

基于二维 Gabor 变换和胶囊网络的铁路扣件检测研究

王笑冬,林建辉

(西南交通大学 牵引动力国家重点实验室,四川 成都 610031)

摘 要:针对目前大部分铁路扣件采用人工巡检的情况,提出基于二维 Gabor 变换和胶囊网络相结合的铁路扣件状态检测方法。在获得扣件原始图像的基础上采用二维 Gabor 变换进行滤波,分析滤波结果,通过胶囊网络进行状态识别,并对比分析滤波后产生的图像在卷积神经网络、胶囊网络以及两者结合的神经网络下所产生的不同检测结果,得出最优检测方法。研究表明,该方法可代替大部分人工检测,有效提高检测效率,保障行车与巡检人员安全。

关键词:二维 Gabor 变换;胶囊网络;卷积神经网络;铁路扣件;自动检测

中图分类号:U216.3 **文献标识码:**A **文章编号:**1671-5276(2020)06-0134-04

Railway Fastener Detection Based on 2D Gabor Transform and Capsule Network

WANG Xiaodong, LIN Jianhui

(State Key Laboratory of Traction Power, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Because most of the railway fasteners need to be manually inspected, this paper proposes an automatic detection method for the railway fasteners based on 2D Gabor transformation and capsule network. Based on the original image of the fastener, the 2D Gabor transform is used to filter and analyze the filtering results. Then, the state recognition is performed through the capsule network. It also compares and analyzes the different detection results produced by the image after filtering in the convolutional neural network, the capsule network and the neural network combined with them, which are used to obtain the best detection method. Research result shows that this method can be used for most of the manual detection. The detection efficiency is improved greatly and the safety of driving and inspection personnel is ensured.

Keywords: 2D Gabor transform; capsule network; convolutional neural network; railway fasteners; automatic detection

0 引言

随着中国铁路事业蓬勃发展,列车运行速度不断提升,铁路沿线检测暴露出来的问题也越来越明显。在列车行驶过程中,轨道沿线设备最易损坏,而轨道状态又与线路安全息息相关。铁路扣件作为轨道沿线设备之一,起着固定轨道、绝缘减震、轨距与水平调整等作用^[1]。由于其众多的数量与地域广泛的检修范围,依靠传统的人工检测方法不仅耗时耗力,而且由于巡检基本都在凌晨线路空窗期,存在一定的漏检率和安全隐患^[2];另外也有先通过检测车拍照再经由工作人员通过拍摄图片来确定扣件状态的检测方法,这种方法明显降低了工人的工作强度,提高了巡检的安全性,但是在本质上依然属于人工检测,不具有较强的客观性^[3]。基于数字图像的检测技术由于自身具备的自动化、智能化以及高精度、高效率 and 低成本等特点,可以在一些不方便人员进行检测的实际工作条件下或者人类视觉可能导致较高的漏检、误检的情况下代替人工工作,及时提供检测维修信息,在铁路扣件检测领域有着很好的应用与发展前景。实现铁路扣件缺陷检测首先对拍摄的扣件图像进行特征提取,而后再进行识别分

析。本文通过二维 Gabor 变换实现对扣件信息的提取,之后进一步介绍用于检测的卷积神经网络与胶囊网络的构架搭建以及两者相结合产生的神经网络对铁路扣件状态识别的检测研究。

1 二维 Gabor 变换

Gabor 滤波器是一种线性滤波器,主要用于分析在指定区域的指定方向上是否有特定的频率存在,是一种分析纹理特征的重要技术手段。Gabor 滤波器对光照信息不敏感,可有效降低强光及阴天对图像的影响,十分适合在视觉信息的纹理特征表示与分析中应用^[4]。其中二维 Gabor 变换是正弦平面波调制的高斯核函数,具有良好的空间和方向局部选择性,其公式如式(1)所示。其由表示正交方向的实部与虚部构成,将二维 Gabor 变换与需要处理的图像做卷积运算就可以有效地提取图像的纹理信息。

$$g(x, y, \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp\left[i\left(2\pi \frac{x'}{\lambda} + \psi\right)\right] \quad (1)$$

式中: $x' = x \cos \theta + y \sin \theta$; $y' = -x \sin \theta + y \cos \theta$; λ 是正弦因子的波长,且有效值 > 2 ; θ 是二维 Gabor 函数平行条纹的法线

方向,取值范围为 $0^\circ \sim 360^\circ$; ψ 是相位偏移,取值范围为 $-180^\circ \sim 180^\circ$; σ 是 Gabor 滤波器中高斯函数标准差; γ 是空间宽高比,文中取值为 1。二维 Gabor 滤波器可以在多尺度和多方向下进行图像特征提取,在人脸识别领域,一般选取 5 个尺度和 8 个方向进行分析。图 1 所示是在 5 个尺度和 8 个方向下的 Gabor 滤波器模板。



图 1 Gabor 滤波器模板示意图

由扣件图像本身特征所决定,在检测中起主导作用的是其横向纹理特征,纵向基本无特征存在,故对公式(1)进行变换,取 $x'=x, y'=y, \psi=0$,并在公式中取模长进行计算,以减小方向因素的干扰,变换后的二维 Gabor 变换公式如公式(2)所示。

$$g(x, y, \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{|x|^2 + \gamma^2 |y|^2}{2\sigma^2}\right) \exp\left[i\left(2\pi \frac{|x|}{\lambda} + \psi\right)\right] \quad (2)$$

使用二维 Gabor 变换时,采用的窗口大小通常为固定值,可以根据实际检测效果选取不同窗口尺寸。二维 Gabor 变换可以拆分为实部、虚部以及复数形式。图 2 是在 5 个窗口尺度(1、3、7、13、19)情况下二维 Gabor 变换的实部、虚部以及复数检测效果图。

由图 2 可以看出,由于扣件图像像素大小为 28×28 ,滤波窗口尺寸过大会使得图像模糊,尺寸窗口过小会徒增运算量。在使用大量样本测试综合对比检测结果后,选择滤波窗口大小为 3,相比于虚部变换和复数变换,实部变换得到的图像特征更为清晰,故选择二维 Gabor 变换中实部形式来进行扣件特征提取。




图 2 二维 Gabor 变换检测效果图

2 神经网络模型配置

2.1 胶囊网络模型

卷积神经网络在图片检测领域有着广泛应用,尤其针对目标的识别与分类有强大的处理功能^[5]。卷积神经网络是通过卷积加池化的方式对图像特征进行提取后放入全连接的神经层和分类器进行分类,池化过程是对检测目标特征概要进行提取的过程,这种机制使图像在卷积层不

进行特征提取而是在池化层完成,可提高神经网络训练效率,减少运算量。但这种网络只针对图像特征进行检测和分类,会忽略如空间相对位置等信息^[6],可以说卷积神经网络是针对图像特征的标量检测。

在图像识别领域 HINTON G E 于 2017 年最新提出了胶囊神经网络(CapsuleNet)的概念^[7]。胶囊神经网络可以对在不同角度位置拍摄的同一物体都能做到有效检测,因为在 CapsuleNet 中聚类思想代替了池化。所谓胶囊就是一个向量,每个胶囊对应的权重值 $\mathbf{W}$ 也是向量,对比全连接神经网络中只是一个值的标量神经元胶囊可以包含方向、位置、颜色、纹理等多重信息^[7],通过胶囊神经网络的动态路由算法反复迭代来更新网络中各个参数,最终模长最大的胶囊即是正确预测的结果。图 3 为针对本文检测目标所搭建的胶囊网络框架图,包含卷积层、主胶囊层(PrimaryCaps)、数字胶囊层(DigitCaps),处理后的数据可继续进入编码层(Masking)与重构层(Decoder)进行数据的复现,网络总损失则包含了扣件图像处理过程中的边际损失与重构损失两部分。




图 3 胶囊网络模型框架图

胶囊网络中胶囊可以理解为一组嵌套的神经网络,胶囊网络给每层嵌套的胶囊都添加了 squash 函数。squash 函数如式(3)所示,这是在胶囊网络中出现的一个全新的压缩函数。其中 $\mathbf{V}_j$ 是 capsule j 的矢量输出; $\mathbf{S}_j$ 是 capsule j 的总输入。squash 函数压缩了输出向量的长度,输出介于 $0 \sim 1$ 。

$$\mathbf{V}_j = \frac{\|\mathbf{S}_j\|^2}{1 + \|\mathbf{S}_j\|^2} \times \frac{\mathbf{S}_j}{\|\mathbf{S}_j\|} \quad (3)$$

胶囊网络通过动态路由算法实现低层网络向高层网络信息传递的权重更新,除第 1 层胶囊外,其他胶囊的输入都来自下层所有胶囊的“预测矢量”加权和^[7],例如一个 capsule j 的总输入 $\mathbf{S}_j$ 如式(4)所示。

$$\mathbf{S}_j = \sum_i c_{ij} \mathbf{u}_{ji} \quad (4)$$

其中“预测矢量” $\mathbf{u}_{ji}$ 由下层胶囊的输出 $\mathbf{u}_i$ 和权重矩阵 $\mathbf{W}_{ji}$ 相乘获得。式(4)中的加权系数 c_{ij} 是取决于动态路由算法迭代的耦合系数, c_{ij} 的计算公式如式(5)所示。

$$c_{ij} = \frac{\exp(b_{ij})}{\sum_k \exp(b_{ik})} \quad (5)$$

式中 b_{ij} 取决于上、下层胶囊间的位置与类型。随着动态路由的迭代而不断优化更新,在本文中设置的迭代次数为3即可达到较好的输出预测结果。低层胶囊与高层胶囊间的信息传递如图4所示,每一个高层胶囊都是所有低层胶囊加上不同权重系数的集合,可包含扣件所有特征信息,图4中以一个高层胶囊为例进行连线示意,其他胶囊与之相同。

在本文搭建的胶囊网络中输入图片大小为 28×28 ,形状为 $(128, 28, 28, 1)$ 的矢量,选取卷积核大小为 3×3 ,将经卷积层后的矢量输入主胶囊层,经过动态路由算法进行迭代,在数字胶囊层的16个胶囊中选取模长最大的矢量为得到的预测矢量,即预测的扣件状态。




图4 胶囊信息传递示意图

2.2 胶囊网络结合卷积神经网络

传统卷积神经网络的池化机制强调的是图像位置的不变性,而胶囊网络的目的是实现图像等价性的检测,因而胶囊神经网络用动态路由算法取代了池化机制,但池化在对低层特征进行提取时有很好的表现,可以有效提取信息,减小运算量。因此本文结合两者优势进行扣件检测神经网络的构建实现。图5为胶囊网络结合卷积神经网络模型框架图,对低层卷积层输出的形状为 $(128, 20, 20, 256)$ 的矢量进行池化(Pooling)处理,输出形状为 $(128, 10, 10, 256)$ 的矢量再送入主胶囊层和数字胶囊层进行迭代。由于加入了池化处理,在训练过程中结合两种网络的检测网络比单独的胶囊网络所需要的训练时长更短,在采用900张尺寸为 28×28 的扣件二值图为训练数据的情况下,两者结合的胶囊网络所需的训练时长仅仅是胶囊网络的1/4,并且对CPU的占用率也更低。

3 铁路扣件状态检测

3.1 样本选取

本文使用的铁路扣件样本为工业相机拍摄所得到的W型弹条铁轨扣件,从拍摄的图像中可以看出扣件状态可以分为4种状态:扣件完整状态、扣件缺失状态、扣件断裂状态以及扣件遮盖状态。图6为扣件的4种状态示意图。在进行铁路扣件状态检测时,首先选用4种不同状态的扣件图共900张,4种分类放入改良的胶囊网络进行训




图5 胶囊网络结合卷积神经网络框架图

练,之后使用另外500张包含4种扣件状态的样本图进行测试结果分析。




图6 铁路扣件状态示意图

3.2 实验结果分析

在训练好改良胶囊网络的基础上将测试图片集的扣件图片放入其中进行测试,实现扣件状态分类识别问题的结果输出,对本文提出的检测方法的实际检测效果进行验证。图7所示为胶囊网络结合卷积神经网络在数据训练阶段总损失的变化情况,为每隔50个数据打印1次总损失变化情况的折线图。从图中可以看出,在单次训练中训练到400个数据时神经网络已经表现出较高的训练水平,实验总损失已经接近0。由于总损失包含重构损失,而神经网络在图像重构时不会达到100%的重构率,所以对于任何训练数据实验得到的总损失只会不断接近0而不会完全无损失。

训练得到的预测标签与实际图像标签的对比结果如图8所示,图中每隔50个数据点打印1次预测标签的准确率。从图中可以看出,在单次训练中>200个的数据预测结果已经达到了较好的准确率,可以准确地实现对数据图片集的检测分类。

在网络测试实验中,本文对比了卷积神经网络、胶囊




图7 胶囊网络结合卷积神经网络训练损失图




图8 胶囊网络结合卷积神经网络结果预测图

网络和胶囊网络结合卷积神经网络3种神经网络的检测结果,得到的实验结果如表1所示。其中正确检测率为正确实现扣件检测分类的占比,误检率为扣件检测分类错误的占比,漏检率为未检测分类出缺失状态的扣件的占比。

表1 检测结果对比表 单位: %

分类	正确检测率	误检率	漏检率
CNN	96.2	3.8	0.4
CapsuleNet	98.2	1.8	0.2
CNN+CapsuleNet	98.4	1.6	0.2

通过表1的检测结果可知,整体上3种神经网络检测方法在扣件检测方面都获得了较好的检测结果,胶囊网络对比卷积神经网络无论在检测准确率还是漏检率上都有一定的进步。由于胶囊网络的聚类特性,在对定位存在部分偏差的扣件图像检测上表现出了更好的容错性,而扣件缺失图像的特征明显,所以3种网络在漏检率上都有很好的表现。融合两者优势的CNN+CapsNet检测方法并未因为被胶囊网络摒弃的池化算法而出现较大的检测失误,在低层进行池化一定程度上帮助了神经网络进行图片的检测,并且对比单纯的胶囊网络进一步提升了检测效率,其中误检图像与漏检图像是由于图像中碎石遮盖扣件部分过多而被识别为扣件断裂或未检测出缺失,此类图像干扰过多,需要人工进一步核查,且在容错范围之内。此外,CNN+CapsNet检测方法在训练时长和处理器资源占用率都大幅度下降。图9所示为3种网络在训练时CPU的资源占用率,本文训练所用CPU型号为Core i5-3230M。从

图中可以看出,CNN资源占用率在80%~100%波动,平均在90%左右;CapsNet资源占用率在95%~100%波动,平均在98%左右;CNN+CapsNet资源占用率在60%~100%波动,平均在75%左右,训练时长上CNN+CapsNet检测也只需要CapsNet检测的1/4左右。




图9 3种网络训练时CPU资源占用率

4 结语

本文提出的铁路扣件状态检测方法在解决传统人工检测、半智能化检测的低效性及不安全性等方面上做了有益的尝试和研究。在通过二维Gabor变换提取扣件纹理特征的基础上进行神经网络智能识别分类扣件的状态,提出了用结合胶囊网络和卷积神经网络两者优势的神经网络进行扣件分类检测,对比单一的胶囊网络和卷积神经网络,不仅保证了检测的精准性,还提高了检测效率,为铁路扣件的智能检测做出了有益的研究尝试,为铁路车辆安全行驶保驾护航。后续工作将继续围绕特征提取与神经网络模型优化进行,不断增加数据集的复杂程度,以便于对网络进行训练、检测与调整,提升铁路扣件的智能化检测水平。

参考文献:

- [1] 卢祖文. 我国铁路的钢轨扣件[J]. 中国铁路,2005(7): 25-26.
- [2] 杭元元. 基于计算机视觉的铁路扣件检测算法研究[D]. 成都:西南交通大学,2014:1-2.
- [3] 张宏强,高红义. 图像自动识别技术在铁路的发展及运用[J]. 中国铁路,2015(5):86-88.
- [4] ZHU Z,TANG M,LU H. A new robust circular Gabor based object matching by using weighted hausdorff distance[J]. Pattern Recognition Letters,2004,25(4): 515-523.
- [5] 钟海军,胡步发. 基于高层特征融合的图像语义分割[J]. 机械制造与自动化,2019,48(3):178-181.
- [6] KRIZHEVSKY A,SUTSKEVER I,HINTON G E. Image Net classification with deep convolutional neural networks[C]. Curran Associates Inc: International Conference on Neural Information Processing Systems,2012: 1097-1105.
- [7] SABOUR S,FROSST N,HINTON G E. Dynamic routing between capsules[C]. Long Beach,CA: 31st Conference on Neural Information Processing Systems (NIPS),2017.

收稿日期:2019-10-10