

激光与光电子学进展

基于梯度提升决策树算法的光纤入侵信号分类

曲洪权¹, 王征一^{1*}, 盛智勇¹, 曲洪斌², 王玲³

¹北方工业大学信息学院, 北京 100144;

²中国石油管道局工程有限公司国际事业部, 河北 廊坊 065000;

³中国石油管道局工程有限公司亚太分公司, 河北 廊坊 065000

摘要 光纤预警系统已被广泛应用于油气管道的入侵检测预警中, 目前的技术难点仍是如何提高光纤入侵信号多分类识别的准确率。采用梯度提升决策树(GBDT)算法训练光纤入侵信号多分类模型, 并提出了一种基于傅里叶分解方法(FDM)及GBDT算法的特征提取与识别算法。该算法采用FDM对光纤入侵信号进行预处理, 提取信号的近似熵、能量和谱熵特征。采用GBDT算法训练模型并对光纤入侵信号进行识别分类。为了检验该算法的性能, 分别用支持向量机和AdaBoost算法训练模型并进行对比实验。结果表明, 该算法能有效识别敲击、小跑、过车和镐刨四类光纤入侵信号, 平均准确率为92.5%。

关键词 光纤光学; 光纤入侵信号; 特征提取与识别; 傅里叶分解; 梯度提升决策树

中图分类号 TN911.6

文献标志码 A

DOI: 10.3788/LOP202259.2306003

Fiber Intrusion Signal Classification Based on Gradient Boosting Decision Tree Algorithm

Qu Hongquan¹, Wang Zhengyi^{1*}, Sheng Zhiyong¹, Qu Hongbin², Wang Ling³

¹School of Information Science and Technology, North China University of Technology, Beijing 100144, China;

²International Business Department, China Petroleum Pipeline Bureau Engineering Co., Ltd., Langfang 065000, Hebei, China;

³Asia Pacific Branch of China Petroleum Pipeline Bureau Engineering Co., Ltd., Langfang 065000, Hebei, China

Abstract The optical fiber early warning system has been widely used in the intrusion detection and early warning of oil and gas pipelines. The current technical difficulty is still how to improve the accuracy of multi-class recognition of optical fiber intrusion signals. In this paper, gradient boosting decision tree (GBDT) algorithm is used to train the multi-classification model of fiber intrusion signal, and a feature extraction and recognition algorithm based on Fourier decomposition method (FDM) and GBDT algorithm is proposed. The algorithm uses FDM to preprocess the fiber intrusion signal, extracts the approximate entropy, energy and spectral entropy characteristics of the signal, and then uses the GBDT algorithm to train the model to identify and classify the fiber intrusion signal. In order to test the performance of the algorithm, use support vector machine and AdaBoost algorithms to train the models and conduct comparative experiments. The results show that the algorithm can effectively identify four types of optical fiber intrusion signals, namely, knocking, trotting, passing and picking, with an average accuracy of 92.5%.

Key words fiber optics; fiber intrusion signal; feature extraction and recognition; fourier decomposition; gradient boosting decision tree

1 引言

随着油气管道的不断增加, 检测油气运输过程中的人侵事件并发出预警尤为重要。基于相位敏感光时

域反射(Φ -OTDR)的干涉型分布式光纤预警系统已被广泛应用于油气管道预警领域^[1-3]。该系统通过采集不同外界入侵扰动产生的光纤入侵信号, 结合模式识别技术对入侵信号进行识别分类, 从而发出预警。

收稿日期: 2021-09-09; 修回日期: 2021-11-12; 录用日期: 2021-11-19

基金项目: 国家自然科学基金(61571014)、北京市自然科学基金(4172017)

通信作者: *415896430@qq.com

实际应用中光纤架设布局环境复杂,易受自然环境噪声的影响,且光纤入侵信号是一种非线性非平稳信号,因此对光纤入侵信号的特征提取和识别是该技术的关键^[4],如何提取有效的特征并设计识别率较高的多类光纤入侵信号识别算法是该领域的研究热点^[5]。

近年来,人们对光纤入侵信号的识别和提取开展了深入研究。马喆等^[6]通过分析小波能量谱并结合相关矢量机对三类入侵信号进行识别分类,平均准确率为 88.6%,但难以区分撞击和行人扰动信号。于发硕等^[7]从时域、差分域及小波域中提取了光纤振动信号的联合特征并用支持向量机(SVM)算法识别光纤振动信号。王兴奇等^[8]提取了 11 种特征参量,采用结合二叉树的 SVM 分类器模型识别四类光纤振动信号,识别率为 90%,但该算法将 11 个特征两两组合,在 165 种组合中寻找最优特征组合并搭建分类器,步骤复杂。上述研究多采用单一强分类器训练光纤入侵信号分类模型,但单一强分类器的多分类性能有限。当待识别信号种类较多时,往往需要提取较多的特征或训练多个分类器以达到较好的识别效果,训练时间较长。随着机器学习的发展和应用,集成学习因能高效解决实际问题^[9]得到了人们的广泛关注和深入研究。其中,Boosting 算法是利用迭代方法将多个弱分类器加权融合为一个强分类器的算法^[10],可提升弱分类器的性能。

本文提出了一种基于傅里叶分解方法(FDM)和梯度提升决策树(GBDT)的光纤入侵信号分类算法。该算法先对光纤入侵信号进行归一化处理,采用 FDM 分解入侵信号并计算各分量的排列熵。然后根据排列熵筛选分量进行信号重构,并提取信号的近似熵、能量和谱熵特征,构建三维特征向量,采用 GBDT 算法训练模型后进行识别分类。最后,通过对比实验验证了该算法的有效性。

2 基本原理

2.1 光纤入侵信号的预处理

光纤入侵信号的预处理步骤:1)对原始信号进行归一化处理;2)采用 FDM 分解光纤入侵信号得到一系列傅里叶固有频带函数(FIBF)分量;3)计算各分量的排列熵,筛选符合条件的分量进行信号重构。FDM 是由 Singh 等^[11]基于傅里叶变换提出的一种非线性非平稳自适应信号处理方法。该方法可自适应地整个傅里叶域内搜寻傅里叶固有频带函数(AFIBF),从而将信号 $x(t)$ 分解成若干个 FIBFs 和一个残余分量^[12],可表示为

$$x(t) = \sum_{i=1}^M y_i(t) + r(t), \quad (1)$$

式中: $y_i(t)$ 为 M 个单分量信号,即 FIBF; $r(t)$ 为残余分量。

FDM 的数学理论充分,是一种具有完备性、正交

性、自适应性的信号分解方法。FDM 搜寻解析傅里叶固有频带函数包括从低频到高频搜索(LTH-FS)和从高频到低频搜索(HTL-FS)两种算法。分析实验采集的光纤入侵信号发现,其噪声信息主要集中在高频,因此采用 LTH-FS 算法。对于离散信号 $x(n)$,LTH-FS 算法的步骤如下。

1) 对 $x(n)$ 进行傅里叶变换,得到 $X[k] = F[x(n)]$ 。

2) 对信号进行分解,得到 AFIBF,可表示为

$$X_i^{\text{AFIBF}} = \sum_{k=N_{i-1}+1}^{N_i} X[k] \exp\left(\frac{j2\pi kn}{N}\right) = a_i[n] \exp(j\varphi_i[n]), \quad (2)$$

式中: $i = 1, \dots, M$; $N_0 = 0$; $N_M = (N/2 - 1)$; $a_i[n] \exp(j\varphi_i[n])$ 为离散信号 $x(n)$ 的傅里叶展开。为了得到最少的 AFIBFs,对每个 i ,从 $N_{i-1} + 1$ 开始,逐渐增加直至最大的 N_i ,即 $(N_{i-1} + 1) \leq N_i \leq (\frac{N}{2} - 1)$,且每个 X_i^{AFIBF} 的相位 $\varphi_i[n]$ 都满足 $\omega_i[n] = (\frac{\varphi_i[n+1] - \varphi_i[n-1]}{2}) \geq 0$ 。

3) 残余分量可表示为

$$r[n] = X[0] + X[N/2](-1)^n. \quad (3)$$

4) 计算 AFIBF 的实部,即可得到 FIBF。

排列熵是 Bandt 等^[13]提出的一种检测时间序列随机性和动力学突变的方法,能准确、方便地定位信号发生突变的时刻和定量评估信号序列中含有的随机噪声。因此,可根据各 FIBF 分量的排列熵值筛选分量并重构信号^[14]。对于长度为 N 的时间序列 $\{X(K), K = 1, \dots, N\}$,其计算步骤如下。

1) 将时间序列相空间重构得到矩阵 \mathbf{Y} ,即

$$\mathbf{Y} = \begin{bmatrix} x(1) & \dots & x[1+(m-1)t] \\ \vdots & & \vdots \\ x(K) & \dots & x[K+(m-1)t] \end{bmatrix}, \quad (4)$$

式中: m 为嵌入维数; t 为延迟时间; $K = N - (m-1)t$ 。

2) 按行将矩阵 \mathbf{Y} 进行升序排列,得到各元素位置的列索引并构成一组符号序列,可表示为

$$S(l) = \{j_1, \dots, j_m\}, l = 1, \dots, k, k \leq m!. \quad (5)$$

3) 计算每一种序列出现的可能性 $\{P_1, \dots, P_k\}$ 。

4) 排列熵可表示为

$$H_{pe} = - \sum_{i=1}^k P_i \ln(P_i), \quad (6)$$

可以发现,当 $P_i = m!$ 时,排列熵取得最大值 $\ln(m!)$ 。实际应用中通常将排列熵进行归一化,可表示为

$$0 \leq H_{pe} = \frac{H_{pe}}{\ln(m!)} \leq 1. \quad (7)$$

计算排列熵时,嵌入维数 m 的选择至关重要, m 过小会使重构信号状态量缺失, m 过大相空间重构过程中时间序列会被均匀化,一般设置 m 的取值范围为

3~7。实验中根据经验选取插入维数 $m=4$, 时间延迟 $t=1$ 。

以敲击信号为例, 对其进行 FDM 分解, 并求取各 FIBF 分量的排列熵值。敲击原始信号及部分 FIBF 分量如图 1 所示, 部分 FIBF 分量的排列熵值如表 1 所示。可以发现, FIBF 分量的高频部分排列熵值较低, 结合图 1 可知这些高频分量比较规则, 有明显的周期, 用




图 1 敲击原始信号及分解结果。
Fig. 1 Original signal of tapping and the decomposition result.
(a) Original signal; (b) decomposition result

表 1 部分 FIBF 分量的排列熵值

Table 1 Permutation entropy value of some FIBF components

FIBF	Permutation entropy
FIBF 1	0.0000
FIBF 2	0.2255
FIBF 3	0.2838
FIBF 4	0.3253
FIBF 7	0.5812
FIBF 8	0.7130
FIBF 16	0.4579
FIBF 17	0.2181

这种高频分量重构信号会使重构结果出现较多毛刺, 不利于特征提取。因此, 重构信号时剔除高频 FIBF 分量, 只在低频 FIBF 分量中筛选分量并重构信号。

设定排列熵阈值为 0.6, 即选取排列熵值小于 0.6 的低频 FIBF 分量重构信号。分别选取小跑、敲击、过车和镐刨入侵信号样本进行预处理, 结果如图 2 所示。可以发现, 预处理保留了光纤入侵信号的有效信息, 同时去除了原始信号中的噪声信息, 有利于后续特征提取。

2.2 光纤入侵信号的特征提取

完成预处理后进行光纤入侵信号的特征提取, 通过大量实验研究决定提取信号的近似熵、能量和谱熵特征。

近似熵 (ApEn) 是由 Pincus^[15] 提出的用于测量时间序列规律性和复杂性的算法, 可以反映光纤入侵信号的非线性动力学特征。近似熵的大小可表征光纤入侵信号的复杂性, 近似熵越大, 表明信号越复杂。

对于长度为 N 的一段光纤入侵信号 $x(N)$, 将其按顺序重构成 m 维矢量 $X(i)$, 即

$$X(i) = [u(i), \dots, u(i+m-1)], i = 1, \dots, N-m+1, \quad (8)$$

定义矢量 $X(i)$ 和 $X(j)$ 之间的距离 $d[X(i), X(j)]$ 为两者差值的极大值, 则

$$d[X(i), X(j)] = \max_{k=0 \sim m-1} |u(i+k) - u(j+k)|, \quad (9)$$

设定阈值 r , 对于每一个 $i \leq N-m+1$, 统计 $d[X(i), X(j)] \leq r$ 的数目, 并计算其与矢量总数的比值 $C_i^m(r)$, 可表示为

$$C_i^m(r) = \{d[X(i), X(j)] \leq r\} / (N-m+1), \quad (10)$$

取 $C_i^m(r)$ 的对数, 再求平均值, 记为 $\phi^m(r)$, 即

$$\phi^m(r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \ln C_i^m(r), \quad (11)$$

将维数 m 增加 1, 重复上述过程, 得到 $\phi^{m+1}(r)$, 则光纤入侵信号的近似熵可表示为

$$X_{\text{ApEn}}(m, r) = \phi^m(r) - \phi^{m+1}(r). \quad (12)$$

通过上述计算过程可以发现, 近似熵值主要与维度 m 和阈值 r 有关。Pincus^[15] 通过大量实验指出, 当 $m=2, r$ 在 $0.1X_{\text{SD}}$ 至 $0.2X_{\text{SD}}$ 之间 (X_{SD} 为原始数据的标准偏差) 时, 实验数据具有最合理的统计性。因此, 实验中取 $m=2, r=0.2X_{\text{SD}}$ 。

能量作为反映不同信号特征的重要物理量, 可作为光纤入侵信号的特征^[16]。对于长度为 N 的光纤入侵信号 $x(n)$, 其能量可表示为

$$E = \sum_{n=1}^N |x(n)|^2. \quad (13)$$

光纤入侵信号谱熵是在对信号进行傅里叶变换后, 计算其频谱的能量熵。即对信号 $x(n)$ 进行傅里叶变换得到 $X[n]$, 再计算频域能量概率密度, 可表示为

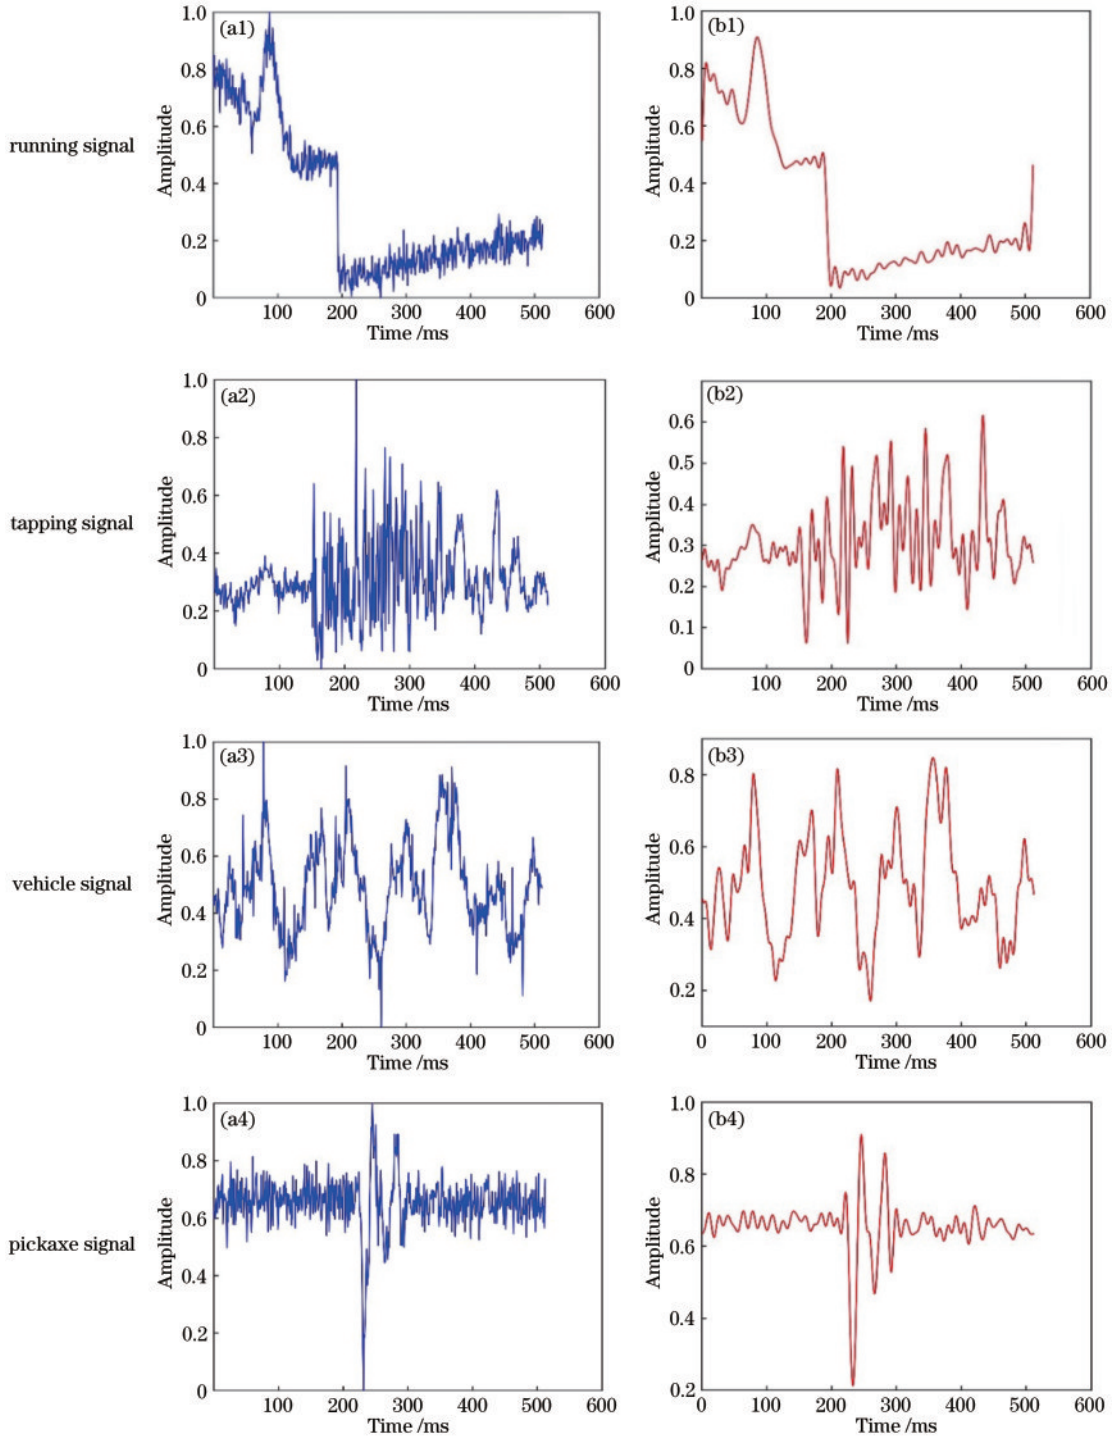


图2 原始光纤入侵信号及预处理结果。(a)原始信号;(b)预处理结果

Fig. 2 Original fiber intrusion signal and preprocessing results. (a) Original signal; (b) preprocessing result

$$p(i) = \frac{X[i]^2}{\sum_{i=0}^n X[i]^2}, i = 0, \dots, n, \quad (14)$$

谱熵可表示为

$$X_{SpEn} = -\sum_{i=0}^n p(i) \log[p(i)]. \quad (15)$$

2.3 Boosting 算法

Boosting 算法是一种提高弱分类器准确率的框架,该框架先对训练样本集进行处理,获得多个训练样本子集,然后反复运行一个弱分类器处理不同的训练

子集得到若干个基分类器,最后将这些基分类器组合成一个强学习器。

2.3.1 AdaBoost 算法

AdaBoost 算法^[17-18]是在迭代生成基分类器的过程中提高上一轮分类错误的训练样本权重,降低分类正确的训练样本权重。通过多轮迭代并不断调整权重得到多个基分类器,最终进行加权融合。AdaBoost 分类算法的训练流程如图 3 所示。

AdaBoost 算法的具体步骤:1)初始化权重,给训练样本赋予相同的权重;2)训练一个弱分类器,计算其错

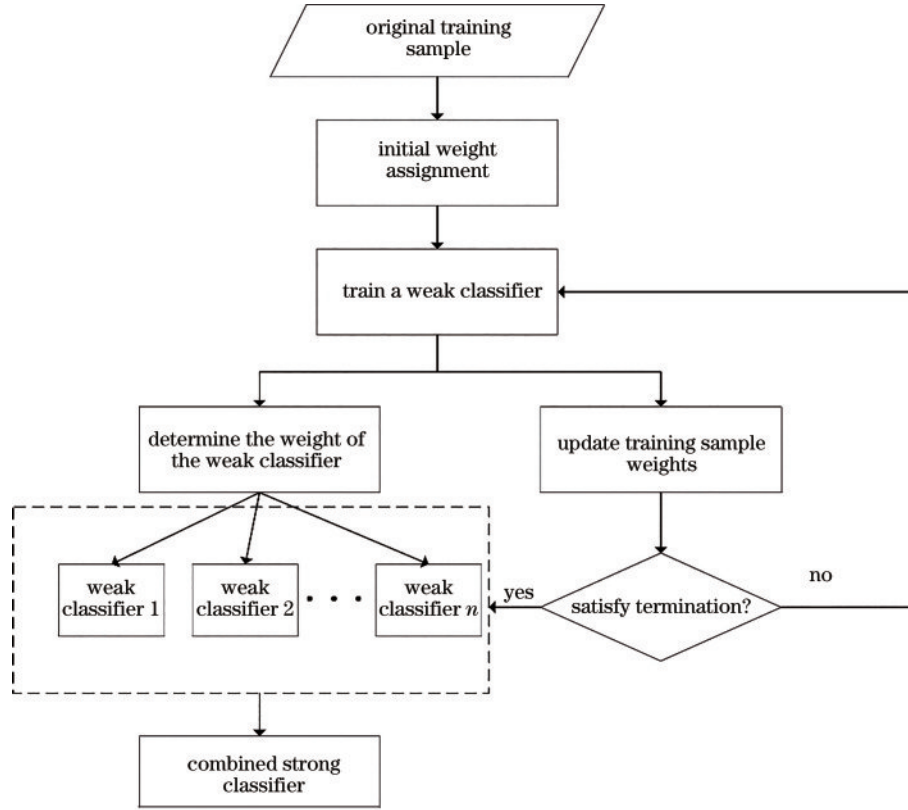


图 3 AdaBoost 算法的流程图
Fig. 3 Flowchart of the AdaBoost algorithm

误率并更新样本权重;3)按照步骤2)中样本的权重训练一个新的弱分类器,同样计算识别错误率并更新样本权重;4)重复步骤3),不断调整权重训练多个弱分类器;5)加权融合所有弱分类器,得到最终的强分类器。
2.3.2 GBDT 算法

GBDT 算法^[19]是在决策树(DT)算法的基础上引入梯度提升(Gradient Boosting),即采用负梯度的方式近似计算残差,从而增强算法的泛化能力^[20]。具体步骤如下。

1) 初始化弱分类器,可表示为

$$f_0(x) = \arg \min_{\gamma} \sum_{i=1}^N L(y_i, \gamma) \quad (16)$$

2) 计算第 i 个样本在第 m 轮迭代时的残差,可表示为

$$r_{mi} = - \left\{ \frac{\partial L[y_i, f(x_i)]}{\partial f(x_i)} \right\}_{f(x)=f_{m-1}(x)} \quad (17)$$

对 r_{mi} 拟合一个新的弱分类器,得到第 m 棵树的叶子结点区 $R_{mj}, j = 1, \dots, J$ (J 为叶子结点数目)。最优系数可表示为

$$\gamma_{mj} = \arg \min_{\gamma} \sum_{x_i \in R_{mj}} L[y_i, f_{m-1}(x_i) + \gamma] \quad (18)$$

更新强分类器的公式为

$$f_m(x) = f_{m-1}(x) + \sum_{m=1}^M \sum_{j=1}^J \gamma_{mj} I, x \in R_{mj} \quad (19)$$

式中, I 为指示记号,用来在节点区域拟合分类器。

3) 完成 M 轮迭代后得到最终的强分类器可表示为

$$f(x) = f_M(x) = f_0(x) + \sum_{m=1}^M \sum_{j=1}^J \gamma_{mj} I, x \in R_{mj} \quad (20)$$

3 模型训练及对比实验

在北京市门头沟取实验场模拟并采集了敲击、小跑、过车和镐刨四类光纤入侵信号,信号采样频率为 1024 Hz,实验光缆埋设在地下 20 cm 处。采集完成后人工截取有效信号样本 800 个,每类信号各 200 个,每个样本的时长为 512 ms。对每个样本进行预处理、提取并构建三维特征向量作为样本集,然后从样本集中随机选取 80% 已知类别标签的样本作为训练集,剩余 20% 作为未知类别的测试集。选择 GBDT 算法、AdaBoost 算法以及 SVM 算法分别训练光纤入侵信号多分类模型,进行识别分类并对比分类效果。为了得到性能优良的模型,采用网格搜索法结合交叉验证进行参数调优。

3.1 光纤入侵信号多分类模型的训练

1) GBDT 算法的参数调优

实验采用 sklearn 包中的 GradientBoostingClassifier 方法训练 GBDT 模型。其中,可调整的参数较多,通过大量实验对部分参数进行调优,包括最大迭代次数 ($n_estimators$, 即弱分类器个数)、学习率

(learning_rate)、决策树最大深度(max_depth)和子采样比例(subsample)。设定网格搜索参数范围如表 2 所示,搜索结果如图 4 所示。可以发现,模型训练过程中无明显过拟合现象,且弱分类个数和决策树最大深度

对模型性能的影响较大,网格搜索输出的合适参数:最大迭代次数为 41;学习率为 0.15;决策树最大深度为 7;子采样比例为 0.6。

2) AdaBoost 算法的参数调优

选择决策树作为 AdaBoost 算法的基分类器,最终训练的模型性能受弱分类器个数、学习率及决策树最大深度的影响。实验中设定决策树的最大深度范围为 1~10,循环使用网格搜索法对弱分类器个数和学习率进行调优,实验结果表明,当最大深度为 4 时,可获得较合适的参数,此时模型的验证曲线如图 5 所示。网格搜索输出的合适参数:弱分类器的数量为 21,学习率为 0.6。

表 2 GBDT 参数的调优范围
Table 2 Tuning range of GBDT parameters

Parameter	Value range
n_estimators	1-50
learning_rate	0.1-0.3
max_depth	3-10
subsample	0.5-0.8

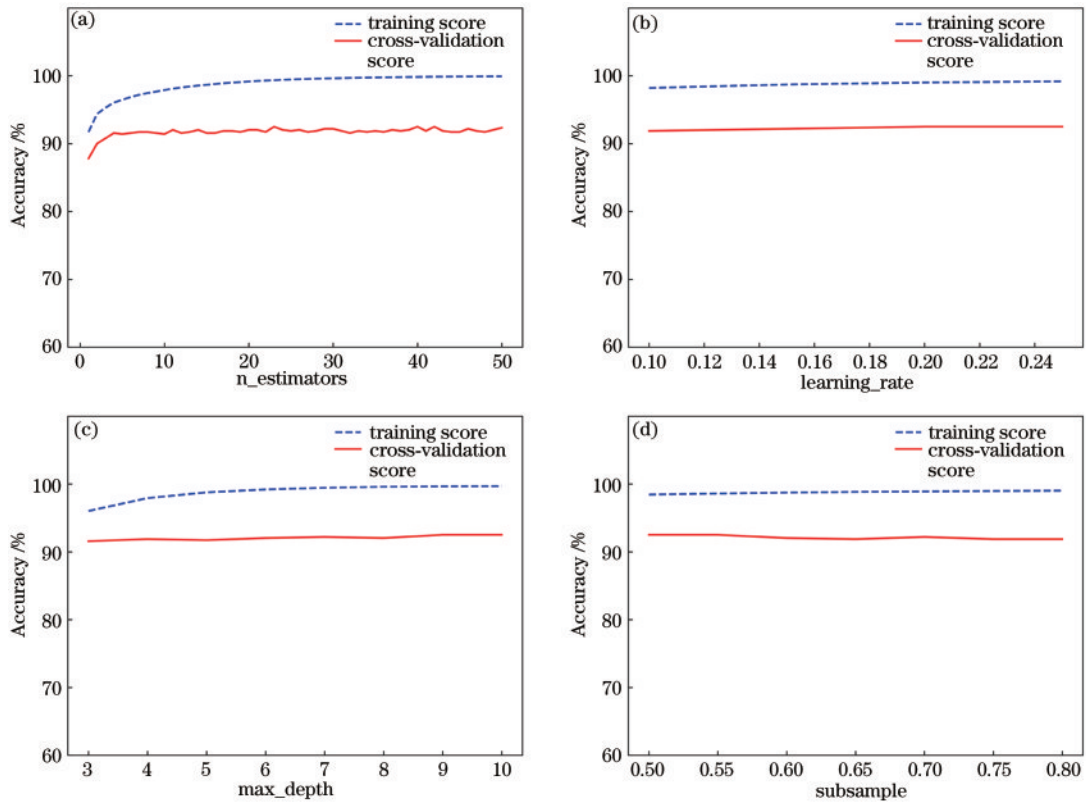


图 4 不同参数下 GBDT 算法的验证曲线。(a)弱分类器个数;(b)学习率;(c)决策树最大深度;(d)子采样比例

Fig. 4 Validation curves of GBDT algorithm under different parameters. (a) n_estimators; (b) learning_rate; (c) max_depth; (d) subsample

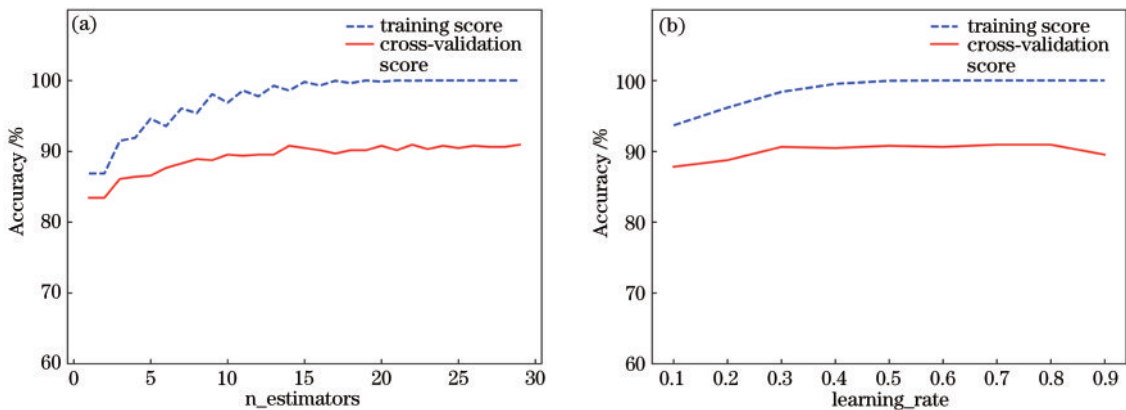


图 5 AdaBoost 算法网格搜索验证曲线。(a)弱分类器个数;(b)学习率

Fig. 5 AdaBoost algorithm grid search validation curve. (a) n_estimators; (b) learning_rate

3) SVM算法的参数调优

SVM算法对于非线性问题,通常选择径向基函数(RBF)作为核函数训练分类模型。实验中,对影响模型性能的惩罚系数 C 和 γ 参数进行参数调优并绘制验证曲线,结果如图 6 所示。可以发现,模型训练过程中并未出现明显过拟合现象,网格搜索输出的合适参数: $C=21$, γ 参数为 0.9。

3.2 识别分类及实验结果分析

根据 3.1 节得到的参数构建模型并对测试集进行识别分类,得到不同模型的混淆矩阵如图 7 所示,统计

得到各分类器对各类信号的识别准确率如图 8 所示。可以发现:SVM算法的平均准确率达到 82.50%,但对敲击信号的和镐刨信号识别准确率较低,分别为 72.50% 和 80.00%;以决策树为基分类器的 AdaBoost (DT-AdaBoost)算法平均准确率为 88.13%,相比 SVM 算法提升了 5.63 个百分点,对敲击信号的识别率仍偏低,为 77.50%,但对过车信号和镐刨信号的识别准确率提升较大;GBDT 算法的平均准确率最高,为 92.50%,其中,小跑信号的识别准确率有所提升但并不明显,而敲击和镐刨信号的识别准确率均有明显提升。

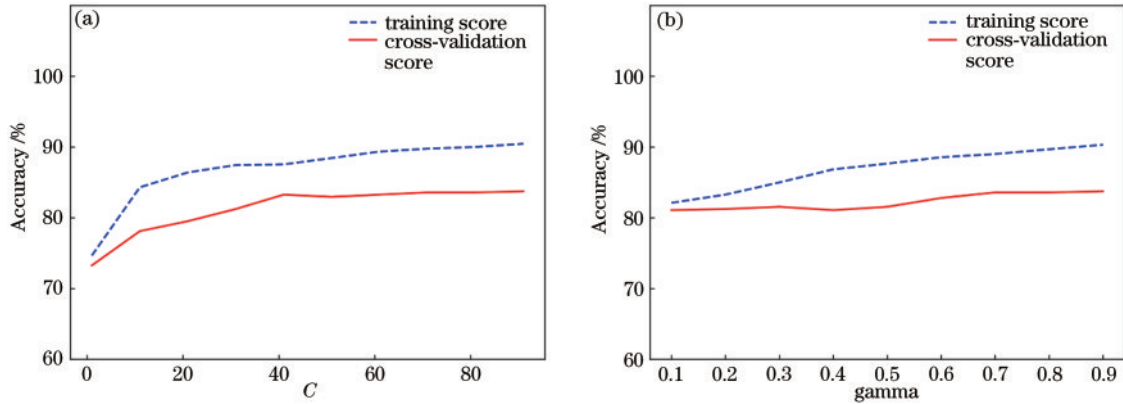


图 6 SVM算法的网格搜索验证曲线。(a) C ; (b) γ

Fig. 6 Grid search verification curve of the SVM algorithm. (a) C ; (b) γ

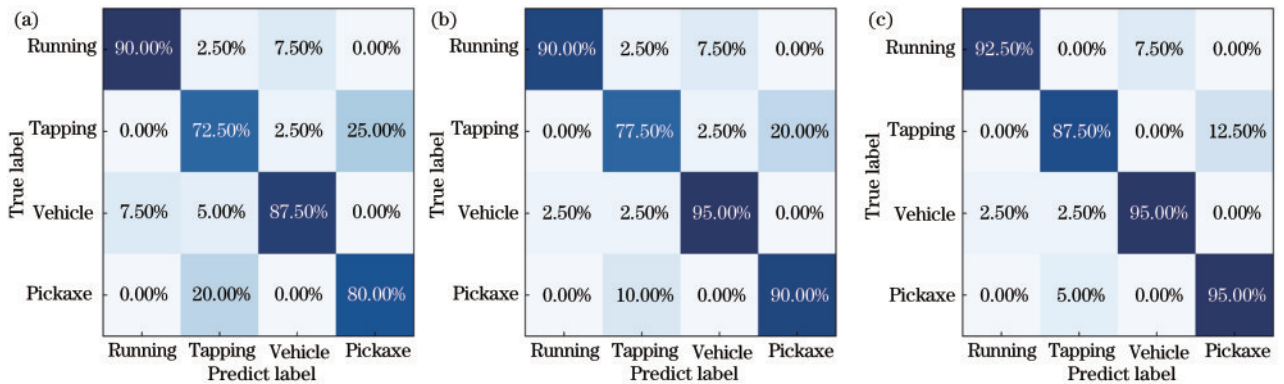


图 7 不同算法的混淆矩阵。(a) GBDT 算法; (b) DT-AdaBoost 算法; (c) SVM 算法

Fig. 7 Confusion matrices for different algorithms. (a) GBDT algorithm; (b) DT-AdaBoost algorithm; (c) SVM algorithm

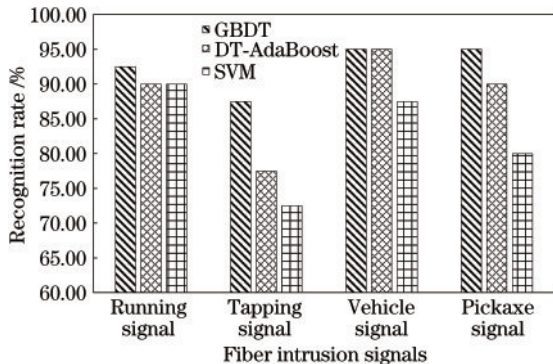


图 8 不同算法的光纤入侵信号识别率

Fig. 8 Recognition rate of fiber intrusion signals for different algorithms

4 结 论

提出了一种基于 FDM 及 GBDT 算法的光纤入侵信号特征提取与识别算法。首先,采用 FDM 分解光纤入侵信号得到 FIBF 分量,计算各分量的排列熵并筛选符合条件的分量进行信号重构。然后,提取重构信号的近似熵、能量和谱熵特征,分别用 GBDT 多分类算法,以决策树为弱分类器的 AdaBoost 算法和 SVM 算法训练分类器,训练过程中采用网格搜索法结合交叉验证进行参数调优。最后,对测试集进行识别分类并对比分类效果。实验结果表明,GBDT 算法在光纤入侵信号多分类上的平均准确率高于 DT-AdaBoost 算法和 SVM 算法,可以有效识别小跑、敲

击、过车和镐刨四类光纤入侵信号,平均准确率达到 92.50%。但本算法对敲击信号的识别准确率偏低,为 87.50%。考虑到敲击信号和镐刨信号存在一定相似性,未来可结合光纤入侵信号的特点,提取更多有效的特征,以提高相似入侵信号间的区分度。

参 考 文 献

- [1] 严爱博, 宛立君, 吴梦实. 一种适用于 φ -OTDR 系统的光纤振动信号快速模式识别算法[J]. 声学及电子工程, 2021(2): 6-10.
Yan A B, Wan L J, Wu M S. A fast pattern recognition algorithm of optical fiber vibration signal suitable for φ -OTDR system[J]. Acoustics and Electronics Engineering, 2021(2): 6-10.
- [2] 于清澄. 光纤预警技术在长输管道中的研究与应用[J]. 中国仪器仪表, 2020(3): 37-40.
Yu Q C. Research and application of optical fiber early warning technology in long distance pipeline[J]. China Instrumentation, 2020(3): 37-40.
- [3] 杨洋, 封皓, 王宗和, 等. 光纤传感技术在管道检测中的应用与发展[J]. 光电技术应用, 2016, 31(6): 1-9, 76.
Yang Y, Feng H, Wang Z H, et al. Application and development of distributed optical fiber sensing technology in pipeline detection[J]. Electro-Optic Technology Application, 2016, 31(6): 1-9, 76.
- [4] 付群健, 于淼, 常天英, 等. 相位敏感光时域反射系统模式识别方法综述[J]. 红外与激光工程, 2018, 47(7): 0722001.
Fu Q J, Yu M, Chang T Y, et al. Summarization of pattern recognition method for phase sensitive optical time domain reflecting system[J]. Infrared and Laser Engineering, 2018, 47(7): 0722001.
- [5] 周子纯, 刘琨, 江俊峰, 等. 基于卷积长短期记忆全连接深度神经网络的光纤振动传感事件识别[J]. 光学学报, 2021, 41(13): 1306019.
Zhou Z C, Liu K, Jiang J F, et al. Optical fiber vibration-sensing event recognition based on CLDNN[J]. Acta Optica Sinica, 2021, 41(13): 1306019.
- [6] 马喆, 王逸璇, 江俊峰, 等. 光纤分布式声传动的动态范围扩展方法研究[J]. 光学学报, 2021, 41(13): 1306008.
Ma Z, Wang Y X, Jiang J F, et al. Research on dynamic range expansion method of fiber-optic distributed acoustic sensing[J]. Acta Optica Sinica, 2021, 41(13): 1306008.
- [7] 于发硕, 吕小毅, 莫家庆. 基于联合特征的两级光纤入侵信号识别方法[J]. 激光杂志, 2019, 40(2): 15-19.
Yu F S, Lv X Y, Mo J Q. The two stage intrusion signal recognition of optical fiber based on joint eigenvectors[J]. Laser Journal, 2019, 40(2): 15-19.
- [8] 王兴奇, 黄丹飞, 衣文索, 等. 基于 SVM 的 φ -OTDR 光纤振动传感系统模式识别方法研究[J]. 长春理工大学学报(自然科学版), 2021, 44(1): 14-21.
Wang X Q, Huang D F, Yi W S, et al. Investigation on pattern method of φ -OTDR fiber vibration sensor system based on SVM[J]. Journal of Changchun University of Science and Technology (Natural Science Edition), 2021, 44(1): 14-21.
- [9] 徐继伟, 杨云. 集成学习方法: 研究综述[J]. 云南大学学报(自然科学版), 2018, 40(6): 1082-1092.
Xu J W, Yang Y. A survey of ensemble learning approaches[J]. Journal of Yunnan University (Natural Sciences Edition), 2018, 40(6): 1082-1092.
- [10] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Journal of Computer and System Sciences, 1997, 55(1): 119-139.
- [11] Singh P, Joshi S D, Patney R K, et al. The Fourier decomposition method for nonlinear and non-stationary time series analysis[J]. Proceedings. Mathematical, Physical, and Engineering Sciences, 2017, 473(2199): 20160871.
- [12] 张国瑞, 王旭元, 郭文斌. 基于傅里叶分解与 1.5 维 Teager 能量谱的滚动轴承故障诊断方法[J]. 机械传动, 2017, 41(3): 191-196.
Zhang G R, Wang X Y, Guo W B. Fault diagnosis method of rolling bearing based on Fourier decomposition method and 1.5-dimensional Teager energy spectrum[J]. Journal of Mechanical Transmission, 2017, 41(3): 191-196.
- [13] Bandt C, Pompe B. Permutation entropy: a natural complexity measure for time series[J]. Physical Review Letters, 2002, 88(17): 174102.
- [14] 任岩, 黄今, 胡雷鸣, 等. 基于傅里叶分解与排列熵的水轮机组去噪方法研究[J]. 水力发电, 2020, 46(10): 96-99, 116.
Ren Y, Huang J, Hu L M, et al. Denoising algorithm of hydro-generator set based on Fourier decomposition and permutation entropy[J]. Water Power, 2020, 46(10): 96-99, 116.
- [15] Pincus S M. Approximate entropy as a measure of system complexity[J]. Proceedings of the National Academy of Sciences of the United States of America, 1991, 88(6): 2297-2301.
- [16] 曲洪权, 宫殿君, 张常年, 等. 光纤入侵信号的特征提取与识别算法[J]. 激光与光电子学进展, 2019, 56(13): 130601.
Qu H Q, Gong D J, Zhang C N, et al. Feature extraction and recognition algorithm for fiber intrusion signals[J]. Laser & Optoelectronics Progress, 2019, 56(13): 130601.
- [17] 杨笑, 王志章, 周子勇, 等. 基于参数优化 AdaBoost 算法的酸性火山岩岩性分类[J]. 石油学报, 2019, 40(4): 457-467.
Yang X, Wang Z Z, Zhou Z Y, et al. Lithology classification of acidic volcanic rocks based on parameter-optimized AdaBoost algorithm[J]. Acta Petrolei Sinica, 2019, 40(4): 457-467.
- [18] 杨新武, 马壮, 袁顺. 基于弱分类器调整的多分类 Adaboost 算法[J]. 电子与信息学报, 2016, 38(2): 373-380.
Yang X W, Ma Z, Yuan S. Multi-class Adaboost algorithm based on the adjusted weak classifier[J]. Journal of Electronics & Information Technology, 2016, 38(2): 373-380.
- [19] Friedman J H. Greedy function approximation: a gradient boosting machine[J]. The Annals of Statistics, 2001, 29(5): 1189-1232.
- [20] 李昕迪, 陈万忠. 基于 FSWT 和 GBDT 的癫痫病电信号分类研究[J]. 吉林大学学报(信息科学版), 2019, 37(2): 186-193.
Li X D, Chen W Z. Classification of epileptic EEG signals based on frequency slice wavelet transform and gradient boosting decision tree[J]. Journal of Jilin University (Information Science Edition), 2019, 37(2): 186-193.