

DOI: 10.19650/j.cnki.cjsi.J1905241

基于深度迁移学习的复杂环境下油气管道周界入侵事件识别*

温江涛¹, 王涛¹, 孙洁娣², 付磊¹, 李刚^{3,4}, 杨文明^{3,4}

(1. 燕山大学 河北省测试计量技术及仪器重点实验室 秦皇岛 066004; 2. 燕山大学 河北省信息传输与信号处理重点实验室 秦皇岛 066004; 3. 中国石油天然气管道通信电力工程有限公司 廊坊 065000; 4. 油气管道输送安全监测与检测国家工程实验室 廊坊 065000)

摘要:长输油气管道沿途运行环境复杂,传统方法中假设的标准样本与实际样本分布一致的前提遭到破坏,导致单一的识别模型在不同环境下对入侵事件识别准确率降低。为了改善识别模型偏差问题,提出一种基于域不变特征深度迁移学习的管道入侵事件识别方法,通过堆叠稀疏自编码网络实现不同环境条件下的入侵事件自适应特征提取,并引入迁移学习实现复杂环境中入侵事件的准确识别。该方法通过场景差异性评测,缩小复杂真实场景与典型场景间分布差异,获得有效的域不变模型。实验结果表明,所提方法能明显改善复杂环境下油气管道入侵事件识别效果,提高识别准确率。

关键词:管道安全监测;深度迁移学习;复杂运行环境;入侵事件识别

中图分类号: TP391.4 TH865 **文献标识码:** A **国家标准学科分类代码:** 460.40

Perimeter intrusion event identification of oil and gas pipelines under complex conditions based on deep transfer learning

Wen Jiangtao¹, Wang Tao¹, Sun Jiedi², Fu Lei¹, Li Gang^{3,4}, Yang Wenming^{3,4}

(1. Key Laboratory of Measurement Technology and Instrumentation of Hebei Province, Yanshan University 066004, China; 2. Hebei Key Laboratory of Information Transmission and Signal Processing, Yanshan University, Qinhuangdao 066004, China; 3. China Petroleum Pipeline Telecom & Electricity Engineering Co., Ltd., Langfang 065000, China; 4. National Engineering Laboratory for Transportation Safety of Oil & Gas Pipelines, Langfang 065000, China)

Abstract: The operating conditions along long-distance oil and gas pipeline are completed, and the premise that the distribution of actual samples is consistent with that of standard samples in traditional method is destroyed. This situation results in the low identification accuracy of intrusion event for single identification model under different conditions. In order to improve the identification model deviation, this paper proposes a pipeline intrusion event identification method based on the deep transfer learning for domain invariant feature. The stacked sparse auto-encoder network is utilized to adaptively extract the domain-invariant features for the intrusion events under different working conditions. Then, the transfer learning is introduced to achieve the accurate identification of pipeline intrusion events under complex conditions. The proposed method reduces the distribution difference between complex real scenes and typical scenes through scene difference evaluation, and obtains an effective domain invariant model. The experiment results show that the proposed method can obviously improve the recognition results of oil and gas pipeline intrusion events under complex conditions, and enhance the identification accuracy.

Keywords: pipeline security monitoring; deep transfer learning; complex working condition; intrusion event identification

收稿日期:2019-06-06 Received Date:2019-06-06

* 基金项目:国家自然科学基金(51475407,51605419,61701429)、河北省自然科学基金(E2018203433,F2018203137)、河北省引进留学人员项目(C201827)、天津市重点研发计划(19YFSLQY00080)资助项目

0 引言

管道是石油和天然气长距离运输的主要方式,自西气东输项目启动至今,我国的油气管网建设已进入飞速发展阶段。但是受管道输送距离长、沿线环境复杂、管道周边实时管理困难等因素影响,管道泄漏事故频发。统计表明,我国管道泄漏事故多数是由于施工、人为破坏和打孔盗油等油气管道周边的入侵事件引起的^[1]。由于管道运输介质的危险性和污染性,一旦发生泄漏事故,必然造成巨大的生命财产损失和环境污染。传统的流量平衡法、负压波法等均为泄漏的事后检测方法,不能起到入侵事件的预警提示作用,因此,对长输油气管道安全的研究也从事后的泄漏检测发展为事前的安全监测^[1]。

目前,Φ-OTDR型管道安全预警系统因其长距离、实时在线监测等优点,获得了业界广泛关注与应用,该方法主要利用与管道同沟铺设的传感光纤检测管道沿线微弱振动引起的光纤内部光强的差异,通过光电探测器、模数转换等处理后,在上位机中进行信号处理及分析,从而实现管道沿线振动状态监测与管道安全预警^[2]。此类管道安全预警系统的核心是对外界入侵目标产生的复杂振动信号进行有效的识别,已有大量研究人员从特征提取与模式识别两方面开展了广泛研究并取得了丰硕成果。在特征提取方面,常用的方法有时域^[3]、频域^[3]、小波分解^[4]、主成分分析^[5]等方法。在模式识别方面,常用聚类算法、前后向传播神经网络(back propagation neural network, BPNN)^[4]、支持向量机(support vector machine, SVM)^[5]等方法学习数据特征,进而实现事件识别。

目前常见的采用特定特征提取结合分类器的方法,一方面严重依赖专业人员的经验,提取的特征无法全面表达不同类型振动信号间差异,甚至由于识别方法在学习过程中受到不良信号特征的影响,可能出现训练性能的恶化,进而对识别结果产生较大影响。另一方面,多数研究中入侵信号采集主要是在较为单一的实验环境或运行距离较短的在线状态,环境单一、信号信噪比高,而实际运营线路周边环境差异大、采集信号的信噪比低,且不同环境采集的振动信号的分布特性差异较大,直接将传统方法用于实际中,将导致入侵事件的识别准确率较低甚至识别不出,这也极大限制了很多理论上的入侵事件识别算法在复杂环境下的应用。因此针对管道实际运营情况,研究自适应的特征提取及识别方法,以实现在复杂的应用环境中能够较好识别入侵事件是目前管道周界入侵事件识别领域的迫切需要。

近年来快速发展的深度学习与迁移学习为解决复杂条件下管道周界入侵事件识别带来了新思路。文献[6-8]通过卷积神经网络、自动编码机等多层非线性网络,实

现了自动、全面的敏感特征学习,减少了对特定算法的依赖,提升了网络识别效果,文献[9-14]等针对图像识别、故障诊断中存在的单一模型面对复杂环境模型偏差问题,依据领域相似性原则,引入迁移学习的概念,提升单一识别模型在新应用领域的识别效果。以上算法虽然在各自领域取得一定的效果,但是将深度迁移学习引入复杂工况下的油气管道周界入侵事件识别的研究尚未见报道。深度学习对解决这一问题能否有效,如何实现迁移学习,这些都是深度迁移学习在油气管道周界入侵事件识别中急待解决的问题。

基于此,本文提出一种基于深度特征提取及迁移学习的复杂环境下油气管道周界入侵事件识别方法。该方法通过堆叠多层稀疏自编码自动学习不同工况下管道周界振动信号的特征;自适应分类器通过将特征映射距离最小化的方法,实现复杂环境下管道周界入侵事件识别。实验表明,相比于传统方法,本文所提出的方法具有较高的识别准确率,且在不同的应用环境下有较强鲁棒性。

1 基于堆叠稀疏自编码的入侵事件特征提取

自编码由输入层、隐层、输出层组成,其中输入层神经单元数与输出神经单元数相同,中间隐含层神经单元数少于输入层和输出层神经单元数,其隐层即可作为学习到的特征描述。相较于传统的浅层神经网络,自编码深度神经网络不依赖于人工特征提取,使用一系列由非线性映射函数组成的网络,快速在原始输入数据上建立高层次抽象模型,实现更加高效的数据表达^[15]。

1.1 稀疏自编码原理

稀疏自编码(sparse auto-encoder, SAE)是在自编码基础上的一种变种算法,其结构如图1所示。




图1 稀疏自编码网络结构

Fig.1 Simplified structure diagram of sparse auto-encoder network

结构中由输入层与隐含层构成编码单元,迫使隐藏层神经单元学习输入信号的压缩表达;由隐含层与输出层构成解码单元,解析隐藏单元压缩表示,使输出

尽量与输入相似。通过在自编码基础上添加限制性条件,解决了典型自编码网络所带来的局部特征影响因子过大而其他特征因子过小的问题。给定样本集 $\{X_s | Y_s\}_{s=1}^M, \{X_s\}$ 为其中任意的一个样本, $\{Y_s\}$ 为样本的标签。 M 为总体样本的个数。设 $f_{|w^1, b^1|}(x) = s_f(w^{(1)}x + b^{(1)})$ 为编码函数, $g_{|w^2, b^2|}(x) = s_g(w^{(2)}x + b^{(2)})$ 为解码函数, 其中 S_f 与 S_g 为激活函数。输入变量 x^i 的编码矢量 a^i 可以表示为:

$$a^i = f_{|w^1, b^1|}(x^i) \tag{1}$$

a^i 通过解码网络重构后的输入可表示为 \hat{x}^i :

$$\hat{x}^i = g_{|w^2, b^2|}(a^i) \tag{2}$$

式中: \hat{x}^i 为输入数据 x^i 经过自编码器的输出数据。若编码矢量 \hat{x}^i 与输入 x^i 之间差距较小, 那么可以认为它保留了样本中大部分信息。

度量自编码器输出 \hat{x}^i 与编码器输入 x 之间误差的函数称为代价函数 $J(w, b)$, 稀疏自编码网络在自编码网络上添加了稀疏性限制, 其代价函数 $J(w, b)$ 为:

$$J_s(W, b) = \frac{1}{M} \sum_{i=1}^M L(x^i, \hat{x}^i) + \lambda \cdot \Omega_w + \beta \cdot \Omega_s \tag{3}$$

式中: $L(x^i, \hat{x}^i) = \|x - \hat{x}^i\|$ 的平均重构误差, λ 为权重惩罚系数, β 为稀疏性惩罚系数, Ω_w 为权重正则化项, Ω_s 为稀疏正则化项。

1.2 堆叠稀疏自编码特征提取

单层稀疏自编码对高维度输入数据特征描述抽取能力不足, 通过堆叠多个网络实现深度特征抽取, 多层分阶段的压缩原始信号特征表示, 即使面对高维数据输入也具有有良好的性能表达效果。

本文针对油气管道周界入侵事件产生的复杂振动信号, 采用3层堆叠稀疏自编码网络结构, 输入神经元的个数为振动样本 x_s^i 的维度。利用大量样本对深度神经网络进行逐层训练。具体的训练过程分为逐层贪婪训练与反向传播强化两个部分, 图2所示为训练流程。

1) 逐层贪婪训练稀疏自编码网络。初始化稀疏自编码网络参数, 使用采集的振动样本作为自编码网络的输入与输出, 训练得到第1层自编码网络, 将训练得到的第1层自编码的隐藏层的编码向量 a_1 作为第2层稀疏自编码网络的输入数据, 初始化深度神经网络的第2个隐藏层; 以此类推, 直到完成第3个稀疏自编码机的训练, 得到第3个编码向量 a_3 。

2) 反向传播强化训练微调多层稀疏自编码网络。单层自编码网络的最优不一定代表其在多层自编码网络上也有最优的分类识别效果。对此, 在步骤1)的基础上, 将各自编码隐层前后连接, 并在末端连接多层感知机, 借助带标签样本集 $\{X_s | Y_s\}_{s=1}^M$, 通过前后向传播最小化交叉熵误差的方式, 实现自动的最优自编码特征提取。




图2 堆叠稀疏自编码网络训练流程

Fig.2 Training process of stack sparse auto-encoder network

2 基于迁移学习的入侵事件识别

油气管道铺设距离长, 沿线经过农田、河流、戈壁等不同环境, 复杂环境对光纤传感监测系统采集信号会产生较大影响, 导致同类入侵目标产生的振动信号也存在较大差异, 并且在部分区域实验困难, 样本数量少, 导致传统入侵事件识别方法存在识别精度低的问题。迁移学习作为机器学习方法的新突破, 利用大量存在的数据辅助少量新问题的数据训练, 实现在新环境中好的识别效果^[16]。

2.1 基于特征映射的迁移学习

基于特征的迁移学习是迁移学习的一种, 主要是利用特征映射, 自适应的学习新应用环境中的敏感数据特性, 实现新环境中数据的准确分类。其结构如图3所示。




图3 基于特征映射的迁移学习结构

Fig.3 Transfer learning based on feature mapping

源域中存在大量带标签样本数据,目标域中存在少量带标签样本数据,源域、目标域的特征分布存在较大的差异,迁移学习将源域、目标域样本数据通过非线性映射到一个新的空间,在新的空间内最小化源域与目标域的特征分布差异,实现使用源域数据辅助目标域网络训练,提升分类效果^[17]。

2.2 特征分布适配

迁移学习目的是最大程度的降低源域、目标域之间样本的分布差异,因此分布差异的衡量指标会直接影响迁移学习的效果^[18]。

本文研究的油气管道周界入侵事件识别中引入迁移学习相关概念,则应用领域的差别主要在于管道长距离监测中实际运行环境差异,导致同类事件采集信号的不同,可将源域视为由某一工况下的管道周界入侵事件样本构成,目标域则由另一工况下同类型入侵事件采集信号构成。不同工况下的源域、目标域信号通过堆叠稀疏自编码网络分别实现自适应特征提取,生成迁移特征集合,分别表示为:

$$D_s = \{ \{ F_{s1}, L_{s1} \}^{m1}, \{ F_{s2}, L_{s2} \}^{m2}, \{ F_{s3}, L_{s3} \}^{m3} \}^m$$

$$D_t = \{ \{ F_{t1}, L_{t1} \}^{n1}, \{ F_{t2}, L_{t2} \}^{n2}, \{ F_{t3}, L_{t3} \}^{n3} \}^n$$

式中: F_s 为源域特征样本集, F_t 为目标域特征样本集, m, n 分别为源域、目标域样本个数, F_{si}, L_{si} 为源域特征样本集中数据标签为 1 的特征样本及其标签。

$m1$ 表示源域特征样本集中数据标签为 1 的特征样本数量。

1) 联合概率分布适配

为了度量源域、目标域之间特征分布差异大小,引入最大均值差异(maximum mean discrepancy, MMD)指标。其基本思想是迁移特征集合 F_s 与 F_t , F_s 与 F_t 独立同分布(independent identically distributed, IID),则存在再生希尔伯特空间(reproducing kernel Hilbert space, RKHS),用映射函数将迁移特征由原特征空间投影到 RKHS^[19]。因此,源域与目标域迁移特征之间的最大均值差异 MMD 可定义为:

$$MMD^2 = \left\| \frac{1}{m} \sum_{i=1}^m \varphi(\vec{F}_{si}) - \frac{1}{n} \sum_{j=1}^n \varphi(\vec{F}_{tj}) \right\|^2 = \frac{1}{m^2} \sum_{i \neq j}^m k(F_i, F_j) + \frac{1}{n^2} \sum_{i \neq j}^n k(F_i, F_j) - \frac{2}{mn} \sum_{i,j=1}^{m,n} k(F_i, F_j) \quad (4)$$

式中: $K()$ 表示核函数运算。

单一的从全体特征集的概率分布出发,而不考虑样本的实际情况,容易出现如图 4 所示问题。

仅使用边缘概率分布对源域与目标域进行特征适配,虽然适配后源域与目标域间概率分布差异降低,但是




图 4 全局边缘概率适配缺陷

Fig.4 Deficiency of global margin probability adaption

易导致样本类别分布差异混乱,容易造成识别错误^[19]。为此本文引入联合概率分布适配方法,通过样本集边缘概率分布差异与类别边缘概率分布共同作用,实现源域与目标域间概率分布差异最小化。更新后其分布差代价函数如下:

$$MMD = MMD(F_s + F_t) + \sum_{i=1}^m MMD(F_{si}, F_{ti}) \quad (5)$$

2) 多核概率分布适配

式(5)源域与目标域最大分布差异计算中,核函数的差异会造成 MMD 估计值的不同,直接影响迁移学习领域适配的实际应用效果^[20]。为降低单一核函数的影响,本文在分布差异计算中用多核核函数替代单一核函数,则传统的核参数选择的问题转化为多核核函数的优化问题。多核核函数集可表示为:

$$K(x, y) = \left\{ \sum_{i=1}^u \beta_i K(x, y)_i \mid \sum_{i=1}^u \beta_i, \beta_i > 0 \right\} \quad (6)$$

式中: $K(x, y)_i$ 为不同的核函数, β_i 为各个核函数的比例系数。

2.3 迁移学习模型的构建与训练

为了提高实际应用环境(目标域)中入侵事件识别准确度,结合式(5)与(6)的典型应用环境与实际应用环境的分布差异优化目标,构建如下迁移学习模型代价函数:

$$\gamma \underbrace{MMD(F_s, F_t)}_{\text{样本集边缘分布差异}} + \gamma \underbrace{\sum_{i=1}^3 MMD(F_{si}, F_{ti})}_{\text{类内边缘分布概率}} \quad (7)$$

式中: γ 为边缘分布概率分布适配正则项惩罚因子。

由式(7)可知基于深度迁移学习的油气管道周界入侵事件识别优化目标函数由两部分组成:1)最小化源域、目标域预测值与真实标记之间的交叉熵损失;2)最小化样本间的边缘概率分布 MMD 值。据此,本文方法的处理过程如图 5 所示。

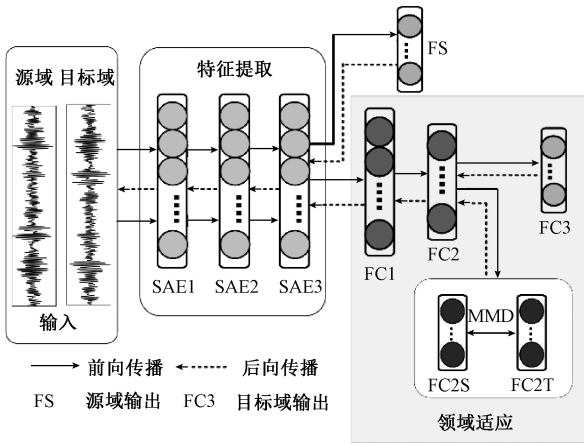


Fig.5 Flowchart of the proposed method

基于深度迁移学习的油气管道周界入侵事件识别模型由三层堆叠稀疏自编码特征提取网络与两层迁移识别网络组成。其实现流程可归纳为如下步骤。

- 1) 初始化, 给定带标签的源域数据集 $\{(x_i^s, y_i^s)\}_i^m$ 与目标域数据集 $\{(x_i^t, y_i^t)\}_i^n$, 初始化网络参数;
- 2) 特征提取: 针对源域数据集, 依据本文之前介绍的方法建立特征提取模型; 并建立源域与目标域特征样本集;
- 3) 迁移网络前向传播: (1) 初始化网络参数, 并将多核概率分布适配加入网络参数之中, (2) 在源域与目标域特征样本集中, 依据式(5)~(7)计算迁移模型目标函数值; (3) 若该数值大于设定的阈值或迭代次数大于最大迭代次数, 执行步骤5);
- 4) 反向传播: (1) 采用 Adam 优化算法, 逐层反向训练更新迁移网络模型参数, (2) 返回继续执行步骤3);
- 5) 目标域事件识别: 依据训练完成的网络, 输入目标域测试样本集 $\{x_i^t\}_i^n$, 返回网络 FC3 层输出结果, 其概率分布最大值处的健康标记即为预测的目标域识别结果。

3 实验结果与分析

3.1 实验情况介绍

实验数据来自西气东输某站西一线光纤管道入侵监测系统采集的振动信号, 该段监测路线全长 80 km, 管道监测系统运行沿线环境复杂, 经过戈壁、河滩、农田、村镇等不同环境。图 6 所示为管道监测系统运行的卫星图片, 图中给出了主要环境特征说明。

目前实际运行的监测系统中影响管道安全的主要入侵事件为机械施工、人工施工, 而引起管道周边异常振动的行为主要为油气管道沿线与公路并行时, 车辆通过管道监测区域附近产生的信号, 可视为干扰。依据沿线环




图6 管道监测系统运行环境描述

Fig.6 The operation environment description of pipeline monitoring system

境, 选取 3 类工况环境进行测试: 测试点 1, 沙土, 土质松软, 含水量中, 管道与公路交叉; 测试点 2, 砂石地, 土质坚硬, 含水量低, 管道在公路桥下方经过; 测试点 3, 农田, 土质松软, 含水量大, 管道与公路并行。人工施工实验分为人工挖掘与人工敲击两种, 人工挖掘实验使用施工中常见的搞头, 在光缆右侧 50 cm 的地方挖掘; 人工敲击实验使用锤子在距离地面 20 cm 的管道正上方, 以自由落体的形式落下进行敲击; 机械施工实验使用 60 型履带挖掘机, 沿光缆轴向 10 m 处挖掘深约 0.8 m、宽约 1 m 的沟渠; 车辆干扰实验为实验地点未发生入侵事件情况下附近公路车辆运行引起的振动。

3.2 数据处理结果

为了验证本文方法的有效性, 基于测试点 1、2、3 提取源域、目标域训练样本集以及测试样本集。按照本文方法构建深度特征提取网络及迁移适配识别网络。具体网络参数如表 1 所示。

表 1 深度迁移网络参数表

Table 1 Parameters table of deep transfer learning network

参数名称	参数值
输入样本尺寸	2 048
源域样本量	3 000
目标域训练样本量	600
目标域测试样本量	2 400
样本类别比例	1:1:1
堆叠自编码隐藏数	800-200-50
权重惩罚系数	1e-6
稀疏性参数	0.1
稀疏惩罚系数	1
分布适配正则项因子	0.05

基于上述构造的数据集, 对本文所提出的迁移学习入侵事件识别方法进行多次重复实验, 统计实验结果, 表 2 所示为未采用迁移学习而仅使用堆叠稀疏自编码网络进行的管道入侵事件识别统计。

表 2 仅采用堆叠自编码方法对入侵事件识别的结果
Table 2 The identification results of intrusion events only using stacked sparse auto-encoder method

训练集	测试集	准确率/%
	测试点 1	95.3
测试点 1	测试点 2	66.3
	测试点 3	72.4
测试点 2	测试点 1	69.8
	测试点 2	90.8
	测试点 3	61.7
测试点 3	测试点 1	69.4
	测试点 2	52.4
	测试点 3	93.0

由统计结果可以看出,当训练集与测试集数据为同一环境时,基于堆叠稀疏自编码的识别方法表现出较优秀的效果,识别准确率分别为 95%、90%、93%;但是当训练集与测试集工况不同时,入侵事件识别效果降低明显,识别效果只有 70% 左右,这表明:1) 基于堆叠自编码的入侵事件识别是可行的;2) 不同环境导致管道入侵事件振动信号存在较大差异。因此引入本文的深度迁移学习识别方法进行处理,表 3 所示为经深度迁移学习方法实现的管道周界入侵事件识别统计结果。

表 3 经深度迁移学习后的入侵事件识别结果
Table 3 The identification results of intrusion events after deep transfer learning

源域	目标域	准确率/%	平均准确率/%
测试点 1	测试点 2	87.3	85.2
	测试点 3	83.1	
测试点 2	测试点 1	85.2	83.4
	测试点 3	81.0	
测试点 3	测试点 1	85.0	84.2
	测试点 2	83.4	

由统计结果可以看出在训练集与测试集样本不变的情况下,本文所提出的方法都能取得 83% 以上的识别准确率,识别效果较好。由于源域的较大差异,同一目标域识别准确率会存在一定的差异,但是这一差异在 2% 的范围内,证明本文所提出的方法具有较高的鲁棒性,环境适应能力强。

3.3 本文方法与常用方法比较

本文将迁移学习引入复杂运行环境下的管道周界入侵目标的识别中,能够改善传统方法在实际应用中性能降低的问题。为了验证方法的有效性,将本文方法与传

统的分类识别方法进行比较,目前在管道周界入侵事件识别方法中较为常用的 BP、SVM 及多层感知机 (multi-layer perceptron, MLP) 方法。此处研究对比了本文方法与 BP、SVM、MLP 的识别准确率,多次实验结果如图 7 所示。

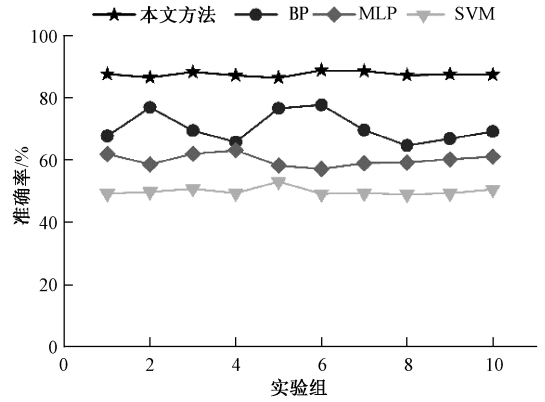


图 7 不同方法识别准确率对比

Fig.7 Comparison of the identification accuracy for different methods

由图 7 可以看出,本文方法具有较高的识别准确率,且不同实验中识别准确率波动较小,有较好的稳定性,单次识别准确率的可信度高。MLP 方法总体分类准确率略低于本文方法,但高于 BP 及 SVM 方法,但波动明显大于本文方法;BP 与 SVM 分类准确率波动区间接近,总体识别准确率低于本文方法及 MLP 方法;且 BP 分类准确率的单次波动大于 SVM 方法。多次实验平均识别准确率及标准差统计如表 4 所示。

表 4 不同方法平均识别准确率统计结果
Table 4 Average identification accuracy with different methods

方法	平均准确率/%	准确率偏差/%
本文方法	85.2	0.4
SVM	48.5	4.5
BP	56.7	8.3
MLP	64.1	10.5

通过表 4 可以看到,对于实际中复杂工况下的管道入侵事件识别,本文方法识别准确率最高,平均识别准确率达到 85.2%,SVM 识别准确率最低,平均准确率仅为 48.5%。从识别准确率稳定性方面看,本文方法稳定性最高,其偏差只有 0.4%,多层感知机 MLP 稳定性最差,识别准确率偏差高达 10.5%。

上述结果表明,本文研究的方法相较于常用分类方法有较大优势,能够有效地对复杂环境下管道周界入侵

事件引发的振动信号实现自适应特征提取以及分类识别。分析原因,堆叠稀疏自编码利用多层次、分阶段的信息转换,能够捕捉到一些隐藏在原始数据中的解释性的信息,放大那些能区别不同原始数据的部分,并抑制无关部分,实现高效特征提取;另一方面,迁移学习拥有强大的知识迁移的能力,通过对其他复杂条件下振动信号内在联系的挖掘,提取环境不敏感特征,提升网络在新应用环境下的分类准确率。

4 结 论

针对传统的油气管道周界入侵事件识别面临的应用环境差异大,特征提取困难、复杂环境下采集信号存在较大差异,从而导致传统分类方法识别准确率低的问题,本文提出了基于深度神经网络迁移学习的油气管道周界入侵事件识别方法。原始振动信号作为深度神经网络输入,通过堆叠稀疏自编码网络的深度学习实现自动的特征提取,解决传统方法特征提取的不足之处;基于特征的迁移学习将管道不同运行环境下的入侵类别信号进行分布差异最小化处理,在变换域中建立自适应分类器,解决管道周边环境复杂造成的识别准确率低问题。实验结果表明,本文方法在复杂的应用环境中,利用少量的目标域标签数据即可获得较好的入侵事件识别效果,为改善实际运营中的油气管道安全预警系统性能提供了新思路。

参考文献

- [1] 李健,陈世利,黄新敬,等.长输油气管道泄漏监测与准实时检测技术综述[J]. 仪器仪表学报, 2016, 37(8): 1747-1760.
- LI J, CHEN SH L, HUANG X J, et al. Review of leakage monitoring and quasi real-time detection technologies for long gas & oil pipelines [J]. Chinese Journal of Scientific Instrument, 2016, 37 (8): 1747-1760.
- [2] 孙洁,李松,刘凯蕾,等.油气管道安全预警技术现状[J]. 油气储运, 2016, 35(9):1023-1026.
- SUN J, LI S, LIU K L, et al. Current status of security pre-warning technologies for oil and gas pipelines [J]. Oil & Gas Storage and Transportation, 2016, 35 (9): 1023-1026.
- [3] 孙茜,封皓,曾周末.基于图像处理的光纤预警系统模式识别[J]. 光学精密工程, 2015, 23(2): 334-341.
- SUN Q, FENG H, ZENG ZH M. Recognition of optical fiber pre-warning system based on image processing[J]. Optics and Precision Engineering, 2015, 23 (2): 334-341.
- [4] 曲志刚,封皓,靳世久,等.基于提升小波的管道安全

系统信号特征提取方法[J]. 传感器与微系统, 2010, 29(5): 59-62.

QU ZH G, FENG H, JIN SH J, et al. Lifting wavelet based fast signal feature extraction method for pipeline leakage detection and pre-warning system[J]. Transducer and Microsystem Technologies, 2010, 29(5): 59-62.

- [5] 王明达,张来斌,梁伟,等.基于独立分量分析和支持向量机的管道泄漏识别方法[J]. 石油学报, 2010, 31(4): 659-663.

WANG M D, ZHANG L B, LIANG W, et al. Pipeline leakage detection method based on independent component analysis and support vector machine[J]. Acta Petrolei Sinica, 2010, 31(4): 659-663.

- [6] 孙洁娣,乔艳雷,温江涛.压缩感知域智能天然气管道泄漏孔径识别[J]. 仪器仪表学报, 2017, 38(12): 3071-3078.

SUN J D, QIAO Y L, WEN J T. Pipeline leak aperture identification based on compressed sensing [J]. Chinese Journal of Scientific Instrument, 2017, 38(12): 3071-3078.

- [7] LEI Y G, JIA F, LIN J, et al. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data[J]. IEEE Transactions on Industrial Electronics, 2016, 63(5): 3137-3147.

- [8] SUN J D, YAN CH H, WEN J T. Intelligent Bearing Fault Diagnosis Method Combining Compressed Data Acquisition and Deep Learning [J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67 (1): 185-195.

- [9] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1349.

- [10] 殷鹏,景军峰.应用深度迁移学习的电子级玻璃纤维布分类[J]. 电子测量与仪器学报, 2019, 33(3): 112-119.

YIN P, JING J F. Classification of E-glass fiber cloth using deep transfer learning [J]. Journal of Electronic Measurement and Instrument, 2019, 33(3): 112-119.

- [11] 雷亚国,杨彬,杜兆钧,等.大数据下机械装备故障的深度迁移诊断方法[J]. 机械工程学报, 2019, 55(7): 1-8.

LEI Y G, YANG B, DU ZH J, et al. Deep transfer diagnosis method for machinery in big data era [J]. Journal of Mechanical Engineering, 2019, 55(7): 1-8.

- [12] GUO L, LEI Y G, XING S B, et al. Deep convolutional transfer learning network: A new method for intelligent

- fault diagnosis of machines with unlabeled data[J]. IEEE Transactions on Industrial Electronics, 2019, 66(9): 7316-7325.
- [13] WEN L, GUO L, LI X Y. A new deep transfer learning based on sparse auto-encoder for fault diagnosis [J]. IEEE Transactions on Systems, 2019, 49(1): 136-144.
- [14] DENG J, XU X ZH, ZH Z X, et al. Universum autoencoder-based domain adaptation for speech emotion recognition[J]. IEEE Signal Processing Letters, 2017, 24(4): 500-504.
- [15] SUN W J, SHAO S Y, ZHAO R, et al. A sparse auto-encoder-based deep neural network approach for induction motor faults classification [J]. Measurement, 2016, 89: 171-178.
- [16] 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26-39.
ZHUANG F ZH, LUO P, HE Q, et al. Survey on transfer learning research[J]. Journal of Software, 2015, 26(1): 26-39.
- [17] QIU SH W, DENG W H. Deep local descriptors with domain adaptation [C]. Pattern Recognition and Computer Vision, 2018:344-355.
- [18] LIU R J, SHI Y Q, JI CH J, et al. A survey of sentiment analysis based on transfer learning [J]. IEEE Access, 2019, 7: 85401-85412.
- [19] LU W N, LIANG B, CHENG Y, et al. Deep model based domain adaptation for fault diagnosis [J]. IEEE Transactions on Industrial Electronic, 2017, 64(3): 2296-2305.
- [20] LONG M SH, WANG J M, CAO Y, et al. Deep learning of transferable representation for scalable domain adaption [J]. IEEE Transactions on Knowledge and Data Engineering, 2016, 28(8): 2027-2040.

作者简介



E-mail: wens2002@163.com

Wen Jiangtao received his B. Sc. degree and M. Sc. degree both from Yanshan University in 1998 and 2003, respectively, and received his Ph. D. degree from Tsinghua University in 2009. He is currently an associate professor in the School of Electrical Engineering at Yanshan University. His current research interests include intelligent fault diagnosis, complex vibration signals processing and pattern recognition.



E-mail: wjtsjd@163.com

Sun Jiedi (Corresponding author) received her B. Sc. degree from Hebei Normal University in 1998, received her M. Sc. degree in 2001 from Yanshan University and received her Ph. D. degree from Tianjin University in 2008. She is currently a professor in School of Information Science and Engineering at Yanshan University. Her current research interest include intelligent fault diagnosis, deep learning and applications, complex vibration signals processing, pipeline leak detection and pre-warning.

温江涛, 1998年、2003年于燕山大学分别获得学士学位及硕士学位, 2009年于清华大学获得博士学位, 现为燕山大学电气工程学院副教授, 主要研究方向为故障诊断、复杂振动信号处理及模式识别。

孙洁娣 (通信作者), 1998年于河北师范大学获得学士学位, 2001年于燕山大学获得硕士学位, 2008年于天津大学获得博士学位, 现为燕山大学信息学院教授, 主要研究方向为智能故障诊断、深度学习理论及应用; 复杂振动信号处理, 管道泄漏监测及预警。