

激光与光电子学进展

基于 AdaBoost 集成学习的光纤振动信号识别分类方法

曲洪权^{1*}, 吉祥¹, 盛智勇¹, 曲洪斌², 王玲³¹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 对光纤振动信号的有效识别是保证油气管道光纤预警系统运行的重要基础。针对传统光纤振动信号检测中单一分类方法的不足,提出一种基于 AdaBoost 集成学习的光纤振动信号识别分类算法。首先通过分析研究 5 类光纤振动信号的特征,选取样本熵、能量分布以及频带宽度作为三维特征向量,并将其分别送入决策树、支持向量机(SVM)以及以决策树作为基分类器的 AdaBoost 分类算法进行训练识别;其次通过交叉验证的方式对得到的模型进行参数优化和模型评价;最后对得到的模型进行对比测试实验。实验结果表明:以决策树作为基分类器的 AdaBoost 集成学习算法可以对不同振动类型进行有效识别,在光纤预警中对不同来源振动信号的识别具有一定意义。

关键词 傅里叶光学与信号处理; 光纤; AdaBoost 集成学习; 光纤振动信号; 特征提取与识别

中图分类号 TN911.6

文献标志码 A

DOI: 10.3788/LOP202259.1307004

Recognition and Classification Method for Fiber Optical Vibration Signal Using AdaBoost Ensemble Learning

Qu Hongquan^{1*}, Ji Xiang¹, Sheng Zhiyong¹, Qu Hongbin², Wang Ling³¹School 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 effective identification of fiber optical vibration signals is an important basis for ensuring the operation of the fiber-optical early warning system for oil and gas pipelines. To mitigate the lack of a single classification method in traditional fiber optical vibration signal detection, this paper proposes a fiber optical vibration signal recognition and classification algorithm using AdaBoost ensemble learning. First, we analyzed and studied the characteristics of five fiber optical vibration signals and selected sample entropy, energy distribution, and bandwidth as the three-dimensional feature vectors. Next, this information was sent to the decision tree, support vector machine (SVM), and AdaBoost classification algorithm with the decision tree as the base classifier for training and recognition. Second, the obtained models were optimized and evaluated by cross-validation. Finally, the obtained models were compared. The experimental results show that the AdaBoost ensemble learning algorithm with a decision tree as the base classifier effectively identifies different vibrations and has certain significance for identifying vibration signals from different sources in the fiber-optical warning.

Key words Fourier optics and signal processing; fiber; AdaBoost ensemble learning; fiber optical vibration signal; feature extraction and recognition

1 引言

与传统电子检测相比,相位敏感光时域反射干涉

型分布式光纤传感技术(Φ -OTDR)^[1-3]具有灵敏度高、功耗低、抗电磁干扰强、化学稳定性高等优点,已被大量应用于油气管道运输安全监测^[4]。该光纤传感器对

收稿日期: 2021-08-02; 修回日期: 2021-08-28; 录用日期: 2021-09-10

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: *qhphd@ncut.edu.cn

于管道外部受到的不同扰动会对应输出不同类别的光纤振动信号,因此依据信号类别的不同识别出扰动来源是否为入侵信号,可达到对管道安全预警的监测效果。然而实际应用中,由于光纤光源所发出的光纤信号中本身就是由多种线性信号和非线性信号经过调制解调等许多步骤所叠加而成的,所以输出的光纤信号是非线性信号。并且,实际应用中也没有理想稳定的光纤光源,加之架设环境布局复杂,极易受到噪声影响,因此输出的光纤信号也是非平稳信号。光纤信号的非线性和非平稳性,使得对扰动来源信号的特征提取与识别显得尤为重要。对于光纤信号的分类识别,近年来已有相关学者针对此问题展开了大量的研究,2019年宫殿君等^[5]提出的通过总体平均经验模态分解(EEMD)对信号进行分解重构,提取其能量占比作为特征的方式结合随机向量函数链接(RVFL)神经网络^[6]对3类光纤入侵信号进行识别。2020年朱程辉等^[7]在EEMD分解的基础上,提出自适应经验模态分解(AEMD)对信号进行处理,并通过提取短时能量和过门限率等特征,结合支持向量机(SVM)对4类信号进行识别。周子纯等^[8]通过长短期记忆全连接深度神经网络,对光纤振动信号进行识别。2020年Chen等^[9]将信号的短时能量比和过零率两个时域特征结合梅尔频率倒谱系数频域特征,通过采用基于注意力的长短期记忆网络(ALSTM)对信号进行分类。2021年Zhu等^[10]将频分复用引入 Φ -OTDR中,实现了对多径振动的同时检测。吴慧娟等^[11]在 Φ -OTDR技术的基础上研究光纤分布式振动/声传感(DVS/DAS)技术对光纤信号信噪分离的信号处理算法,提高识别效率。

综上所述,对于光纤信号的识别,大都采用单一强分类器的方式进行模式辨识,然而由于光纤振动的敏感性使得信号的信息较为丰富,因此单一分类器存在一定的局限性,近年来随着机器学习的飞速发展,其中的集成学习思想也开始倍受关注,其核心是通过某种策略将多个学习器集成为一个总学习器,从而获得比单一学习器更加优越的性能。本文提出了一种基于局部均值分解(LMD)^[12]多特征和AdaBoost集成学习^[13]的光纤振动识别方法。首先通过LMD将不同光纤振动信号进行分解,根据自相关原理对信号重构,然后提取信号的能量、样本熵和频带宽度作为分类的三维特征,最后通过AdaBoost集成学习策略,将决策树作为基分类器^[14],通过训练得到一个最终模型进行预测。并与其他预测算法结果进行对比,最终证明以AdaBoost集成学习策略对光纤振动信号识别的方式优于SVM、决策树两类单一分类器。

2 光纤振动信号的特征提取与构造

对于光纤振动信号的特征提取,首先就是筛选出目标分量,但是由于光纤信号属于非线性、非平稳信号^[15],且光纤信号的敏感性使其极易对外界振动产生

反应^[16],所以该振动信号往往比较复杂,并蕴含多种相似信息分量的干扰,因此对于光纤振动信号的预处理不能简单地直接去噪。本文采用的是LMD和重构的模式^[17]代替直接去噪,并将重构信号的样本熵、能量分布以及频带宽度构造为特征向量用于后续的识别。

2.1 光纤振动信号的LMD与重构

LMD是一种具有自适应特点的时频分析方法,其核心思想是基于信号 $x(t)$ 的局部极值点,自动地确定信号在不同尺度上的分辨率,循环迭代,将 $x(t)$ 分解成为若干个瞬时频率具有物理意义的乘积函数(PF)分量与残余分量的和。其中的PF分量本质上是调频调幅信号的乘积,具体算法如下:

1) 构造局部均值函数 $m_{11}(t)$ 和包络估计函数 $a_{11}(t)$:

找到 $x(t)$ 的所有局部极值点 n_i ,分别求出两个相邻极值点的平均值 m_i 和包络估计值 a_i :

$$\begin{cases} m_i = \frac{n_i + n_{i+1}}{2} \\ a_i = \frac{|n_i - n_{i+1}|}{2} \end{cases}, \quad (1)$$

再分别将求得的 m_i 和 a_i 用折线连接起来,通过滑动平均处理,得到局部均值函数 $m_{11}(t)$ 和包络估计函数 $a_{11}(t)$ 。

2) 求调频信号:

$$s_{11}(t) = \frac{h_{11}(t)}{a_{11}(t)}, \quad (2)$$

式中, $h_{11}(t) = x(t) - m_{11}(t)$,取 $s_{11}(t)$ 的包络估计函数 $a_{12}(t)$,若 $a_{12}(t)$ 是一个恒等于1的常函数,则此时 $s_{11}(t)$ 为纯调频信号,否则重复上述步骤进行 n 次迭代直到 $a_{1n}(t) = 1$,此时 $s_{1n}(t)$ 为纯调频信号,实际应用中可以将终止条件调整为 $a_{1n}(t) \approx 1$ 以减少迭代次数进而提高运算速度。

3) 用瞬时幅值 $a_1(t)$ 乘以纯调频信号 $s_{1n}(t)$,便得到第一个PF分量:

$$P_1(t) = a_1(t)s_{1n}(t), \quad (3)$$

式中, $a_1(t) = \prod_{j=1}^n a_{1j}(t)$,此时的 $a_1(t)$ 和 $s_1(t)$ 分别为第一个PF分量的瞬时幅值和瞬时频率。

4) 分离出PF分量,得到新信号 $u_1(t)$,将 $u_1(t)$ 作为新的信号重复步骤1)~3),重复 k 次,直到信号 $u_k(t)$ 为单调信号为止:

$$u_k(t) = x(t) - \sum_{p=1}^k P_p(t). \quad (4)$$

至此,便能将原始信号 $x(t)$ 分解为 k 个PF分量和一个残差分量 $u_k(t)$ 的和,即

$$x(t) = \sum_{p=1}^k P_p(t) + u_k(t). \quad (5)$$

根据以上原理,将过车、小跑、噪声、镐刨、敲击5类光纤振动信号分别进行LMD与重构,结果如图1

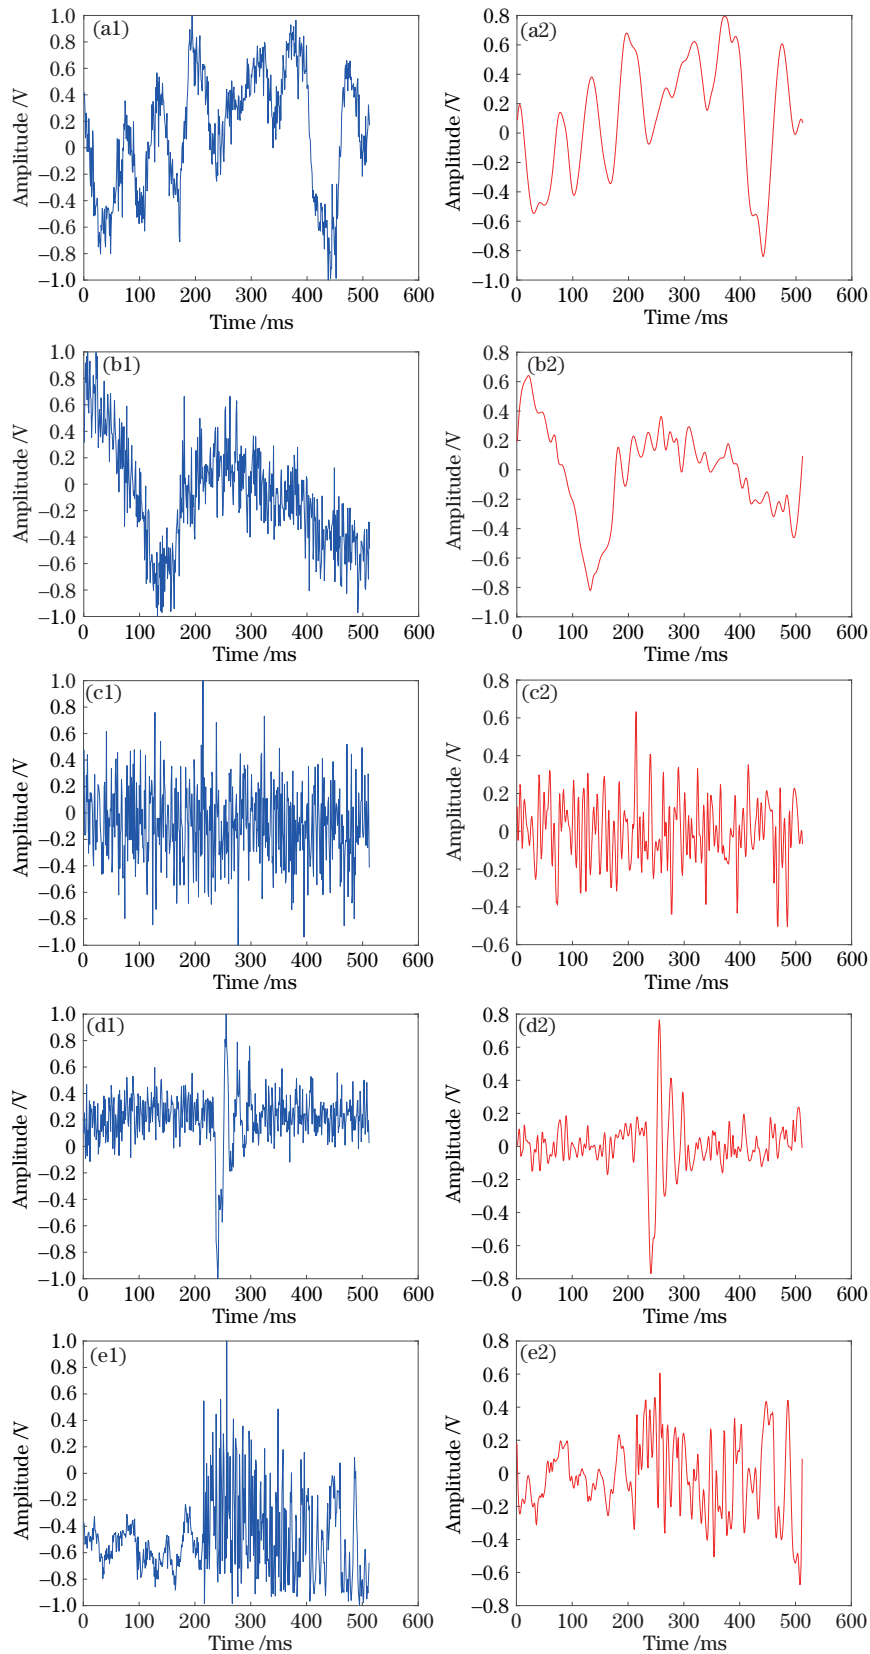


图 1 原始信号与LMD重构信号。(a1)过车原信号;(a2)过车重构信号;(b1)小跑原信号;(b2)小跑重构信号;(c1)噪声原信号;(c2)噪声重构信号;(d1)镐刨原信号;(d2)镐刨重构信号;(e1)敲击原信号;(e2)敲击重构信号

Fig. 1 Original signals and reconstructed signals by LMD. (a1) Car cross original signal; (a2) car cross reconstructed signal; (b1) running original signal; (b2) running reconstructed signal; (c1) noise original signal; (c2) noise reconstructed signal; (d1) pickaxe original signal; (d2) pickaxe reconstructed signal; (e1) tapping original signal; (e2) tapping reconstructed signal

所示,从图中可知,经过LMD处理之后的信号在保留原始信息的情况下,将干扰信息进行了有效滤除。

2.2 光纤振动信号的特征选取

样本熵是一种以熵理论为基础,从熵域角度来度量信号时间序列复杂性的方式^[18],光纤振动信号符合样本熵对信号微小波动较为敏感的特点,因此选择样本熵对光纤振动信号的特点进行描述;频带宽度是描述信号频率范围的物理量^[19],由于光纤信号针对外界不同振动类型所反馈的振动信号不同,其频带宽度也会有差异,因此,选用频带宽度作为光纤振动信号的另一特征。

本文通过提取重构信号的样本熵、能量分布以及频带宽度作为三维特征参数矢量 T , 即 $T=[\text{sampen}, \text{energy}, \text{bandwidth}]$, 得到如图 2 所示的三维特征分布, 可以看出 5 类信号的三维特征分布区别明显且相对集中, 因此, 特征参数矢量 T 能够对 5 类信号进行较好区分。




图 2 5 类信号的三维特征分布图

Fig. 2 Three-dimensional feature map of five different signals

3 AdaBoost 与 SVM 和决策树对比研究

集成学习分类是将多个弱分类器以某种策略组合起来去解决问题的方式, 这些弱分类器可以是相同类型的分类器, 也可以是不同类型的分类器。常见的弱分类器有决策树(DTC)和逻辑回归(LR)等^[13]。通常来说, 经过集成学习之后的分类器, 会在集成过程中逐步汲取单个弱分类器的优点, 减弱单个弱分类器的缺点, 故性能会优于单个弱分类器, 图 3 为采用集成学习进行分类的流程图。

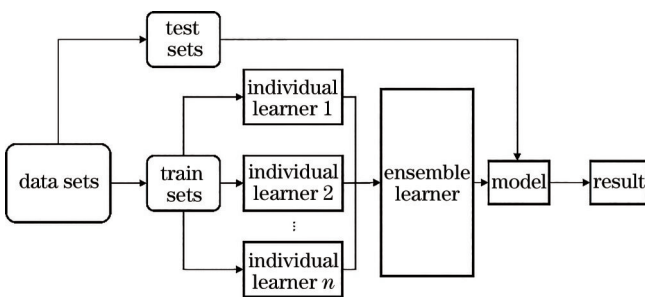


图 3 集成学习分类流程图

Fig. 3 Flow chart of ensemble learning classification

3.1 AdaBoost 分类算法

AdaBoost 分类作为常用的集成学习分类算法, 其核心思想是改变训练样本中错误标记的样本权重来训练一系列弱分类器, 并以串行的方式将这些分类器联合。图 4 表示 AdaBoost 分类算法的执行过程。

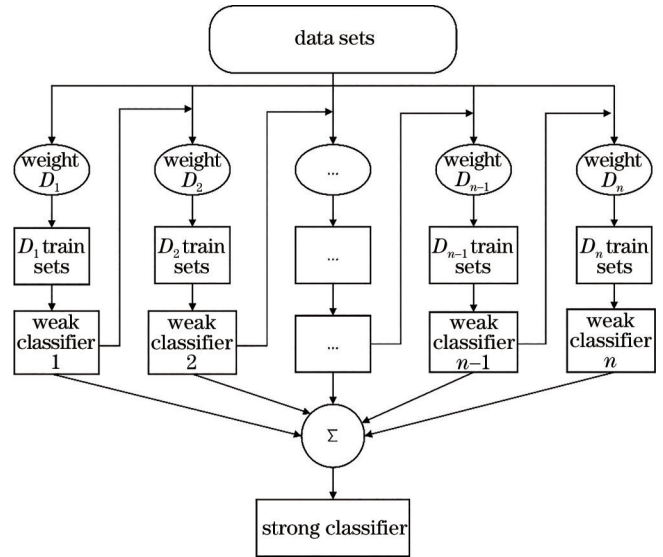


图 4 AdaBoost 的执行过程

Fig. 4 Implementation of AdaBoost

由图 4 可知, 在 AdaBoost 分类算法中, 每生成一个弱分类器, 便会改变下一个弱分类器的训练集的权重 D_{i+1} , 当满足输出条件时, 将所有的弱分类器通过线性级联的方式组合, 便能得到强分类器。具体步骤如下:

1) 给定样本总数为 N 的特征数据训练集为 $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, 其中 x_i 为样本特征, y_i 为样本标签, $y_i \in (-1, 1), i = 1, 2, \dots, N$;

2) 初始化训练集权重为

$$D_1 = (w_{11}, w_{12}, \dots, w_{1N}) = (1/N, 1/N, \dots, 1/N); \quad (6)$$

3) 根据设定值, 迭代 m 次, $m = 1, 2, \dots, M, M$ 为总迭代次数, 根据具有权重分布 D_m 的训练集训练出弱分类器 h_m ;

4) 计算 h_m 的误差率

$$e_m = w_{mi} I[h_m(x_i) \neq y_i], \quad (7)$$

式中: w_{mi} 是迭代 m 次的时候, 第 i 个特征数据所对应的权值; I 是弱分类器 h_m 对 x_i 的分类结果, 若 $h_m(x_i) \neq y_i$, 则 $I[h_m(x_i) \neq y_i] = 1$, 否则 $I[h_m(x_i) \neq y_i] = 0$;

5) 计算弱分类器 h_m 的系数

$$\alpha_m = \frac{1}{2} \ln \frac{1 - e_m}{e_m}; \quad (8)$$

6) 更新训练数据集的权值分布

$$D_{m+1} = \frac{D_m e^{[-\alpha_m y_i h_m(x_i)]}}{Z_m}, \quad (9)$$

式中, Z_m 是规范化因子, 有

$$Z_m = \sum_{i=1}^N D_m e^{[-\alpha_m y_i h_m(x_i)]}; \quad (10)$$

7) 重复步骤 3)~6) M 次, 得到最终分类器

$$G(x) = \text{sign} \left[\sum_{m=1}^M \alpha_m h_m(x) \right]. \quad (11)$$

3.2 AdaBoost 与其他算法对比研究

相对于通过将若干弱分类器集成为强分类器的 AdaBoost 算法, SVM 本身就是一类强分类器, 对于非线性可分而言, 其分类思想是选择一个合适的核函数, 并用非线性映射将特征映射高维特征空间中形成一个最优边界面, 使得不同类型的特征能够区分开, SVM 利用结构化风险最小的原理, 在一定程度上提高了泛化能力。目前, SVM 在小样本和非线性等方面的分类已经得到了广泛应用。本小节对第 2 节中提到的 5 类信号 (每类信号各 200 组共计 1000 组) 进行随机划分, 将其中的 80% 作为训练集, 并通过过拟合/欠拟合判断, 网格参数搜索以及模型评价指标对 AdaBoost 集成分类算法和 SVM 进行参数寻优和模型描述, 对这两类算法针对 5 类光纤振动信号的适用性进行说明。

1) 网格参数调优

不同的分类器会涉及到对多个参数的选择问题, 通过对不同参数的最佳选择, 可以使得模型的训练得以优化。网格搜索是一种调参的手段, 它是以穷举搜索的方式, 将所有候选的参数, 以循环遍历的方式, 尝试每一种组合的可能性, 并将表现最好的参数筛选出来^[21], 表 1 是上述分类器的参数指标以及经过网格搜

表 1 不同分类器的重要参数以及最优参数值

Table 1 Important parameters and optimal parameter values of different classifiers

Classifier	DTC		AdaBoost-DTC	SVM		
Parameter	feature selection criteria	feature divide criteria	max-depth	number of weak classifiers	C	γ
Parameter range	gini/entropy	best/random	1-30	1-30	0.1-100	0.1-1
Best parameter	entropy	best	10	20	80	0.63

索之后的参数最优结果。

2) 过拟合/欠拟合判断

学习曲线是用于判断模型是否过拟合和欠拟合的工具^[22], 通常来说, 学习曲线通过以样本数据为横坐标, 训练集和验证集上的得分作为纵坐标去描述该模型是否过拟合或欠拟合: 若二者曲线相差过大说明该模型泛化能力较差, 属于过拟合, 此时应该减少特征, 降低模型的复杂度; 若二者曲线相差不大, 但是曲线得分均比较低则说明模型无法对数据进行准确预测, 此时应该增加特征, 使其对数据描述更全面。图 5 分别是决策树在其不同最大深度 max_depth 下的学习曲线以及对应的 AdaBoost 集成下不同分类器个数的学习曲线 (采用 10 折交叉验证), 从图中可以得出: 决策树方面, 训练曲线和验证曲线出现一定差异但相差不大并且没有出现过拟合/欠拟合状况。

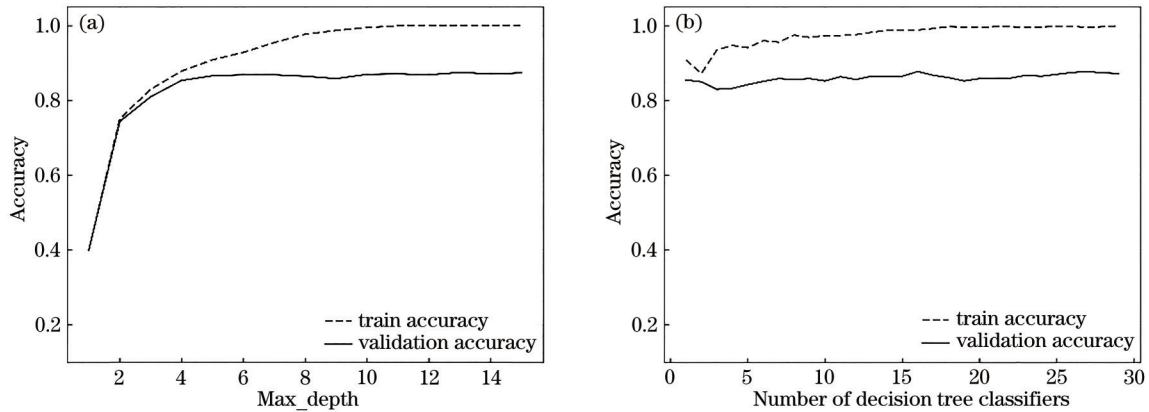


图 5 决策树及其 AdaBoost 分类器在不同参数下的学习曲线。(a) 决策树最大深度; (b) 基分类器个数

Fig. 5 Learning curves of decision tree and its AdaBoost classifier under different parameters. (a) Max_depth of decision tree;

(b) number of base classifiers

图 6 是采用 rbf 核的 SVM 分类在不同惩罚系数 C 和 rbf 核参数 γ 下的学习曲线。相关的参数值设定为本小节 1) 中通过网格搜索得到的最优值。从图中可以看出, SVM 模型训练未出现过拟合/欠拟合问题。

3) 模型评价指标

在机器学习分类算法评价指标中, 引入如下概念: TP (true positive) 为正例样本预测为正 (预测正

确), S_{TP} ;

FP (false positive) 为负例样本预测为正 (预测错误), S_{FP} ;

TN (true negative) 为正例样本预测为负 (预测错误), S_{TN} ;

FN (false negative) 为负例样本预测为负 (预测正

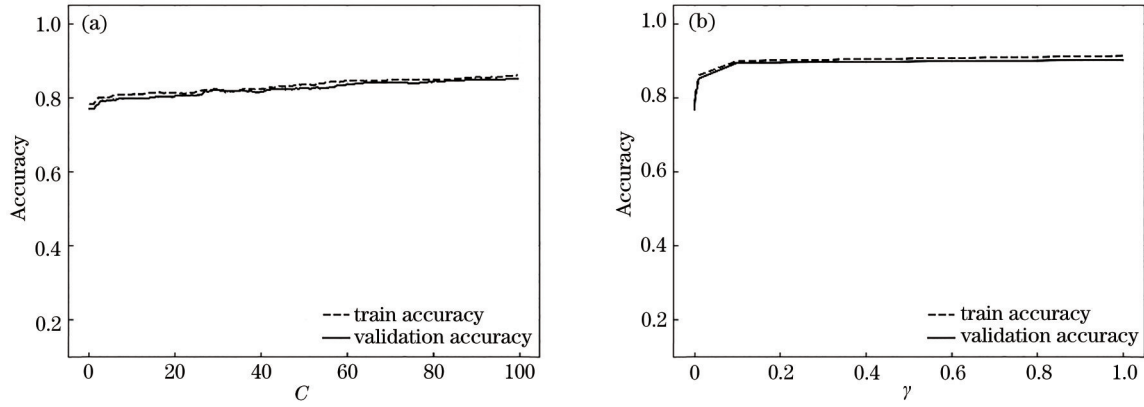


图 6 SVM 学习曲线。(a) 惩罚系数 C; (b) 核参数 γ
Fig. 6 SVM learning curves. (a) Penalty coefficient C; (b) core parameter γ

确), S_{FN} 。

注意, 本文在进行分类时将目标样本视作正例, 其余均视作负例。

采用精确率 ($P_{precision}$)、召回率 (R_{recall}) 以及 F_1 得分对分类算法进行评估, 精确率是指在预测为正例的样本当中, 真正的正例所占比例:

$$P_{precision} = \frac{S_{TP}}{S_{TP} + S_{FP}}, \quad (12)$$

召回率是指正确预测为正的样本占全部实际为正的样本的比例:

$$R_{recall} = \frac{S_{TP}}{S_{TP} + S_{FN}}. \quad (13)$$

精确率与召回率是相互影响的, 理想情况下的最优算法是精确率和召回率都高, 但是实际情况下精确率高召回率就低, 召回率高精确率就低。因此, 引入 F_1 值对二者进行综合评估, F_1 值是对精确率和召回率的调和平均:

$$F_1 = \frac{2P_{precision} \times R_{recall}}{P_{precision} + R_{recall}}. \quad (14)$$

图 7 表示对上述分类器的精确率、召回率、 F_1 值做的统计分布。从图中可以看出, 单一决策树分类效果最差, AdaBoost 集成分类效果有着显著提高并且优于 SVM 分类。

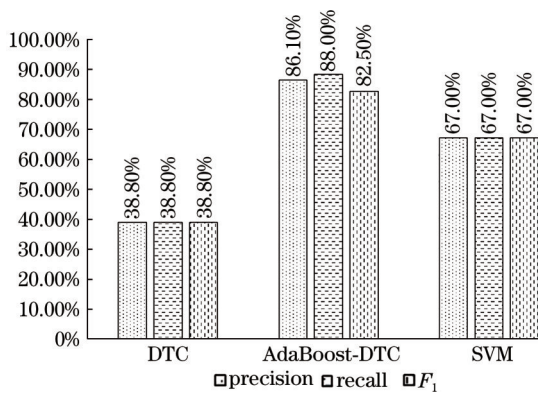


图 7 不同分类器的 10 折交叉验证精确率、召回率和 F_1 得分
Fig. 7 Precision, recall and F_1 -score for 10-fold cross-validation with different classifiers

4 实验与结果分析

4.1 实验流程

实验数据来源于北京门头沟现场所实测的光纤振动信号, 采样率为 1024 Hz, 包含过车、小跑、噪声、锯刨、敲击各 200 组样本, 共计 1000 组样本, 每组样本时长为 512 ms, 即 512 个点, 通过对原始信号的前期预处理, 使用 python3 语言作为工具, 基于 Pycharm 软件开发平台对数据进行研究。实验的具体流程如下:

- 1) 对 5 类光纤振动信号进行 LMD 处理, 并依据自相关原理进行信号重构, 完成对信号的降噪处理;
- 2) 分别提取重构信号的样本熵 (sampen)、能量分布 (energy) 以及频带宽度 (bandwidth) 构造三维特征参数矢量 T , 即 $T = [sampen, energy, bandwidth]$;
- 3) 结合第 3 节中的结果, 选择合适参数, 选取数据的 80% 作为训练集, 分别构建分类器 DTC、AdaBoost-DTC、SVM;
- 4) 选取数据剩余的 20% 作为测试集, 分别送入已构建的分类器中进行测试, 并分析实验结果, 对基于 AdaBoost 的光纤振动信号识别算法进行研究。

实验流程如图 8 所示。

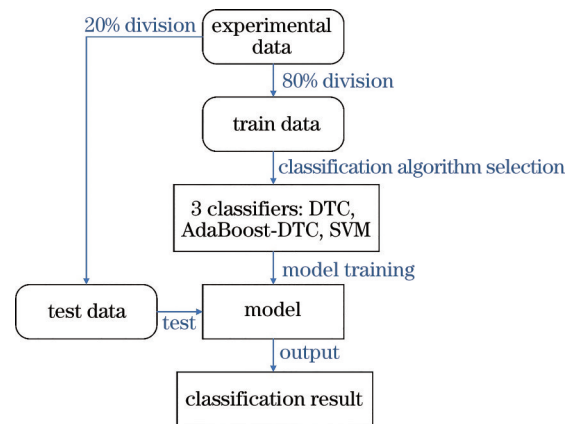


图 8 实验流程图
Fig. 8 Experimental flowchart

4.2 实验结果及分析

实验输出的混淆矩阵如图 9 所示,图 10 表示的是 3 种分类器对不同信号识别的真阳率,真阳率是指在正确预测为正的样本占实际上全部为正的比率,真阳率能够更好地说明何种分类器针对何种信号更具有识别性。结合图 9、图 10 可以得出:DTC 平均识别率达到 57.00%,但是对小跑、镐刨以及敲击信号却几乎无法准确识别;SVM 平均识别率达到 68.00%,但是对小跑、镐刨以及敲击信号分类识别较低;而 AdaBoost-DTC 平均识别率达到 87.50%,并且对 5 类信号都能实现较好识

别。SVM 识别优于 DTC 分类,而 AdaBoost-DTC 比 SVM 分类效果更好,这是因为 DTC 是线性模型,而光纤振动信号是一种非线性的信号,SVM 本身就是强分类器,相较于 DTC 而言,其更能适应非线性信号,因此 SVM 分类效果优于 DTC。AdaBoost 集成算法改善了单一分类器识别率较低的缺点,通过不断修改权重的方式,提升了抗干扰能力,能够很好地提升弱分类器的精度,且提升效果明显优于 SVM 强分类器。综上所述,对 5 类光纤振动信号而言,以决策树作为基分类器的 AdaBoost 集成算法,分类效果更为准确。




图 9 测试样本的混淆矩阵。(a) SVM;(b) DTC;(c) AdaBoost-DTC

Fig. 9 Confusion matrixes of test samples. (a) SVM; (b) DTC; (c) AdaBoost-DTC

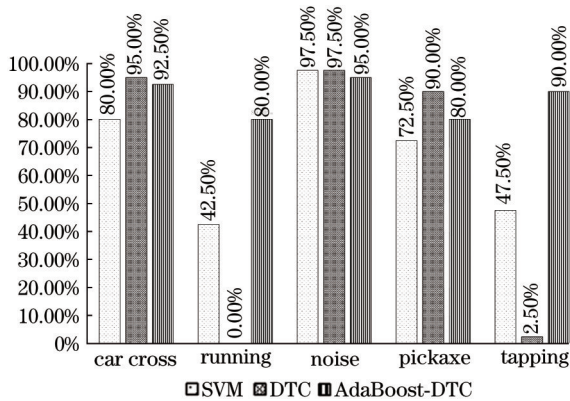


图 10 3 种不同分类器下的光纤识别真阳率

Fig. 10 Fiber optical identification true positive rates based on three different classifiers

5 结 论

提出一种基于 AdaBoost 集成学习的光纤振动信号识别算法。首先通过 LMD 对 Φ -OTDR 传感器所采集的光纤振动信号降噪,并对处理过后的信号提取样本熵、能量分布以及频带宽度 3 个特征作为三维特征向量 T ;然后分别构造 SVM、DTC 和以决策树为基分类器的 AdaBoost-DTC,将数据集的 80% 划分为上述 3 种分类器的训练集,并通过参数调优、学习曲线构造以及精确率和召回率等多种模型指标评估对分类器进行合理验证;最后将剩余的 20% 作为测试集对 3 种模型进行测试。实验结果显示,相较于 DTC 和 SVM,

AdaBoost-DTC 可以实现对 5 类光纤振动信号的有效识别,平均识别率达到 87.50%,算法的有效性得到了验证。该算法核心是通过引入 AdaBoost 集成学习的思想对光纤振动信号进行识别,但是由于该集成学习的思想是通过多次迭代以确定样本权值分布,需要充分考虑到每个分类器的权重,所以会有迭代次数过多造成训练时间过长等缺点,因此,未来可以根据两个方面来改善此问题:1)根据光纤振动信号的特点,增加更多维度特征,使得各类信号之间更具有区别性;2)对基分类器进行选择和优化,即通过提高单个基分类器的性能来减少迭代次数,节省训练时间。

参 考 文 献

- [1] Zhan Y G, Song Z K, Sun Z Y, et al. A distributed optical fiber sensor system for intrusion detection and location based on the phase-sensitive OTDR with remote pump EDFA[J]. Optik, 2021, 225: 165020.
- [2] 刘铁根, 刘琨, 戴林, 等. 光电信息事件识别感知关键技术研究进展[J]. 光学学报, 2021, 41(1): 0106002. Liu T G, Liu K, Dai L, et al. Research progress of key technologies in recognition sensing for opto-electronic information and event[J]. Acta Optica Sinica, 2021, 41(1): 0106002.
- [3] 陈浩, 徐阳, 钱森, 等. 分布式光纤超声传感器用于检测电缆接头放电故障[J]. 光学学报, 2021, 41(3): 0306001. Chen H, Xu Y, Qian S, et al. Distributed fiber-optic ultrasonic sensor applied in detection of discharging fault of power cable joint[J]. Acta Optica Sinica, 2021, 41(3):

- 0306001.
- [4] 张聪, 禹胜阳, 李兴涛. 光纤预警系统在长输管道完整性管理中的应用[J]. 石油规划设计, 2020, 31(1): 9-12, 60.
Zhang C, Yu S Y, Li X T. Application of the optic fiber forewarning system for long-distance pipeline integrity management[J]. Petroleum Planning & Engineering, 2020, 31(1): 9-12, 60.
- [5] 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.
- [6] Wang Y P, Gong D J, Pang L P, et al. RVFL-based optical fiber intrusion signal recognition with multi-level wavelet decomposition as feature[J]. Photonic Sensors, 2018, 8(3): 234-241.
- [7] 朱程辉, 朱睿, 王建平, 等. 基于自适应EMD的光纤安防系统入侵信号识别[J]. 传感器与微系统, 2020, 39(4): 26-30.
Zhu C H, Zhu R, Wang J P, et al. Intrusion signal recognition of optical fiber security & protection system based on adaptive EMD[J]. Transducer and Microsystem Technologies, 2020, 39(4): 26-30.
- [8] 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.
- [9] Chen X, Xu C J. Disturbance pattern recognition based on an ALSTM in a long-distance ϕ -OTDR sensing system[J]. Microwave and Optical Technology Letters, 2020, 62(1): 168-175.
- [10] Zhu K, Zhou B, Wu H, et al. Multipath distributed acoustic sensing system based on phase-sensitive optical time-domain reflectometry with frequency division multiplexing technique[J]. Optics and Lasers in Engineering, 2021, 142: 106593.
- [11] 吴慧娟, 刘欣雨, 饶云江. 基于 Φ -OTDR 的光纤分布式传感信号处理及应用[J]. 激光与光电子学进展, 2021, 58(13): 1306003.
Wu H J, Liu X Y, Rao Y J. Processing and application of fiber optic distributed sensing signal based on Φ -OTDR[J]. Laser & Optoelectronics Progress, 2021, 58(13): 1306003.
- [12] Smith J S. The local mean decomposition and its application to EEG perception data[J]. Journal of the Royal Society, Interface, 2005, 2(5): 443-454.
- [13] 曹莹, 苗启广, 刘家辰, 等. AdaBoost 算法研究进展与展望[J]. 自动化学报, 2013, 39(6): 745-758.
Cao Y, Miao Q G, Liu J C, et al. Advance and prospects of AdaBoost algorithm[J]. Acta Automatica Sinica, 2013, 39(6): 745-758.
- [14] 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.
- [15] 梁益丰, 许江宁, 吴苗, 等. 光纤时频同步技术的研究进展[J]. 激光与光电子学进展, 2020, 57(5): 050004.
Liang Y F, Xu J N, Wu M, et al. Research progress on optical fiber time-frequency synchronization technology [J]. Laser & Optoelectronics Progress, 2020, 57(5): 050004.
- [16] 张旭苹, 丁哲文, 洪瑞, 等. 相位敏感光时域反射分布式光纤传感技术[J]. 光学学报, 2021, 41(1): 0106004.
Zhang X P, Ding Z W, Hong R, et al. Phase sensitive optical time-domain reflective distributed optical fiber sensing technology[J]. Acta Optica Sinica, 2021, 41(1): 0106004.
- [17] 洪晓艺, 翟东媛, 乔庆鹏. 基于LMD信号重构和支持向量机的柱塞泵故障诊断分析[J]. 液压与气动, 2021, 45(6): 91-96.
Hong X Y, Zhai D Y, Qiao Q P. Fault diagnosis analysis of plunger pump based on LMD signal reconstruction and support vector machine[J]. Chinese Hydraulics & Pneumatics, 2021, 45(6): 91-96.
- [18] 罗志增, 鲁先举, 周莹. 基于脑功能网络和样本熵的脑电信号特征提取[J]. 电子与信息学报, 2021(2): 412-418.
Luo Z Z, Lu X J, Zhou Y. EEG feature extraction based on brain function network and sample entropy[J]. Journal of Electronics & Information Technology, 2021(2): 412-418.
- [19] Yin Z Z, Gao S Q, Jin L, et al. A dual impact driven frequency up-conversion piezoelectric energy harvester for ultralow-frequency and wide-bandwidth operation[J]. Sensors and Actuators A: Physical, 2021, 331: 112961.
- [20] Verma R, Bhardwaj N, Singh P D, et al. Estimation of sex through morphometric landmark indices in facial images with strength of evidence in logistic regression analysis[J]. Forensic Science International: Reports, 2021, 4: 100226.
- [21] Sumreddee P, Hay E H, Toghiani S, et al. Grid search approach to discriminate between old and recent inbreeding using phenotypic, pedigree and genomic information[J]. BMC Genomics, 2021, 22(1): 538.
- [22] 沈微微, 李颖, 杨志豪, 等. 防止过拟合的属性约简[J]. 计算机应用研究, 2020, 37(9): 2665-2668.
Shen W W, Li Y, Yang Z H, et al. Attribute reduction with avoiding overfitting[J]. Application Research of Computers, 2020, 37(9): 2665-2668.