

文章编号: 0559-9350(2023)05-0587-12

基于原型试验的输水工程 PCCP 断丝信号智能识别与分析方法

张野, 袁思敏, 李炎隆, 温立峰, 司政, 孙凯宇

(西安理工大学 省部共建西北旱区生态水利国家重点实验室, 陕西 西安 710048)

摘要: 在引调水工程中, 钢丝断裂易导致预应力钢筒混凝土管(Prestressed Concrete Cylinder Pipe, PCCP)出现结构破坏和功能失效。本研究通过智能学习模型分析原型试验信号特征并判断断丝类型。采用内径 3.4 m, 长度 5 m 埋置式 PCCP 开展断丝原型试验, 利用分布式光纤传感器分别对切割断丝、腐蚀断丝和敲击噪声信号进行实时监测, 并基于短时傅里叶变换和深度学习模型重构断丝信号, 最终利用支持向量机建立了断丝信号识别模型。以 Inception-ResNet-v2 重构信号的断丝识别模型最低和最高准确率分别为 92.9% 和 100%, 之后利用 t -SNE 证明了信号重构的有效性。本研究结合不同智能学习方法实现了 PCCP 断丝类型的有效判别, 为其长期运行断丝监测及预警分析提供了新的手段。

关键词: 预应力钢筒混凝土管; 深度学习; 知识迁移; 短时傅里叶变换; 断丝信号; 智能识别

中图分类号: TV332

文献标识码: A

doi: 10.13243/j.cnki.slxb.20220913

1 研究背景

预应力钢筒混凝土管(Prestressed Concrete Cylinder Pipe, PCCP)因其较强的承压能力和较好的耐久性在长距离输水工程中得到了广泛应用, 如美国加利福尼亚州的中央亚利桑那调水工程、利比亚的大人工河工程^[1]以及国内的南水北调工程^[2]、引黄入晋工程^[3]和引汉济渭工程^[4]等。PCCP 在美国和加拿大应用很多, 约 90% 的美国自来水公司在供水工程中采用 PCCP^[5], 美国已使用 PCCP 超 35 000 km^[6]。

PCCP 长期服役于输水工程中, 会受到水锤、腐蚀、地形、接口问题等多方面影响而造成管体破坏。中央亚利桑那调水工程的 PCCP 服役 15 年即因大规模腐蚀而失效^[7], 这不仅远低于引调水工程的设计年限, 也低于管体的设计寿命。PCCP 中预应力钢丝是承担水压的主要结构, 一旦断丝发生并在管线运行过程中持续发展, 可能导致管体产生裂缝甚至出现爆管现象, 威胁群众财产安全^[8]。针对 PCCP 承载力和断丝的研究已取得许多进展, 如窦铁生等^[9-10]基于原型试验研究了在内外压力作用下 PCCP 管体变形规律, 也分析了断丝数量对于管体承载力的影响^[11]。翟科杰等^[12]利用 CFRP 加固断丝并利用试验和仿真的方法进行了验证。胡少伟等^[13]也分析了断丝对于超大口径 PCCP 结构承载力的影响。但目前 PCCP 断丝信号特征的重构与分析仍是工程中的难题。

在 PCCP 缺陷检测研究方面, 许多学者将不同的无损检测方法应用于这一领域。Rizzo^[14]以及 Liu 等^[15]总结了输水管道失效的无损检测方法并分析其优缺点。众多学者也将新技术应用于 PCCP 安全监测中, 如声发射技术^[16-17]、声谱共振^[18]以及电磁法^[19-20]等。Elfergani 等^[21]在实验室条件下利用声发射技术对腐蚀断丝进行长时间监测, 以证实这一技术的可行性, 但工程实践应用还需进一步研究。

收稿日期: 2022-11-05; 网络首发日期: 2023-05-18

网络首发地址: <https://kns.cnki.net/kcms/detail/11.1882.TV.20230517.1250.004.html>

基金项目: 国家自然科学基金青年项目(52009109); 博士启动基金项目(104-451120005); 陕西省自然科学基金基础研究计划—引汉济渭联合基金项目(2021JLM-46)

作者简介: 张野(1990-), 讲师, 主要从事水利工程仿真与智能化分析研究。E-mail: zhangye1990@xaut.edu.cn

通讯作者: 李炎隆(1980-), 教授, 主要从事水工结构数值仿真研究。E-mail: liyanlong@xaut.edu.cn

Xie 等^[22]将电磁法应用于 PCCP 断丝监测中, 结果表明电磁信号能够反映断丝事件的特征, 但是钢筒和钢丝的电磁信号会相互影响, 需要经验丰富的工程师对断丝事件进行判别, 因此也难以应用于工程实践。

分布式光纤因信号抗干扰性强、信噪比高以及设备体积小、便携性强的特点, 在不同的结构监测领域得到了广泛应用。Muggleton 等^[23]采用专门设计的埋地管道分布式光纤监测油气泄漏, 比较泄露处的信号和管壁辐射信号, 证明了光纤信号能够反映损伤特征。Liu 等^[24]将分布式光纤声学传感技术用于实时车辆检测任务, 通过分布式传感器信号特征识别车辆类别和估计车辆数量。Cao 等^[25]在湖泊中设置分布式传感光纤并对水下目标进行监测, 证明了光纤信号能够反映水下目标的特征。分布式光纤在 PCCP 结构损伤监测中也有应用。姚宣德^[26]研发了基于光纤光栅传感技术的 PCCP 管道断丝和漏水实时监测集成系统。骆建军等^[27]则采用光纤传感技术对大口径 PCCP 管道断丝频谱响应进行了试验研究, 证明光纤信号能够反映不同敲击声音频谱特征, 进而可判断 PCCP 断丝位置。齐海铭等^[28]采用分布式光纤光栅传感器识别断丝信号并实现断丝位置的精准定位。Li 等^[29]则用分布式光纤传感器收集断丝信号, 利用小波分析方法对不同断丝信号特征进行了简要概述。以上研究说明分布式光纤能够应用于 PCCP 断丝监测, 且在工程实践中应用也具有广阔的前景。

近几年, 智能学习方法开始应用于工程领域, 如施工日志分析^[30], 大坝安全监测^[31-32]以及工程日常巡检^[33]等。在振动信号处理方面, 机器学习和深度模型迁移方法也得到了广泛应用。Ren 等^[34]通过地质锤采集了不同岩石的声音信号, 对比分析了 5 种智能算法在岩体分类中的表现, 认为支持向量机具有优势。Han 等^[35]在基于声信号的岩体分类和强度回归的研究中, 采用深度模型网络迁移的方法建立岩体的强度区间, 最终实现了岩体强度的准确估计。Han^[36]同时采用了 K-近邻算法、随机森林和支持向量机来拟合岩体表面强度, 取得了良好的效果。在地震动信号监测方面, 智能算法也得到了广泛应用。Lu 等^[37]将地震动的时频分布图作为输入, 利用卷积神经网络对地震损失进行评价。Liao 等^[38]采用深度迁移学习方法重构振动信号的时频特性, 并证明了重构特征能够较好地反映振动信号特征。以上研究对于 PCCP 断丝识别具有一定的启发, 但是 PCCP 断丝信号收集较为困难, 数据量少, 是否能够采用智能算法构建模型仍需要进一步讨论。同时基于不同架构的深度模型陆续被学者提出, 如 ResNet^[39]、Inception-v4^[40]和 Inception-ResNet-v2^[40]。一般来说, 网络深度较大会导致网络训练困难。ResNet 通过使用深度残差学习模块解决了梯度消失问题。Inception-v4 和 Inception-ResNet-v2 一起由 Google 提出。残差网络的思想被尝试应用在 Inception 网络中, 从而实现了 Inception-ResNet-v1 和 v2 模型。同时, Google 设计出了更为复杂和精巧的 Inception-v4 网络, 在不使用残差网络的情况下也达到了与 Inception-ResNet-v2 近似的精度。ResNet 强调残差模块, Inception-v4 强调网络设计, Inception-ResNet-v2 则是在一定程度上综合了二者的特性。三种模型架构差异性较强, 可用于分析不同模块在断丝信号重构中的作用。

在本研究中, 采用分布式光纤传感技术对单节埋置式 PCCP 的断丝信号进行了实时监测, 利用切割、腐蚀和敲击的方式, 模拟 PCCP 断丝信号和噪声信号, 之后采用傅里叶变换和深度学习模型对信号特征进行处理分析, 重构 PCCP 断丝信号特征, 并将智能识别算法应用于断丝信号的最终识别, 为长距离输水工程中 PCCP 断丝长期监测提供技术支撑。

2 原型试验

2.1 试验设计 在 PCCP 断丝原型试验中, 采用 NZS-DSS-C09 型号的光纤传感器进行断丝信号监测, 采样频率为 1 kHz。该传感器是由碳纤维和玻璃纤维等组成, 携带方便、布置简易且可靠性强。由于光纤传感器柔韧性好, 因此采用螺旋缠绕的方式在管壁内外侧分别进行布设, 光纤布设总长度约为 80 m, 其中内外管壁分别约为 40 m。在距离承口(管底部)1.0、2.5 和 4.0 m 的位置选定 3 个断面进行光纤传感器布设, 3 个断丝区域 A、B、C 分别在距离承口(管底部)1.2、2.7 和 4.2 m 的位置, 即断丝区域比最近的光纤传感器监测断面高 0.2 m, 如图 1(a)所示。这样布置主要是为了使光纤传感器能够近距离

地感知断丝信号，更好地反映不同类型断丝信号特征。断丝试验需将 PCCP 砂浆保护层剥落开展断丝试验，如图 1(b)所示。PCCP 管体的几何参数和力学参数如表 1 所示。




图 1 PCCP 断丝试验光纤传感器布设

表 1 PCCP 管体参数

几何参数	参数值/mm	力学参数	参数值/MPa
管长	5000	工作内压	0.8
管径	3400	设计内压	1.12
内层混凝土厚度	75	钢丝强度	1570
钢筒厚度	1.5	钢丝弹性模量	205000
管芯混凝土厚度	280	钢筒强度	215
钢丝直径	7	钢筋预应力	1177.5
缠丝间距	16.5	混凝土强度	55
砂浆保护层厚度	32	砂浆强度	45

2.2 断丝试验 根据目前 PCCP 事故报告，管线断丝的原因主要包括两类：一类是由于钢筋生产质量导致的氢脆断裂；另一类是由于土壤中离子进入混凝土而导致的腐蚀断裂。本次试验采用人工切割和电化学腐蚀的方式分别模拟两种断丝信号；敲击信号是用地质锤锤击 PCCP 砂浆保护层得到。点 A 处试验是在管内无内压的条件下进行。在点 B 和点 C 处则采用逐级加压的方式施加内水压力，每增加 0.1 MPa 并稳压 5 min。在点 B 处，选用质量分数为 5% 的 NaCl 溶液对钢丝进行电化学加速腐蚀，腐蚀电流为 10 mA/cm²。在点 C 处，当管体内压达到 0.8 MPa 时切割钢丝。切割断丝试验和腐蚀断丝试验如图 2 所示。在试验过程中，采用光纤信号解译设备 MS-DAS2000III 对断丝信号和环境噪音进行监测。

在 PCCP 断丝试验中共收集了 137 组信号数据，包括 41 组切割断丝信号、46 组腐蚀断丝信号和 50 组敲击噪声信号。本研究在断丝试验光纤布设过程中，采用强力胶水和环氧树脂对光纤传感器进行固定，保证光纤传感器与 PCCP 管壁振动相一致。其他声音或振动无法引起管壁振动，分布式光纤传感器无法感知，因此得到的断丝信号信噪比较高，可直接用于 PCCP 断丝信号识别。

断丝信号波形整体符合指数衰减的规律。图 3 展示了切割断丝信号、腐蚀断丝信号和敲击噪声信号，相比于切割断丝，腐蚀断丝信号振幅更大，衰减时间更长；敲击噪声信号的衰减规律不完全符合指数衰减规律，振幅很小，这是因为敲击的能量远小于断丝能量，因此产生的振动信号也较弱。



图2 PCCP 断丝模拟




图3 PCCP 断丝信号实例

3 基于深度学习特征的断丝信号识别方法

3.1 短时傅里叶变换 声音信号是典型的非平稳信号，但其非平稳性由物体的运动过程产生，因而声音信号的变化可认为是相对缓慢的，即在短时间内的信号可认为是平稳的。傅里叶变换是分析线性系统和平稳信号稳态特征的重要手段，短时傅里叶变换则是采用稳态分析方法来处理非平稳信号，因此可采用短时傅里叶变换对声波信号进行处理。假设声音波形时域信号为 $s(l)$ ，分帧处理后得到的第 n 帧声音信号为 $s_n(m)$ ， n 为帧序号， m 为与帧同步的时间序号， $0 \leq n \leq N-1$ ， $0 \leq m \leq N-1$ ，其中 N 为信号采样长度，则有：

$$s_n(m) = w(m)s(n+m) \quad (1)$$

其中 w 为窗口函数，决定声波的取样频率。将声波信号进行短时傅里叶变换后可得：

$$S_n(e^{j\omega}) = \sum_{m=0}^{N-1} s_n(m) e^{-j\omega m} \quad (2)$$

式中： j 为虚数单位， $j^2 = -1$ ； ω 为角频率，取 $\omega = 2\pi k/N$ ， $0 \leq k \leq N-1$ ，则有：

$$S_n(e^{j\frac{2\pi k}{N}}) = S_n(k) = \sum_{m=0}^{N-1} s_n(m) e^{-j\frac{2\pi km}{N}} \quad (3)$$

其中 $S_n(k)$ 为一复数矩阵，横向按帧数 n 递增，纵向按频率 k 递增，以 $P_n(k)$ 表示频谱能量密度，即声波信号强度，则有：

$$P_n(k) = |S_n(k)|^2 = |S_n(e^{j\frac{2\pi k}{N}})|^2 \quad (4)$$

式中 $P_n(k)$ 为非负的实数矩阵，维数与 $S_n(k)$ 一致，横向按帧数 n 递增，纵向按频率 k 递增。在本研究中有声信号取 2 s。

3.2 知识迁移 知识迁移是将其他领域知识学习方法或者过程应用于本领域知识学习的一种智能算法。尽管目前机器学习技术已经广泛应用于各个领域，但其中大部分算法假设训练数据（源域）和

测试数据(目标域)具有相同的特征空间分布。因此,一旦特征空间或测试数据分布发生变化,预测模型将不再有效,必须基于新的数据从头开始训练和建模。但在工程领域中,很多情况下收集训练数据需要很高的经济成本和时间成本,如本研究中的 PCCP 断丝试验成本较高,单节 PCCP 埋置管的成本在几十万元的量级,而且由于管节尺寸较大,切割以及腐蚀预应力钢丝存在相当大的难度,信号收集也十分不易。因此,本研究采用知识迁移的方法构建分析 PCCP 断丝信号数据,利用已训练好的模型重构信号特征,并将重构的信号输入智能识别模型,最终构建 PCCP 断丝识别模型。

通过对信号的短时傅里叶变换,将信号数据生成频谱图。采用 3 种深度学习模型重构信号特征,将深度模型在大型数据集上所学到的知识迁移到信号特征重构中去,再将重构后的信号输入到不同的机器学习模型中并训练,最终通过测试结果对模型性能进行评价。3 种深度学习模型分别选择 ResNet、Inception-v4 和 Inception-ResNet-v2。本文采用的这 3 个模型都是在 ImageNet 数据集上训练的,该数据集的训练部分包括 120 万个数据,因此这 3 个模型作为预训练模型具有较大的潜力。

3.3 智能学习算法 如图 4 所示,PCCP 原始断丝信号数据是 2 s,采样频率是 1 kHz,因此,每组断丝数据包含 2000 个特征维度;但利用 ResNet、Inception-v4 和 Inception-ResNet-v2 三种深度模型进行信号特征重构后,断丝信号特征的维度分别为 1000、1001 和 1536。与原始的断丝信号相比,重构后的特征维度降低了约 500~1000 维,数据维度降低后可能造成信号信息的缺失。支持向量机(Support vector machine, SVM)本质上是单层神经网络结构,但其核函数能够对数据空间进行构造,将低维特征映射到更高维度,建立高维空间超平面来进行分析,从而将低维空间的超曲面非线性问题转化为高维空间超平面的线性可分问题。核函数表示为两映射函数的内积,如下式所示:

$$K(x_i, x_j) = \varphi(x_i) \cdot \varphi(x_j) \quad (5)$$

变量 x_i 和 x_j 均为低维特征向量,函数 φ 表示低维特征空间到高维特征空间的映射。




图 4 PCCP 断丝信号短时傅里叶变换生成频谱图

为了解决数据空间低维度线性不可分的问题,核函数将当前维度空间中的样本映射到高维中去,在高维空间建立超平面方程。但在核函数计算中,采用的策略是使用低维特征进行计算,避免高维特征空间产生较大的计算量,所以采用核函数是低维度的计算结果,只是这一结果与将数据映射到高维空间计算向量点积是等价的。所以 SVM 既能利用高维空间对数据进行分析,又能避免高维空间的巨大计算量。

除了应用 SVM 以外,本研究还将多种不同类型的智能算法应用于断丝信号识别中,包括 K 邻近算法(K-NearestNeighbor, KNN)、极端随机树(Extra-Trees, ET)和多层感知机(Multilayer Perceptron, MLP)。ET 为树形结构模型;KNN 是无监督学习算法,通过数据类间距离进行判别;MLP 是多层神经网络。基于不同理论的方法计算过程也不相同,因此可对比分析其在断丝信号识别中的性能,建立针对 PCCP 断丝信号的智能识别模型。图 5 为 PCCP 断丝信号识别方法的构建流程。

3.4 模型性能评价 本文采用混淆矩阵和模型准确率来评价模型结果的优劣。此处以二分类为例介绍混淆矩阵,参见图 6。在混淆矩阵中,横轴为预测类别,纵轴为实际类别,0 和 1 代表不同的类别,0




图5 PCCP断丝信号识别模型构建方法

代表正类,1代表负类;主对角线方向为预测准确的样本。将样本中正类预测为正类的为真正类(True Positive, TP),将样本中负类预测为正类的为假正类(False Positive, FP),将样本中负类预测为负类的为真负类(True Negative, TN),将样本中正类预测为负类的为假负类(False Negative, FN)。本文采用召回率(Recall)、精准率(Precision)、F1_score和AUC(Area under curve)来评价模型性能。召回率、精准率和F1_score的计算方法如式(6)~(8)所示。AUC是ROC(Receiver Operating Characteristic)下的面积,曲线的横坐标是假正类率,纵坐标是真正类率。准确率(Accuracy)也可以利用混淆矩阵中的数值表达,如式(9)所示。

$$Recall = \frac{TP}{TP+FP} \quad (6)$$

$$Precision = \frac{TP}{TP+FN} \quad (7)$$

$$F1_score = \frac{2 \cdot Precision \cdot Recall}{Precision+Recall} \quad (8)$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (9)$$

		预测类别	
		0	1
实际类别	0	TP	FN
	1	FP	TN

图6 混淆矩阵

4 PCCP断丝信号识别结果分析

4.1 模型参数选取 在利用深度模型重构断丝信号特征过程中,不同模型对于输入数据的尺寸是有要求的,因此需要对输入的断丝声谱信号进行尺寸调整。对于ResNet模型,PCCP断丝信号声谱图尺寸大小为224×224×3,对于Inception-v4和Inception-ResNet-v2模型,PCCP断丝信号声谱图尺寸为299×299×3。其中299和224表示图像的宽和高,3表示图像的3个颜色通道。

在智能模型构建过程中,KNN断丝识别类型数设为3。同时对SVM、ET和MLP进行了参数寻优。在SVM的参数中,分别对核函数、惩罚参数以及gamma参数进行寻优;在ET的参数中,

分别对 `n_estimators` 和 `max_depth` 进行寻优；在 MLP 的参数中，对隐层数以及学习率进行寻优。在参数寻优过程中采用 5 折交叉验证的方式，寻优方法为网格搜索法，最终选取的模型参数如表 2 所示。

4.2 模型结果分析 将断丝试验中获取的 137 组信号数据乱序排列并随机选取其中 20% 的数据作为测试数据，分为 28 组，包含 9 组切割断丝信号，9 组腐蚀断丝信号和 10 组敲击噪声信号，在 PCCP 断丝识别的混淆矩阵中，以数字代表不同的断丝信号分类，对应关系为：0-切割断丝信号，1-腐蚀断丝信号，2-敲击噪声信号。断丝识别过程分两组进行。第一组将原始的信号数据直接输入 4 种智能识别模型中，参数采用表 1 中的最优参数；第二组利用 3 种不同的深度模型分别对断丝信号进行重构，之后输入到 4 种智能识别模型中，利用混淆矩阵对两组试验以及第二组试验中不同模型的识别结果进行评价。

首先将原始 PCCP 断丝信号数据输入至 4 种不同的智能模型中进行分析，利用不同模型评价指标对识别结构进行评价，结果如表 3 和图 7 所示。

由表 3 和图 7 可以看出，直接将原始信号数据输入智能模型，尽管耗时较短，多数智能模型的准确率在 80% 以下，其他指标除 AUC 外也均在 80% 左右。这也说明两种断丝信号以及敲击噪声信号具有一定的相似性，智能模型难以将原始信号中的噪声进行识别，最终导致 PCCP 断丝信号识别准确率低。

利用 ResNet、Inception-v4 和 Inception-ResNet-v2 分别对 PCCP 断丝信号进行重构，并利用不同的智能模型进行识别，用不同模型评价指标对识别结果进行评价。结果如表 4 和图 8 所示。图 8 每一列混淆矩阵表示对应深度模型重构信号的测试结果，每一行表示对应的智能模型的测试结果。

对比表 3 和表 4 可以看出，直接输入原始数据的智能模型准确率最高为 82.1%，利用深度模型重构断丝信号并输入智能模型最低准确率为 85.7%，最高达 100%，Recall、Precision、F1_score 等指标与准确率相似，AUC 值较高。基于深度模型重构特征的模型远高于直接将原始数据输入智能模型的方法，说明利用深度模型重构信号可以有效表征信号特征值。从表 4 中可以看出，基于 Inception-ResNet-v2 的重构信号输入到智能识别模型中，其准确率最低为 92.9%，最高为 100%，采用智能模型 SVM 实现，整体高于基于 ResNet 和 Inception-v4 重构信号的识别结果，说明 Inception-ResNet-v2 能够将信号特征更好地提取出来，也说明了通过结合 ResNet 和 Inception 模块的优点，Inception-ResNet-v2 的有效性更强。从图 8 中可以看出，基于 Inception-ResNet-v2 重构的特征信号，KNN 和 ET 模型可能将切割断丝信号预测为腐蚀断丝信号，MLP 模型分别将切割断丝信号预测为腐蚀断丝信号，将腐蚀断丝信号预测为敲击噪声，这说明不同信号间均有一定的相似性，因此造成了断丝信号识别错误。模型识别多个信号的时间均在 1 s 以内，也说明该建模方法能够应用于 PCCP 断丝实时监测分析中。

表 2 模型参数选取

深度学习模型	机器学习方法	参数	参数选择
ResNet	SVM	kernel	RBF
		C	100
		gamma	10^{-4}
	ET	<code>n_estimators</code>	100
		<code>max_depth</code>	40
	MLP	隐层数	200
Inception-v4	SVM	学习率	0.001
		kernel	RBF
		C	1
	ET	gamma	10^{-3}
		<code>n_estimators</code>	600
		<code>max_depth</code>	30
Inception-ResNet-v2	MLP	隐层数	300
		学习率	10^{-3}
	SVM	kernel	Linear
		C	1
	ET	<code>n_estimators</code>	100
		<code>max_depth</code>	50
	MLP	隐层数	300
		学习率	0.001

表 3 基于原始信号数据的智能模型断丝识别评价结果

智能识别模型	Recall/%	Precision/%	F1_score/%	AUC	Accuracy/%	耗时/s
SVM	75.0	75.6	74.1	0.893	75.0	0.06
KNN	60.7	70.2	58.2	0.695	60.7	0.16
ET	78.6	80.8	77.3	0.941	78.6	0.42
MLP	82.1	82.2	82.0	0.933	82.1	2.41




图 7 基于原始断丝信号的 PCCP 断丝识别结果

表 4 基于重构信号的智能模型断丝识别评价结果

深度学习模型	机器学习方法	Recall/%	Precision/%	F1_score/%	AUC	Accuracy/%	耗时/s
ResNet	SVM	85.7	86.4	85.9	0.976	85.7	0.73
	KNN	89.3	89.6	89.3	0.921	89.3	0.12
	ET	89.3	89.6	89.3	0.921	89.3	0.63
	MLP	85.7	85.7	85.7	0.977	85.7	0.87
Inception-v4	SVM	92.9	94.2	92.8	0.986	92.9	0.54
	KNN	85.7	90.1	86.2	0.895	85.7	0.13
	ET	85.7	90.1	86.2	0.895	85.7	0.41
	MLP	92.9	94.2	92.8	0.986	92.9	0.91
Inception-ResNet-v2	SVM	100	100	100	100	100	0.77
	KNN	96.4	96.8	96.4	0.973	96.4	0.37
	ET	96.4	96.8	96.4	0.973	96.4	0.54
	MLP	92.8	93.2	92.8	0.998	92.9	0.88

4.3 基于 t -SNE 的重构特征降维可视化验证 在上节已经对重构信号和智能模型识别进行了量化评价，从结果中可以看出基于 Inception-ResNet-v2 的特征有效性更强，如何更直观的表示不同模型的特征分布仍需进一步研究。基于 ResNet、Inception-v4 和 Inception-ResNet-v2 模型的重构信号维度分别为 1000、1001 和 1536，如此高维度的特征很难进行可视化验证，因此采用 t -Distributed Stochastic Neighbor Embedding (t -SNE) 进行分析。

算法 t -SNE 是一种非线性、无监督和基于流形的特征提取方法，能够将高维数据映射到低维，如 2 维或 3 维，同时能够保留原始数据的基本结构，因此 t -SNE 主要用于数据探索和可视化。简而言之， t -SNE 提供了对数据在高维空间中的直观排列方式。尽管不同特征重构方法具有强大的性能，如本文提出的 3 种断丝信号重构模型，但在高维特征可视化方面并不理想，其中大多数是不能同时保留局部和全局结构数据，而 t -SNE 能够通过保留数据的显著性来方便地可视化高维数据结构体。

t -SNE 将随机邻域嵌入(SNE)应用于数据特征，将高维欧氏距离转换成表示相似性的条件概率。数据 x_a 与 x_b 的相似性由条件概率表示，如下所示。




图 8 基于不同深度模型及智能识别模型的 PCCP 断丝信号识别结果

$$P_{a/b} = \frac{\exp \frac{-\|x_b - x_a\|^2}{2\sigma_b^2}}{\sum_{c \neq b} \exp \frac{-\|x_b - x_c\|^2}{2\sigma_b^2}} \quad (10)$$

其中 σ_b^2 为 x_b 的方差。

利用 t -SNE 对 ResNet、Inception-v4 和 Inception-ResNet-v2 三种深度模型的重构特征进行可视化分析，结果如图 9 所示，横轴和纵轴分别代表高维特征降为二维后的两个特征维度，是无量纲值。




图 9 基于 t -SNE 的深度模型重构信号可视化分析

在图 9 中,红色点(0)代表切割断丝,蓝色点(1)代表腐蚀断丝,绿色点(2)代表敲击噪声,从图 9 中可以看出,基于 ResNet 模型重构的断丝特征,切割断丝信号和敲击噪声信号边界不清晰,部分敲击噪声信号远离敲击噪声信号总体数据群;基于 Inception-v4 模型重构的断丝特征,切割断丝信号和腐蚀断丝信号边界不清晰;基于 Inception-ResNet-v2 模型重构的断丝特征,3 种声音信号间有较为明确的界限,这也说明采用 Inception-ResNet-v2 提取断丝特征信号更为有效。

5 结论

本文采用分布式光纤传感器,通过 PCCP 原型断丝试验获得切割断丝、腐蚀断丝和敲击噪声的声波信号,利用短时傅里叶变换对原始信号进行处理,并将不同的深度学习模型用于断丝信号重构中,最终将断丝信号输入智能模型进行信号识别,通过评价智能模型识别性能,建立最优的 PCCP 断丝信号识别模型。通过整体的 PCCP 断丝识别研究所得到的具体结论如下。

(1)本研究进行了输水管道 PCCP 原型断丝试验,利用分布式光纤传感器,收集了多组 PCCP 切割断丝信号、PCCP 腐蚀断丝信号以及噪声信号。从原始信号特征来看,信号受环境噪声影响小,波形能够反映信号的特征,能为 PCCP 断丝信号识别与分析奠定数据基础。

(2)对比将原始信号直接输入智能模型和将原始信号重构输入智能模型两种方式,结果显示将重构后的特征输入智能模型,其准确性有了较大的提升,表明深度模型能够用于重构断丝信号特征,并将重构的特征应用于 PCCP 断丝信号识别中。

(3)对比不同深度模型重构的断丝信号在智能模型中的表现,结果显示基于 Inception-ResNet-v2 模型重构的断丝特征在 4 种不同类型的智能模型中均表现优异,说明基于 Inception-ResNet-v2 重构的断丝特征信号更具有有效性,尤其对于 SVM 模型,在测试集中达到了 100%的准确率,说明该模型能够应用于 PCCP 断丝监测。

(4)基于 Inception-ResNet-v2 模型重构的断丝特征,从混淆矩阵中可以看出仍有部分信号出现识别错误,说明切割断丝信号、腐蚀断丝信号和敲击噪声信号具有一定的相似性,这也显示了直接将原始信号输入智能模型而整体识别准确率不高的原因,亦说明对断丝信号进行重构是必要的。

(5)最后采用 t -SNE 方法对 3 种深度模型提取的特征进行可视化分析,可以发现基于 ResNet 和 Inception-v4 重构的 3 种信号分界不清晰,数据点有交叠,而基于 Inception-ResNet-v2 模型重构的断丝信号数据边界较清晰,为 PCCP 断丝识别奠定了良好的基础。

由于 PCCP 断丝试验数据采集十分困难,所以在本研究中采用的断丝数据信号只有 87 组,因此还需要在进一步的试验中收集更多的 PCCP 断丝监测数据,更深层次地验证本文所提出的模型方法,在 PCCP 长期监测的实践中不断迭代模型,使之能够适用于 PCCP 长期运行监测过程中的断丝事件识别。

参 考 文 献:

- [1] ALLAN J A. The great man-made river: progress and prospects of Libya's great water carrier[J]. Libyan Studies, 1988, 19: 141-146.
- [2] 蒋家林. 预应力钢筒混凝土管(PCCP)在南水北调工程中的应用[J]. 混凝土世界, 2009(12): 44-47.
- [3] 崔阿李. 万家寨引黄入晋工程 PCCP 管抗震性能分析[J]. 人民黄河, 2009, 31(8): 78, 81.
- [4] 杨军超. 引汉济渭二期工程输水管道管材比选[J]. 水利规划与设计, 2022(8): 106-109, 122.
- [5] BALL R T, MOORE W G, SMITH D L, et al. Prestressed concrete cylinder pipe rehabilitation repair and replacement: large diameter success stories[J]. Florida Water Resources Journal, 2012, 6(9): 4-10.
- [6] ATHERTON D L, MORTON K, MERGELAS B J. Detecting breaks in prestressing pipe wire[J]. Journal-American Water Works Association, 2000, 92(7): 50-56.
- [7] TRAVERS F A. Acoustic monitoring of prestressed concrete pipe[J]. Construction and Building Materials, 1997, 11(3): 175-187.

- [8] HU B, FANG H, WANG F, et al. Full-scale test and numerical simulation study on load-carrying capacity of prestressed concrete cylinder pipe (PCCP) with broken wires under internal water pressure[J]. Engineering Failure Analysis, 2019, 104: 513-530.
- [9] 窦铁生, 程冰清, 胡赫, 等. 预应力钢筒混凝土管结构变形规律的原型试验研究 I: 内压[J]. 水利学报, 2017, 48(12): 1438-1446.
- [10] 窦铁生, 程冰清, 胡赫, 等. 预应力钢筒混凝土管结构变形规律的原型试验研究 II: 外压[J]. 水利学报, 2018, 49(2): 207-215.
- [11] 窦铁生, 胡赫, 杨进新, 等. PCCP 断丝数量对内压承载力的影响[J]. 混凝土与水泥制品, 2015(7): 35-37.
- [12] 翟科杰, 方宏远, 郭成超, 等. 预应力 CFRP 加固断丝 PCCP 的试验与仿真研究[J]. 水利学报, 2021, 52(6): 739-749.
- [13] 胡少伟, 沈捷. 超大口径 PCCP 内断丝对其承载能力影响研究[J]. 水利水电技术, 2011, 42(4): 41-44.
- [14] RIZZO P. Water and wastewater pipe nondestructive evaluation and health monitoring: a review[J]. Advances in Civil Engineering, 2010. doi: 10.1155/2010/818597.
- [15] LIU Z, KLEINER Y. State of the art review of inspection technologies for condition assessment of water pipes[J]. Measurement, 2013, 46(1): 1-15.
- [16] GOLDARAN R, TURER A, KOUHDARAGH M, et al. Identification of corrosion in a prestressed concrete pipe utilizing acoustic emission technique[J]. Construction and Building Materials, 2020, 242: 118053.
- [17] LI D, TAN M, ZHANG S, et al. Stress corrosion damage evolution analysis and mechanism identification for prestressed steel strands using acoustic emission technique[J]. Structural Control and Health Monitoring, 2018, 25(8): e2189.
- [18] LESAGE J C, SINCLAIR A N. Characterization of prestressed concrete cylinder pipe by resonance acoustic spectroscopy[J]. Journal of Pipeline Systems Engineering and Practice, 2015, 6(1): 04014011.
- [19] DÉROBERT X, LATASSE J F, BALAYSSAC J P, et al. Evaluation of chloride contamination in concrete using electromagnetic non-destructive testing methods[J]. NDT & E International, 2017, 89: 19-29.
- [20] 李润斌. 基于电磁感应原理的预应力钢筒混凝土管断丝检测研究[D]. 天津: 天津大学, 2020.
- [21] ELFERGANI H A, PULLIN R, HOLFORD K M. Damage assessment of corrosion in prestressed concrete by acoustic emission[J]. Construction and Building Materials, 2013, 40: 925-933.
- [22] XIE Y B, FENG H, ZHAO M X, et al. PCCP broken wire detection based on orthogonal electromagnetic principle[J]. Journal of Measurement Science and Instrumentation, 2019, 10(1): 81-90.
- [23] MUGGLETON J M, HUNT R, RUSTIGHI E, et al. Gas pipeline leak noise measurements using optical fibre distributed acoustic sensing[J]. Journal of Natural Gas Science and Engineering, 2020, 78: 103293.
- [24] LIU H, MA J, XU T, et al. Vehicle detection and classification using distributed fiber optic acoustic sensing[J]. IEEE Transactions on Vehicular Technology, 2019, 69(2): 1363-1374.
- [25] CAO W, CHENG G. Modeling and experimental research on receiving signal of multi-layer distributed acoustic sensing optical fiber in shallow water[J]. Optical Fiber Technology, 2021, 67: 102692.
- [26] 姚宣德. 北京市南水北调配套工程 PCCP 管道断丝、漏水实时监测集成系统[J]. 水利水电技术, 2016, 47(10): 67-72.
- [27] 骆建军, 姚宣德, 张东生, 等. 大口径 PCCP 管道断丝频谱响应现场试验研究 (I)[J]. 土木工程学报, 2016, 49(9): 110-116.
- [28] 齐海铭, 宋建华, 韩继明, 等. 基于分布式光纤光栅传感器的 PCCP 断丝监测技术[J]. 管道技术与设备, 2018(4): 1-4, 8.
- [29] LI Y, SUN K, SI Z, et al. Monitoring and identification of wire breaks in prestressed concrete cylinder pipe based on distributed fiber optic acoustic sensing[J]. Journal of Civil Structural Health Monitoring, 2022. doi: 10.1007/s13349-022-00605-0.
- [30] 李明超, 田丹, 沈扬, 等. 融入 Attention 机制改进 Word2vec 技术的水利水电工程专业词智能提取与分析方法[J]. 水利学报, 2020, 51(7): 816-826.
- [31] 李明超, 任秋兵, 孔锐, 等. 多维复杂关联因素下的大坝变形动态建模与预测分析[J]. 水利学报, 2019,

50(6): 687–698.

- [32] 任秋兵, 沈扬, 李明超, 等. 水工建筑物安全监控深度分析模型及其优化研究[J]. 水利学报, 2021, 52(1): 71–80.
- [33] 陈俊杰. 耦合 BIM 的长距离输水渠道无人机巡检与险情智能图像识别研究[D]. 天津: 天津大学, 2020.
- [34] REN Q, WANG G, LI M, et al. Prediction of rock compressive strength using machine learning algorithms based on spectrum analysis of geological hammer[J]. Geotechnical and Geological Engineering, 2019, 37(1): 475–489.
- [35] HAN S, LI H, LI M, et al. Measuring rock surface strength based on spectrograms with deep convolutional networks[J]. Computers & Geosciences, 2019, 133: 104312.
- [36] HAN S, LI H, LI M, et al. A deep learning based method for the non-destructive measuring of rock strength through hammering sound[J]. Applied Sciences, 2019, 9(17): 3484.
- [37] LU X, XU Y, TIAN Y, et al. A deep learning approach to rapid regional post-event seismic damage assessment using time-frequency distributions of ground motions[J]. Earthquake Engineering & Structural Dynamics, 2021, 50(6): 1612–1627.
- [38] LIAO W, CHEN X, LU X, et al. Deep transfer learning and time-frequency characteristics-based identification method for structural seismic response[J]. Frontiers in Built Environment, 2021, 7(10). doi: 10.3389/fbuil.2021.627058.
- [39] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [40] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, Inception-resnet and the impact of residual connections on learning[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2017.

Intelligent identification and analysis of PCCP wire broken signal in water diversion project using prototype testing

ZHANG Ye, YUAN Simin, LI Yanlong, WEN Lifeng, SI Zheng, SUN Kaiyu

(State Key Laboratory of Eco-hydraulics in Northwest Arid Region, Xi'an University of Technology, Xi'an 710048, China)

Abstract: In water diversion projects, the breakage of steel wires can easily lead to structural and functional failure of Prestressed Concrete Cylinder Pipes (PCCP). This study aims to analyze signal characteristics and identify the type of wire breakage using intelligent learning models. In the research, A prototype test for wire breakage was conducted on an embedded PCCP with an inner diameter of 3.4 meters and a length of 5 meters. Real-time monitoring was carried out using a distributed optical fiber sensor to detect cutting wire, corrosion wire, and impact noise signals. Based on Short-time Fourier Transform (STFT) and deep learning models, the wire breakage signals were reconstructed. Finally, a wire breakage signal recognition model was established using a support vector machine. Based on the reconstruction of signals using Inception-ResNet-v2, the lowest and highest accuracy of the wire breakage recognition model are 92.9% and 100%, respectively. The effectiveness of the signal reconstruction was also demonstrated using t -SNE. This study has achieved effective recognition of wire breakage types by combining different intelligent learning methods. It provides new methods for long-term wire breakage monitoring and early warning analysis in PCCP operation.

Keywords: prestressed concrete cylinder pipes (PCCP); deep learning; knowledge transfer; short-time Fourier transform; wire broken signal; intelligent identification

(责任编辑: 韩 昆)