Magnetic Anomaly Detection Based on Multi-Feature Fusion and Improved Ensemble Learning*

GAO Yingxin[1], LI Bin[2], WANG Yaoli[1*], CAHNG Qing[1]
(1.College of Electronic Information Engineering, Taiyuan University of Technology, Taiyuan Shanxi 030600, China;
(2.School of Marine Science and Technology, Northwestern Polytechnical University, Xi'an Shaanxi 710072, China)

Abstract: The magnetic anomaly signal consists of the anomaly signal and the geomagnetic field signal. In the actual measurement, the detection probability is limited by the low signal-to-noise ratio due to the existence of environmental noise. To solve this problem, a magnetic anomaly detection method based on multi-feature fusion and improved ensemble learning is proposed. Firstly, the magnetic signal features are extracted from multiple angles. Besides the traditional magnetic moment features and statistical features, EEMD-SVD features are also introduced. Then the features are fused with t-SNE dimensionality reduction. Finally, random forest, decision tree and naive Bayes are used as the basic learning of ensemble learning, and an efficient magnetic anomaly classification network is constructed by using the fusion strategy based on Manhattan distance. The experimental results show that the classification accuracy of the proposed method is 97.62%, the F1 score is 97.40%, the AUC score is 98.73%, and it performs well in the task of magnetic anomaly signal classification.

Key words: magnetic anomaly detection; signal classification; feature fusion; integrated learning; Manhattan distance
EEACC: 7310; 7310L **doi**: 10.3969/j.issn.1004-1699.2026.09.012

基于多特征融合和改进集成学习的磁异常检测*

高濛欣[1], 李 斌[2], 王耀力[1*], 常 青[1]
(1.太原理工大学电子信息工程学院, 山西 太原 030600; 2.西北工业大学航海学院, 陕西 西安 710072)

摘 要: 磁异常信号由异常信号和地磁场信号组成, 在实际测量中, 由于环境噪声的存在, 检测概率受到信噪比低的限制。针对这一问题, 提出了一种基于多特征融合和改进集成学习的磁异常检测方法。首先, 从多个角度提取磁场信号特征, 除了传统的磁矩特征和统计特征外, 还引入了 EEMD-SVD 特征; 再将特征进行 t-SNE 降维融合; 最后采用随机森林、决策树和朴素贝叶斯作为集成学习的基学习器, 并利用基于曼哈顿距离的融合策略结合三者, 构建了一个高效的磁异常分类网络。实验结果表明, 该方法的分类准确率为 97.62%, F1 分数为 97.40%, AUC 分数为 98.73%, 在磁异常信号分类任务中表现良好。

关键词: 磁异常检测; 信号分类; 特征融合; 集成学习; 曼哈顿距离
中图分类号: TP391 **文献标识码**: A **文章编号**: 1004-1699(2026)09-2014-08

铁磁物体产生的磁场叠加在原磁场上, 生成磁场扰动, 称为磁异常现象[1]。磁异常检测(MAD)技术由此发展, 通过对磁传感器测得的信号进行分析, 可以得到铁磁物体的相关信息[2]。由于磁场在传播过程中不容易受到空气、水、土壤等介质的影响, 磁场信号保持相对稳定[3]。因此, MAD 技术在地质勘探、地震预测等多个领域得到了广泛应用[4-5]。

目前研究者常用的磁异常检测方法, 可以归纳为两大类。

第一类是依赖信号处理的磁异常检测方法。其中, 最具代表性的是基于正交基函数(OBF)的检测方法[6]。实验表明, 在高信噪比条件下 OBF 方法可以得到较好的检测效果。但是, 随着背景环境的复杂化, 信噪比降低, 传统的 OBF 方法性能显著下降。因此, 研究者提出了多种改进方法, 例如, Sheinker 等[7]提出对信号进行预白化滤波后, 再进行 OBF 检测; 邱伟成等[8]提出利用 K-L 展开对 OBF 的基函数进行修正, 提高有色背景噪声下的磁异常检测精度。此外, 研究人员还进行了其他改进, 如利用奇异值分解(SVD)方法[9]、主成分分析法(PCA)[10]、时频分析法[11]、经验模态分解(EMD)[12]等。这类检测方法大多是对单一特征的检测, 不能充分利用信号中的信息。

第二类是基于机器学习的磁异常检测方法, 此

项目来源: 山西省自然科学基金项目(201801D121141); 山西省重点研发项目(201903D321003)
收稿日期: 2024-08-13 **修改日期**: 2024-09-11

方法将 MAD 视为一个二分类问题[13]。例如,Fan 等[14]利用一维卷积神经网络,通过希尔伯特-黄变换和离散小波变换获得磁信号不同维度的预特征,再使用一维卷积神经网络进一步提取特征,来识别是否存在异常信号;Liu 等[15]提出了基于全连接神经网络的 MAD 方法,输入信号的特征,通过迭代得到层数和节点数最优的网络结构。此外,集成学习也是一种热门算法,它将多个基学习器结合来完成学习任务,具有精度高、泛化性能好等优点。研究证明,与传统的机器学习算法相比,集成方法具有较好的准确性[16-17]。

本文将多特征融合和集成学习用于磁异常检测,并进行了相应的改进,主要创新点如下:

①多角度提取磁场信号的特征,除了传统的磁矩特征和统计特征外,选取了 EEMD-SVD 特征,提高信噪比的同时,提取更易于分类的特征。多特征提取提供了全面的磁场数据表征,克服数据的局限性。

②针对多个特征间关系冗余的问题,将特征进行 t-SNE 降维,减轻计算负担的同时,保留高维数据的结构信息,有助于提高分类网络的效率和准确性,将降维后的特征作为磁异常分类网络的输入。

③利用随机森林、决策树、朴素贝叶斯三种方法作为集成学习的基学习器,使用基于曼哈顿距离的改进结合策略,构成磁异常分类网络,提高磁异常检测的精度。

1　特征提取及特征融合

1.1　数据集构造

磁场数据集由三轴磁通门传感器采集得到,测量现场由磁传感器模块、数据采集模块和上位机软件三部分组成,如图 1 所示。数据采集模块采集到的数据通过以太网方式与上位机通信,上位机软件可以存储数据,便于对测得的磁场数据进行后续处理。现场采集情况如图 2 所示。

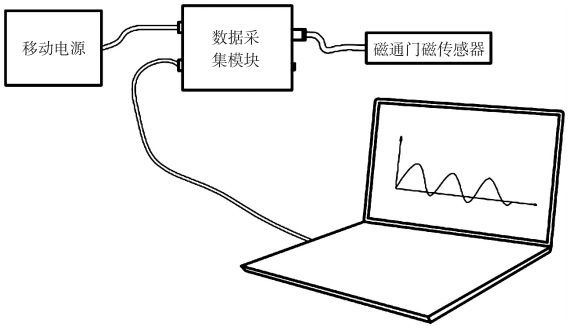

图 1　数据采集示意图

图 2　现场采集情况

传感器采集磁场数据的采样频率为 200 Hz,以直径为 30 cm 的铁磁体为磁异常目标,在不同位置,不同噪声情况下测量磁异常数据和地磁场数据。磁异常数据采用点采样法,地磁场数据采用定点测量法。

1.2　磁矩特征

磁场数据的统计特征是表征磁场特征的一种方式,本文提取均值、标准差、均方根、方差、峰峰值、最大值、最小值、偏度和峰度等 13 个统计特征。这些特征全面描述了磁场数据的波动程度、极端变化及分布形状,提高检测的准确性和效率。部分统计特征(均值、标准差、均方根、方差、峰峰值)公式如下:

$$\begin{aligned}\beta_1 &= \frac{1}{N}\sum_{i=1}^{N} x_i \\ \beta_2 &= \sqrt{\frac{1}{N}\sum_{i=1}^{N}(x_i - \mathrm{Mean})^2} \\ \beta_3 &= \sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^2} \\ \beta_4 &= \frac{1}{N}\sum_{i=1}^{N}(x_i - \mathrm{Mean})^2 \\ \beta_5 &= \max(x) - \min(x)\end{aligned} \tag{1}$$

1.3　统计特征

根据磁偶极子理论[18],当探测距离大于磁性目标尺寸的 2.5 倍时,被测目标可以视为一个磁偶极子,距离磁性目标 r 处的磁场矢量 $\boldsymbol{B}$ 可以表示为:

$$\boldsymbol{B}=\frac{\mu_0}{4\pi r^3}\left[\frac{3(\boldsymbol{M}\times r)r}{r^2}-\boldsymbol{M}\right] \tag{2}$$

式中:$\mu_0 = 4\pi\times10^{-7}$ H/m,为空间磁导率;$\boldsymbol{M}$ 表示目标磁矩矢量。当被测目标满足磁偶极子模型,目标与传感器之间存在相对运动时,建立 OBF 磁异常检测模型,如图 3 所示,模型参数如表 1 所示。

当 $\boldsymbol{B}\ll\boldsymbol{T}$ 时,磁通门传感器测得的信号 S 可视为 $\boldsymbol{B}$ 在 $\boldsymbol{T}$ 上的投影,即:

$$S=\frac{\boldsymbol{B}\times\boldsymbol{T}}{|\boldsymbol{T}|} \tag{3}$$

将式(2)代入式(3)可得:

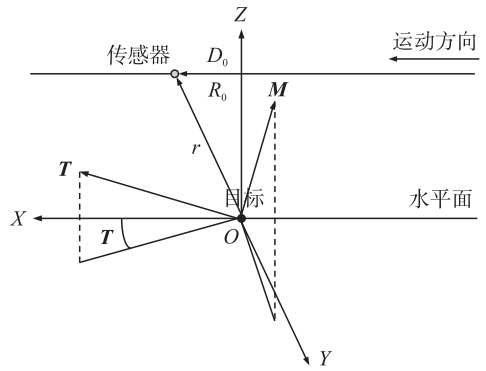

图 3 目标与磁传感器的相对运动关系

表 1 模型参数

参数	含义
X	运动载体沿直线运动的方向
Y	运动载体的左舷方向
Z	竖直向上方向
$\boldsymbol{M}$	目标磁矩矢量
$\boldsymbol{T}$	地磁场矢量
O	目标的位置(偶极子)
R_0	传感器和磁性目标之间的 CPA 距离
D_0	传感器当前位置和 CPA 点之间的距离
θ_M	目标磁矩方向与 Z 轴的夹角
θ_T	地磁场方向与 Z 轴的夹角
ϕ_M	目标磁矩矢量在 OXY 面的投影与 X 轴的夹角

$$S=\frac{\mu_0\boldsymbol{M}}{4\pi R_0^3}\sum_{j=1}^{4} b_j\varphi_j(\omega) \tag{4}$$

式中:

$$\omega=\frac{D_0}{R_0} \tag{5}$$

$$\begin{aligned}\varphi_1(\omega)&=\frac{\omega^2}{(1+\omega^2)^{5/2}}\\ \varphi_2(\omega)&=\frac{\omega}{(1+\omega^2)^{5/2}}\\ \varphi_3(\omega)&=\frac{1}{(1+\omega^2)^{5/2}}\\ \varphi_4(\omega)&=\frac{\omega}{(1+\omega^2)^{3/2}}\end{aligned} \tag{6}$$

$$\begin{aligned}b_1&=3\sin\theta_M\cos\phi_M\sin\theta_T\cos\phi_T\\ b_2&=3(\cos\theta_M\sin\theta_T\cos\phi_T+\sin\phi_M\cos\phi_M\cos\theta_T)\\ b_3&=3\cos\theta_M\cos\theta_T\\ b_4&=-\sin\theta_M\sin\theta_T\cos(\phi_M-\phi_T)-\cos\theta_M\cos\theta_T\end{aligned} \tag{7}$$

对基函数 $\varphi(\omega)$ 进行施密特正交化,得到如下:

$$S(\omega)=\frac{\mu_0\boldsymbol{M}}{4\pi R_0^3}\sum_{j^*=1}^{3} a_{j^*}f_{j^*}(\omega) \tag{8}$$

式中:

$$\begin{aligned}a_1&=\sqrt{\frac{3\pi}{128}}\left[(b_1+b_4)+\frac{5}{3}(b_3+b_4)\right]\\ a_2&=\sqrt{\frac{5\pi}{128}}b_2\\ a_3&=\sqrt{\frac{5\pi}{24}}(b_3+b_4)\end{aligned} \tag{9}$$

$$\begin{aligned}f_1(\omega)&=\varphi_1(\omega)\sqrt{\frac{128}{3\pi}}\\ f_2(\omega)&=\varphi_2(\omega)\sqrt{\frac{128}{5\pi}}\\ f_3(\omega)&=\left[\varphi_3(\omega)-\frac{5}{3}\varphi_1(\omega)\right]\sqrt{\frac{24}{5\pi}}\end{aligned} \tag{10}$$

本文提取 a_1、a_2、a_3 3 个系数作为磁场数据的磁矩特征。

1.4 EEMD-SVD 特征

集合经验模态分解(Ensemble Empirical Mode Decomposition,EEMD)是对经验模态分解(Empirical Mode Decomposition,EMD)的一种改进,用于处理非线性和非平稳信号。EMD 对信号本身进行分解,但会出现模态混叠现象。针对此问题,Huang 等[19]引入了 EEMD 方法,通过不同时间尺度的白噪声补偿频带缺失。基于此特性,任何数据序列都可以通过以下过程进行分解:①向原始信号中加入不同强度的白噪声,生成多个噪声辅助信号。②对每个噪声辅助信号进行 EMD 分解,得到一系列本征模态函数(IMF)。③对每一个加入不同白噪声的信号重复上述 EMD 分解过程,得到若干组 IMF。④对所有噪声辅助信号的 IMF 取平均,消除白噪声的影响,得到最终的 IMF。磁异常信号的 EEMD 分解如图 4 所示。

对磁场信号进行 EEMD 分解,可以得到从高频到低频的一系列频带分量,反映信号在不同时间尺度上的局部特征。然而,每个频带分量包含大量样本点,准确描述这些点的特征很困难。因此,需要简化这些频带组成的矩阵的特征信息。本文采取奇异值分解(SVD)的方法,SVD 将矩阵分解为三个部分:一个正交矩阵、一个包含奇异值的对角矩阵和另一个正交矩阵的转置。这种分解方法能够提取矩阵的主要特征,奇异值越大,特征信息越明显。因此,少量的奇异值可以近似大量样本数据的特征。

本文先利用 EEMD 将磁场信号分解,取前 10 个 IMF,再利用 SVD 从 IMFs 组成的矩阵中提取奇异值,将最终提取的 10 个奇异值作为磁场数据的 EEMD-SVD 特征。

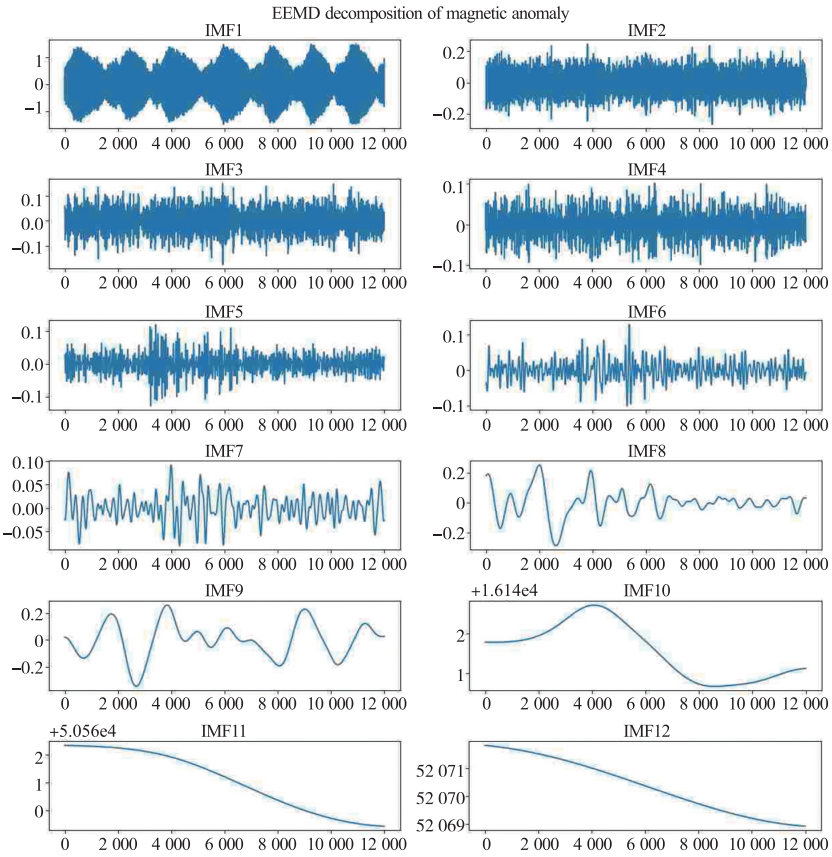

图 4　磁异常信号的 EEMD 分解图

1.5　t-SNE 降维

t-SNE 通过计算高维空间中数据点之间的相似性概率来实现降维,步骤如下:①计算每对数据点之间的高维相似性,用高斯核函数表示相似性概率。②在低维空间中,用学生分布计算降维后的数据点之间的相似性。③通过最小化高维相似性分布和低维相似性分布之间的 Kullback-Leibler 散度来优化降维结果。这个过程通过梯度下降法进行,使高维数据的结构在低维空间中得到最大程度的保留,使降维后的数据仍能反映原始数据的重要特征。

将前面提取的三类特征,通过 t-SNE 降维后,输入后续的分类网络进行磁异常检测,可以显著简化特征空间,使数据更易于处理。处理后的数据保留了重要特征,减少了冗余和噪声信息,使分类器能够更准确地学习和识别关键特征。且降维后的数据大大降低了计算复杂度,训练速度更快,也降低了过拟合风险,使得分类网络在处理复杂高维数据时更加高效和稳定,提高了分类性能。

t-SNE 的降维结果受困惑度 P、学习率 L 和最大迭代次数 iter 三个参数影响较大,经多次试验表明,当 $P=20$、$L=200$、iter1000 时,对磁场数据的降维效果最好,摘取典型参数的结果对比,如图 5 所示,参数设置如表 2 所示。可以看出,在图 5(b)参数组合下,两类数据在三维空间中的相关性最低,区分度最高。

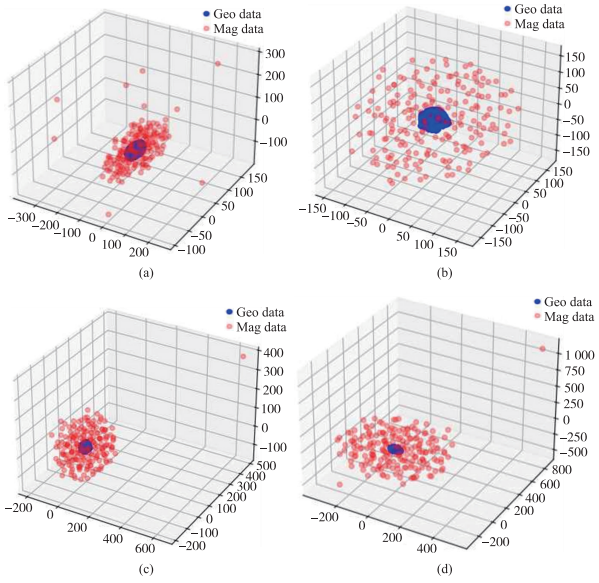

图 5　不同参数 t-SNE 的降维对比

表 2　参数设置

P	L	iter	图示
10	200	500	图 5(a)
20	**200**	**1 000**	**图 5(b)**
30	1 000	500	图 5(c)
50	1 000	1 000	图 5(d)

2 磁异常分类网络

2.1 学习算法

集成学习通过结合多个基学习器提升整体模型的性能和鲁棒性。基学习器单独效果较差,但集成后组合成一个强学习器,准确性和泛化能力显著提升。在分类任务中,集成学习能处理复杂多变的数据,充分利用不同学习器的优势。本文选择随机森林(RF)、朴素贝叶斯(NB)和决策树(DT)作为基学习器。

2.2 结合策略

在集成学习中,结合策略用于整合多个基学习器的结果,生成最终决策。常见的结合策略包括投票法、加权平均法和平均法。投票法选择获得最多票数的类别作为最终决策;加权平均法根据每个基学习器的预测结果和对应权重进行加权平均;平均法直接对所有基学习器的预测结果取平均值。这些策略通过融合各基学习器的结果,形成一个更强的学习器。

本文提出了一种改进的结合策略:基于曼哈顿距离来计算基学习器结果之间的差异,通过这些差异重新分配权重,并利用融合策略对决策结果进行推理,最终生成一个强学习器。具体步骤如下:

①曼哈顿距离的差异度量

首先,计算各个基学习器结果之间的曼哈顿距离。曼哈顿距离定义为两点在各个坐标轴上的绝对差值之和,公式如下:

$$D(x,y)=\sum_{i=1}^{n}|x_i-y_i| \tag{11}$$

式中:$D(x,y)$表示结果 x 和 y 之间的曼哈顿距离,n 为特征维度。

②差异度量与支持度计算

根据计算得到的曼哈顿距离,确定每个基学习器结果的支持度。差异越小,两个基学习器的结果越相似,其支持度越高。支持度通过以下公式计算:

$$S_i=\frac{1}{1+D_i} \tag{12}$$

式中:S_i 表示第 i 个基学习器的支持度,D_i 表示该基学习器与其他基学习器结果的平均曼哈顿距离。

③重新赋予权重

利用计算得到的支持度,对每个基学习器的结果重新赋予权重。权重越高的基学习器对最终决策的影响越大。权重通过以下公式计算:

$$W_i=\frac{S_i}{\sum_{j=1}^{k}S_j} \tag{13}$$

式中:W_i 表示第 i 个基学习器的权重,k 为基学习器的总数。

④融合策略

最后,通过融合策略,将各个加权后的基学习器结果进行合成,推理出最终的分类决策。公式如下:

$$\begin{aligned} m_{12}(D)&=\sum_{B\cap C=A}m_1(B)\times m_2(C)\\ m_{123}(A)&=\sum_{D\cap E=A}m_{12}(D)\times m_3(E)\end{aligned} \tag{14}$$

式中:$m_{123}(A)$表示最终合成的结果,$m_{12}(D)$表示第一步合成的中间结果,m_1、m_2 和 m_3 分别表示三个基学习器的支持度。

本文提出的集成学习方法,通过基于曼哈顿距离的改进结合策略,将随机森林、朴素贝叶斯和决策树三种基学习器整合成一个强学习器。不仅充分利用了各个基学习器的优势,还通过权重重新分配和融合策略,提高了模型的鲁棒性和泛化能力。本文提出的磁异常检测方法流程如图 6 所示。

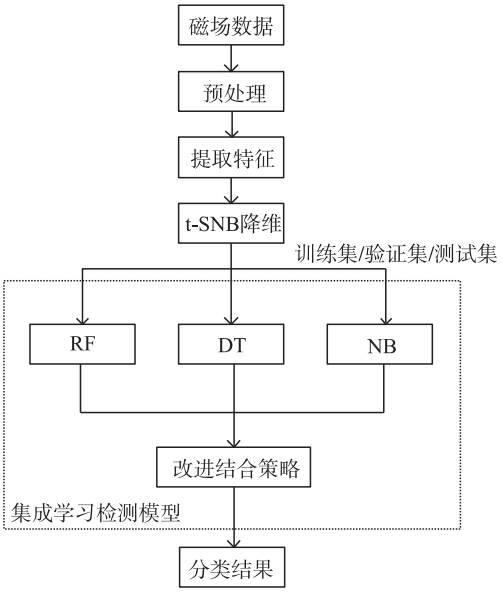

图 6 磁异常检测方法流程图

3 实验结果

3.1 实验数据说明

通过 1.1 章节介绍的三轴磁通门传感器系统的现场采集,确保捕捉到目标的三个正交磁场分量。根据磁偶极子的物理特性,测得的信号包含磁场的空间分布和强度信息。将数据进行预处理后,为本次实验分别准备了 1 500 组磁异常样本和 1 500 组地磁场样本,采集得到的数据示例如图 7 所示,图中的横轴表示数据量,纵轴表示归一化后的磁场强度,可见测量信号的信噪比很低,磁异常信号淹没在噪声中,难以分辨。

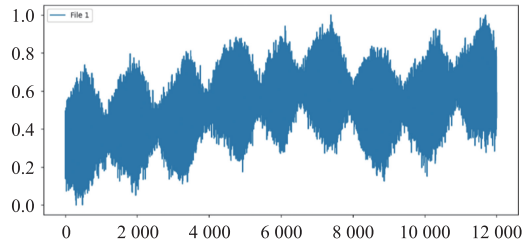

(a) 实测地磁场

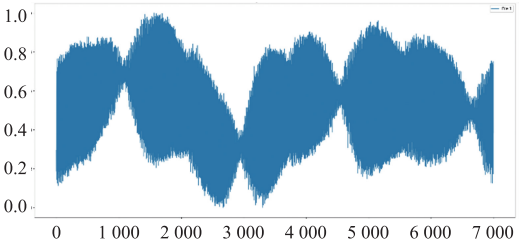

(b) 实测磁异常

图 7　实测数据示例

3.2　学习算法对比

将磁场数据进行特征提取,t-SNE 降维融合后,用 RF 算法、NB 算法、DT 算法进行训练、测试及验证,三种算法的参数对检测结果均产生影响,调试不同的参数进行实验,其中,朴素贝叶斯在每次实验中使用不同的随机种子进行数据分割。三种基学习器的训练参数和检测结果见表 3~表 5。

如表 3~表 5 所示,三种方法均在不同的参数条件下,训练了 10 个磁异常检测模型,RF 算法检测结果范围为 95.83%~96.83%,NB 算法检测结果范围为 88.67%~92.11%,DT 算法检测结果范围为 95.67%~97.33%,三者中,RF 算法的方差最小,为 0.000 012 7,可见 RF 算法的稳定性最好,DT 算法的检测准确率相对最高,NB 算法的准确率相对较低,方差最大,即稳定性较差。

表 3　RF 参数设置与检测结果

模型编号	树的数量	最大深度	最小样本分割数	最小样本叶子数	最大特征数	训练模型准确率/%	磁异常检测准确率/%
1	100	10	2	1	auto	96.56	96.50
2	100	20	2	1	auto	95.44	96.00
3	200	10	2	1	auto	97.94	96.67
4	200	20	2	1	auto	97.94	96.83
5	150	15	2	1	auto	96.44	96.50
6	150	15	4	2	sqrt	96.94	96.67
7	250	15	2	2	log2	96.44	96.50
8	300	20	4	2	sqrt	95.39	95.83
9	200	10	4	2	log2	95.33	96.00
10	200	20	2	2	sqrt	95.44	96.00

表 4　NB 参数设置与检测结果

模型编号	训练模型准确率/%	磁异常检测准确率/%	模型编号	训练模型准确率/%	磁异常检测准确率/%
1	91.19	90.89	6	89.76	88.67
2	90.29	91.44	7	90.24	92.11
3	90.67	91.44	8	90.48	90.89
4	91.00	90.44	9	90.24	90.56
5	91.29	90.89	10	90.86	91.00

表 5　DT 参数设置与检测结果

模型编号	最大深度	最小样本分割数	最小样本叶子数	训练模型准确率/%	磁异常检测准确率/%	模型编号	最大深度	最小样本分割数	最小样本叶子数	训练模型准确率/%	磁异常检测准确率/%
1	10	2	1	96.39	96.50	6	20	4	1	97.39	95.67
2	15	2	1	94.56	95.67	7	10	2	2	96.11	97.00
3	20	2	1	96.11	96.00	8	15	4	2	96.39	97.33
4	10	4	1	97.22	97.00	9	20	2	2	94.56	97.00
5	15	4	1	94.56	95.67	10	20	4	2	94.56	97.33

3.3 结合策略对比

从 3.2 节中的三类模型中,每类随机选择一个模型以组成基学习器组,并使用结合策略形成强学习器,构建磁异常检测模型,随机进行 10 次实验。将本文提出的改进结合策略与软投票、改进欧几里得距离、改进余弦距离进行对比,实验结果如图 8 所示。

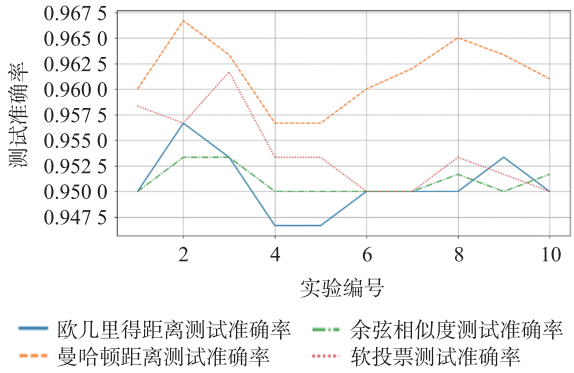

图 8 结合策略对比

由图 8 可以看出,使用本文提出的改进结合策略的磁异常检测准确率高于其余三种方法,能更好地实现磁场信号分类。

3.4 检测结果对比

从 3.2 节中的三类模型中,每类随机选择一个模型以组成基学习器组,并使用基于曼哈顿距离的改进结合策略,构建磁异常检测模型。随机进行 20 次试验,图 9 结果展示了三种基学习器与改进的集成学习方法的磁异常检测性能对比。

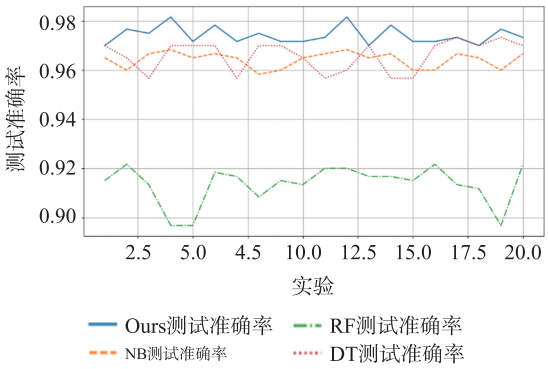

图 9 三种基学习器与改进的集成学习方法检测结果对比

由图 9 可知,与三种基学习器对比,本文的集成学习网络的准确率明显高于三种基学习器,且波动较平缓,分类效果和稳定性能更佳,具有更高的磁异常检测准确率和更好的可靠性。

另外,统计 20 次随机试验的实验结果取平均值,如表 6 所示,实验结果显示,所提出模型的准确率为 97.62%,显著高于 RF 的 96.32%、DT 的 96.5%和 NB 的 91.34%,表明所提出模型在实际应用中能够更准确地识别磁异常。F1 分数方面,所提出模型为 97.40%,远高于 RF 的 95.42%、DT 的 95.03%和 NB 的 90.81%,表明其不仅能有效识别正样本,还能减少误报,具有更好的分类平衡性。AUC 分数方面,所提出模型高达 98.73%,明显优于 RF 的 96.17%、DT 的 96.01%和 NB 的 94.70%,反映出其在不同阈值下的整体表现更为优越,具有更强的区分能力。三种传统模型的平均准确率、F1 分数和 AUC 分数分别为 94.72%、93.75%和 95.62%,与此相比,所提出模型在每个指标上均有显著提升,进一步验证了其检测性能的优越性。综合来看,所提出模型在各项关键指标上均表现优异,表明了其在磁异常检测任务中的卓越性能。综上所述,通过多特征融合和改进的集成学习网络,所提出模型能够更有效地进行磁异常检测,提高检测准确率和分类性能。

表 6 20 次随机试验结果汇总

模型	Accuracy/%	F1 Score/%	AUC Score/%
RF	96.32	95.42	96.17
DT	96.50	95.03	96.01
NB	91.34	90.81	94.70
Mean	94.72	93.75	95.62
Ours	**97.62**	**97.40**	**98.73**

4 总结

本文将多特征融合和集成学习应用于磁异常检测,并进行了创新性的改进。首先,从多角度提取磁场信号特征,除了传统的磁矩和统计特征外,增加了 EEMD-SVD 特征,以提高信噪比并提取更适合分类的特征。通过多特征提取,提供了更全面的磁场数据表示,克服了单一特征带来的数据局限性。其次,针对特征间冗余和非线性关系问题,使用 t-SNE 方法对特征进行降维,既减轻了计算负担,又保留了高维数据的结构信息,提高了分类网络的效率和准确性。最后,利用随机森林、决策树和朴素贝叶斯作为基学习器,采用基于曼哈顿距离的改进结合策略进行集成学习,构建了高效的磁异常分类网络。实验结果表明,本文提出的模型在测试集上的准确率达到 97.62%,F1 分数为 97.40%,AUC 分数高达 98.73%,显著优于单个基学习器。综上,本文的模型在准确性和整体分类能力上表现出色,证明了该方法的有效性和优越性。

参考文献:

[1] Sheinker A, Lerner B, Salomonski N, et al. Localization and Magnetic Moment Estimation of a Ferromagnetic Target by Simulated Annealing[J]. Measurement Science & Technology, 2007, 18(11): 3451.

[2] Kim W H, Kim J C, Choi I K, et al. Improvement of the Signal to Noise Ratio of the Magnetic Detection System Using the Geological Magnetic Filter [C]//1999 6th IEEE International Conference on Electronics, Circuits and Systems, Pafos, Cyprus, 1999:237-240.

[3] Chen L Z, Feng Y Q, Wu P L, et al. An Innovative Magnetic Anomaly Detection Algorithm Based on Signal Modulation[J]. IEEE Transactions on Magnetics, 2020, 56(9):6200609.

[4] Zhang S, Guan Z C, Wang J Y, et al. Detect Adjacent Well by Analyzing Geomagnetic Anomalies[J]. Research Journal of Applied Sciences, Engineering and Technology, 2014, 7(11):2353-2361.

[5] Zhang J S, Gao R, Zeng L S, et al. Relationship between Characteristics of Gravity and Magnetic Anomalies and the Earthquakes in the Longmenshan Range and Adjacent Areas[J]. Tectonophysics, 2010, 491(1-4):218-229.

[6] Ginzburg B, Frumkis L, Kaplan B Z. Processing of Magnetic Scalar Gradiometer Signals Using Orthonormalized Functions [J]. Sensors and Actuators A: Physical, 2002, 102(1-2): 67-75.

[7] Sheinker A, Shkalim A, Salomonski N, et al. Processing of a Scalar Magnetometer Signal Contaminatedby 1/fα Noise [J]. Sensors & Actuators A Physical, 2007, 138(1): 105-111.

[8] 邱伟成,张欣苗. 基于卡亨南-洛维展开的修正 OBF 磁目标检测方法[J]. 电子测量与仪器学报, 2023, 37(9):119-125.

[9] Zheng J, Fan H, Zhang Q, et al. Magnetic Anomaly Target Recognition Based on SVD and SVMs[J]. IEEE Transactions on Magnetics, 2019, 55(9):6000708.

[10] Sheinker A, Moldwin M B. Magnetic Anomaly Detection (MAD) of Ferromagnetic Pipelines Using Principal Component Analysis (PCA) [J]. Measurement Science and Technology, 2016, 27(4):045104.

[11] Wang X L, Zhao D D, Liu J X, et al. Efficient 2D Modeling of Magnetic Anomalies Using NUFFT in the Fourier Domain[J]. Pure and Applied Geophysics, 2022, 179(6-7):2311-2325.

[12] 宁文茜,王艳华,樊黎明,等. 基于 EEMD 和 DWT 的弱磁异常信号提取方法[J]. 水下无人系统学报, 2023, 31(4):568-574.

[13] Zozor S, Rouve L L, Cauffet G, et al. Compared Performances of MF-Based and Locally Optimal-Based Magnetic Anomaly Detection[C]//2010 18th European Signal Processing Conference, Aalborg, Denmark, 2010:149-153.

[14] Fan L, Hu H, Zhang X, et al. Magnetic Anomaly Detection Using One-Dimensional Convolutional Neural Net-Work with Multi-Feature Fusion [J]. IEEE Sensors Journal, 2022, 22(12):11637-11643.

[15] Liu S C, Chen Z, Pan M C, et al. Magnetic Anomaly Detection Based on Full Connected Neural Network [J]. IEEE Access, 2019, 7:182198-182206.

[16] Zounemat-Kermani M, Batelaan O, Fadaee M, et al. Ensemble Machine Learning Paradigms in Hydrology: A Review[J]. Journal of Hydrology, 2021, 598:126266.

[17] Dhibi K, Mansouri M, Bouzrara K, et al. An Enhanced Ensemble Learning-Based Fault Detection and Diagnosis for Grid-Connected PV Systems[J]. IEEE Access, 2021, 9:155622-155633.

[18] 张朝阳,肖昌汉,高俊吉,等. 磁性物体磁偶极子模型适用性的试验研究[J]. 应用基础与工程科学学报, 2010, 18(5):862-868.

[19] Wu Z H, Huang N E. Ensemble Empirical Mode Decomposition: a Noise-Assisted Data Analysis Method. Advances in Adaptive Data Analysis, 2009, 1(1):1-4.

高漯欣(2000—),女,硕士研究生,研究方向为磁异常检测与定位;

李　斌(1964—),男,教授,研究生导师,研究方向为海洋磁场;

王耀力(1965—),男,通讯作者,副教授,研究生导师,研究方向为机器视觉、计算智能与最优化建模,wangyaoli@tyut.edu.cn;

常　青(1981—),男,副教授,研究生导师,研究方向为嵌入式系统、信息系统设计。