

文国军,高晓峰,毛宇,等.基于GRU-CNN网络的隧道裂缝实时检测算法[J].地质科技通报,2023,42(6):249-256.
Wen Guojun,Gao Xiaofeng,Mao Yu,et al.Real-time detection algorithm of tunnel cracks based on GRU-CNN[J].Bulletin of Geological Science and Technology,2023,42(6):249-256.

基于GRU-CNN网络的隧道裂缝实时检测算法

文国军,高晓峰,毛宇,程斯一

(中国地质大学(武汉)机械与电子信息学院,武汉 430074)

摘要:隧道裂缝严重损害隧道的使用寿命以及行车安全,而传统人工检测方法无法对长隧道中的大量裂缝进行高效精确识别。提出了一种隧道表面裂缝实时检测算法,该方法创新性地将用于文本学习、信号分析的门控循环单元(GRU)模型应用于图像分类中,用于提升隧道裂缝检测速度并保证检测精度。为提高训练效率,首先对裂缝进行预处理将其转换至频域中提取隧道裂缝的关键信息并矩阵重构为一维向量,再利用一维卷积神经网络提取一维向量的深度特征并输入循环神经网络学习深度特征中的序列依存关系,最终实现对隧道裂缝的检测。测试结果表明该模型不仅能降低模型训练参数量和硬件配置需求,同时该模型在精度上能达到99.0%,检测单张图片速度能达到2.1s,相较于主流的分类检测模型其准确率保持不变,训练时间和预测速度显著提升。最后针对大尺寸隧道裂缝图像开发了检测框架,可实现对大尺寸图像中裂缝信息的有效提取。

关键词:隧道裂缝;实时检测;分类检测;频域处理

2022-03-25 收稿;2022-07-02 修回;2022-07-07 接受

中图分类号:U456;TP391.41

文章编号:2096-8523(2023)06-0249-08

doi:10.19509/j.cnki.dzkg.tb20220129

开放科学(资源服务)标识码(OSID):



Real-time detection algorithm of tunnel cracks based on GRU-CNN

Wen Guojun, Gao Xiaofeng, Mao Yu, Cheng Siyi

(School of Mechanical Engineering and Electronic Information,
China University of Geosciences(Wuhan), Wuhan 430074, China)

Abstract: [Objective] Tunnel cracks seriously damage the corresponding life time and traffic safety. However, traditional manual detections cannot efficiently and accurately identify a large number of cracks in long tunnels. This paper proposes a real-time detection algorithm for tunnel surface cracks. [Methods] It innovatively applies the Gate Recurrent Unit (GRU) model for text learning and signal analysis to image classification, improving detection speed and ensuring detection accuracy of tunnel cracks. To enhance training efficiency, the cracks are preprocessed and converted into the frequency domain to extract the key information of tunnel cracks, and the matrix is reconstructed into one-dimensional vectors. Then, one-dimensional convolutional neural network is used to extract the vector depth feature, and recurrent neural networks can learn corresponding sequential dependencies to realize tunnel cracks detection. [Results] Test results show that this model can reduce the number of training parameters and hardware configuration requirements. At the same time, the detection accuracy can reach 98.8%, and the detection speed for single image can reach in 2.1 s. Comparing with the mainstream classification detection algorithms, its accuracy

基金项目:国家自然科学基金项目(41972325;52205611);湖北省重点研发计划(2020BAB054)

作者简介:文国军(1978—),男,教授,主要从事机器视觉、智能定向钻进的研究与教学工作。E-mail:wenguojun@cug.edu.cn

通信作者:程斯一(1988—),男,副教授,主要从事智能检测、工程机械设计的研究与教学工作。E-mail:chengsiyi@cug.edu.cn

© Editorial Office of Bulletin of Geological Science and Technology. This is an open access article under the CC BY-NC-ND license.

remains unchanged, with significantly improvements of both training efficiency and prediction rate respectively. [Conclusion] Finally, a detection framework is developed for large-scale tunnel cracks to extract corresponding crack information effectively.

Key words: tunnel crack; real-time detection; classification detection; frequency domain

Received: 2022-03-25; Revised: 2022-07-02; Accepted: 2022-07-07

隧道裂缝作为最为常见的隧道病害,不仅表现形式多样,同时也是其他病害的早期表现形式。裂缝的存在可直接导致隧道结构失稳进而发生坍塌,同时也对运营安全造成极大威胁,故及时发现并修复隧道裂缝对交通安全运营有重要意义^[1-2]。传统人工检测方法往往存在效率低下和人力物力浪费等问题,而自动化检测能大幅节省人力物力,裂缝自动化检测一般通过隧道巡检小车结合机器视觉算法,对视频拍摄的裂缝进行动态识别。由于隧道长且环境复杂(光照低、灰尘大等),为提升裂缝检测的精度和实时性,需进一步优化裂缝检测算法。

近年来,研究人员针对隧道裂缝检测开发了基于不同原理的机器视觉算法,其中裂缝检测早期以图像处理算法为主,例如阈值分割法^[3-4]、边缘检测法^[5-6]和区域生长法^[7-8]等。但是该类方法往往受到光照、遮挡、表面不均等环境因素影响,同时算法的算子和参数往往只针对某些特定场景,一旦场景发生变化即需要重新设计,存在普适性差、检测效率低等不足。与图像处理方法相比,深度学习具有覆盖范围广、适应性强、可移植性强等优点,在隧道裂缝分类识别中极具应用前景^[9]。目前,在面向裂缝检测的应用中,语义分割和目标检测是深度学习算法的研究热点。Faster R-CNN 目标算法被广泛应用于裂缝检测,众多学者基于 Faster R-CNN 算法引入图像前处理或新的特征提取模块来提升检测精度,却忽略了检测效率^[10-12]。为进一步优化裂缝检测效果,改进的语义分割模型(SegNet、Mask R-CNN 等)被大量提出,实现裂缝在像素级别上的提取,提高了裂缝提取完整度以及对裂缝的量化^[13-15],追求高精度而放弃了检测效率。单一网络无法对多尺度缺陷特征进行有效提取,通过改进模型损失函数^[15]或者增强模型局部感受视野^[16]可实现对裂缝信息多尺度提取,提升模型检测小尺寸裂缝能力。但现有基于深度学习的隧道裂缝检测方法主要缺点为计算强度大和训练时间长。其不仅影响这些方法在实践中的实用性,也阻碍实时状态评估系统的开发^[17]。

此外,裂缝检测一般在空间域中进行,而将空间域中的裂缝转换到频域中进行高频信息提取和学习,已被证明可有效提升训练效率和预测速度,为高性能裂缝检测提供了新的思路。Zhao 等^[18]通过小

波变换—注意力机制模块处理频域中的高频信息,后续结合 MobileNetV2 骨架实现了图像的有效分类。Watanabe 等^[19]提出了一种新颖的频域 ReLU 层——2SReLU 层,解决了频域图像的分类问题。Brosch 等^[20]提出了在频域中高效训练解决卷积的计算耗时,并运用于高分辨率图像。

卷积神经网络(CNN)的全连接层被广泛用于提取特征与调整权重,但其对高级信息的提取能力有限。在文本信息^[21-22]和传感器信号^[23-24]等长序列数据信息提取中,门控循环单元(GRU)已表现出计算复杂度低、避免梯度消失和关联性获取能力强等优势。因此,通过 GRU 优化 CNN 的输出结果并输入全连接层,有助于 CNN 对高级信息的提取,增强其对裂缝特征的学习能力,这可为 CNN 在裂缝检测中的性能提升提供新思路,然而,相关研究仍然较少,有待进一步探索。

综合以上分析,本研究提出一种基于 GRU-CNN 融合网络模型,用于隧道裂缝的实时检测。本方法通过将隧道裂缝图片转换到频域中来保证对裂缝边缘信息的提取能力,并提升模型的训练效率和预测速度。同时将用于文本信息、信号处理的 GRU 应用于 CNN 中,其通过对卷积提取的裂缝深层信息再提取得到更多特征信息来保证模型训练精度能符合实际需求,并减少计算时间。同时对该系统的实时裂缝检测效率并进行测试验证其在隧道裂缝检测中的效果。

1 隧道裂缝检测网络模型

1.1 检测流程框架

图 1 显示了隧道裂缝实时检测方法的流程。如图 1 所示,第一步是建立一个数据库,其中包括数千张含有裂缝或无裂缝的隧道表面图像。然后将数据库分为训练集、验证集和测试集。训练和验证数据集在预处理阶段通过快速傅里叶变换(FFT)转换到频域中。通过高通滤波器(HPF)来滤除与背景相对应的低频。滤波后展平矢量频率信号,将向量训练提出的 GRU-CNN 算法,引入滑动窗口测试实际图像。

1.2 原始图像频域预处理

图像处理可在空间域和频域中进行,其中空间

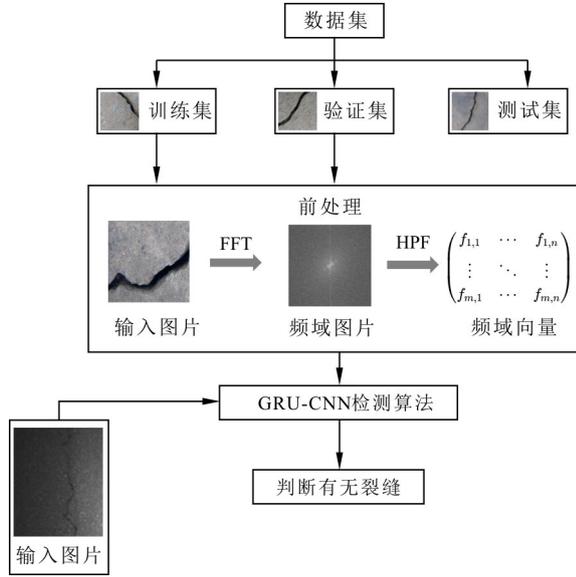


图 1 GRU-CNN 模型检测流程

Fig. 1 Testing process of GRU-CNN model

域中的图像处理主要是基于像素值的大小，而频域则是基于图像像素值的变化率。图像转换到频域可以显著加快神经网络的训练速度，并且降低训练成本和检测成本；而使用原始图像输入网络训练，如同在空间域中进行二维卷积的工作，并不是获取隧道裂缝数据信息的有效解决方案。在频域中，由于图像的频率取决于像素值的变化率，因此当隧道裂缝图像从空间域转换至频域后，裂缝信息主要包括 2 个部分：裂缝边缘像素值快速变化的高频分量和图片背景中变化率较低的低频分量。利用神经网络模型对频域中的高频信息和低频信息进行学习，可判断出图片中是否含有裂缝，因此本研究中隧道裂缝图片的预处理选择在频域中进行。

预处理流程图如图 2 所示，隧道裂缝原始图像经灰度化后进行频域处理，再通过矩阵重构获得裂缝信息的一维向量。其中频域处理包括傅里叶变换、信息转换和高通滤波。

其中傅里叶变换将 1 组足够大的裂缝样本保存处理，用于充分描述空间域中的裂缝图像。傅里叶变换得到的频率数量分别对应于空间域图像中的像素数量，因此空间域和频域中的图像大小相同。对

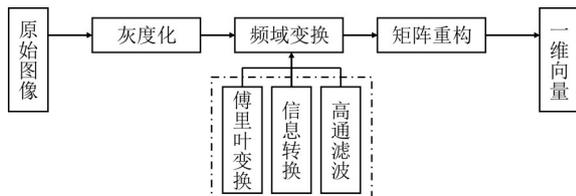


图 2 隧道裂缝预处理流程图

Fig. 2 Preprocessing flow diagram

于尺寸为 $M \times N$ 的裂缝图像，其二维一离散傅里叶变换(2D-DFT)可表示为：

$$F(k, l) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \exp \left[-i 2\pi \left(\frac{kx}{M} + \frac{ly}{N} \right) \right] \quad (1)$$

式中： (x, y) 为图像空间域中的像素位置； (k, l) 为图像频域中的位置信息； $f(x, y)$ 为图像像素在空间域的信息； $\exp[-i 2\pi(kx/M + ly/N)]$ 为将空间域的每个值转换到频域中的对应值。

但对于大尺寸的图像，离散傅里叶变换存在运算量大、时间长等问题，而快速傅里叶变换(FFT)往往能降低维数的复杂性并减少计算时间。FFT 处理会产生复值，包括实部和虚部或者幅值和相位。而在图像处理过程中，往往只会显示幅值，主要因为它包含了空间域大部分的几何结构信息。其中幅值 $|F(k, l)|$ 和相位 $\varphi(k, l)$ 可表示如下：

$$|F(k, l)| = \sqrt{R(k, l)^2 + I(k, l)^2} \quad (2)$$

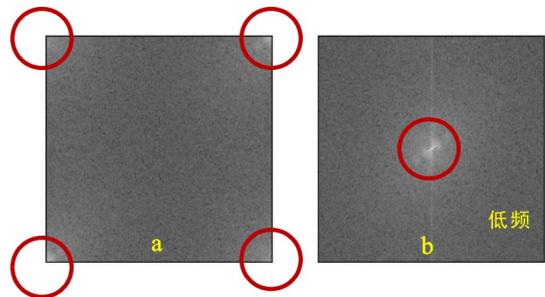
$$\varphi(k, l) = \tan^{-1} \left[\frac{I(k, l)}{R(k, l)} \right] \quad (3)$$

式中： $I(k, l)$ 为快速傅里叶变换后值的虚部； $R(k, l)$ 为快速傅里叶变换后值的实部。

如图 3 所示，快速傅里叶变换得到的频域图中高频信息往往位于矩阵的正中心，低频信息则位于矩阵的 4 个角上，不便于图像处理和展示，故需要对其进行频域转换，使高频信息转换至 4 个角，低频信息位于矩阵中心，便于后期通过频域滤波对频域信息进行处理。

通过对频域信息可视化发现有裂缝图像和无裂缝图像在频域中的分布差异显著。如图 3 所示，对于含有裂缝的图像，频域图具有线形火花，但是对于没有裂缝的图像，频域图则不具有此类线形火花。

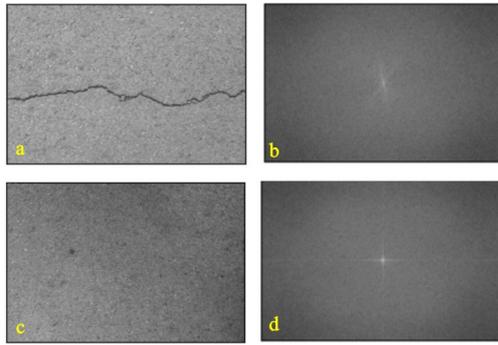
完成隧道裂缝图像频域转换后需要对频域进行滤波处理，突出裂缝边缘信息，便于后期模型学习裂缝特征信息。由图 4 可见，裂缝图像和无裂缝图像的主要区别在于高频域信息部分。其中可通过使用



a. 转换前频域图；b. 转换后频域图

图 3 2D 图像频域信息转换

Fig. 3 2D image frequency domain transformation



a. 裂缝图; b. 裂缝频域线图; c. 无裂缝图; d. 无裂缝频域线图
图 4 有裂缝频域图对比

Fig. 4 Comparison of frequency domain diagram with and without cracks

高通滤波器 (HPF) 消除与平滑背景区域相对应的低频, 保留裂缝边缘的高频信息。主要采用二维理想高通滤波器对频域图进行处理。

二维理想高通滤波器的传递函数如下:

$$H(u, v) = \begin{cases} 1, & D(u, v) > D_0 \\ 0, & D(u, v) \leq D_0 \end{cases} \quad (4)$$

式中: 阶段频率 D_0 是一个非负整数; $D(u, v)$ 是从点 (u, v) 到频率平面原点的距离, 即 $D(u, v) = \sqrt{u^2 + v^2}$ 。

理想高通滤波器的含义是指大于 D_0 的频率, 即以 D_0 为半径的圆外的所有频率分量可以完全无损地通过, 而圆内的频率, 即小于 D_0 的频率分量则完全被除掉。经过对阶段频率的测试以获得最佳参数, 最终选择 7 作为频率滤波器的截止频率。经过高通滤波器后的裂缝图像结果如图 5 所示, 裂缝信息与背景信息对比更鲜明。

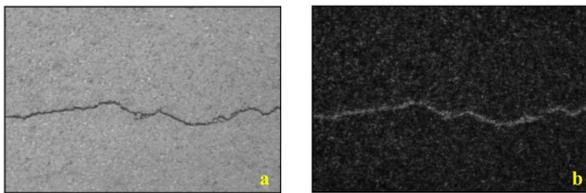


图 5 高通滤波器前(a)、后(b)裂缝图片对比

Fig. 5 Comparison of cracks images before (a) and after (b) high-pass filter

高通滤波后, 对每个图像的频率-振幅矩阵进行计算, 并将其展平为频率-振幅向量, 对预处理后的图像数据进行形状 (图像数 \times 展平频率向量长度 $\times 1$) 的矩阵重构。最后将变形得到的一维向量输入卷积神经网络中。

1.3 模型构建和原理

1.3.1 GRU 原理和结构

GRU^[25] (gate recurrent unit) 是循环神经网络

的一种, 同 LSTM (long-short term memory) 类似, 都是为了解决长期记忆和反向传播中的梯度问题。GRU 结构与 RNN (recurrent neural network) 相似, 内部思想则借鉴了 LSTM 的“门控”思想, 但 GRU 内部比 LSTM 少一个“门控”, 参数比 LSTM 少, 最终效果与 LSTM 类似。GRU 相对于 LSTM 更容易进行训练, 在很大程度上提高了模型的训练效率, 故本研究使用 GRU 对序列信息进行提取。

GRU 的结构如图 6 所示, 包括 2 个门状态, 分别为重置门控 r (reset gate) 和更新门控 z (update data)。重置门控的输入包括 2 个部分: 原始输入和上一节点状态。对于得到的门控信息首先使用重置门控重置得到数据, 然后通过 \tanh 激活函数将数据放缩至 $-1 \sim 1$ 范围, 最终得到输出, 其公式如下:

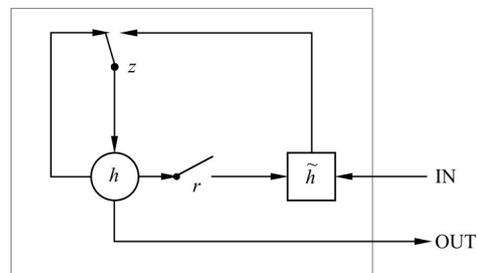
$$h' = \tanh(W_{h'}^{X'} \cdot h^{t-1}) \quad (5)$$

式中: h' 为当前状态; W 为层权重; X' 和 h^{t-1} 分别为上一个时间步的输入和输出。

更新门控主要包括遗忘和记忆 2 部分。重置门的功能主要为对原隐状态的信息删减并加入当前节点的部分信息, 其公式如下:

$$h^t = (1 - z) \odot h^{t-1} + z \odot h' \quad (6)$$

式中: $(1 - z) \odot h^{t-1}$ 为对原输入的隐状态选择性遗忘; $z \odot h'$ 为对当前节点信息的选择性记忆。



r . 重置门控; z . 更新门控; h . 隐层单元; \tilde{h} . 待更新隐层单元

图 6 GRU 工作机制

Fig. 6 Working mechanism of GRU

1.3.2 GRU-CNN 模型结构

CNN 主要对数据进行卷积和池化操作, 其中卷积层为 CNN 的核心, 通过局部连接和权值共享, 提取数据的深层特征; 池化层主要对卷积输出结果进行池化操作, 提取主要特征并减少参数数目和计算量, 防止过拟合。

本研究 GRU-CNN 架构是基于 Pytorch 模块开发, 通过将现有的一维文本神经网络以及简单的二维卷积模型进行对比, 综合测试之后得到的网络整体框架, 其组成为: 1 个输入层、5 组卷积层 (Layer 1 ~ 5)、1 个 GRU 层 (Layer 6)、6 个完全连接层和 1 个 Dropout 层 (Layer 7) 以及 1 个输出层 (表 1)。

表 1 GRU-CNN 模型框架及参数

Table 1 Framework and parameters of GRU-CNN

层类型	类型	输出形态	参数量
Layer 1	Conv1d-1	$[-1, 32, 4 \ 096]$	128
	BatchNorm1d-2	$[-1, 32, 4 \ 096]$	64
	ReLU-3	$[-1, 32, 4 \ 096]$	0
	MaxPool1d-4	$[-1, 32, 2 \ 047]$	0
Layer 2	Conv1d-5	$[-1, 64, 2 \ 047]$	6 208
	BatchNorm1d-6	$[-1, 64, 2 \ 047]$	128
	ReLU-7	$[-1, 64, 2 \ 047]$	0
	MaxPool1d-8	$[-1, 64, 1 \ 022]$	0
Layer 3	Conv1d-9	$[-1, 128, 1 \ 022]$	24 704
	BatchNorm1d-10	$[-1, 128, 1 \ 022]$	256
	ReLU-11	$[-1, 128, 1 \ 022]$	0
	MaxPool1d-12	$[-1, 128, 255]$	0
Layer 4	Conv1d-13	$[-1, 256, 255]$	98 560
	BatchNorm1d-14	$[-1, 256, 255]$	512
	ReLU-15	$[-1, 256, 255]$	0
	MaxPool1d-16	$[-1, 256, 63]$	0
Layer 5	Conv1d-17	$[-1, 256, 63]$	196 864
	BatchNorm1d-18	$[-1, 256, 63]$	512
	ReLU-19	$[-1, 256, 63]$	0
	MaxPool1d-20	$[-1, 256, 15]$	0
Layer 6	GRU-21	$[[-1, 256, 256], [4, -1, 256]]$	1 393 920
	Dropout-22	$[-1, 256]$	0
Layer 7	Linear-23	$[-1, 256]$	65 792
	ReLU-24	$[-1, 256]$	0
	Linear-26	$[-1, 2]$	514
总参数：张量			(1 788 162)

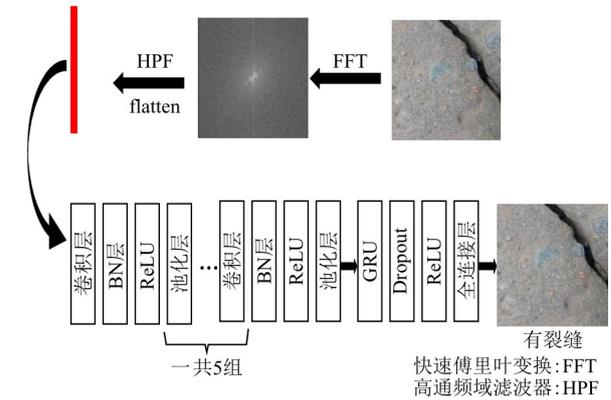
每 1 组卷积层首先需要使用一维卷积对其进行特征提取,再对其应用批归一化层(BN, batch normalization),并采用 ReLU 函数作为卷积层的激活函数,最后经过最大池化层处理后输入下一卷积层。模型经过 GRU 处理后,采用全连接层和 ReLU 激活函数,随之继续使用全连接层提取参数并输出。表 1 显示了设计的 GRU-CNN 模型框架及其具体参数。

本研究提出的基于 GRU-CNN 网络的隧道裂缝实时检测算法结构如图 7 所示,主要包括 2 个部分:频域预处理模块和 GRU-CNN 模型。其中频域预处理模块主要通过将二维裂缝图像转换至频域中来提取裂缝信息,并转换为一维向量输入神经网络;GRU-CNN 模型提取一维向量中的深度特征和序列信息,学习并识别裂缝信息。

2 实验与分析

2.1 实验数据与配置

实验环境由计算机软件环境搭建,硬件配置为:



ReLU. 激活函数;HPF. 高通滤波;FFT. 离散傅里叶变换

图 7 GRU-CNN 模型框架

Fig. 7 GRU-CNN framework

内存 16 G,CPU 型号为英特尔 Intel(R) Core(TM) i5-10400F CPU @ 2.90 GHz、GPU 为 NVIDIA RTX2060,编程语言 Python 3.7.7,编程框架 Pytorch 1.7.1,torchvision 0.8.2,编程软件 Anaconda 3。

模型是基于一个自制作数据集开发的,数据集的组成包括拍摄的隧道混凝土表面的裂缝图片以及网络下载数据集中的部分裂缝图片。由于裂缝图片尺寸不一,所有裂缝图片都被裁剪至 64×64 像素,然后再进行分类和筛选,最终得到的数据集一共包含有 8 312 张裂缝图片和 14 580 张无裂缝图片。

训练过程中,模型采用随机梯度下降作为优化器,训练最小批次为 32 张图像,并采用学习率递减的方式加快收敛速度。初始学习率设置为 0.01,随着模型的训练,每 5 个 epoch 后学习率乘以一个固定系数,此处固定系数设置为 0.9。模型中 GRU 后的 Dropout 层参数设置为 0.5。

2.2 评价指标

对于二分类问题,根据正类别和负类别计算准确率,并作为模型评价指标,其公式如下:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

式中:TP 为真正例;TN 为真负例;FP 为假正例;FN 为假负例。

其中各参数可用混淆矩阵进行表示,其具体如表 2 所示。

表 2 评价指标混淆矩阵表示

Table 2 Evaluation for confusion matrix representation

混淆矩阵		真实值	
		裂缝	无裂缝
预测值	裂缝	TP	FP
	无裂缝	FN	TN

2.3 实验结果与分析

人工采集的 22 892 张图像经过预处理后建立

数据库,其中裂缝图像与无裂缝图像的比例大致为 1:2,然后数据库被随机分为训练集、验证集和测试集,占比分别为 80%,10%,10%。将分类完成后的数据库导入模型中对模型进行训练,并实时计算模型的损失(loss)和准确率(accuracy),如图 8 所示。由图 8 可知,随着训练轮次的增加,模型的准确率波动式上升并趋于稳定,最高准确率可达 99.0%,同时模型的损失逐渐减小并趋于稳定说明模型训练已完成。训练完成后,将准确率最高的模型保存并作为最佳模型应用于后期的数据集测试和验证试验。

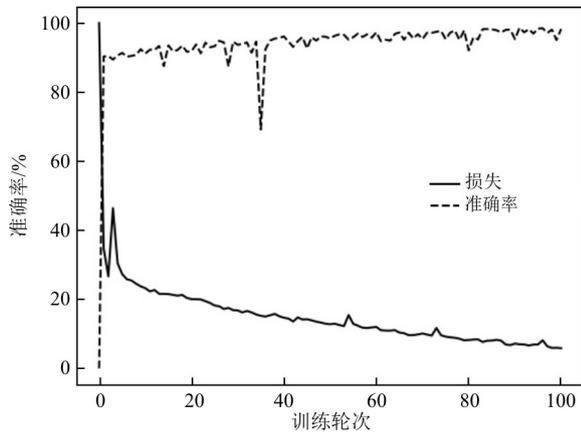


图 8 模型损失 loss 和准确率 accuracy 变化图

Fig. 8 Trends for both GRU-RNN loss and Accuracy

为进一步验证设计的最佳模型的准确率、训练效率、以及图片预测速率,将设计模型与主流分类模型进行对比实验,得到的结果如表 3 所示。

表 3 主流模型对比实验结果

Table 3 Comparison of experimental result of mainstream models

模型	准确率/%	训练时间/s	预测速度/(s · per ⁻¹)
VGG	99.1	29 596	3.94
GoogLeNet	99.5	11 580	2.65
ResNet	97.5	17 582	3.01
GRU-CNN	99.0	8 859	2.21

由表 3 可知,相较于传统的二维卷积神经网络,GRU-CNN 模型在不影响准确率的情况下,训练时间和预测速度显著提升,综合评价较高。

同时为了验证 GRU 的有效性和优越性,对其进行了消融实验和替换实验,即去除 GRU 仅保留一维神经网络和将 GRU 替换为 LSTM 的 2 组实验,并从准确率、训练时间、预测速度和参数量 4 方面展开对比,其对比结果如表 4 所示。

对比表 4 中 GRU-CNN 模型与 LSTM-CNN 模型,GRU-CNN 模型的准确率、训练时间、预测速度以及

表 4 循环神经网络消融和替换实验

Table 4 Ablation and replacement of recurrent neural networks

模型	准确率/%	训练时间/s	预测速度/(s · per ⁻¹)	参数量
1D-CNN	98.5	8 305	2.21	858 882
LSTM-CNN	98.7	10 711	2.34	2 252 802
GRU-CNN	99.0	8 859	2.21	1 788 162

参数量均优于 LSTM-CNN 模型。与 1D-CNN 模型对比,虽训练时间和参数量略有逊色,但参数量的成倍增加并没有带来训练时间的成倍提升,对训练时间影响较小,但 GRU-CNN 模型准确率更高。所以总体而言,GRU-CNN 模型比其他模型更有效,也更优越。

对比验证后,我们将 GRU-CNN 模型应用于大尺寸隧道裂缝图片的实时检测,具体检测流程如图 9 所示。大尺寸图像被划分成大小为 64 × 64 像素的小图像组,然后每个小图像组经过傅里叶变换转换到频域中,再通过相同比例的 HPF 进行滤波处理。随后,小图像组依次输入所建立的模型中,并依次被判定为裂缝图像或非裂缝图像,其中带有裂缝的小图像保留为输出,并恢复至其在大比例图像中的原始位置,同时对其进行颜色添加处理以使其更明显。所有其他无裂缝的小图像则添加相异的颜色来形成对比。

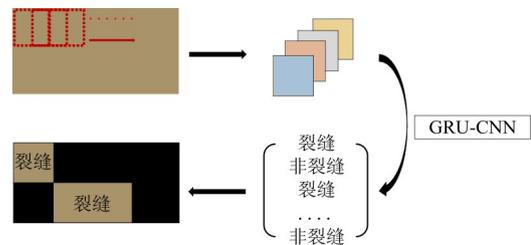


图 9 裂缝检测框架

Fig. 9 Crack detection framework

图 10 为训练的模型对现有隧道表面裂缝图片的检测结果。由图 10 可知,在模型的训练过程中,GRU-CNN 能快速收敛,迅速提高模型训练精度,并通过后期训练逐步提升整体精度。其中在小于 60 个 epoch(训练轮次)前发现模型对于裂缝检测的精度十分不稳定,主要为对于非裂缝图像的误判,但随着模型的继续训练,其在训练 100 个 epoch 后基本达到稳定且能更好地分类非裂缝图像,具有更好的检测结果。同时 GRU-CNN 能对大尺寸图中的裂缝具体位置进行精确提取并准确表达,并对单张图片的检测速度相较于主流模型提升了 17% 以上,可满足实际隧道裂缝的检测需求。

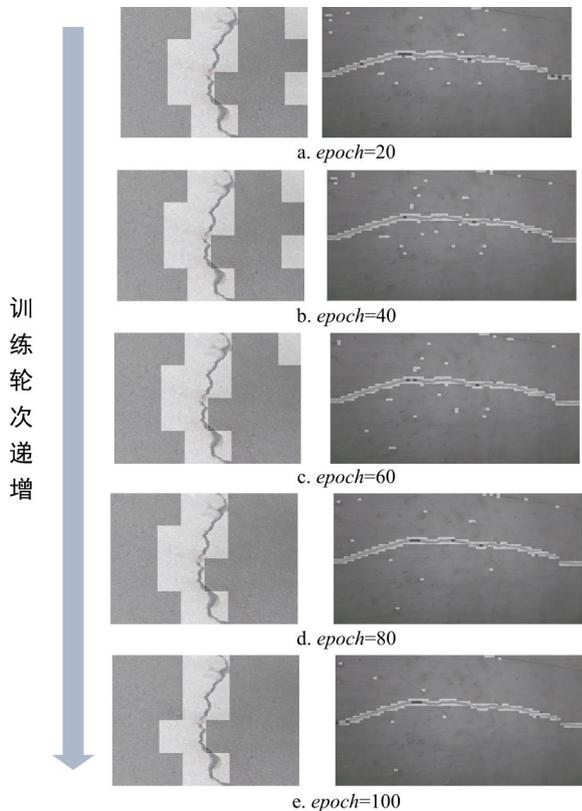


图10 训练不同阶段裂缝检测结果图(epoch代表训练轮次)
Fig. 10 Crack detection results under different epochs

3 结论与展望

(1)通过将裂缝图像转换到频域中,能有效提取隧道裂缝信息,并显著提高模型训练效率和训练速度,同时通过GRU对卷积层输出结果的序列信息学习,提升了模型的训练精度。其中速度到达每张2.21 s,准确率为99.0%。并通过消融实验证明了各个模块的有效性。

(2)GRU-CNN模型相较于主流的图片分类模型在准确率上与最优模型基本持平,但训练时间和预测速度均显著提升,综合评价较高。

(3)通过将大尺寸图片划分为小图像组,并依此用模型识别小图像组,可实现对大尺寸图像中裂缝具体位置的精确提取并实时显示。

现有算法验证主要基于实际场景下人工拍摄的隧道裂缝图片,与实际车载摄像拍摄的照片有一定的出入,后期将进行车载系统的研究,并进一步将相关算法与车载裂缝检测相结合。同时针对光线昏暗及图片不清晰等问题,后期可通过改善相机、光源等硬件设备,提升不同隧道环境下的适应性,并最终应用于实际的工程应用中。

(所有作者声明不存在利益冲突)

参考文献:

- [1] 王剑非,刘昆珏,周文皎,等. 香丽高速公路昌格洛滑坡—隧道工程病害三维数值分析[J]. 地质科技通报, 2022, 41(2): 34-43.
Wang J F, Liu K J, Zhou W J, et al. Three-dimensional numerical analysis of the Changgeluo landslide-tunnel engineering disaster on Shangri-La to Lijiang Highway[J]. Bulletin of Geological Science and Technology, 2022, 41(2): 34-43 (in Chinese with English abstract)
- [2] 李喜,殷坤龙,陈标典,等. 武汉白沙洲长江两岸岩溶塌陷易发性评价与地铁建设过程中的防治对策[J]. 地质科技通报, 2020, 39(6): 121-130.
Li X, Yin K L, Chen B D, et al. Evaluation of susceptibility to karst collapse on both sides of the Yangtze River in Baishazhou, Wuhan and preventive measures in the process of metro construction [J]. Bulletin of Geological Science and Technology, 2020, 39(6): 121-130 (in Chinese with English abstract)
- [3] Li P, Wang C, Li S M, et al. Research on crack detection method of airport runway based on twice-threshold segmentation [C]//Anon. International Conference on Instrumentation and Measurement, Computer, Communication and Control (IMCC). Qinhuaydao: IEEE, 2015: 1716-1720.
- [4] 杨心蕊,许辰扬,郑玉莹,等. 基于遗传算法的阈值分割桥梁裂缝检测算法研究[J]. 广东土木与建筑, 2021, 28(10): 5-9.
Yang X R, Xu C Y, Zheng Y Y, et al. Research on threshold segmentation algorithm of bridge crack detection based on genetic algorithm[J]. Guangdong Architecture Civil Engineering, 2021, 28(10): 5-9 (in Chinese with English abstract).
- [5] Wang W X, Wang M F, Li H X, et al. Pavement crack image acquisition methods and crack extraction algorithms: A review [J]. Journal of Traffic and Transportation Engineering: English Edition, 2019, 6(6): 535-556.
- [6] 赵芳,周旺辉,陈岳涛,等. 改进的Canny算子在裂缝检测中的应用[J]. 电子测量技术, 2018, 41(20): 107-111.
Zhao F, Zhou W H, Chen Y T, et al. Application of improved Canny operator in crack detection[J]. Electronic Measurement Technology, 2018, 41(20): 107-111 (in Chinese with English abstract).
- [7] 董安国,宋君,张仙艳,等. 基于图像的桥梁裂缝检测算法[J]. 自动化仪表, 2013, 34(8): 1-4.
Dong A G, Song J, Zhang X Y, et al. Image-based bridge crack detection algorithm[J]. Process Automation Instrumentation, 2013, 34(8): 1-4 (in Chinese with English abstract).
- [8] 武旭娟,郭骞,宋捷. 公路隧道衬砌裂缝检测方法研究[J]. 北方交通, 2017(2): 81-83.
Wu X J, Guo Q, Song J. Research on detection method of cracks in highway tunnel lining [J]. Northern Communications, 2017(2): 81-83 (in Chinese with English abstract).
- [9] 刘彦锋,张文彪,段太忠,等. 深度学习油气藏地质建模研究进展[J]. 地质科技通报, 2021, 40(4): 235-241.
Liu Y F, Zhang W B, Duan T Z, et al. Progress of deep learning in oil and gas reservoir geological modeling[J]. Bulletin of Geological Science and Technology, 2021, 40(4): 235-241 (in Chinese with English abstract)
- [10] Yang X, Wei S Y, Bao Y Q, et al. Automatic seismic damage identification of reinforced concrete columns from images by a region-based deep convolutional neural network[J]. Structural

- Control & Health Monitoring, 2019, 26(3): e2313.
- [11] Cha Y J, Choi W, Suh G, et al. Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(9): 731-747.
- [12] Protopapadakis E, Voulodimos A, Doulamis A, et al. Automatic crack detection for tunnel inspection using deep learning and heuristic image post-processing[J]. Applied Intelligence, 2019, 49(7): 2793-2806.
- [13] Ren Y P, Huang J S, Hong Z Y, et al. Image-based concrete crack detection in tunnels using deep fully convolutional networks[J]. Construction and Building Materials, 2020, 234: 117367.
- [14] Kim B, Cho S. Image-based concrete crack assessment using mask and region-based convolutional neural network [J]. Structural Control & Health Monitoring, 2019, 26(8): e2381.
- [15] Dong Y A, Wang J, Wang Z F, et al. A deep-learning-based multiple defect detection method for tunnel lining damages [J]. IEEE Access, 2019, 7: 182643-182657.
- [16] 常惠, 饶志强, 李益晨, 等. 基于改进残差网络的铁路隧道裂缝检测算法研究[J]. 东北师大学报: 自然科学版, 2021, 53(3): 56-63.
Chang H, Rao Z Q, Li Y C, et al. Research on crack detection algorithm of railway tunnel based on improved residual network[J]. Journal of Northeast Normal University: Natural Science Edition, 2021, 53(3): 56-63 (in Chinese with English abstract).
- [17] Zhang Q, Barri K, Babanajad S K, et al. Real-time detection of cracks on concrete bridge decks using deep learning in the Frequency Domain[J]. Engineering, 2021, 7(12): 1786-1796.
- [18] Zhao X Y, Huang P, Shu X B. Wavelet-attention CNN for image classification[J]. Multimedia Systems, 2022, 28(3): 915-924.
- [19] Watanabe T, Wolf D F. Image classification in frequency domain with 2SRReLU: A second harmonics superposition activation function[J]. Applied Soft Computing, 2021, 112: 107851.
- [20] Brosch T, Tam R. Efficient training of convolutional deep belief networks in the frequency domain for application to high-resolution 2D and 3D images[J]. Neural computation, 2015, 27(1): 211-227.
- [21] 庞庆华, 董显蔚, 周斌, 等. 基于情感分析与 TextRank 的负面在线评论关键词抽取[J]. 情报科学, 2022, 40(5): 111-117.
Pang Q H, Dong X W, Zhou B, et al. Keyword extraction of negative online reviews based on sentiment analysis[J]. Information Science, 2022, 40(5): 111-117 (in Chinese with English abstract).
- [22] 李冉冉, 刘大明, 刘正, 等. 融合笔画特征的胶囊网络文本分类[J]. 计算机工程, 2022, 48(3): 69-73, 80.
Li R R, Liu D M, Liu Z, et al. Text classification using capsule network integrating stroke features[J]. Computer Engineering, 2022, 48(3): 69-73, 80 (in Chinese with English abstract).
- [23] Zou J Z, Yang J X, Wang G P, et al. Bridge structural damage identification based on parallel CNN-GRU[J]. IOP Conference Series: Earth and Environmental Science, 2021, 626: 012017.
- [24] 王亚飞, 韩静, 郭凤, 等. 基于 Bi-LSTM 的结构变形预测[J]. 计算机系统应用, 2021, 30(11): 304-309.
Wang Y F, Han J, Guo H, et al. Prediction of structural deformation based on Bi-LSTM[J]. Computer Systems & Applications, 2021, 30(11): 304-309 (in Chinese with English abstract).
- [25] Cho K, Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. CoRR, 2014. doi: org/10. 48550/arXiv. 1406. 1078.

(上接第 248 页)

- [20] 郭婷婷. 矿区不同重构方式下土壤水文性质研究[D]. 太原: 山西大学, 2020.
Guo T T. Study on properties of soil hydrological under different reconstruction patterns in mining area[D]. Taiyuan: Shanxi University, 2020 (in Chinese with English abstract).
- [21] 王强民, 赵明, 彭鸿杰, 等. 旱区不同层状结构土壤的水分运移过程与模拟[J]. 水文地质工程地质, 2023, 50(4): 84-94.
Wang Q M, Zhao M, Peng H J, et al. Water transport process and simulation of layered soils with different configurations in an arid region [J]. Hydrogeology & Engineering Geology, 2023, 50(4): 84-94 (in Chinese with English abstract).
- [22] 郭志萍, 李斌, 孙西欢, 等. 不同生态修复模式下土壤水文性质及其对溶质运移的影响[J]. 环境科学学报, 2019, 39(12): 4251-4260.
Guo Z P, Li B, Sun X H, et al. Soil hydrological properties and their effects on solute transport under different ecological restoration models in coal mining area[J]. Journal of Environmental Sciences, 2019, 39(12): 4251-4260 (in Chinese with English abstract).
- [23] 福纳德. 中国东部草原区露天矿排土场土壤构建与改良研究[D]. 江苏徐州: 中国矿业大学, 2019.
Fernand N A A. Construction and improvement of open pit mine dumped soil structure in China eastern grassland area [D]. Xuzhou Jiangsu: China University of Mining and Technology, 2019 (in Chinese with English abstract).