

卷积神经网络在土木工程中的应用研究综述

滕权^{1,2}, 李曙光^{2*}, 陈改新²

(1.华北水利水电大学 土木与交通学院, 河南 郑州 450045;

2.中国水利水电科学研究院 流域水循环模拟与调控国家重点实验室, 北京 100038)

摘要: 深度学习是机器学习的一个经典分支, 而卷积神经网络模型是一种典型的深度学习模型。随着训练数据集的剧增和计算机硬件(GPU)处理能力的显著提高, 卷积神经网络强大的特征学习和特征表达能力引起了广泛的关注, 并在众多领域取得了一系列突破性的研究成果。首先回顾了卷积神经网络的发展历史, 介绍了卷积神经网络的基本结构及部分典型卷积神经网络模型, 重点以道路工程、轨道交通工程、桥涵工程、水利工程等为例, 对卷积神经网络在土木工程中的应用现状进行了归纳与分析, 最后指出了卷积神经网络在土木工程领域中的应用特点及未来的发展方向。

关键词: 卷积神经网络; 土木工程; 深度学习; 发展历史; 综述

中图分类号: TP391

文献标识码: A

Review of application of Convolutional Neural Network in Civil Engineering

Teng Quan^{1,2}, Li Shuguang^{2*}, Chen Gaixin²

(1. School of Civil Engineering and Communication, North China University of Water Resources and Electric Power, Zhengzhou 450045, China;

2. State Key Laboratory of Simulation and Regulation of Water Cycle in River Basin, China Institute of Water Resources and Hydropower Research, Beijing 100038, China)

Abstract: Deep learning is a classical branch of machine learning, and the convolutional neural network model is a typical deep learning model. With the increase of training data set and the significant improvement of computer hardware (GPU) processing capacity, the powerful feature learning and feature expression ability of convolutional neural network has attracted wide attention and achieved a series of breakthrough research results in many fields. Firstly reviewed the development history of convolution neural network, this paper introduces the convolution of the neural network basic structure, the key to road, rail traffic engineering, bridge engineering, water conservancy project as an example, the convolutional neural network application in civil engineering present situation has carried on the summary and analysis, and finally points out the characteristics of convolution neural network application in the field of civil engineering and development direction in the future.

Keywords: Convolutional neural network; Civil Engineering; Deep learning; History of development; Review

引言

卷积神经网络(Convolutional Neural Network, CNN)是一种广为人知的典型深度学习模型, 其发展历史可分为三个阶段: 提出理论、建立模型、成为研究热点。

1962年, Hubel和Wiesel[1]通过对猫脑视觉皮层的研究, 发现在视觉皮层中存在一系列构造复杂的细胞, 它们被称为“感受野”。感受野所在的层级结构中处于较低阶段的细胞通常会相应刺激模式

收稿日期:

基金项目: 十三五国家重点研发计划(2018YFC0406700); 国家自然科学基金项目(51879286); 流域水循环模拟与调控国家重点实验室课题(SK2018TS09)

作者简介: 滕权(1997-), 男, 河南南阳人, 硕士研究生, 研究方向为数字图像处理。E-mail:1531275632@qq.com

通信作者: 李曙光(1981-), 男, 河南漯河人, 教授级高工, 博士, 研究发为混凝土耐久性。E-mail:lisg@iwhr.com

较为简单的特征，而处于较高阶段的细胞通常也会选择性地响应刺激模式更复杂的特征，且都对刺激模式位置的变化更加不敏感。

1980年，在Hubel和Wiesel的层级模型基础上，Fukushima提出了神经认知机(Neocognitron)^[2]。神经认知机采用简单细胞层(S-layer, S层)和复杂细胞层(C-layer, C层)交替组成，被认为是CNN的第一个工程实现网络，CNN中的卷积和池化(也称作下采样)分别对应简单细胞和复杂细胞。

在模型建立阶段，LeCun做出了重要贡献。1990年，LeCun等^[3]提出了CNN的初始版本，之后又基于Fukushima的研究工作进行了改进，并于1998年提出了基于梯度学习的CNN模型——LeNet-5^[4]，并在手写数字字符的识别应用中获得了成功。在手写数字识别领域的成功应用引起了学术界对CNN的关注，这在CNN的发展过程中具有里程碑式的意义，同一时期，CNN在语音识别^[5]、物体检测^[6]、人脸识别^[7]等方面的研究也逐渐发展起来。

CNN成为研究热点有两个关键历史时刻。一个是2006年，Hinton等人^[8]在《Science》上发表论文，提出了两个主要观点并引出了深度学习(Deep Learning, DL)的研究，掀起了神经网络的研究热潮^[9]。其主要观点有：(1)多隐层的人工神经网络具有优异的特征学习能力；(2)可通过“逐层预训练”(layer-wise pre-training)来有效克服深层神经网络在训练上的困难。

另一个是2012年，Hinton的学生Krizhevsky等^[10]提出的一种与LeNet-5类似但具有更深结构的CNN架构——AlexNet，并在大型图像数据库ImageNet^[11]的图像分类竞赛中以准确度超越第二名11%的巨大优势夺得了冠军，使得CNN成为了学术界的焦点。在此之后，不断有新的CNN模型在AlexNet的基础上被提出，比如牛津大学的VGG(Visual Geometry Group)^[12]、Google的GoogLeNet^[13]、微软的ResNet^[14]等，这些网络不断刷新着AlexNet在ImageNet竞赛上创造的纪录。

CNN的局部连接、权值共享及池化操作等特性使之可以有效地降低网络的复杂度，减少训练参数的数目，使模型对平移、扭曲、缩放具有一定程度的不变性，并具有强鲁棒性和容错能力，且也易于训练和优化。

本文概述了CNN的基本结构和工作原理、介绍了AlexNet及改进后的Faster R-CNN网络模型结构，之后以道路工程、轨道交通工程、桥涵工程、水利工程等为例，对CNN在土木工程中的应用现状进行了归纳与分析。

1 CNN概述

CNN是目前深度学习技术领域中最具有代表性的神经网络之一，在学术界常用的标准图像标注集ImageNet上，学者们基于CNN取得了许多成就。

CNN是一种前馈型的神经网络，相比于其他神经网络结构，能够有效降低网络模型的学习复杂度，具有更少的网络连接数和权值参数，从而更容易训练。

1.1 CNN的基本结构

CNN是一个多层次结构模型，由输入层、卷积层、池化层、全连接层以及输出层组成。CNN的主要特点在于卷积层的特征由前一层的局部特征通过卷积共享的权重得到。

在CNN中，输入图像通过多个卷积层和池化层进行特征提取，逐步由低层特征变为高层特征；高层特征再经过全连接层和输出层进行特征分类，产生一维向量输出。

一个简单的CNN模型的结构示意图如图1所示，该网络模型由两个卷积层(C1, C2)和两个池化层(S1, S2)交替组成。首先，原始输入图像通过与3个可训练的滤波器(或称作卷积核)和可加偏置向量进行卷积运算，在C1层产生3个特征映射图，然后对每个特征映射图的局部区域进行加权平均求和，增加偏置后通过一个非线性激活函数在S1层得到3个新的特征映射图。随后这些特征映射图与C2层的

3 个可训练的滤波器进行卷积，并进一步通过 S2 层后输出 3 个特征映射图。最终 S2 层的 3 个输出分别被向量化，然后输入到传统的神经网络中进行训练。




图 1 CNN 模型的简单结构示意图

在传统的 CNN 中，激励函数一般使用饱和非线性函数(saturating nonlinearity)如 sigmoid 函数、tanh 函数等。相比较于饱和非线性函数，不饱和非线性函数(non-saturating nonlinearity)能够解决梯度爆炸/梯度消失问题，同时也能够加快收敛速度^[15]。Jarrett 等人^[16]通过实验发现修正非线性函数(rectified nonlinearity)能够显著提升卷积网络的性能，Nair 等人^[17]验证了这一结论。因此在目前的 CNN 结构中常用不饱和非线性函数作为卷积层的激励函数如 ReLU 函数。

池化层的功能主要有两点：1)对特征图进行降维；2)通过降低特征面的分辨率在一定程度上保持特征的尺度不变特性^[18]。池化层起到二次提取特征的作用，常用的池化方法有最大池化、均值池化、随机池化等^[19,20]。

CNN 的训练目标是 minimized 网络的损失函数。输入经过前向传导后得到输出，通过损失函数计算出与期望值之间的差异，称为“残差”。常见损失函数有均方误差(Mean Squared Error, MSE)函数，负对数似然(Negative Log Likelihood, NLL)函数等^[21]。

1.2 AlexNet 模型

2012 年，Krizhevsky 等^[10]提出了大型深度 CNN——AlexNet，并在 2012-ILSVRC 中首次实现了 15.4% 的 Top 5 误差率，赢得当年的冠军。AlexNet 由 5 个卷积层和 3 个全连接层组成。Krizhevsky 在 AlexNet 中集成了大量技术来提高性能并减少训练时间，如提高训练速度的 ReLU 非饱和非线性激活函数，提高泛化能力的 LRN(local response normalization)，增强数据的图像转换(image translation)、水平反射(horizontal reflection)和改变图像 RGB 通道的强度，使用 dropout 来减弱全连接层的过拟合问题，使用随机梯度下降(SGD)训练模型等。

1.3 Faster R-CNN 模型

在 AlexNet 基础上得到的 GoogLeNet、VGGNet 等 CNN 模型可以自动从训练数据集中提取高维特征，使得识别检测分类的精度和准确率得到了显著提升，但也存在计算过程复杂度高、耗时长等问题。

Girshick 等人^[22]在 CNN 的基础上进一步开发了 R-CNN(Region-CNN)。R-CNN 使用 Selective Search 的方法替代传统 CNN 的滑动窗口，预先找出输入图像中目标可能出现的位置即区域建议 (Region Proposal)，计算对应区域建议的特征，最后结合预先训练得到的分类器进行分类。相较于传统 CNN 所使用的滑动窗口，R-CNN 利用 Selective Search 避免了对目标检测框的海量枚举，有效提升了计算效率。图 2 给出了 R-CNN 算法的示意图。

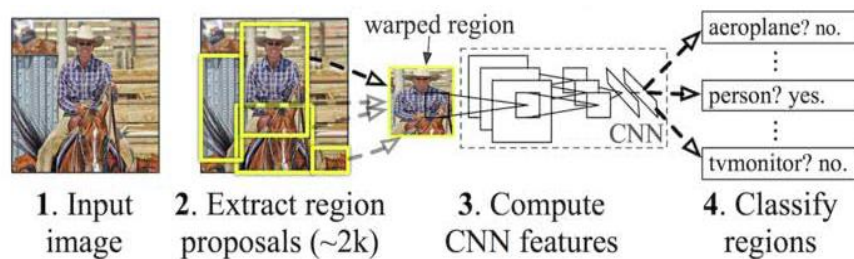


图 2 R-CNN 算法示意图

R-CNN 算法虽设计巧妙，但是其将模型检测过程分为多个阶段的做法极大地消耗了检测效率，因此学者们提出了 Fast R-CNN^[23]。Fast R-CNN 首先将区域建议映射到卷积层上，避免对每一个区域都进行特征提取；之后提出了区域建议池化层（RoI Pooling），将不同尺寸区域建议都用一个固定维度进行特征表示，进而可以送入同一个全连接层进行识别。图 3 给出了 Fast R-CNN 的架构示意图，其在提高检测精度的同时，也大幅提高了训练与测试的速度。




图 3 Fast R-CNN 算法示意图

为进一步提升速度，Ren 等人^[24]在 Fast R-CNN 的基础上增加了候选窗口网络(region proposal network, RPN)，提出了 Faster R-CNN 算法。RPN 通过设置不同尺度的锚(anchor)来提取候选框，代替了 Selective Search 对区域建议进行预测，进一步缩短了检测框的生成时间，大大降低了检测耗时。相比于 Fast R-CNN，Faster R-CNN 的所有任务都统一在单一的深度学习框架之下，计算速度大幅度提升。

1.4 CNN 的工作原理

1、定义网络模型。网络模型需要根据具体的应用而定义，包括应用的数据量和数据特点，网络深度、网络每一层的功能，以及网络中的超参数等。网络模型的各方面均已有一定的研究，如模型深度方面^[14]、卷积的步长方面^[25]、激励函数方面^[26]、网络中的超参数选择^[27]等。

2、训练网络模型。CNN 通过残差的反向传播对修改网络中的参数达到训练效果。事实上，训练过程中的过拟合、梯度的消逝与爆炸等问题^[28]极大影响了训练的收敛。改善训练收敛问题的研究有：基于高斯分布的随机初始化网络参数^[10]；利用经过预训练的网络参数进行初始化^[12]；对 CNN 不同层的参数进行相互独立同分布的初始化^[29]。

3、预测网络结果。CNN 的预测过程就是在训练好的网络上，对输入数据进行前向传导，在各个层次上输出特征图，最后利用全连接网络的输出进行预测。近期的研究表明，经过前向传导的 CNN 高层特征具有很强的判别能力和泛化性能^[30]；另外，通过迁移学习，这些特征可以被应用到更加广泛的领域。

2 CNN 在土木工程中的应用

CNN 的应用主要体现在计算机视觉、自然语言处理、数据预测等方向。

2.1 道路工程

准确的路面病害检测结果可为路面养护管理决策提供可靠、有效的技术支持。为进一步提高利用二维图像统计路面病害的精度与效率,沙爱民等人^[31]将 CNN 引入了基于图像分析的路面病害识别与测量:将原始图像进行等尺寸分割作为训练样本以建立病害识别模型,将识别出的结果作为训练样本分别建立裂缝特征提取模型、坑槽特征提取模型。构建的 CNN 网络模型的识别与计算的高度自动化,可大幅提高病害检测速率,且模型具有较高的测量精度和效率。

前方车辆的实时准确检测有助于提前发现安全隐患,并及时向驾驶员发出警告。为区分车底阴影和非车底阴影干扰、提高车辆检测的准确率和可靠性、降低误检率,李琳辉等人^[32]提出一种基于 CNN 的前方车辆检测方法:首先用边缘增强的区域增长方法实现路面检测,其次提出了车底阴影自适应分割算法以分割出不同光照下的车底候选区域,最后运用 CNN 对有限个候选区域检测结果进行验证和剔除,最终获得精确的检测结果,实现车辆目标的准确检测。

车牌识别在交通信息控制与智能交通中发挥着重要作用,车牌识别系统的三个部分(车牌定位、字符分割与字符识别)中字符识别的效果起到决定性作用。赵志宏等人^[33]为了适应目前中国车牌字符识别的需要,对传统的 CNN 模型——LeNet-5 的结构进行了改进,主要是改变输出单元的个数与增加卷积层 C5 特征图的个数。结果表明改进后的 CNN 模型识别率高达 98.68%,且正确率和识别速度上都极具优势。

2.2 轨道交通工程

高速铁路两旁每隔几米远就会有架设的高压输电线路保障列车有足够的动力,而对每个输电架进行编号可以方便铁路保障人员对输电线路进行检修。为克服人工识别处理繁琐而低效的问题、实现轨道交通周围环境信息的智能感知,孟球等人^[34]设计并实现了一种基于 CNN 的高铁轨道周边路牌数字识别的智能系统。系统采用了目标检测、语义分割以及数字识别三大模块,其中语义分割模块使用了全卷积的方式,对目标检测的结果进一步处理,可准确得到路牌中的数字区域;数字识别模块则参考 MNIST 数据集的手写体识别系统并针对路牌中数字的特点做了相应改进。实验结果表明,白天的平均识别准确率为 87.98%,黑天的平均识别准确率为 72.92%。

塞钉是安装轨道电路轨端连接线的关键部件,当前对塞钉的巡检主要依赖于人工上道作业的方式,效率低下,因此在轨腰处安装了线阵相机以对采集到的图像进行分析。杜馨瑜等人^[35]在既有计算机视觉的目标检测算法的基础上,提出了基于深度学习的铁道塞钉自动检测算法。该算法在目标检测的特征提取阶段,设计了塞钉卷积神经网络(plug Convolution Neural Network, pCNN)以自动从候选目标区域逐层提取最能表现塞钉特征的特征图像。经对比试验验证,所提出的基于深度学习的铁道塞钉自动检测算法与其他现有算法相比能进一步提升目标检测性能。

2.3 桥涵工程

桥梁等大型钢结构中高强螺栓延迟断裂偶有发生,若发现及处理不及时,将会累积连接失效的风险。赵欣欣等人^[36]针对铁路桥梁高强螺栓缺失的场景特征,开展了基于 CNN 的桥梁高强螺栓缺失图像识别方法研究。在保证数据多样性的前提下经过数据增强和均衡处理建立螺栓缺失数据集,之后建立不带分支的扁平化深层 CNN 模型,最后在 ImageNet 训练集中预训练后再使用本数据集进行参数微调。试验结构表明最终的螺栓识别准确率达 94.7%。

常采用计算机视觉检测方法提高桥梁结构中表面病害的检测效率。

韩晓健等人^[37]将桥梁结构表面病害归纳为裂缝、锈蚀与缺损三大类，并结合迁移学习技术调整 AlexNet 模型的参数，最终构建了桥梁结构表面病害自动识别模型并在实际工程中进行测试。结果表明该模型的识别率分别为裂缝 86%、锈蚀 82%、缺损 70%，可用于桥梁结构表面病害的快速识别。

刘洪公等人^[38]在对桥梁表面图像进行一系列图像预处理后对 LeNet-5 模型进行改进以对横向裂缝、纵向裂缝、块状裂缝和网状裂缝进行识别及分类。分类结果显示，横向裂缝，纵向裂缝、块状裂缝的分类准确率均达到 90%以上，网状裂缝的分类准确率达到 85%。

朱苏雅等人^[39]针对裂缝检测算法准确度不高、容易丢失细节等问题，提出一种基于 U-Net 网络的裂缝检测方法，该方法因可以保留裂缝细节而提高了检测的准确性，达 90%以上。在保留裂缝细节的前提下，实现了对裂缝宽度的测量，准确性高。

梁雪慧等人^[40]构建了一个较大规模的桥梁裂缝数据集，并在 GoogLeNet 模型的基础上改进了网络结构及 inception 模块，建立起了桥梁裂缝特征图像分类系统，检测结果表明该方法的检测准确率超过 96%。在识别出裂缝的同时用小矩形框出裂缝图片进行定位，进一步实现了裂缝长度及宽度的计算。

2.4 水利工程

水利工程中，大体积混凝土在成型过程中产生的温度应力会破坏整体结构的受力性能，因此有必要对成型中的混凝土进行最大温度值监测。丁杨等^[41]以大体积混凝土浇筑过程为工程背景，选取受外界影响因素较小、实测温度曲线最大的监测点的监测数据作为研究对象，以该点 0~211h 的监测数据作为 CNN 网络模型的输入，预测 233~355h 的监测数据并与实测数据进行对比。预测结果显示在第 223h 计算出的结果与实测数据的误差仅为 1.9%。

在土木工程中，常用 ANSYS 等大型商用有限元分析软件进行计算，但难以准确确定初始条件，相对地，由已知数据预测未知数据，可以在确保精确度的基础上极大地降低成本。

Wesafety 平台^[42]可以实时统计出某大型水电站施工现场的大量安全隐患数据，其中高处坠落、物体打击、起重伤害、触电、坍塌、机械伤害、三违行为等为典型安全隐患。为降低事故率、加强施工现场的安全管理，林鹏等人^[43]提出了基于 CNN 的安全隐患学习与挖掘模型，可以从大量隐患中高效、准确地识别典型隐患，其中典型隐患识别正确率为 95.4%，非典型隐患的识别正确率为 97.1%。识别效率得以提高、整改时间更为宽裕、整改效率得到明显提升。

在土方需求巨大且无精确的单个卡车负载称量要求的土木工程项目，如水电，机场，大规模景观改造等场景^[44]中，现场土方量统计常采用卡车计数的方式。为克服人工误差、高人工成本、持续维护和应用环境等限制，Quan Liu 等人^[45]通过引入 CNN 和迁移学习(Transfer learning, TL)提出了一种基于机器视觉的大土方需求工程现场土方工程量统计方法以对满载/空载货车进行分类。分析结果表明 CNN 与迁移学习的组合中最高工作精度为 98%，最快的卡车图像分类速度为 41.1 图像/秒。

3 结束语

CNN 在土木工程领域的应用已经取得了一定的研究成果，成本低、效率高、准确度高，优势显著，但也有很多工作值得进一步研究。其应用特点及未来可能的发展方向有以下几点：

- 1、CNN 在土木工程中的应用主要体现在计算机视觉方向，借助采集到的图像进行特征提取和检测呈主要趋势。

2、CNN 在土木工程领域中的不同任务时面临的关键问题是如何选择合适的网络架构和训练参数，值得进一步研究。

3、当前数据集采用的人工标记方式需要投入大量的人力财力，因此无监督式的 CNN 训练方式越来越重要，未来在训练 CNN 时可更多地考虑无监督方式。

致谢

本文获得了十三五国家重点研发计划（2018YFC0406700）；国家自然科学基金项目（51879286）；流域水循环模拟与调控国家重点实验室课题（SKL2018TS09）的资助。

参考文献

- [1] HUBEL D H, WIESEL T N. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex [J]. *Journal of Physiology*, 160(1): 106-54.
- [2] FUKUSHIMA K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position [J]. *Biological Cybernetics*, 36(4): 193-202.
- [3] CUN Y L, BOSER B, DENKER J S, et al. Handwritten Digit Recognition with a Back-Propagation Network [J]. *Advances in Neural Information Processing Systems*, 1997, 2(2): 396--404.
- [4] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. *Proceedings of the IEEE*, 86(11): 2278-324.
- [5] WAIBEL A, HANAZAWA T, HINTON G E, et al. Phoneme recognition using time-delay neural networks [J]. *IEEE Transactions on Acoustics Speech & Signal Processing*, 1989, 37(3): 328-39.
- [6] VAILLANT R, MONROU C, LE CUN Y. Original approach for the localisation of objects in images [J]. *IEE Proceedings-Vision, Image and Signal Processing*, 141(4): 245-0.
- [7] LAWRENCE S, MEMBER, IEEE, et al. Face Recognition: A Convolutional Neural-Network Approach [J]. *IEEE Transactions on Neural Networks*, 2002, 8(1): 98-113.
- [8] HINTON, E. G. Reducing the Dimensionality of Data with Neural Networks [J]. *Science*, 313(5786): 504-7.
- [9] 余凯, 贾磊, 陈雨强, et al. 深度学习的昨天、今天和明天 [J]. *计算机研究与发展*, 2013, 50(09): 1799-804.
- [10] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet Classification with Deep Convolutional Neural Networks; proceedings of the International Conference on Neural Information Processing Systems, F, 2012 [C].
- [11] DENG J, DONG W, SOCHER R, et al. ImageNet: a Large-Scale Hierarchical Image Database; proceedings of the 2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2009), 20-25 June 2009, Miami, Florida, USA, F, 2009 [C].
- [12] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition [J]. *Computer Science*, 2014,
- [13] SZEGEDY C, LIU W, JIA Y, et al. Going Deeper with Convolutions [J].
- [14] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition; proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), F, 2016 [C].
- [15] XU B, WANG N, CHEN T, et al. Empirical Evaluation of Rectified Activations in Convolutional Network [J].
- [16] JARRETT K, KAVUKCUOGLU K, RANZATO M A, et al. What is the Best Multi-Stage Architecture for Object Recognition?; proceedings of the Proc International Conference on Computer Vision (ICCV'09), F, 2009 [C].
- [17] NAIR V, HINTON G E. Rectified Linear Units Improve Restricted Boltzmann Machines Vinod Nair; proceedings of the Proceedings of the 27th International Conference on Machine Learning (ICML-10), June 21-24, 2010, Haifa, Israel, F, 2010 [C].

- [18] GU, JIUXIANG, WANG, et al. Recent advances in convolutional neural networks [J].
- [19] BOUREAU Y L, ROUX N, BACH F, et al. Ask the locals: Multi-way local pooling for image recognition [M]. 2011.
- [20] ZEILER M D, FERGUS R. Stochastic Pooling for Regularization of Deep Convolutional Neural Networks [J].
- [21] MURPHY K P. Machine Learning: A Probabilistic Perspective [J].
- [22] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [M]. 2014 Ieee Conference on Computer Vision and Pattern Recognition. 2014: 580-7.
- [23] HE K, ZHANG X, REN S, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition [J]. Ieee Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-16.
- [24] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks [J]. Ieee Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-49.
- [25] ZEILER M D, FERGUS R. Visualizing and Understanding Convolutional Networks [M]. 2014.
- [26] GOODFELLOW I J, WARDE-FARLEY D, MIRZA M, et al. Maxout Networks [J].
- [27] MONTAVON G, ORR G B, MÜLLER K-R. [Lecture Notes in Computer Science] Neural Networks: Tricks of the Trade Volume 7700 || Efficient BackProp [J]. 10.1007/978-3-642-35289-8(Chapter 3): 9-48.
- [28] BENGIO Y. Learning Long-term Dependencies With Gradient Descent is Difficult [J]. IEEE Trans Neural Netw, 1994, 5.
- [29] HE K, ZHANG X, REN S, et al. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification [J]. 2015,
- [30] DONAHUE J, JIA Y, VINYALS O, et al. DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition, F, 2014 [C].
- [31] 沙爱民, 童峥, 高杰. 基于卷积神经网络的路表病害识别与测量 [J]. 中国公路学报,
- [32] 李琳辉, 伦智梅, 连静, et al. 基于卷积神经网络的道路车辆检测方法 [J]. 吉林大学学报(工学版), v.47;No.190(2): 384-91.
- [33] 赵志宏, 杨绍普, 马增强. 基于卷积神经网络 LeNet-5 的车牌字符识别研究 [J]. 系统仿真学报, 03): 94-7.
- [34] 孟球, 孙霄宇, 赵滨. 基于卷积神经网络的铁路路牌识别方法 [J]. 自动化学报, 1-13.
- [35] 杜馨瑜, 戴鹏, 李颖, et al. 基于深度学习的铁道塞钉自动检测算法 [J]. 中国铁道科学, 2017, 38(03): 89-96.
- [36] 赵欣欣, 钱胜胜, 刘晓光. 基于卷积神经网络的铁路桥梁高强螺栓缺失图像识别方法 [J]. 中国铁道科学, 2018, 39(04): 56-62.
- [37] 韩晓健, 赵志成, 沈泽江. 卷积神经网络在桥梁结构表面病害检测中的应用研究 [J]. 结构工程师, 2019, 35(02): 106-11.
- [38] 刘洪公, 王学军, 李冰莹, et al. 基于卷积神经网络的桥梁裂缝检测与识别 [J]. 河北科技大学学报, 2016, 37(05): 485-90.
- [39] 朱苏雅, 杜建超, 李云松, et al. 采用 U-Net 卷积网络的桥梁裂缝检测方法 [J]. 西安电子科技大学学报, 2019, 46(04): 35-42.
- [40] 梁雪慧, 程云泽, 张瑞杰, et al. 基于卷积神经网络的桥梁裂缝识别和测量方法 [J]. 计算机应用, 1-7.
- [41] 丁杨, 周双喜, 董晶亮, et al. 人工智能方法在土木工程监测中的运用 [J]. 2019,
- [42] 林鹏, 王英龙, 汪志林, et al. 基于微信的大型水电工程安全隐患排查治理系统研发与应用 [J]. 中国安全生产科学技术, 7):
- [43] 林鹏, 魏鹏程, 樊启祥, et al. 基于 CNN 模型的施工现场典型安全隐患数据学习 [J]. 清华大学学报:自然科学版, 2019,
- [44] BISWAS D, SU H, WANG C, et al. An Automatic Car Counting System Using OverFeat Framework [J]. Sensors, 2017, 17(7):

[45] LIU Q, FENG C, SONG Z, et al. Deep Learning Model Comparison for Vision-Based Classification of Full/Empty-Load Trucks in Earthmoving Operations [J]. Applied Sciences-Basel, 2019, 9(22):