

# 基于一维堆叠卷积自编码器的分布式应变裂缝检测<sup>①</sup>



严国萍, 陈禹, 李雨冲, 闫昭帆

(长安大学 信息工程学院, 西安 710064)

通讯作者: 陈禹, E-mail: 1823213844@qq.com

**摘要:** 桥梁裂缝检测对于桥梁健康检测具有重要的意义. 基于布里渊时域分析的分布式光纤传感器能够测量整个结构表面的应变数据. 由于测量所得应变数据信噪比低, 存在裂缝损伤处的应变异常被噪声“淹没”和“混淆”的问题. 针对这一问题, 提出一种基于一维堆叠卷积自编码器的分类检测方法. 该方法具有噪声鲁棒性强、自提取特征可判别性高等优势. 首先, 通过布置光纤传感器获取结构表面应变数据, 对光纤应变数据进行标准化预处理, 并划分应变子序列. 然后, 使用一维堆叠卷积自编码器自动提取应变子序列的特征. 最后, 通过 Softmax 分类器对所提取的应变子序列特征进行分类, 即裂缝或非裂缝. 实验结果表明, 该方法可以有效检测微小裂缝, 检测准确率高. 并且该方法提取的特征可判别性优于卷积神经网络和堆叠自编码器等方法.

**关键词:** 裂缝检测; 特征提取; 堆叠卷积自编码器; Softmax 分类器

引用格式: 严国萍, 陈禹, 李雨冲, 闫昭帆. 基于一维堆叠卷积自编码器的分布式应变裂缝检测. 计算机系统应用, 2020, 29(1): 144-150. <http://www.c-s-a.org.cn/1003-3254/7248.html>

## Distributed Strain Crack Detection Based on One-Dimensional Stacked Convolutional Autoencoder

YAN Guo-Ping, CHEN Yu, LI Yu-Chong, YAN Zhao-Fan

(School of Information Engineering, Chang'an University, Xi'an 710064, China)

**Abstract:** Bridge crack detection has great significance for bridge condition monitoring. Distributed fiber optic sensors are widely used to detect bridge cracks. The state quo approach is based on Brillouin time domain analysis. Though being capable of measuring strain data across the surface of the structure, it has its own flaw—the strain anomaly at the crack damage is “submerged” and “confused” by the noise due to the lower signal-to-noise ratio of the measured strain data. To this end, we propose a classification detection method based on one-dimensional stacked convolution autoencoder, which are endowed with strong noise robustness and high resolution of auto extraction features. The proposed method consists of three steps. First, structural surface strain data is acquired by arranging fiber optic sensors, the fiber strain data preprocessed and the strain subsequence divided. Second, the characteristics of the strain subsequence are automatically extracted using a one-dimensional stacked convolution autoencoder. Finally, the extracted strain subsequence features are classified by a Softmax classifier into two categories—cracks or non-cracks. The method can effectively detect micro cracks and has high detection accuracy. Moreover, by experimental contrast we claim that the feature discriminability extracted by this method is better than that of convolutional neural network and stacking autoencoder.

**Key words:** crack detection; feature extraction; stacked convolutional autoencoder; Softmax classifier

① 收稿时间: 2019-06-24; 修改时间: 2019-07-16; 采用时间: 2019-07-22; csa 在线出版时间: 2019-12-27

桥梁裂缝的产生和发展往往体现桥梁的健康状态,全面、尽早、准确地发现表面裂缝对桥梁安全运营具有重大意义.传统上利用超声波、X射线、红外线等传感器来识别土木结构内部或表面是否存在裂缝,它们本质上是点式传感器,很难一次性测量出全尺度信息<sup>[1,2]</sup>.近年来,基于布里渊时域分析(BOTDA)的光纤传感器被广泛应用<sup>[3]</sup>.分布式光纤传感器能够以厘米级的空间分辨率一次测量获取桥梁数百甚至上千米全尺度表面上的分布式应变.在分布式光纤传感器所测得的分布式应变数据中,裂缝区域会表现为异常,通过检测分布式应变的异常来发现桥梁表面裂缝.在测量过程中为了测量更多的应变细节,通常会配置尽量小的空间分辨率,所以测得应变数据的信噪比(SNR)较低,导致源自裂缝损伤处的应变异常难以被发现<sup>[4]</sup>.在早期,异常模式发现是基于概率统计模型来实现的<sup>[5]</sup>.使用统计学方法来实现异常检测必须要确定适合数据的分布模型,设置模型参数,但实际情况是,往往无法知道数据集所遵循的标准分布类型,或许数据本身就不服从任何的标准分布.此外改进的基于距离的异常点检测算法、基于密度的局部异常点检测算法<sup>[6-8]</sup>.它们以欧氏距离作为异常评判标准,但这两种方法在面对海量数据时,计算复杂度高,具有潜在的局限性.随着模式识别领域中深度学习方法的迅速发展,深度学习算法开始被应用到异常检测中来<sup>[9]</sup>,如基于神经网络的方法,此方法采用自适应学习算法对异常活动和非异常活动进行特征提取,训练结束后提供待测数据进行异常检测<sup>[10,11]</sup>.此方法不需要对原始数据作统计假设,有很好的抗干扰能力.自动编码器(AutoEncoder, AE)是典型的神经网络之一,它可以被看作是一个三层全连接网络,具有出色的抗噪声特征表征能力<sup>[12,13]</sup>.但是当数据更加复杂时,单层编码器无法有效的提取复杂数据的特征.因此, Hinton 等<sup>[14]</sup>将多个 AE 逐层堆叠构成一个堆叠自编码器用于对高维数据进行降维和特征提取.卷积神经网络是一类前向传播的神经网络,通过若干个卷积核挖掘特征的局部相关性,卷积神经网络实现了权值共享,降低了深度神经网络的计算代价并且更易于训练<sup>[15,16]</sup>.卷积神经网络多被利用于处理图像,但是最近的一些研究也将其引入到对序列数据的挖掘中<sup>[17,18]</sup>.

受此启发,本文充分挖掘到自动编码器自动提取高质量特征表征的能力,卷积神经网络可以利用多个

卷积核提取多个特征.所以,结合自动编码器与卷积神经网络的优势,本文提出一种基于一维堆叠卷积自编码器(Stacking Convolutional AutoEncoder, SCAE)的分类检测方法来处理低信噪比的分布式应变裂缝检测.该方法首先将应变序列标准化后划分为等长的子序列,所有的子序列可以分为两类,一类是从存在裂缝的结构表面获得的裂缝应变子序列(CS),另一类是从正常的结构表面获得的非裂缝子序列(NS),然后利用 SCAE 对这些子序列进行自适应的特征提取,最后将 SCAE 提取的特征作为 Softmax 分类器的输入来进行分类,以达到检测的目的.微小裂缝检测是基于 CS/NS 二元分类的结果实现的.该方法在人为制造微小裂缝的 15 米工字钢梁上进行了验证.

## 1 模型与算法

本文设计的基于一维堆叠卷积自编码器的分布式应变裂缝检测过程的具体算法流程如图 1,图中数据处理部分的虚线框表示子序列截取,特征提取部分的椭圆虚线框表示池化窗口,矩形虚线表示卷积核.

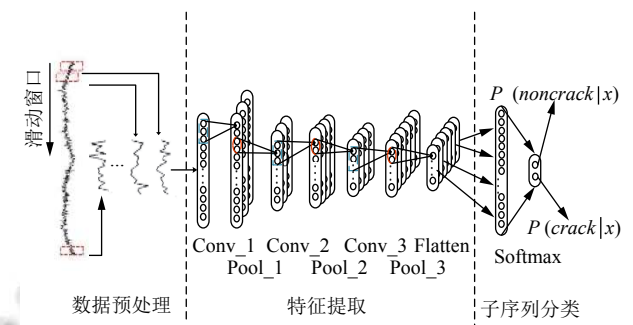


图 1 所提出方法的 3 个部分

第 1 部分为数据预处理部分,将分布式光纤传感器感测到的应变序列进行标准化,使用滑动窗口将其截取为多个子序列,作为第 2 部分的输入样本数据.

第 2 部分为特征提取部分,此部分由一维堆叠卷积自编码器的 3 个卷积层(Conv)和 3 个池化层(Pool)构成,用以提取输入子序列具有噪声鲁棒性和高分辨率特征,并将其输入第 3 部分.

第 3 部分为分类部分,将提取到的高分辨率的特征表征输入 Softmax 分类器,得到两个概率,  $p(\text{crack}|x)$  表示当前特征表征判断为裂缝的概率,  $p(\text{noncrack}|x)$  表示当前特征表征判断为非裂缝的概率,根据两个概率的大小,来判断是否该子序列为裂缝.

### 1.1 数据预处理

本文首先采用模式识别中常用的 z-score 标准化方法对采集的分布式光纤应变数据进行标准化, 其公式为:  $\hat{S}^i = \frac{S^i - \mu_i}{\sigma_i}$ ,  $S^i$  是独立测量中的第  $i$  个分布式应变序列.  $\mu_i$  为  $S^i$  的均值;  $\sigma_i$  为  $S^i$  的标准差.  $\hat{S}^i$  则为  $S^i$  标准化后的数据.

由于应变序列数据点与点之间并不独立, 很多异常都是存在于子序列中, 所以本文关注应变序列子序列的异常检测, 运用具有固定长度的滑动窗口, 把应变序列分为若干子序列进行异常检测, 该方法不仅能够观测单个数据点的异常情况, 还可对整个应变序列中所有子序列进行异常检测. 正样本选取以裂缝点 {80, 200, 362, 482} 为中心的样本视为最佳正样本, 步长为 1, 滑动窗口大小为 24, 将距离最佳正样本最近的 7 个样本标记为正样本, 其他数据全部标记为负样本. 具体的样本扩增情况图 2 所示.

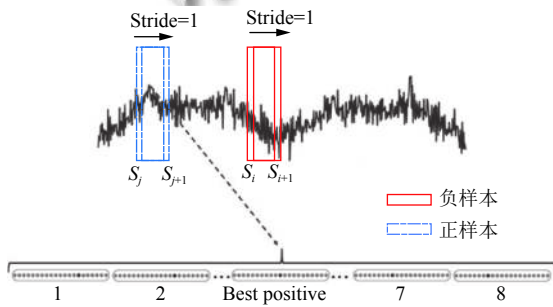


图 2 样本扩增

### 1.2 一维卷积堆叠自编码器 (SCAE)

自动编码器是一种无监督的神经网络模型, 它可以学习到输入数据的隐含特征, 这称为编码, 同时用学习到的新特征重构出原始输入数据, 称之为解码. 单层 AE 可以被认为是一个三层全连接神经网络, 分别为输入层, 隐藏层, 输出层. 卷积自编码器 (Convolutional AutoEncoder, CAE) 其核心思想是将 AE 中全连接网络换为卷积神经网络. 一维堆叠卷积自编码器由多个一维 CAE 分层堆叠而成, 前一个 CAE 编码器的输出为后一个 CAE 的输入, 第一个 CAE 的输入为预处理后应变子序列. 一维卷积自编码器可以获取噪声鲁棒性强, 可判别性高的特征, 主要是因为其模型堆叠起来的深层结构与单层自动编码器相比, 具有更强的特征表征能力. 每一层 CAE 的编码器对输入数据进行映射, 解码器对编码数据进行映射, 映射后的数据是输入数

据的近似. 解码器和编码器同时训练, 不断的最小化重构误差, 得到最优模型. 此外其网络模型采用了卷积神经网络, 卷积神经网络相比于全连接网络的优势在于它采用了局部连接、参数共享、多个卷积核、池化. 局部连接主要是卷积层的节点和其前一层的部分节点相连接, 用来学习局部特征, 这种局部连接的方式减少了大量的参数数量, 加快了学习速率; 参数共享是指每一个卷积核在遍历整个数据时, 卷积核的参数不变, 这样的机制最大的作用就是很大程度地减少了运算量; 使用多个卷积核是因为一个核的参数是固定的, 其提取的特征也会单一化, 使用多个卷积核有利于提取多特征; 池化层其实是一个下采样的过程, 主要是为了降低维度并保留特征的有效信息, 减小过拟合, 同时提高模型的容错性.

图 3 是由两个 CAE 堆叠的 SCAE 模型, 其中  $X$  为第一个 CAE 的输入, 其大小为  $w \times 1$ . 图中左边虚线框部分, 每一个卷积和池化表示一次 CAE 的编码过程. 其公式如下所示:

$$h_{i,1} = s_f(W \otimes X_i + b) \quad (1)$$

$$h_{i,2} = \text{pool}(h_{i,1}) \quad (2)$$




图 3 一维堆叠卷积自编码

上式中,  $X_i = h_{i-1,2} (i = 1, 2, \dots, n)$ , 当  $i=1$  时,  $X_i = X$ .  $h_{i,1}, h_{i,2}$  分别表示为第  $i$  个编码器中卷积后的数据和池化后的数据,  $h_{i,2}$  也是第  $i$  个编码器输出的特征;  $\otimes$  表示卷积;  $W$  为卷积核, 其大小为  $k_w \times 1$ , 数目为  $k_n$ ;  $b$  为偏置向量;  $s_f$  为激活函数;  $\text{pool}$  表示池化. 图中右边虚线框部分表示一次 CAE 的解码过程. 解码的具体过程如下:

$$\hat{h}_{i,1} = s_g(\hat{W}_{i,1} \otimes h_{i,2} + \hat{b}_{i,1}) \quad (3)$$



$$\hat{h}_{i,2} = \text{upsample}(\hat{h}_{i,1}) \quad (4)$$

$$\hat{X}_i = s_g(\hat{W}_{i,2} \otimes \hat{h}_{i,2} + \hat{b}_{i,2}) \quad (5)$$

上式中,  $\hat{X}_i$  为输入  $X_i$  的重构数据;  $\hat{b}_{i,1}$  和  $\hat{W}_{i,1}$  为第  $i$  个卷积自编码器解码过程中的第一个卷积的偏置和卷积核;  $\hat{b}_{i,2}$  和  $\hat{W}_{i,2}$  为第  $i$  个卷积自编码器解码过程中第二次卷积的偏置和卷积核, 其中  $\hat{W}_{i,2}$  卷积核的数量为 1, 因此最终重构出  $\hat{X}_i$  的大小与输入  $X_i$  一致; 上采样得到的特征为  $\hat{h}_{1,2}$ ;  $s_g$  是解码器中的激活函数, 与编码器中一致. 本文使用 ReLU 函数作为激活函数.

单层 CAE 模型的目标是最小化输入数据  $X_i$  与重构数据  $\hat{X}_i$  的误差, 其损失函数如下所示:

$$L_1(X_i, \hat{X}_i) = \left( \frac{1}{2M} \sum_{m=1}^M \|X_i^m - \hat{X}_i^m\|^2 \right) \quad (6)$$

其中,  $i$  表示堆叠卷积自编码器中第  $i$  个 CAE,  $M$  表示训练过程中输入样本的总数.

### 1.3 Softmax 分类器

Softmax 是一个基于概率的多类分类器<sup>[19]</sup>. 数据集  $\{(z_1, y_1), (z_2, y_2), \dots, (z_M, y_M)\}$  中共包含  $M$  个样本, 分为  $K$  个类别, 对于给定的输入样本  $z_m$ , Softmax 分类器会基于式 (7) 判断属于每一类别的概率, 输出一个分类标签  $y_m$ .

$$H_w(z_m) = \begin{bmatrix} p(o_m = 1|z_m; w) \\ p(o_m = 2|z_m; w) \\ \vdots \\ p(o_m = K|z_m; w) \end{bmatrix} = \frac{1}{\sum_{c=1}^K e^{w_c^T z_m}} \begin{bmatrix} e^{w_1^T z_m} \\ e^{w_2^T z_m} \\ \vdots \\ e^{w_K^T z_m} \end{bmatrix} \quad (7)$$

其中,  $o_m$  是输入  $z_m$  的输出类别;  $w = [w_1, w_2, \dots, w_K]^T$  是

模型的参数, 需要通过训练数据来优化;  $\frac{1}{\sum_{c=1}^K e^{w_c^T z_m}}$  对概率分布进行归一化, 使得所有类别的概率和为 1.

### 1.4 预训练和微调算法

用于二分类的一维 SCAE 和 Softmax 中的卷积核的权重和自由参数都是需要调整的. 本文采用预训练和微调来调整其参数. 预训练分为两个阶段, 第一个阶段是对堆叠自编码器中的 3 个 CAE 单独训练, 训练目标是最小化公式 (6) 中的损失函数. 第二阶段是将训练好的 3 个单层 CAE 以图 3 方式堆叠起来, 再对 Softmax 进行预训练. 通过最小化交叉熵函数  $L_2$  对其优化.

$$L_2(w) = -\frac{1}{M} \sum_{m=1}^M \sum_{j=1}^K \left( 1(y_m = j) \log \left( \frac{e^{w_j^T z_m}}{\sum_{k=1}^K e^{w_k^T z_m}} \right) \right) \quad (8)$$

其中,  $M$  表示数据集中共包含  $M$  个样本,  $K$  表示类别,  $z_m$  为一维 SCAE 输出的第  $m$  个子序列的特征,  $w = [w_1, w_2, \dots, w_K]^T$  为 Softmax 回归模型的自由参数. 在预训练之后, 对整个模型进行微调, 以重新优化 SCAE 中所有编码器以及 Softmax 分类器的自由参数. 本文中微调是将一维 SCAE 中各 CAE 编码器和 Softmax 作为一个整体去微调它们的自由参数. 通过最小化交叉熵函数  $L_3$  对其优化.

$$L_3(\Theta) = -\frac{1}{M} \sum_{m=1}^M \sum_{j=1}^K (1(y_i = j) \log(H(X^m; \Theta))) \quad (9)$$

整个模型为  $o_i = H(X^m; \Theta)$ ,  $\Theta$  为模型中所有需要训练的的参数,  $X^m$  为输入的第  $m$  个子序列.

## 2 实验

### 2.1 实验数据

本文中使用的数据由实验室搭建试验台采集, 实验台由工字梁、分布式光纤应变传感器和光纳仪组成, 如图 4 所示.




图 4 实验台布局示意图

工字梁钢结构由三段长度分别为 4.575 m、5.85 m 和 4.575 m 的工字钢拼接而成, 两个拼接接头处有张口宽度可调的人造裂缝, 通过在工字钢结构两端施加配重, 微小裂缝的裂缝张口宽度 (COD) 会相应的从 0 逐渐增加. 分布式光纤传感器一去一回平行地粘附在钢结构上表面, 由此每个裂缝被独立感测两次, 分布式应变数据呈现 4 个裂缝损伤.

本文中的分布式应变测量分为 2 个组, 设置为两个不同的空间分辨率 (SR), 分别为 10 cm 和 20 cm. 其中两个分组中又各分为 5 个 case, 一共 10 个 case, 每个 case 中独立测量 20 次, 具体测得的裂缝张口宽度见表 1.

表1 钢梁应变测量的10种情况

SR (cm)	case	裂缝张口宽度 (μm)	
		Crack A	Crack B
10	1	0.0	0.0
	3	23	57
	5	32	119
	7	52	218
	9	69	304
20	2	0.0	0.0
	4	23	57
	6	32	119
	8	52	218
	10	69	304

### 2.2 数据预处理

首先采用 1.1 节中 z-score 标准化方法对采集的数据进行标准化, 标准化后如图 5 所示, 图 5(a) 是分布式应变序列 case3, case5, case7 独立测量 20 条数据中的其中 1 条, 图 5(b) 是对 3 条应变序列标准化后的序列数据。




图5 标准化的分布式应变序列

使用 1.1 节中样本扩增的方法对数据样本进行扩增, 经过数据样本扩增之后, 一共得到 108 400 个子序列样本, 其中正样本子序列有 5120 个, 负样本子序列

有 103 280 个. 把扩增后子序列取 40% 作为训练集, 20% 作为验证集, 40% 作为测试集, 用于本文模型的训练、验证与测试。

### 2.3 模型参数设置

在模型中主要的参数设置如表 2 所示, 主要包括卷积自编码器中每个卷积层中的卷积核大小、卷积核数量以及步长. 池化层中池化窗口大小以及步长。

表2 模型参数设置

类型	输入尺寸	核/窗口大小	卷积核数量	步长	输出尺寸
卷积层_1	(24×1)×1	3×1	64	1	(24×1)×64
池化层_1	(24×1)×64	2×1	/	2	(12×1)×64
卷积层_2	(12×1)×64	3×1	128	1	(12×1)×128
池化层_2	(12×1)×128	2×1	/	2	(6×1)×128
卷积层_3	(6×1)×128	3×1	256	1	(6×1)×256
池化层_3	(6×1)×256	2×1	/	2	(3×1)×256
Flatten	(3×1)×256	/	/	/	768×1
SoftMax	768×1	/	/	/	2×1

(1) 输入为 24×1 的一维分布式应变子序列;

(2) 网络共有 3 个卷积层, 其卷积核数目为分别为 64、128 和 256, 卷积核大小均为 3×1, 卷积层中, 步长为 1, 同时两侧进行大小为 1 的零填充, 因此每层卷积后的尺寸与输入尺寸相同;

(3) 网络共有 3 个池化层, 每层使用平均池化, 池化窗口大小均为 2×1. 池化层中, 步长为 2, 因此每次池化后输出尺寸是输入尺寸的 1/2;

(4) 卷积后的特征要经过 Flatten 过程, 将得到的多特征图“压平”为一个一维序列. 将其输入 Softmax 分类器分类。

### 2.4 模拟钢梁实验结果及分析

预训练和微调两个过程都是通过最小化损失函数来得到最优自由参数. 预训练过程是单独调整各个 CAE 以及 Softmax 的自由参数. 微调是把 SCAE 中各 CAE 编码器和 Softmax 作为一个整体去调整自由参数. 自由参数调整的准确性体现在迭代过程中, 损失不断降低, 趋于收敛时得到的自由参数是最优的. 图 6 是微调过程中, 训练集 (train) 和验证集 (val) 的损失变化曲线, 实线表示训练集的损失变化曲线, 虚线表示验证集损失变化曲线. 本文设置的微调迭代次数为 400 次, 从图中可以看出, 迭代 240 次后, 训练集和验证集的损失已经慢慢趋于稳定, 运用了早停法 (early stopping) 策略实际迭代 288 次, 保留迭代 288 次后的参数作为最优模型参数. 早停法是验证集在训练好的模型的表

现, 当验证集连续迭代几次后, 损失增大, 停止训练, 这样就能避免继续训练导致过拟合的问题。

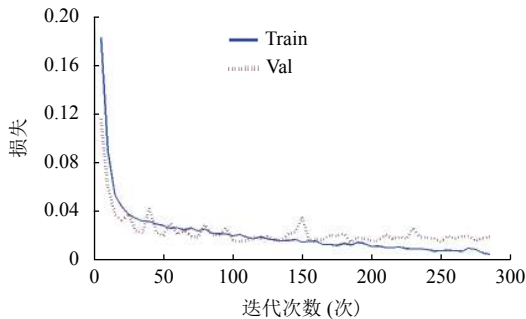


图6 微调损失变化

t-SNE 算法是一种典型的降维和数据可视化的方法<sup>[20,21]</sup>。为了直观的看出一维堆叠自编码器模型参数调整的准确性以及在训练好的模型中所提取特征的可分辨性。本文使用 t-SNE 算法将输出特征可视化到二维空间, 图7是 t-SNE 可视化图, 图中\*是正样本, o是负样本, 图7(a)是对原始输入样本数据可视化, 可以看出, 正负样本混合在一起; 图7(b)是对一维堆叠卷积自编码器第3个 CAE 输出特征的可视化, 可以看出, 经过深层网络训练后, 正负样本的特征可辨识分离度变得明显。因此, 所提出的基于 SCAE 的模型具有提取可识别特征的能力。

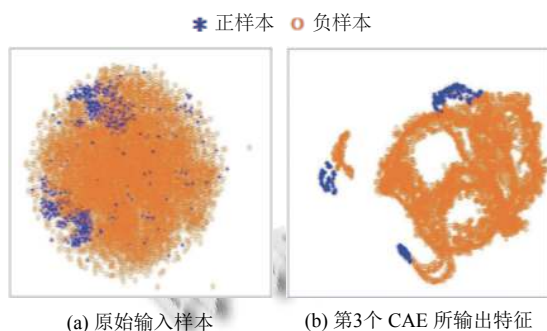


图7 t-SNE 可视化图

将测试集送入训练好的模型中进行分类检测。为了说明本文方法相较于全连接网络的优势和预训练对检测结果的影响。将本文方法与堆叠自编码器 (SAE) 和卷积神经网络 (CNN) 的检测结果进行了比较, 其比较结果如表3所示, 本文 CNN 的结构与 SCAE 的结构相同, 但在其训练过程中, 没有进行预训练的阶段只有对整体进行了微调。SAE 是由3个 AE 堆叠起来, 在训

练过程中, 对每一层 AE 进行预训练, 预训练的过程分为两个阶段, 第一个阶段是对每一层的 AE 独立训练, 优化参数。第二个阶段对3个一维 AE 逐一训练后将 AE 堆叠起来, 并利用堆叠后隐藏层输出的特征对 Softmax 进行预训练。最后对整体进行微调。表中两种方法所使用的训练集、验证集以及测试集相同。

表3 不同深度学习方法比较

方法	Error	FN	FP	Acc (%)
本文方法	162	22	140	99.62
SAE	667	256	411	98.46
CNN	598	189	409	98.62

表3中 FN 为假阴性, 表示裂缝子序列被检测为非裂缝, FP 为假阳性, 表示为非裂缝子序列被检测为裂缝, FP 与 FN 出现的总和记为 Error。Acc 为准确率, 表示预测正确的样本的占总样本数的比重。从表中可以看出本文方法准确率最高。

本文方法用于微小裂缝检测, 因此假阴性 (FN) 很重要。从表中可以看出有22个裂缝子序列误检为非裂缝, 将分类后的结果定位到光纤应变序列。当 SR=10 cm 时有16个检错的子序列出现的 case3 的第二和第三个裂缝部分, 有3个检错的子序列出现在 case3 的第四个裂缝上, 有3个检错的子序列出现在 case5 的第二个裂缝上。其他的 case 中, 所有的裂缝子序列都被正确的检测。当 SR=20 cm 时, 所有的裂缝都被正确的检测。结果表明, 本文方法能够有效的检测微裂缝, 但性能受空间分辨率的影响。

### 3 总结

本文针对具有人为裂缝工字钢梁表面上的分布式应变, 提出了一种基于一维堆叠自编码器的微小裂缝检测方法。该方法将裂缝检测当作一种二分类问题。通过逐层堆叠3个 CAE 来构建深度 SCAE 模型, 利用该模型从分段的应变子序列中自动提取高质量判别性高的特征表征。将 Softmax 附加至最后一个 CAE 后, 以特征表征作为输入, 对原始输入应变子序列做出分类决策。实验结果验证了本文方法的有效性, 其检测性能受空间分辨率的影响, 当 SR 为 20 cm 时, 可以准确检测出 23  $\mu\text{m}$  及以上的微小裂缝, 取得好的检测效果。但当 SR=10 cm 时, 因为数据信噪比较低, 对 COD 为 23  $\mu\text{m}$  的微小裂缝无法完全检测。因此在未来的工作中探索如何消除空间分辨率对裂缝检测的影响是必要的。



## 参考文献

- 1 Yao Y, Tung STE, Glisic B. Crack detection and characterization techniques-An overview. *Structural Control and Health Monitoring*, 2014, 21(12): 1387–1413. [doi: [10.1002/stc.1655](https://doi.org/10.1002/stc.1655)]
- 2 Das S, Saha P. A review of some advanced sensors used for health diagnosis of civil engineering structures. *Measurement*, 2018, 129: 68–90. [doi: [10.1016/j.measurement.2018.07.008](https://doi.org/10.1016/j.measurement.2018.07.008)]
- 3 Xu DS, Dong LJ, Borana L, *et al.* Early-warning system with quasi-distributed fiber optic sensor networks and cloud computing for soil slopes. *IEEE Access*, 2017, 5: 25437–25444. [doi: [10.1109/ACCESS.2017.2771494](https://doi.org/10.1109/ACCESS.2017.2771494)]
- 4 Zornoza A, Sagues M, Loayssa A. Self-heterodyne detection for SNR improvement and distributed phase-shift measurements in BOTDA. *Journal of Lightwave Technology*, 2012, 30(8): 1066–1072. [doi: [10.1109/JLT.2011.2168808](https://doi.org/10.1109/JLT.2011.2168808)]
- 5 叶家宇, 张顺健, 黄剑. 基于概率分布的异常数据发现与识别算法. *计算机应用与软件*, 2012, 29(11): 139–140.
- 6 Liu S, Yamada M, Collier N, *et al.* Change-point detection in time-series data by relative density-ratio estimation. *Neural Networks*, 2013, 43: 72–83. [doi: [10.1016/j.neunet.2013.01.012](https://doi.org/10.1016/j.neunet.2013.01.012)]
- 7 曹科研, 栾方军, 孙焕良, 等. 不确定数据基于密度的局部异常点检测. *计算机学报*, 2017, 40(10): 2231–2244. [doi: [10.11897/SP.J.1016.2017.02231](https://doi.org/10.11897/SP.J.1016.2017.02231)]
- 8 孙梅玉. 基于距离和密度的时间序列异常检测方法研究. *计算机工程与应用*, 2012, 48(20): 11–17, 22. [doi: [10.3778/j.issn.1002-8331.2012.20.003](https://doi.org/10.3778/j.issn.1002-8331.2012.20.003)]
- 9 陈波. 基于协同学习的时间序列异常检测研究[硕士学位论文]. 北京: 中国矿业大学, 2018.
- 10 Makarenko AV. Deep learning algorithms for signal recognition in long perimeter monitoring distributed fiber optic sensors. *Proceedings of the 2016 IEEE 26th International Workshop on Machine Learning for Signal Processing*. Vietri sul Mare, Italy. 2016. 1–6. [doi: [10.1109/MLSP.2016.7738863](https://doi.org/10.1109/MLSP.2016.7738863)]
- 11 蔡瑞初, 谢伟浩, 郝志峰, 等. 基于多尺度时间递归神经网络的人群异常检测. *软件学报*, 2015, 26(11): 2884–2896. [doi: [10.13328/j.cnki.jos.004893](https://doi.org/10.13328/j.cnki.jos.004893)]
- 12 韩敏. *神经网络基础*. 大连: 大连理工大学出版社, 2014.
- 13 崔广新, 李殿奎. 基于自编码算法的深度学习的综述. *计算机系统应用*, 2018, 27(9): 47–51. [doi: [10.15888/j.cnki.csa.006542](https://doi.org/10.15888/j.cnki.csa.006542)]
- 14 Hinton GE, Osindero S, Teh YW. A fast learning algorithm for deep belief nets. *Neural Computation*, 2006, 18(7): 1527–1554. [doi: [10.1162/neco.2006.18.7.1527](https://doi.org/10.1162/neco.2006.18.7.1527)]
- 15 Lopes AT, de Aguiar E, de Souza AF, *et al.* Facial expression recognition with convolutional neural networks: Coping with few data and the training sample order. *Pattern Recognition*, 2017, 61: 610–628. [doi: [10.1016/j.patcog.2016.07.026](https://doi.org/10.1016/j.patcog.2016.07.026)]
- 16 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述. *计算机学报*, 2017, 40(6): 1229–1251. [doi: [10.11897/SP.J.1016.2017.01229](https://doi.org/10.11897/SP.J.1016.2017.01229)]
- 17 Tang YJ, Xu JF, Matsumoto K, *et al.* Sequence-to-sequence model with attention for time series classification. *Proceedings of the 2016 IEEE 16th International Conference on Data Mining Workshops*. Barcelona, Spain. 2016. 503–510. [doi: [10.1109/ICDMW.2016.0078](https://doi.org/10.1109/ICDMW.2016.0078)]
- 18 Zheng Y, Liu Q, Chen EH, *et al.* Exploiting multi-channels deep convolutional neural networks for multivariate time series classification. *Frontiers of Computer Science*, 2016, 10(1): 96–112. [doi: [10.1007/s11704-015-4478-2](https://doi.org/10.1007/s11704-015-4478-2)]
- 19 张彦, 彭华. 基于深度自编码器的单样本人脸识别. *模式识别与人工智能*, 2017, 30(4): 343–352. [doi: [10.16451/j.cnki.issn1003-6059.201704006](https://doi.org/10.16451/j.cnki.issn1003-6059.201704006)]
- 20 徐森, 花小朋, 徐静, 等. 一种基于 T-分布随机近邻嵌入的聚类集成方法. *电子与信息学报*, 2018, 40(6): 1316–1322. [doi: [10.11999/JEIT170937](https://doi.org/10.11999/JEIT170937)]
- 21 van der Maaten L. Accelerating t-SNE using tree-based algorithms. *The Journal of Machine Learning Research*, 2014, 15(1): 3221–3245.