密度也都相等。对DMDM进行改进以提升复杂缺陷边界与深度突变区域计算精度,并控制节点规模。在细化过程中,为避免新节点Z取端点均值而导致多层细化后曲面偏离原始深度场$\boldsymbol{Z}(x,y)$,对任一边端点的中点$(x_{\mathrm{m}},y_{\mathrm{m}})$计算,公式为

$$z_{\mathrm{m}}=\mathcal{I}_Z(x_{\mathrm{m}},y_{\mathrm{m}})。\tag{1}$$

式中:z_{m}为新生成的中点节点在z方向上的坐标值,$\mathcal{I}_Z(\cdot)$为规则深度矩阵的双线性插值算子,用以保证细化网格始终贴合缺陷曲面。

其次,为减小顶点点源近似在一定条件下的系统误差,引入面元三点求积方法,并定义面元积分型离散前向算子,漏磁信号$\boldsymbol{B}(P)$计算公式为

$$\boldsymbol{B}(P)=\frac{\mu_0\mu_r}{4\pi}\sum_e\sum_{k=1}^{3}\left(\frac{Q_e}{3}\right)\frac{\boldsymbol{r}_{e,k}}{\|\boldsymbol{r}_{e,k}\|^3},\quad \boldsymbol{r}_{e,k}=P-\boldsymbol{x}_{e,k}。\tag{2}$$

式中:e为缺陷表面离散拆分后的第e个三角形面元单元;k为积分点编号;$\boldsymbol{x}_{e,k}$为面元内积分点坐标;μ_0为真空中的磁导率;μ_{r}为相对磁导率;Q_e为单元上的总磁荷量;$\boldsymbol{r}_{e,k}$为从积分点$\boldsymbol{x}_{e,k}$到场点$\boldsymbol{P}$的向量,并在正演计算中取$\boldsymbol{B}(P)$作为模型输出。

此外,为使有限网格预算优先分配到坑缘与突变带,在深度场上计算二阶响应,并定义曲率响应指标κ计算公式为

$$\kappa=\left|\boldsymbol{Z}_{xx}+\boldsymbol{Z}_{yy}\right|。\tag{3}$$

式中:$\boldsymbol{Z}_{xx}$和$\boldsymbol{Z}_{yy}$为深度场对x,y的二阶偏导,并采用归一化阈值触发细化。

$$\tau=\beta\cdot\max(\kappa)。\tag{4}$$

式中:τ为网格细化触发阈值;β为细化强度控制参数。每个三角面元取三顶点处κ的均值,若该均值超过阈值则标记细化;面元细化采用边中点四分裂与边中点映射机制,以避免生成重复节点;当某层无单元满足条件时则提前终止,以实现精度、节点规模与耗时的权衡。

2　基于NRBO-RBF-CMA-ES模型的反演方法

在缺陷反演部分提出融合数据驱动初值与物理一致性精修的三维缺陷反演框架,见图2,MFL(magnetic flux leakage)为漏磁检测信号。总体采用两阶段策略:首先基于训练样本构建融合PCA与NRBO-RBF的初始估计模型,得到反演初始深度场;之后在深度场低维子空间中引入CMA-ES,以物理正问题构建目标函数对初值进行全局精修。

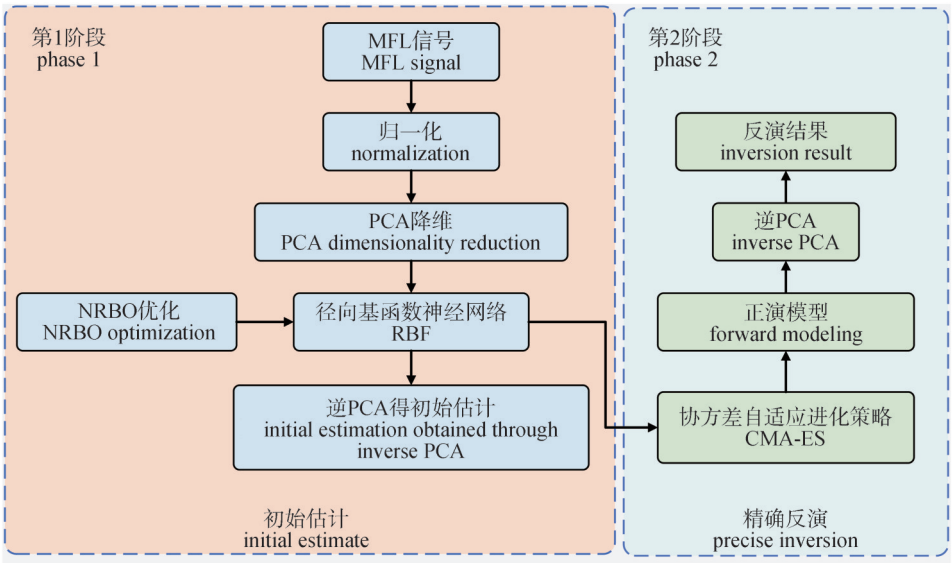


图2　反演方法的框图

Fig. 2　Block diagram of the inversion method

2.1　PCA-RBF初始值估计

反演部分采用基于主成分分析与径向基函数神经网络的降维初始估计方法以保证反演精度[18-19]。首先采用PCA对信号进行降维提取特征,并在输出端引入输出PCA将高维深度场参数化为低维系数向量,在低维空间内训练RBF回归模型以获得稳健的初始估计,见图3。该方法通过提取数据集的统计特征并利用神经网络的非线性映射能力,能够高效生成高精度的初始深度向量。

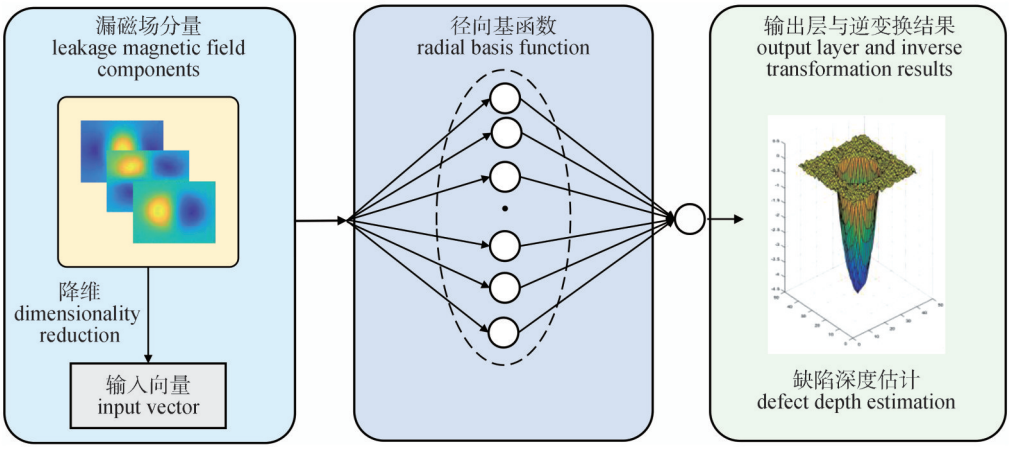


图 3 缺陷初始估计框图

Fig. 3 Initial defect estimation flowchart

初始阶段统一处理三维漏磁信号的不同分量，将3个磁场分量矩阵按列向量化并拼接，构成输入向量$\boldsymbol{X}$，其计算公式为

$$\boldsymbol{X}=\left[\mathrm{vec}(\boldsymbol{B}_x)^{\top},\mathrm{vec}(\boldsymbol{B}_y)^{\top},\mathrm{vec}(\boldsymbol{B}_z)^{\top}\right]^{\top}。\tag{5}$$

式中：$\mathrm{vec}(\boldsymbol{B})$为矩阵向量化操作；$\boldsymbol{B}_x$、$\boldsymbol{B}_y$、$\boldsymbol{B}_z$分别为三维$x$、$y$、$z$的信号矩阵。

反演过程中为消除量纲影响并加速模型收敛，采用训练集统计量对输入向量进行z-score标准化，计算公式为

$$\tilde{\boldsymbol{X}}=\frac{\boldsymbol{X}-\boldsymbol{\mu}_x}{\boldsymbol{\sigma}_x}。\tag{6}$$

式中：$\tilde{\boldsymbol{X}}$为标准化后的输入向量；$\boldsymbol{\mu}_x$与$\boldsymbol{\sigma}_x$分别为训练集输入在各维度上的均值向量与标准差向量。

由于漏磁信号初始维度高且存在冗余，采用PCA对归一化后的输入数据进行降维处理。保留累计方差贡献率达到需求的前k_x个主成分，得到低维特征。公式为

$$\boldsymbol{u}=\boldsymbol{P}_X^{\top}\tilde{\boldsymbol{X}}。\tag{7}$$

式中：$\boldsymbol{u}$为输入PCA低维特征向量；$\boldsymbol{P}_X$为PCA特征矩阵，由前k_x个特征向量构成。

为获得后续全局精修的稳定初值，实现漏磁特征到缺陷深度场的快速映射，在低维特征上构建RBF网络。设隐含层共有K个基函数，$\boldsymbol{\phi}_j$为中心向量，采用高斯核函数，$\varphi_j(\boldsymbol{u})$为第$j$个径向基函数输出，其公式为

$$\varphi_j(\boldsymbol{u})=\exp\left(-\frac{\left\|\boldsymbol{u}-\boldsymbol{\phi}_j\right\|_2^2}{2\sigma^2}\right),\quad j=1,2,\cdots,K。\tag{8}$$

通过对所有中心的输出进行组合，可得隐含层输出矩阵$\boldsymbol{H}$，输出层通过线性加权将隐含层结果按公式映射为输出PCA系数的预测值，公式为

$$\hat{\boldsymbol{C}}=\boldsymbol{H}\boldsymbol{W}。\tag{9}$$

式中：$\hat{\boldsymbol{C}}$为模型预测的输出PCA系数矩阵；$\boldsymbol{W}$为输出权重矩阵。为减小过拟合并提升数值稳定性，引入正则项，输出权重采用闭式解求得。预测后由输出PCA逆变换重构深度向量，其公式为

$$z_0=\boldsymbol{\mu}_Y+\boldsymbol{P}_Y\boldsymbol{c}_0。\tag{10}$$

式中：$\boldsymbol{\mu}_Y$为训练集缺陷深度向量均值；$\boldsymbol{P}_Y$为输出PCA基矩阵；$\boldsymbol{c}_0$为NRBO-RBF预测的输出PCA系数。

2.2 RBF超参数寻优

RBF模型的性能受超参数影响显著，初始估计部分引入NRBO优化算法实现超参数的自适应全局优化以保证模型性能[20]，见图4。NRBO算法通过牛顿-拉夫逊搜索规则(newton-raphson search rule，NRSR)引导种群向最优解方向进化，并结合陷阱规避操作(trap avoidance operator，TAO)增强全局探索能力，有效避免陷入局部最优解。NRBO算法通过最小化目标函数来驱动超参数的优化过程，函数公式为

$$J(\boldsymbol{\theta})=\mathrm{MAE}\left(\hat{z}_{\mathrm{val}}(\boldsymbol{\theta}),z_{\mathrm{val}}\right),\boldsymbol{\theta}=[K,\sigma,\lambda]。\tag{11}$$

式中：$J(\boldsymbol{\theta})$是目标函数；$\boldsymbol{\theta}$为待优化的超参数组合；$\hat{z}_{\mathrm{val}}(\boldsymbol{\theta})$为在超参数$\boldsymbol{\theta}$下，RBF网络预测输出PCA系数后，经式(10)逆变换重构得到的验证集深度向量；z_{val}为真实深度向量；K为RBF神经网络隐含层的径向基函数(高斯核)节点数量；σ为高斯径向基函数的核宽度；λ为岭回归的正则化系数。

2.3 CMA-ES算法对初始值的全局精修

反演第2阶段，为弥补单一数据驱动的不足引入协方差矩阵自适应进化策略(CMA-ES)，并与改进DMDM正演模型耦合，在低维参数空间内对初值进行全局精修。为降低优化维度并保持深度场统计先验，第2阶段沿用第1阶段训练集输出PCA得到的均值与基底，将向量化深度场表示为

$$\boldsymbol{Z}(\tilde{\boldsymbol{c}})=\boldsymbol{\mu}_Y+\boldsymbol{P}_Y\tilde{\boldsymbol{c}}\tag{12}$$

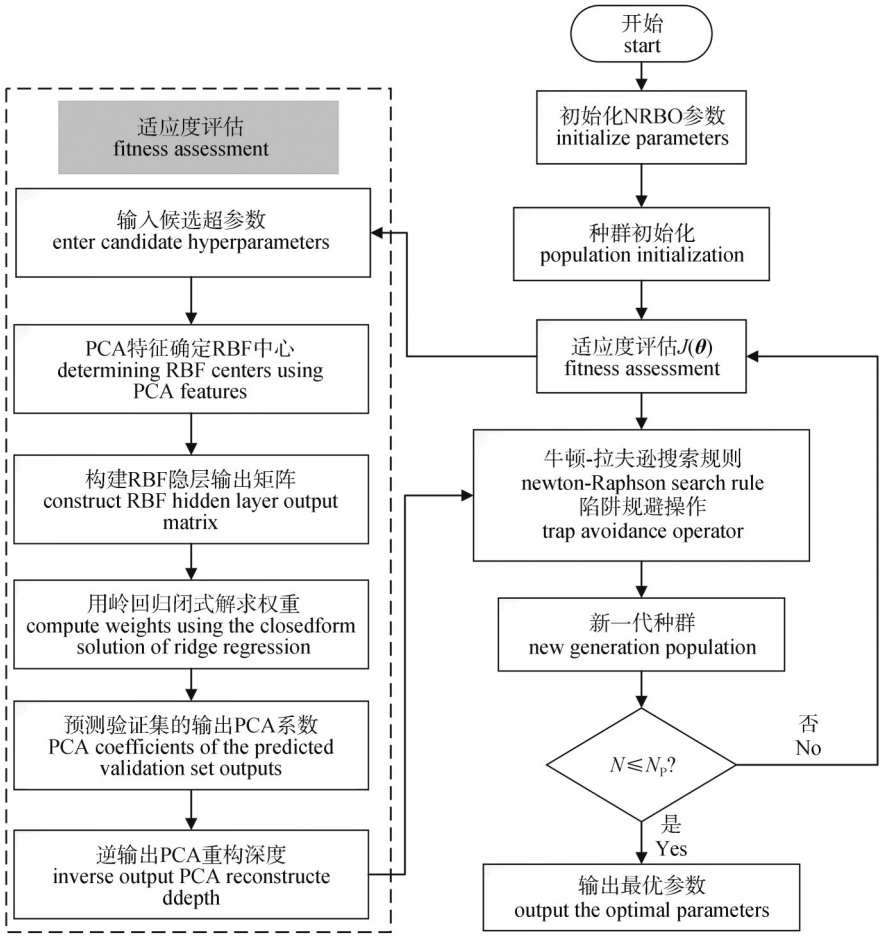


图 4　反演初始估计流程图

Fig. 4　Inversion initial estimation flowchart

式中:$\tilde{\boldsymbol{c}}$为输出 PCA 系数;$\boldsymbol{Z}(\tilde{\boldsymbol{c}})$为重构的缺陷深度场。令第 1 阶段 NRBO-RBF 输出的初始系数为$\tilde{\boldsymbol{c}}_0$,并以其初始化 CMA-ES 搜索分布均值。

设$\mathcal{F}(\cdot)$为正演算子,$\boldsymbol{B}_{\mathrm{obs}}$为漏磁信号,则利用 CMA-ES 算法进行精细化反演。其公式为

$$\tilde{\boldsymbol{c}}_{\mathrm{last}} = \arg\min_{\tilde{\boldsymbol{c}} \in \Omega} \left\| \mathcal{F}\left(\boldsymbol{Z}(\tilde{\boldsymbol{c}})\right) - \boldsymbol{B}_{\mathrm{obs}} \right\|_2^2 + \gamma \left\| \tilde{\boldsymbol{c}} - \tilde{\boldsymbol{c}}_0 \right\|_2^2 \circ \tag{13}$$

式中:$\gamma \geqslant 0$为初值约束权重;Ω为物理可行域。CMA-ES 在第g代从$\mathcal{N}\left(\boldsymbol{m}^{(g)}, (\sigma^{(g)})^2 \boldsymbol{C}^{(g)}\right)$采样候选系数,依次完成逆 PCA 重构、正演计算与目标函数评估,并根据排序结果更新参数直至收敛,重构得到缺陷深度场,见图5。

3　试验与仿真

为验证改进模型的有效性,正演方面,将改进正演模型计算结果与有限元模型(finite element model, FEM)结果进行对比。反演方面,基于 FEM 与改进正演模型构建的仿真数据,评估两阶段反演框架的三维缺陷反演能力,并与多种反演模型进行对比分析。

3.1　数据来源与处理流程

基于改进模型与有限元模型仿真共生成 1 430 组样本,缺陷类型包含腐蚀坑、开槽缺口以及多缺陷叠加形变。上述形貌分别用于等效描述林区钢制管网的局部点蚀与坑蚀减薄、接触导向与张紧机构的沟槽状磨损减薄以及腐蚀和磨损耦合导致的复合损伤区,从而保证数值样本与林业工程对象的对应可解释性。样本按 70%、20%、10% 随机划分为训练集、验证集与测试集。所有归一化参数与 PCA 投影矩阵均仅由训练集估计,并在验证集与测试集上保持一致。

3.2　改进前向模型验证

利用有限元仿真软件建立缺陷模型,并将有限元模型计算结果视为近似真实漏磁场,见图 6。随后在相同几何与磁化条件下,将改进的离散化磁偶极子模型的计算结果与有限元仿真结果进行对比。

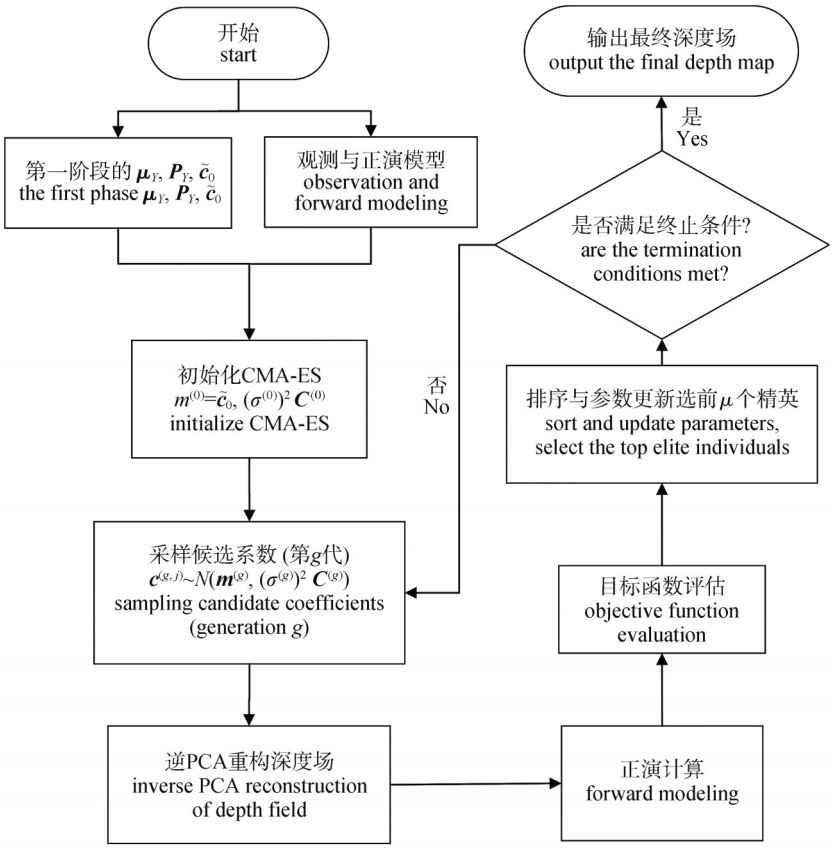


图 5 CMA-ES 优化反演

Fig. 5 CMA-ES optimization for inversion

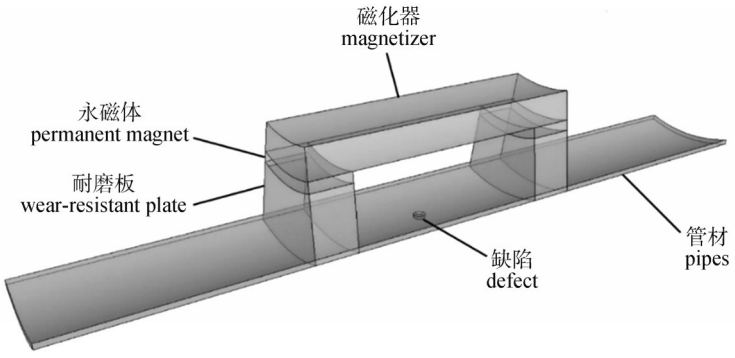


图 6 有限元仿真模型

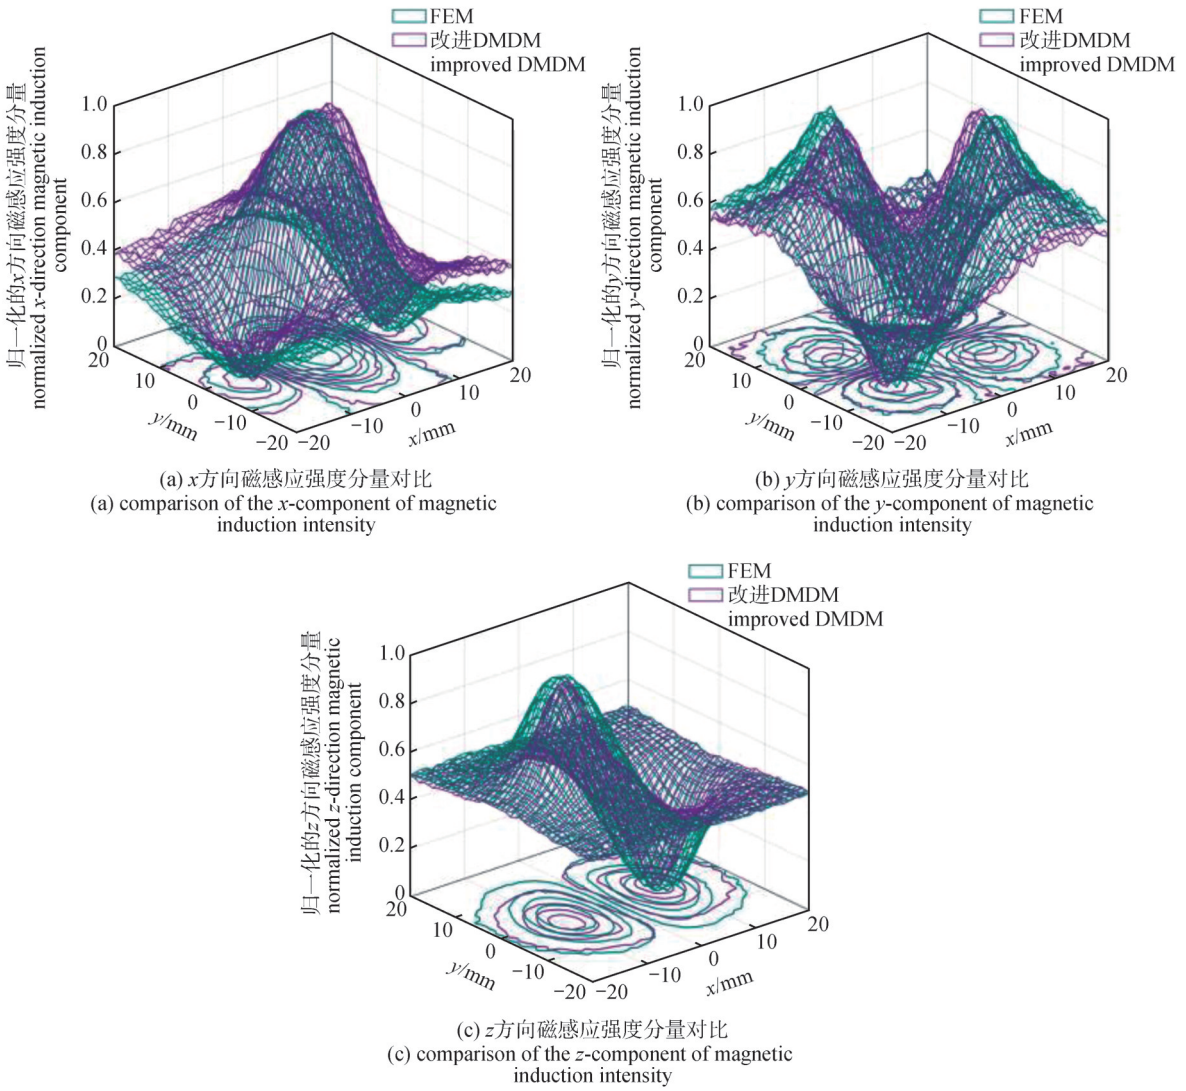
Fig. 6 Finite element simulation model

在采样平面计算模型输出与 FEM 数据之间的均方根误差(root mean square error, RMSE),并记录细化后的节点数与单次前向耗时从而量化改进模型的精度与效率。在β扫描试验中,FEM 仅在相同条件下预先计算一次,得到有限元计算结果$\boldsymbol{B}_{\mathrm{FEM}}$作为参考,随后在$\beta$扫描中复用该参考场进行误差评估。RMSE(式中记为R_{MSE})定义公式为

$$R_{\mathrm{MSE}}=\sqrt{\frac{1}{|\mathcal{P}|}\sum_{p\in\mathcal{P}}\left(\boldsymbol{B}(p)-\boldsymbol{B}_{\mathrm{FEM}}(p)\right)^2}。\tag{14}$$

式中:$\mathcal{P}$为采样点集合;$\boldsymbol{B}_{\mathrm{FEM}}$为有限元计算结果;$\boldsymbol{B}(p)$为改进模型计算结果。

对于同一缺陷,不同正向模型的计算对比结果见图 7。其中,各分量采用相同归一化基准。由式(14)计算出归一化 RMSE 为 1.98%,该结果表明两者在缺陷特征的求解精度上误差较小。



(a) x方向磁感应强度分量对比
(a) comparison of the x-component of magnetic induction intensity

(b) y方向磁感应强度分量对比
(b) comparison of the y-component of magnetic induction intensity

(c) z方向磁感应强度分量对比
(c) comparison of the z-component of magnetic induction intensity

图 7　改进模型与有限元模型信号对比

Fig. 7　Comparison of signals from the improved model and the finite element model

在固定工况与同一椭球缺陷样本下,采用式(4)对$\beta \in [0.05, 0.50]$进行扫描,记录RMSE、细化后节点数与单次前向耗时,见图8。随β增大,细化区域收缩,节点数与耗时整体下降,并在$\beta = 0.35$时出现跃迁式下降。精度方面,节点磁荷离散在$\beta = 0.30$附近达到最低RMSE,而当$\beta \geqslant 0.35$时欠细化导致RMSE上升。相比之下,面元三点求积的RMSE随β缓慢变化,在欠细化区间内具有更强的鲁棒性,但耗时更高。综合权衡精度与计算效率,取$\beta = 0.30$作为默认阈值系数。

3.3　反演算法评估

为验证改进反演算法的效果,通过与传统反演方法对比分析,量化其反演性能。对比方法包括RBF、支持向量回归(support vector regression,SVR)、BP神经网络(back propagation neural network,BP)、极限学习机(extreme learning machine,ELM);评价指标选取拟合优度(goodness of fit,GoF)、平均绝对误差(mean absolute error,MAE)与轮廓标准差(profile standard deviation,PSD)。所有对比试验基于相同的缺陷漏磁数据与试验条件开展,数据集涵盖多种类型、不同尺寸缺陷的漏磁检测仿真数据,输入特征为三维漏磁信号经标准化处理后的主成分向量,输出为缺陷深度场分布。模型训练参数、样本划分比例及终止条件均保持一致,具体对比结果见表1。

由表1可以看出,NRBO-RBF-CMA-ES算法在多个评价指标上取得最佳结果,表明该方法能够有效捕捉漏磁信号与缺陷形貌间的非线性映射关系,实现较高的全局一致性与趋势拟合能力,拟合优度GoF达到0.875 9,验证了反演算法在多类型缺陷下的整体稳定性。

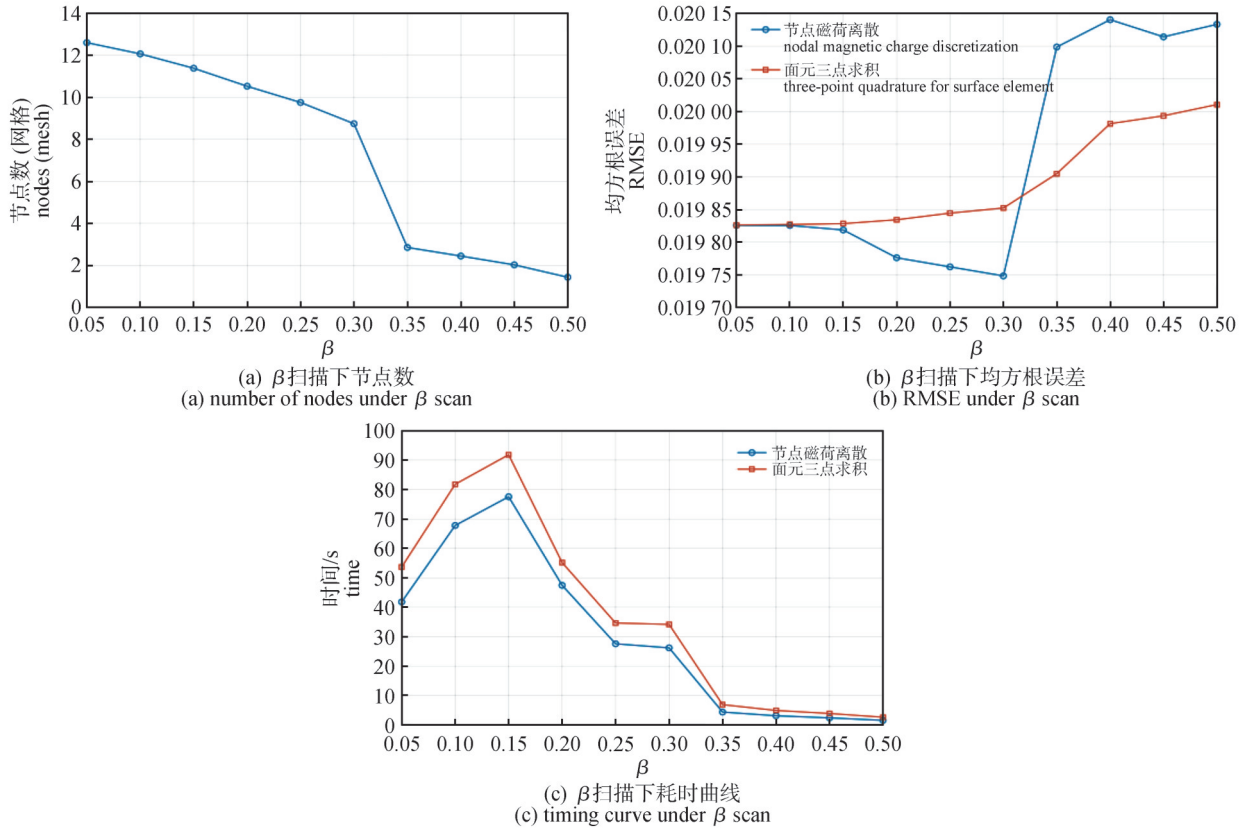


图 8 β扫描下节点数、RMSE 与耗时曲线

Fig. 8 Number of nodes, RMSE and computation time curves under β scan

表 1 改进算法与其他反演模型效果对比

Tab. 1 Comparison of the improved algorithm with other inversion models

反演方法 inversion methods	平均绝对误差/% MAE	轮廓标准差/% PSD	拟合优度 GoF
RBF	7.2	9.5	0.713 1
BP	9.8	13.0	0.703 5
SVR	8.5	11.2	0.671 2
ELM	11.5	15.3	0.662 0
NRBO-RBF-CMA-ES	3.5	4.8	0.875 9

漏磁三维反演不仅需满足数值误差较小，更需要保证反演深度场在空间形貌上与真实缺陷的位置、边界与深度变化趋势一致。为直观展现方法对缺陷三维形貌的恢复能力，研究选取测试集中典型样本展示深度场重建结果与误差分布，见图9。

为验证两阶段反演流程中各组成部分的必要性，设计一组消融试验进行对比分析。在相同缺陷样本及其漏磁信号条件下，对不同策略组合方案进行反演对比，以保证试验结果具有可比性。试验结果见表2。

由表 2 可知，仅采用 RBF 进行反演初始估计的 MAE 为 7. 2%、PSD 为 9. 5%，拟合优度 GoF 为 0. 713 1。在反演的初始估计的基础上引入 NRBO 对 RBF 相关参数进行自适应优化后，反演精度得到提升，MAE 降至 4. 9%、PSD 降至 6. 5%，GoF 提升至 0. 821 0。该结果表明，NRBO 优化能够有效提高反演初值质量。在 NRBO-RBF 的基础上进一步引入 CMA-ES 精修后，各项指标继续改善，MAE 进一步降至 3. 5%、PSD 降至 4. 8%，GoF 提升至 0. 875 9。MAE 与 PSD 的降低反映了整体误差水平与轮廓稳定性的提升，而 GoF 的增大则表明反演结果与检测信号之间的拟合一致性更强。

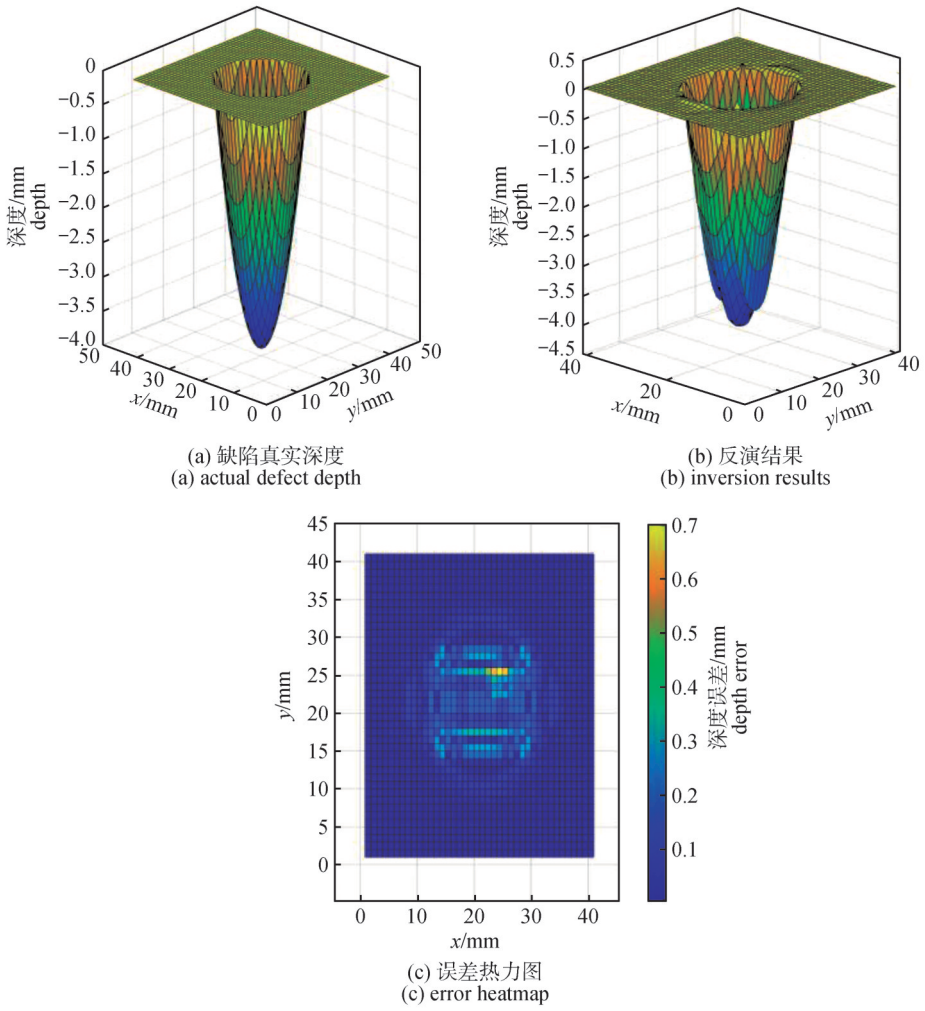


图 9　典型缺陷最终反演结果

Fig. 9　Typical defect inversion results

表 2　反演消融对比

Tab. 2　Comparison of inversion ablation

反演过程 inversion process	NRBO 优化 NRBO optimization	CMA-ES 精修 CMA-ES refinement	平均绝对误差/% MAE	轮廓标准差/% PSD	拟合优度 GoF
PCA-RBF	×	×	7.2	9.5	0.713 1
PCA-NRBO-RBF	√	×	4.9	6.5	0.821 0
PCA-NRBO-RBF-CMA-ES	√	√	3.5	4.8	0.875 9

注:表中“√”表示对应模块参与该反演流程,“×”表示对应模块未参与该反演流程。

Note: In the table, “√” indicates that the corresponding module is involved in the inversion process, while “×” indicates that the corresponding module is not involved in the inversion process.

通过 NRBO 优化的 RBF 与 CMA-ES 精修的策略组合,所提出的反演方法在反演精度、拟合能力与稳定性方面均获得有效提升,验证了两阶段反演框架中各模块的必要性与协同作用。

同时,为更直观地展示反演效果,初始估计误差呈现沿缺陷边界分布的环状误差带,表明数据驱动初值模型在深度突变与边界定位方面易产生系统性偏差,见图 10。因此在第 2 阶段引入 CMA-ES,在前向模型约束下对深度场参数进行全局搜索与细化校正,从而抑制边界伪影并提升重建稳定性。

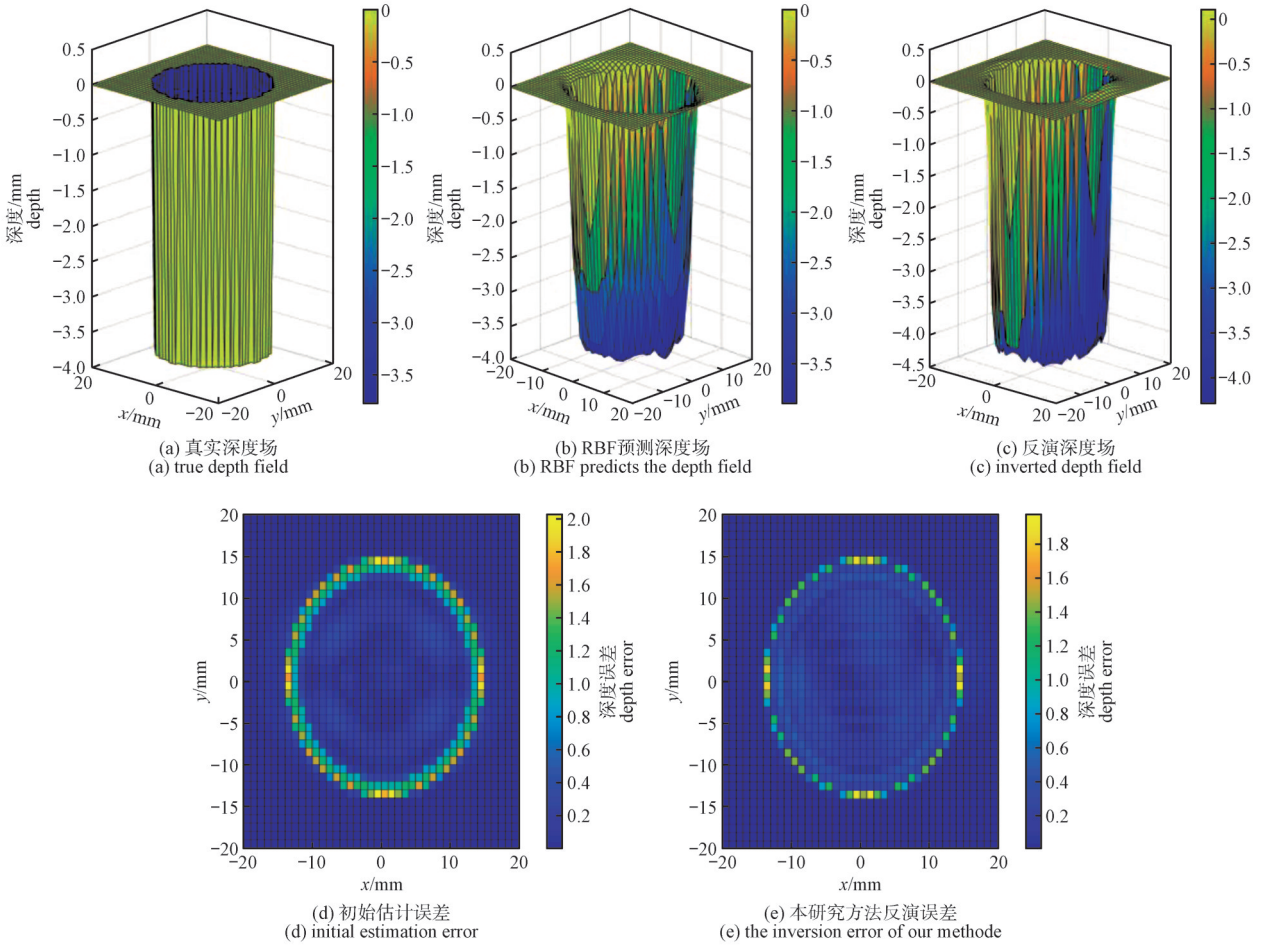


图10 反演结果对比

Fig. 10 Comparison of inversion results

4 结论

本研究基于改进的离散化磁偶极子模型和两阶段反演策略，成功实现了林业装备钢制构件缺陷的三维定量反演过程。经过仿真验证后得到以下结论。

1）正演精度与效率提升。改进的正演模型中二阶响应驱动自适应网格细化和面元三点求积的引入降低了坑缘与突变带的系统建模误差，在漏磁场计算精度接近有限元模型，均方根误差相差较小，在可控节点规模下单次前向计算耗时降低至秒级，实现了精度与效率的良好平衡，提高了反演目标函数的可信度。

2）反演稳定性与量化精度提高。NRBO-RBF-CMA-ES两阶段反演框架在多种腐蚀等效形貌（点蚀、沟槽等缺陷）下的三维重建效果更稳定。消融试验表明，NRBO的参数寻优与CMA-ES的物理约束优势形成互补，通过物理约束修正了数据驱动的边界伪影，验证了该组合的协同增益效应。与传统RBF、SVR、BP、ELM方法相比改进反演方法的GoF提升至0.875 9，MAE和PSD均较RBF降低51.39%和49.47%，提升了形貌一致性。

改进方法在仿真试验中取得了较好的三维反演效果，但在真实林区复杂工况下仍存在一定局限性。该方法可为智慧林业关键钢制构件的腐蚀风险评估、预测性维护与检修优先级排序提供可靠的量化深度依据，降低安全隐患与停机损失，推动林区基础设施与装备维护向智能化、预防性方向转型。未来可进一步引入实测数据增强训练样本，结合多传感器融合与前沿技术优化初值生成，以提升方法在实际林业装备状态感知场景中的鲁棒性与工程适用性。

参 考 文 献

[1] 杨津，闫哲，雷永杰，等. 低空经济驱动下天空地一体化智能林机装备体系构建研究[J]. 林业机械与木工设备，2025，53(10)：61-71，80.
Yang Jin，Yan Zhe，Lei Yongjie，et al. Construction of an integrated sky-air-ground intelligent forestry machinery system in the context of low-altitude economy[J]. Forestry Machinery & Woodworking Equipment，2025，53(10)：61-71，80.

[2] 颜世运，张慧斌，籍浩恺，等. 基于改进YOLOv8模型的

木材缺陷检测[J]. 森林工程,2025,41(4):750-760.
Yan Shiyun, Zhang Huibin, Ji Haokai, et al. Research on wood defect detection based on improved YOLOv8 model [J]. Forest Engineering, 2025, 41(4): 750-760.

[3] Maktoubian J, Taskhiri M S, Turner P. Intelligent predictive maintenance (IPdM) in forestry: a review of challenges and opportunities[J]. Forests, 2021, 12(11): 1495.

[4] 杨朔,阚江明,赵汐璇. 基于APO-RBF神经网络的林区能见度预测方法[J]. 林业工程学报,2026,11(2):100-107.
Yang Shuo, Kan Jiangming, Zhao Xixuan. Forest visibility prediction method based on APO-RBF neural network[J]. Journal of Forestry Engineering, 2026, 11(2): 100-107.

[5] Cui C, Zhang Q, Zhang D, et al. Monitoring and detection of steel bridge diseases: a review[J]. Journal of Traffic and Transportation Engineering (English Edition), 2024, 11(2): 188-208.

[6] 胡晓暄,贾艳敏,许峻铭,等. 基于开孔钢板连接的钢-混组合梁抗弯性能[J]. 森林工程,2025,41(5):1073-1081.
Hu Xiaoxuan, Jia Yanmin, Xu Junming, et al. Study on flexural behavior of connecting steel-concrete composite beams based on PBL[J]. Forest Engineering, 2025, 41(5): 1073-1081.

[7] 韩文花,原野,张玉祥,等. 任意形状缺陷漏磁检测的有限元前向模型[J]. 火力与指挥控制,2018,43(1):80-84.
Han Wenhua, Yuan Ye, Zhang Yuxiang, et al. Research on finite element forward model for magnetic flux leakage testing of arbitrary shape defects[J]. Fire Control & Command Control, 2018, 43(1): 80-84.

[8] 王雨菲,韩文花. 基于坐标偏移磁偶极子-牛顿-拉夫逊法的三维不规则缺陷重构方法[J]. 仪器仪表学报,2024,45(6):328-336.
Wang Yufei, Han Wenhua. 3D irregular defect reconstruction method based on coordinate offset magnetic dipole-Newton-Raphson method[J]. Chinese Journal of Scientific Instrument, 2024, 45(6): 328-336.

[9] Zhong Y, Wang G, Yu X, et al. Defect size quantification for pipeline dynamic MFL detection via 3-D dynamic magnetic dipole forward model[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 6001910.

[10] Wang Y, Guo J, Hu T, et al. Machine learning-based dipole modeling of 3-D magnetic flux leakage caused by outer-surface linear cracks for pipeline in-line inspection [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 2531614.

[11] Li S, Zhang J, Zhang X, et al. A 3D reconstruction method for complex defects based on MFD and multidirectional MFL [C]//2024 IEEE International Instrumentation and Measurement Technology Conference (I2MTC). May 20-23, 2024, Glasgow, United Kingdom. IEEE, 2024.

[12] 缪立恒,潘峰,彭丽莎,等. 基于漏磁信号深度特性的缺陷深度轮廓迭代优化方法[J]. 中国电机工程学报,2022,42(8):3077-3086.
Miao Liheng, Pan Feng, Peng Lisha, et al. Iterative optimization method of defect depth profile based on depth characteristics of MFL signal[J]. Proceedings of the Chinese Society for Electrical Engineering, 2022, 42(8): 3077-3086.

[13] Hou D, Lu S, Yi G, et al. A target-focusing optimization method for 3-D profile reconstruction of defects using MFL measurements[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-11.

[14] 石晴,张国山,刚蓓,等. 基于随机森林的管道漏磁缺陷检测与量化[J]. 电子测量与仪器学报,2025,39(3):199-207.
Shi Qing, Zhang Guoshan, Gang Bei, et al. Detection and quantification of pipeline magnetic flux leakage defects based on random forest[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(3): 199-207.

[15] 于祉祺,刘皓源,何璐瑶,等. 基于CNN-Transformer的管道缺陷三维重构方法[J]. 现代信息科技,2024,8(20):48-55.
Yu Zhiqi, Liu Haoyuan, He Luyao, et al. Three dimensional reconstruction method of pipeline defects based on CNN-Transformer [J]. Modern Information Technology, 2024, 8(20): 48-55.

[16] 赵东升,杨理践,耿浩,等. 一种面向管道缺陷检测的漏磁数据增强方法[J]. 仪表技术与传感器,2023(12):111-116.
Zhao Dongsheng, Yang Lijian, Geng Hao, et al. MFL data augmentation method for pipeline defect detection[J]. Instrument Technique and Sensor, 2023(12): 111-116.

[17] Zhang S, Li H, Zhao C. Defect-depth-field algorithm for simulating magnetic flux leakage signals based on discrete magnetic dipole model[J]. NDT & E International, 2023, 139: 102939.

[18] 朱红秀,刘欢,李宏远,等. 基于优化RBF神经网络的管道缺陷量化分析方法[J]. 仪表技术与传感器,2016(2):83-86.
Zhu Hongxiu, Liu Huan, Li Hongyuan, et al. Quantitative analysis method for pipeline defects based on optimized RBF neural network[J]. Instrument Technique and Sensor, 2016(2): 83-86.

[19] 王晓红,辛守英,张薇,等. 基于主成分分析下贝叶斯优化卷积神经网络模型人工林树种识别的研究[J]. 森林工程,2025,41(2):298-311.
Wang Xiaohong, Xin Shouying, Zhang Wei, et al. Study on tree species identification of planted forests based on PCA-BO-CNN model[J]. Forest Engineering, 2025, 41(2): 298-311.

[20] Sowmya R, Premkumar M, Jangir P. Newton-raphson-based optimizer: a new population-based metaheuristic algorithm for continuous optimization problems[J]. Engineering Applications of Artificial Intelligence, 2024, 128: 107532.