

JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象学报 图形学报

2021
12
VOL.26

ISSN1006-8961
CN11-3758/TB





第26卷第12期（总第308期）
2021年12月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院
主办单位 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

主 编 吴一戎
编辑出版 《中国图象图形学报》编辑出版委员会
通信地址 北京市海淀区北四环西路19号
邮 编 100190
电子信箱 jig@aircas.ac.cn
电 话 010-58887035
网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号
总 发 行 北京报刊发行局
订 购 全国各地邮局
海外发行 中国国际图书贸易集团有限公司
(邮政信箱: 北京399信箱 邮编: 100048)
印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian | Monthly, Started in 1996

Superintended by Chinese Academy of Sciences
Sponsored by Aerospace Information Research Institute, CAS
China Society of Image and Graphics
Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Wu Yirong
Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics
Address No. 19, North 4th Ring Road West, Haidian District, Beijing, P. R. China
Zip code 100190
E-mail jig@aircas.ac.cn
Telephone 010-58887035
Website www.cjig.cn


Distributed by Beijing Bureau for Distribution of Newspapers and Journals
Domestic All Local Post Offices in China
Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China)
Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB
ISSN 1006-8961
CODEN ZTTXFZ

国外发行代号 M1406
国内邮发代号 82-831
国内定价 60.00元



环视鱼眼图像处理深度学习
研究进展(第2778页)



结合空间深度卷积和残差
的大尺度点云场景分割
(第2848页)



曼哈顿世界环境下消失点非线
性优化估计算法(第2931页)

综述

深度对抗视觉生成综述

谭明奎, 许守恺, 张书海, 陈奇 2751

人机交互中的智能体情感计算研究

刘婷婷, 刘箴, 柴艳杰, 王瑾, 王媛怡 2767

环视鱼眼图像处理深度学习研究进展

包俊, 刘宏哲, 褚文博 2778

图像处理和编码

图像分解与色彩先验下的多曝光图像融合

李嫛源, 王琴, 朱智勤, 齐观秋 2800

双尺度分解和显著性分析相结合的红外与可见光图像融合

霍星, 邹韵, 陈影, 檀结庆 2813

轻量级注意力特征选择循环网络的超分辨率重建

徐雯捷, 宋慧慧, 袁晓彤, 刘青山 2826

区域级通道注意力融合高频损失的图像超分辨率重建

周波, 李成华, 陈伟 2836

图像分析和识别

结合空间深度卷积和残差的大尺度点云场景分割

刘盛, 黄圣跃, 程豪豪, 沈家瑜, 陈胜勇 2848

细粒度图像分类的互补注意力方法

赵勋, 王家宝, 李阳, 王亚鹏, 苗壮 2860

联合分块谱带优选和深度特征的高光谱人脸识别

谢志华, 李毅, 牛杰一 2870

时空双仿射微分不变量及骨架动作识别

李琪, 墨瀚林, 赵婧涵, 郝宏翔, 李华 2879

多尺度分割先验迭代重加权低秩恢复显著性检测

张荣国, 郑维佳, 赵建, 胡静, 刘小君 2892

融合环境特征与改进YOLOv4的安全帽佩戴检测

葛青青, 张智杰, 袁琰, 李秀梅, 孙军梅 2904

图像理解和计算机视觉

关节轴角先验对3维人体重建结果的影响

姚砾, 张幼安, 张梦雪, 万燕 2918

曼哈顿世界环境下消失点非线性优化估计算法

韩冰心, 卢惠民, 于清华, 张礼廉 2931

双目机器视觉及RetinaNet模型的路侧行人感知定位

连丽容, 罗文婷, 秦勇, 李林 2941

遥感图像处理

遥感图像中油罐目标精确定位与参数提取

江哈, 张月婷, 郭嘉逸, 赵鑫, 李芳芳, 黄丽佳, 胡玉新, 雷斌, 丁赤飏 2953

参数合成空间变换网络的遥感图像一致性配准

陈颖, 张祺, 李文举, 石艳娇, 陈磊 2964

改进Mask R-CNN模型的海洋锋检测

徐慧芳, 黄冬梅, 贺琪, 杜艳玲, 覃学标 2981

噪声鲁棒的轻量级深度遥感场景图像分类检索

王亚鹏, 李阳, 王家宝, 赵勋, 苗壮 2991

改进U-Net型网络的遥感图像道路提取

杨佳林, 郭学俊, 陈泽华 3005

弱监督深度语义分割网络的多源遥感影像水体检测

李鑫伟, 李彦胜, 张永军 3015


总目次 I

CONTENTS

JOURNAL OF IMAGE AND GRAPHICS



Research progress of fisheye image processing based on deep learning(P2778)



A deep residual network with spatial depthwise convolution for large-scale point cloud semantic segmentation(P2848)



Vanishing point estimation based on non-linear optimization in manhattan world environments (P2931)

Review

A review on deep adversarial visual generation	
Tan Mingkui, Xu Shoukai, Zhang Shuhai, Chen Qi	2751
Agent affective computing in human-computer interaction	
Liu Tingting, Liu Zhen, Chai Yanjie, Wang Jin, Wang Yuanyi	2767
Research progress of fisheye image processing based on deep learning	
Bao Jun, Liu Hongzhe, Chu Wenbo	2778

Image Processing and Coding

Multi-exposure image fusion based on image decomposition and color prior	
Li Yuanyuan, Wang Qin, Zhu Zhiqin, Qi Guanqiu	2800
Dual-scale decomposition and saliency analysis based infrared and visible image fusion	
Huo Xing, Zou Yun, Chen Ying, Tan Jieqing	2813
Lightweight attention feature selection recursive network for super-resolution	
Xu Wenjie, Song Huihui, Yuan Xiaotong, Liu Qingshan	2826
Region-level channel attention for single image super-resolution combining high frequency loss	
Zhou Bo, Li Chenghua, Chen Wei	2836

Image Analysis and Recognition

A deep residual network with spatial depthwise convolution for large-scale point cloud semantic segmentation	
Liu Sheng, Huang Shengyue, Cheng Haohao, Shen Jiayu, Chen Shengyong	2848
Complemented attention method for fine-grained image classification	
Zhao Xun, Wang Jiabao, Li Yang, Wang Yapeng, Miao Zhuang	2860
Hyperspectral face recognition based on partition bands optimal selection and deep features	
Xie Zhihua, Li Yi, Niu Jieyi	2870
Spatio-temporal dual affine differential invariants for skeleton-based action recognition	
Li Qi, Mo Hanlin, Zhao Jinghan, Hao Hongxiang, Li Hua	2879
Iterative reweighted low-rank recovery salient object detection with multiscale segmentation prior	
Zhang Rongguo, Zheng Weijia, Zhao Jian, Hu Jing, Liu Xiaojun	2892
Safety helmet wearing detection method of fusing environmental features and improved YOLOv4	
Ge Qingqing, Zhang Zhijie, Yuan Long, Li Xiumei, Sun Junmei	2904

Image Understanding and Computer Vision

The impact of joint axis angle prior on the results of 3D human body reconstruction	
Yao Li, Zhang Youan, Zhang Mengxue, Wan Yan	2918
Vanishing point estimation based on non-linear optimization in manhattan world environments	
Han Bingxin, Lu Huimin, Yu Qinghua, Zhang Lilian	2931
Roadside pedestrian detection and location based on binocular machine vision and RetinaNet	
Lian Lirong, Luo Wenting, Qin Yong, Li Lin	2941

Remote Sensing Image Processing

Accurate localization and parameter extraction of oil tank in remote sensing images	
Jiang Han, Zhang Yueting, Guo Jiayi, Zhao Xin, Li Fangfang, Huang Lijia, Hu Yuxin, Lei Bin, Ding Chibiao	2953
Consistent registration of remote sensing images in parametric synthesized spatial transformation network	
Chen Ying, Zhang Qi, Li Wenju, Shi Yanjiao, Chen Lei	2964
Ocean front detection method based on improved Mask R-CNN	
Xu Huifang, Huang Dongmei, He Qi, Du Yanling, Qin Xuebiao	2981
A robust lightweight deep neural network for remote sensing scene image classification and retrieval under label noise	
Wang Yapeng, Li Yang, Wang Jiabao, Zhao Xun, Miao Zhuang	2991
Road extraction method from remote sensing images based on improved U-Net network	
Yang Jialin, Guo Xuejun, Chen Zehua	3005
Weakly supervised deep semantic segmentation network for water body extraction based on multi-source remote sensing imagery	
Li Xinwei, Li Yansheng, Zhang Yongjun	3015

中图法分类号: TP753 文献标识码: A 文章编号: 1006-8961(2021)12-2953-11

论文引用格式: Jiang H, Zhang Y T, Guo J Y, Zhao X, Li F F, Huang L J, Hu Y X, Lei B and Ding C B. 2021. Accurate localization and parameter extraction of oil tank in remote sensing images. Journal of Image and Graphics, 26(12): 2953-2963 (江晗, 张月婷, 郭嘉逸, 赵鑫, 李芳芳, 黄丽佳, 胡玉新, 雷斌, 丁赤飏. 2021. 遥感图像中油罐目标精确定位与参数提取. 中国图象图形学报, 26(12): 2953-2963) [DOI:10.11834/jig.200604]

遥感图像中油罐目标精确定位与参数提取

江晗^{1,2,3}, 张月婷^{1,2*}, 郭嘉逸¹, 赵鑫^{1,2,3}, 李芳芳¹,
黄丽佳¹, 胡玉新¹, 雷斌¹, 丁赤飏¹

1. 中国科学院空天信息创新研究院, 北京 100194; 2. 中国科学院空天信息创新研究院空间信息处理与应用系统技术重点实验室, 北京 100190; 3. 中国科学院大学电子电气与通信工程学院, 北京 100049

摘要: 目的 浮动顶油罐是遥感图像中具有圆形特征的典型人造目标, 其高精度定位与参数提取问题是一类代表性的应用问题, 针对该问题, 传统的基于圆形特征的变换域提取方法鲁棒性差, 参数选择需要不断手动调整; 基于深度学习的方法利用对已有标注图像的训练求解网络参数, 提高了自动化程度, 但对于圆形目标而言, 覆盖圆周需要较大的感受野, 这对应较大的网络结构, 随之带来细节信息缺失或参数量、运算量增大的问题。本文针对油罐的定位与参数提取问题, 将传统特征提取与深度学习结合, 提出了一种计算量小、精度高的方法。方法 基于快速径向对称变换(fast radial symmetry transform, FRST)后的变换域数据及原始数据构建了卷积神经网络(convolutional neural networks, CNN), 给出了训练过程及参数选择, 有效地将圆形特征的先验引入深度学习过程, 计算复杂度低, 用较少层的网络实现了高精度的定位。结果 基于 SkySat 数据的实验表明, 该方法比单纯基于深度学习的方法在相同网络量级上精度得到了有效提高, 预测误差平均降低了 17.42%, 且随着网络深度的增加, 精度仍有明显提高, 在较浅层次网络中, 预测误差平均降低了 19.19%, 在较深层次网络中, 预测误差平均降低了 15.66%。结论 本文针对油罐遥感图像定位与参数提取问题, 提出了一种基于变换域特征结合深度学习的方法, 有效降低了计算量, 提升了精度和稳定性。本文方法适用于油罐等圆形或类圆形目标的精确定位和参数提取。

关键词: 遥感图像; 油罐; 定位; 参数提取; 深度学习; 快速径向对称变换(FRST)

Accurate localization and parameter extraction of oil tank in remote sensing images

Jiang Han^{1,2,3}, Zhang Yueting^{1,2*}, Guo Jiayi¹, Zhao Xin^{1,2,3}, Li Fangfang¹,
Huang Lijia¹, Hu Yuxin¹, Lei Bin¹, Ding Chibiao¹

1. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100194, China;

2. Key Laboratory of Technology in Geo-Spatial Information Processing and Application Systems, Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100190, China;

3. School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049, China

Abstract: Objective Object localization and parameter extraction have been one of the vital applications for remote sensing

收稿日期: 2020-10-21; 修回日期: 2020-12-15; 预印本日期: 2020-12-22

* 通信作者: 张月婷 zhangyueting06@mails.gucas.ac.cn

基金项目: 国家重点研发计划资助(2016YFF0202700); 国家自然科学基金项目(61991420)

Supported by: National Key R&D Program of China (2016YFF0202700); National Natural Science Foundation of China (61991420)

image interpretation and the basis of information extraction nowadays. The acquired accuracy is the key factor to improve the accuracy of information inversion. As a typical man-made object with circle shape in remote sensing image, the high-precision localization and parameter extraction of floating roof oil tank have been the representative application issues. The elevation of the top cover of the floating roof oil tank has been fluctuated up and down with the change of oil storage volume. The remote sensing image of the oil tank has presented different circle shadows and multiple circle areas in terms of the elevation change. The localization and parameter extraction analysis of the oil tank has referred to the measurement of the center position of the tank roof, the center position of the circular-arc-shaped shadow cast has projected by the sunshine on the floating roof and the radius of the oil tank image, which is of great significance for the inversion of the oil tank structure and the oil storage information. However, the distribution and overlapping characteristics of circles in oil tank images have related to many factors, such as illumination, cloud cover, satellite observation and imaging conditions, background environment, side wall occlusion and so on. Therefore, for localization and parameter extraction of floating roof oil tank, it is necessary to develop a localization and parameter extraction method to adapt with circle shaped objects. The traditional parameterized feature extraction method has included Hough transform and template matching. The emerging deep learning method has been developed recently. Traditional parameterized feature extraction method can make effective use of the circumference feature with the non-learnable and the poor applicability of parameters. The lower automation has relied on priori knowledge to adjust parameters manually. The method based on deep learning has its advantages to use the training of the existing labeled images to solve the parameters of the network, which improves the degree of automation. For objects with circular structure, convolutional neural networks (CNNs) can predict the radius and get accurate location of the circle center. The disadvantages have been described as follows: First, the main feature of an object with circular structure such as oil tank is on the circumference, but not in the circle. The neural networks need to traverse all the pixels, which leads to redundant computation and a low processing efficiency. Next, CNN has increased the receptive field and aggregated the spatial features via cascading networks subject to the receptive field. At last, abundant training samples requirement has not existed in traditional parameterized feature extraction method. This research has proposed a method of low calculation and high precision by combining the traditional feature extraction method with deep learning to resolve the problem of localization and parameter extraction of oil tank in remote sensing images, which no longer needs to sacrifice resolution or increase the network.

Method A CNN has been constructed via fast radial symmetry transform (FRST). The training process and parameter has been sorted out. The image is processed by FRST and the original image and the processed image are superimposed as two channels of the image into a new dual channel image, which is input into the designed CNN for processing. The result has been compared with the result of the single channel original image into the same CNN for processing. The experiment is based on a self-made dataset of SkySat satellite data, compared under two CNN architectures, and ran once under two fixed random seeds. This method has illustrated the priori knowledge of circular feature into the deep learning process effectively. Low-computational complexity has been presented. High-precision localization based on relatively few layers of network has been realized.

Result The experimental results have shown that the accuracy of the proposed method is effectively improved at the same network level and the average prediction error is reduced by 17.42%. Moreover, the prediction error has been decreased by 19.19% on average in the shallower network. In the deeper network, the prediction error has been deducted by 15.66% on average.

Conclusion This research has demonstrated the transform domain features combined with deep learning to improve the accuracy of the localization and parameter extraction of oil tank in remote sensing images effectively.

Key words: remote sensing image; oil tank; localization; parameter extraction; deep learning; fast radial symmetry transform (FRST)

0 引言

针对遥感图像的目标定位和参数提取在农林调

查、城区测量、海洋监测及军事侦察等方面(孟繁烁,2012;隋雪莲等,2019)都有着广泛的应用,是重要的研究问题之一。油罐作为圆形特征的代表性人造目标,在军事和民用方面均起着重要作用(Xu

等,2014)。浮动顶油罐的顶盖位置随着储油量的变化而上下浮动,随着储油量的变化,其遥感图像中会呈现出不同的圆形阴影和多个圆形区域分布。在具体应用中,由于油罐目标是固定目标,且遥感图像具有对应像素的地理信息,故油罐可依赖位置信息进行检测,因此,本文研究的油罐定位和参数提取关注在获得油罐切片之后,如何确定图像中的罐顶圆心位置、阳光投射在浮动顶上的圆弧所在的圆心位置及油罐半径(如图1所示),这对于反演油罐结构(于圣涛,2019)和获知储油量信息(张金芳等,2017)有着重要意义,是计算机视觉的精确定位问题。然而浮动顶油罐遥感图像的圆形分布及交叠特征与光照、云量、卫星观测与成像条件、背景环境、侧壁遮挡等诸多因素相关,因此,面对浮动顶油罐的定位和参数提取问题,应当探索一种适合于此类圆形结构目标的定位和参数提取方法。

针对圆心定位和参数提取问题的方法主要分为两类,一类是传统参数化特征提取方法,包括基于Hough变换(Duda和Hart,1972)的方法和基于模板匹配(Shin等,2007)的方法(吴晓东等,2015),韩现伟等人(2011)通过利用梯度的方向信息和降低参数空间维数的方法改进了Hough变换,再结合图搜索方法作用于油罐(蔡肖芋和眭海刚,2015),张维胜等人(2006)利用改进的随机Hough变换(randomized Hough transform, RHT)、改进的Canny算法和模板匹配算法来处理油罐目标;另一类是近年迅速发展的基于深度学习(Hinton等,2006)的方法,将原始数据通过非线性模型转变为抽象的高层表达,以发现数据的分布式特征表示(LeCun等,2015;孙志军等,2012),LeCun等人(1989)提出了卷积神经网络(convolutional neural network, CNN),Krizhevsky等人(2012)构建的深度CNN模型在ImageNet比赛中取得佳绩,引发工业界和学术界的广泛关注,He等人(2015)提出的ResNet在ILSVRC(ImageNet Large Scale Visual Recognition Challenge)竞赛上获得图像检测、图像分类和图像定位3项冠军,首次超过人类识别的精度(王颖洁等,2019)。

针对遥感图像油罐目标的定位和参数提取问题,两类方法各有优势与缺点,传统参数化特征提取方法有效利用了圆周特征,但具有不可学习性,参数适用性差,需要依靠经验或先验知识来不断手动调节参数,自动化程度低;深度学习方法是端到端的方


法,然而在面对油罐这类圆形结构目标时,无法充分挖掘数据特有模式,需要较大的感受野,因而需要通过级联多层网络的方式来增大感受野,这导致其参数量和运算量大增。基于此,本文旨在有效利用先验特征的同时,加入已有数据的学习特征,降低计算量,提高精度和效率,提出一种二者结合的方法。

本文讨论了CNN方法的感受野覆盖问题,利用快速径向对称变换(fast radial symmetry transform, FRST)(Loy和Zelinsky,2003)将圆周特征实现空间区域聚集,构建了一种FRST和CNN相结合的方法,能够高效聚合空间特征,提高网络的精度和效率。基于SkySat卫星(龚燃,2016)数据进行了验证实验,结果表明,相比于普通CNN,该方法能有效提升油罐目标定位和参数提取的精度,并具有良好的稳定性。

1 本文方法

1.1 基于CNN的油罐目标定位与参数提取方法

CNN作为一种带卷积的有监督的深度前馈神经网络结构,因其在计算机视觉领域的出色表现而得到广泛应用,是深度学习的代表算法之一。面对油罐目标的定位与参数提取,CNN能够预测半径信息并得到精确的圆心定位,然而它的缺点也较为明显:1)油罐这类圆形结构目标,其主要特征在圆周,而不在圆内(如图1所示),然而目前神经网络需要遍历所有像素,这就导致其不必要的运算量增加,降低了处理效率;2)由于感受野的限制,CNN通过级联多层网络的方式来逐渐增大感受野,聚合空间特征,因此,目标尺寸越大,需要的网络结构越



(a) 原图 (b) 油罐顶部及浮动顶上的圆弧所在圆

图1 油罐图像中的圆形结构

Fig.1 Circular structure in oil tank image

((a) original image; (b) top of oil tank and circle of circular arc on floating roof of oil tank)

深,这导致其参数量和运算量都较大;3) 对训练样本的丰富度及数量较为依赖,而这个问题在传统参数化特征提取算法中不需要考虑。

1.2 基于 FRST 的油罐目标定位方法

1.2.1 FRST 原理

FRST 是一种利用局部径向对称来突出场景中感兴趣点的变换方法,其灵感来自于广义对称变换 (Reisfeld 等, 1995) 的结果,效果接近于 Sela 和 Levine (1997) 的工作和圆形 Hough 变换 (Kimme 等, 1975)。但不同在于,FRST 确定的是每个像素对其周围像素对称性的贡献,而不是局部邻域对中心像素的贡献。

FRST 可对一个或多个半径 $n \in N$ 进行计算,其中 N 为待检测的径向对称特征的半径集。半径为 n 时的变换值表示对距离每个点为 n 处的梯度的径向对称性的贡献。

首先定义正影响像素和负影响像素:对于像素 p ,正影响像素定义为沿梯度向量 $\mathbf{g}(p)$ 所指方向,且距 p 距离为 n 的像素,其坐标计算式为

$$\mathbf{p}_{+ve}(p) = p + \text{round}\left(\frac{\mathbf{g}(p)}{\|\mathbf{g}(p)\|}n\right) \quad (1)$$

负影响像素定义为沿梯度向量 $\mathbf{g}(p)$ 所指相反方向,且距 p 距离为 n 的像素,其坐标计算式为

$$\mathbf{p}_{-ve}(p) = p - \text{round}\left(\frac{\mathbf{g}(p)}{\|\mathbf{g}(p)\|}n\right) \quad (2)$$

式中,round 表示将元素数值四舍五入为整数。正影响像素和负影响像素如图 2 所示 (Loy 和 Zelinsky, 2003)。




图2 正影响像素与负影响像素示意图

Fig. 2 Schematic map of the positively-affected pixel and the negatively-affected pixel

对于每个半径 $n \in N$,通过检查每个点 p 处的梯度 $\mathbf{g}$,可形成一幅方向投影图 O_n 和幅度投影图 M_n :对于每对影响像素,方向投影图 O_n 和幅度投影图 M_n 中对应的点 $\mathbf{p}_{+ve}$ 分别递增 1 和 $\|\mathbf{g}(p)\|$,而对应的点 $\mathbf{p}_{-ve}$ 分别递减 1 和 $\|\mathbf{g}(p)\|$ (两种投影图初始值

皆设为零),即

$$O_n(\mathbf{p}_{+ve}(p)) = O_n(\mathbf{p}_{+ve}(p)) + 1 \quad (3)$$

$$O_n(\mathbf{p}_{-ve}(p)) = O_n(\mathbf{p}_{-ve}(p)) - 1 \quad (4)$$

$$M_n(\mathbf{p}_{+ve}(p)) = M_n(\mathbf{p}_{+ve}(p)) + \|\mathbf{g}(p)\| \quad (5)$$

$$M_n(\mathbf{p}_{-ve}(p)) = M_n(\mathbf{p}_{-ve}(p)) - \|\mathbf{g}(p)\| \quad (6)$$

半径 n 处的径向对称性贡献定义为

$$S_n = F_n * A_n \quad (7)$$

式中

$$F_n(p) = \frac{M_n(p)}{k_n} \left(\frac{|\tilde{O}_n(p)|}{k_n} \right)^\alpha \quad (8)$$

$$\tilde{O}_n(p) = \begin{cases} O_n(p) & O_n(p) < k_n \\ k_n & \text{其他} \end{cases} \quad (9)$$

A_n 是一个 2 维高斯核函数, α 为径向严格度参数, k_n 是一个归一化因子,可实现在不同半径下对 M_n 和 O_n 的标准化。

整个变换定义为所有半径 $n \in N$ 上对称性贡献的平均值,即

$$S = \frac{1}{|N|} \sum_{n \in N} S_n \quad (10)$$

该变换的完整步骤如图 3 所示 (Loy 和 Zelinsky, 2003)。

FRST 应用于人眼的效果如图 4 所示。FRST 中利用图像梯度定位高度径向对称点的思想,使其十分适合于圆的检测,同时,它无需像 CNN 遍历整个圆,只需利用圆周及其周边部分像素即可完成变换 (如图 5 所示,图中右侧数据表示使用不同方法时,所遍历像素中有效像素和冗余像素的比值),因而计算复杂度低,运行速度快。

1.2.2 FRST 应用于遥感图像油罐目标

本文基于分辨率 0.8 m 的 Skysat 卫星进行分析和实验。

对油罐图像进行 FRST 特征提取的分析如图 6 所示,针对 68×68 像素的图像进行了不同半径输入的 FRST 变换,可以看到:1) 变换的效果极大受制于所输入的半径范围,范围越广则效果越差,这导致变换极度依赖半径这一先验知识;2) 油罐浮动顶低于罐壁时,在图像中会呈现出明显较亮和较暗的两个区域 (图 6(a) 原图),这使得浮动顶边界的像素在变换时有部分正影响像素与负影响像素相互抵消,从而影响方向投影图、幅度投影图的像素值分布 (Ok 和 Başeski, 2015),进而影响最终的变换结果;3) 最终的对称映射是对所有半径的贡献平均之后




图3 FRST示意图

Fig. 3 Schematic diagram of FRST



图4 FRST 应用于人眼

Fig. 4 FRST method applied to the human eye

((a) original image; (b) transformed image)




图5 CNN、FRST处理圆形结构目标所需遍历的像素数对比

Fig. 5 Comparison of the number of pixels traversed by CNN and FRST to process circular objects ((a) CNN; (b) FRST)

产生的,因此,变换的输出中积累了不同的半径信息,只要输入的半径是一个范围而非单个值,就无法计算出投影矩阵在特定位置和特定半径处的像素数,从而无法达到精确定位圆心及确定半径的目的。

基于以上分析发现,对于遥感图像油罐目标的定位问题,仅利用FRST难以达到较好的精度和较高的自动化水平,值得注意的是,FRST对圆周的变换具备缩小圆心位置范围的能力,且对小半径范围具有良好的变换效果,因此可以考虑将其与其他方




图6 运行结果对比

Fig. 6 Comparison of results((a) original image;

(b) when the radius is 23.5; (c) when the radius

range is [20,27]; (d) when the radius range is [1,34])

法结合,以更好地实现油罐的精确定位。

1.3 基于FRST的CNN油罐目标定位与参数提取方法

1.3.1 方法概述

FRST无法精确定位圆心及确定半径,能缩小圆心位置范围,实现圆周特征的空间聚合。本文将FRST与CNN结合构建网络参数,提出基于FRST的CNN方法,方法原理如图7所示。CNN处理圆形结构目标时,为使圆心处的感受野包含圆的特征,必须通过多层堆叠来扩张感受野,效率较低;而FRST能在圆心附近对圆周像素进行累加,聚合效率较高,因此本文将原图像和经FRST处理后的图像以叠加成双通道的方式组合,这将使得圆心处感受野大大扩张。3种方法的计算位置与处理特征位置的对比如表1所示,卷积运算和FRST分别只有在圆周、圆心处计算时能够处理到圆周处的特征,新方法将它们组合之后,在圆周、圆心处均能处理到圆周处的特征。




图7 CNN、FRST、新方法应用于圆形结构目标的原理图

Fig. 7 Schematic diagram of CNN, FRST, and new methods applied to circular objects

((a) CNN applied to circular objects; (b) FRST applied to circular objects; (c) FRST-based CNN applied to circular objects)

表1 3种方法对比

Table 1 Comparison of three methods

计算位置	能否处理到圆周处特征		
	卷积运算	FRST	卷积运算 + FRST
圆周	✓	×	✓
圆心	×	✓	✓

1.3.2 方法流程

方法流程如图8所示。

1) 数据集准备。本文利用 Skysat 卫星数据, Skysat 卫星是一颗业务型商业对地观测的亚米分辨率微卫星(龚然,2016),文中实验数据集是基于 0.8 m 分辨率 SkySat 图像制作的 1 312 幅图像切片,选择油罐半径、罐顶圆心位置及阳光投射到浮动顶上的圆弧对应的圆心位置进行标注,按接近 4 : 1 的比例分为 1 024 个训练集样本和 288 个测试集样本,创

建数据集。

2) 预处理。采用双线性插值法,将样本图像压缩至统一尺寸。

3) 定义 CNN。本文设计了两种多层的 CNN 结构。将第 1 种网络命名为 net_c2(“c”意为 convolution),其结构模型如图 9 所示,共分为 3 个部分:输入层、隐藏层及输出层。输入层为所输入的样本数据;隐藏层是网络的关键部分,包含 2 个卷积层和 2 个 BN(batch normalization)层,其中,卷积层均由一个滤波器层、一个空间采样层和一个非线性层组成,非线性层通过 ReLU 激活函数来实现,考虑到最大池化对像素点的抽样位置不定,会影响油罐的精确定位,因而未添加池化层,而是通过将 2 个卷积层的卷积步长(stride)设置为 2 来实现抽样;输出层为全连接层,设计为一个 3 层感知器,每层输出特征数分别为 120、84、5。样本输入网络之后,通过隐藏层




图8 方法流程图

Fig.8 Flow chart of the method




图9 net_c2 网络结构模型

Fig.9 Structural model of net_c2 network

的运算进行特征提取,最后由全连接层完成对相关参数的预测。将第2种网络命名为net_c3,在net_c2的

第2个BN层之后再加上1个卷积层和1个BN层,其他不变,其结构模型如图10所示。




图10 net_c3 网络结构模型

Fig.10 Structural model of net_c3 network

4) 训练网络。选择适用于回归的 L1 损失函数作为损失函数,即

$$L_1(y, \hat{y}) = \sum_{i=0}^m |\hat{y}^{(i)} - y^{(i)}| \quad (11)$$

式中, y 表示真实值, $\hat{y}$ 表示模型的输出。

出于收敛速度和精度的考虑,选用适应性矩估

计 (adaptive moment estimation, Adam) 算法来更新网络参数。

对训练集样本进行训练,绘制损失曲线,通过观察曲线走势判断训练情况。

5) 测试集上测试网络。利用测试集样本进行测试,计算 5 个参数各自和总的平均损失,绘制以样

本为单位的损失曲线。

2 实验结果和分析

2.1 实验设计和安排

本文设计了 4 个实验,如表 2 所示。

表 2 实验具体安排		
Table 2 Specific arrangement of experiment		
实验类型	方式	网络结构
对照组 1:浅层 CNN	仅采用 CNN	net_c2
对照组 2:较深层 CNN		net_c3
实验组 1: 基于 FRST 的浅层 CNN	基于 FRST 的 CNN	net_c2
实验组 2: 基于 FRST 的较深层 CNN		net_c3

2.2 实验过程及结果

根据 1.3.2 节中算法进行处理,在随机种子为 0 和 1 的条件下各进行一次实验。

在训练前的准备中,设置优化器 Adam 的学习率为 0.002 5,一阶矩估计的指数衰减率为 0.9,二阶矩估计的指数衰减率为 0.99。通过 MultiStepLR 方法来动态调整学习率,设置 epoch = 300、epoch = 650 处为学习率调整点,学习率调整倍数为 0.5。

在训练过程中,利用训练集的 1 024 个样本即 32 个 batch 进行训练,网络使用 GPU 实现加速训练,设置迭代次数(epoch)为 1 000,绘制损失曲线,通过观察曲线走势判断训练情况。

在测试集上测试网络时,利用测试集的 288 个样本即 9 个 batch 进行测试,对测试结果计算 5 个参数各自和总的平均损失,将样本图像尺寸恢复为压缩前的状态,对样本参数预测值按照相同的压缩比例进行转换,用转换后的结果代表原始尺寸下样本参数的预测值,计算该值与原始样本的真实值之间的损失,绘制以样本为单位的损失曲线。

为保证网络运用在测试集上的效果,先将训练过程中每个 epoch 对应的网络应用在测试集当中,绘制测试集的损失走势图,如图 11 和图 12 所示,为保证展示效果,已对纵轴进行了对数化处理,并进行了平滑处理,设置平滑系数为 0.95。

从图 11 和图 12 中可以看出,在学习率调整点 epoch = 300、epoch = 650 之后,损失均仍是下降的,




图 11 随机种子为 0 的条件下测试集的损失走势图

Fig. 11 Loss trend of test set with random seed 0




图 12 随机种子为 1 的条件下测试集的损失走势图

Fig. 12 Loss trend of test set with random seed 1

得到该保证之后,将训练好的网络用于测试集的处理,得到对 5 个参数各自的预测损失,绘制箱线图如图 13 和图 14 所示,其中的 x_1 、 y_1 、 x_2 、 y_2 、 r 依次表示




图 13 随机种子为 0 的条件下各参数的预测损失

Fig. 13 Prediction loss of each parameter with random seed 0




图 14 随机种子为 1 的条件下各参数的预测损失

Fig. 14 Prediction loss of each parameter with random seed 1

图像中油罐顶部圆心的 x, y 坐标, 阳光投射到浮动顶上的圆弧对应的圆心的 x, y 坐标及油罐半径。

将图 13 和图 14 中的对照组 1 与实验组 1 进行对比, 对照组 2 与实验组 2 进行对比, 可以发现, 实验组的平均值普遍低于对应的对照组, 实验组的四分位间距普遍小于对应的对照组, 说明无论处于浅层网络还是较深层网络, 基于 FRST 的 CNN 始终比仅采用 CNN 的预测精准度更高, 且稳定性更好。

4 个实验中的 5 个参数的平均预测误差结果如表 3。

为了衡量基于 FRST 的 CNN 方法对于计算效率的影响, 现引入参数量 (params) 和衡量计算量的 MAC (multiplication and addition counts) 对不同网络进行评估, 结果如表 4。根据表 4 绘制图 15, 图中标注的数据表示在 net_c3 基础上额外添加的卷积层数。

表 3 4 个实验平均预测误差汇总

Table 3 Summary of the average prediction error of the four experiments

随机种子	实验类型	方式	网络结构	平均预测误差/像素
0	对照组 1	仅采用 CNN	net_c2	1.550 9
	对照组 2		net_c3	1.272 5
	实验组 1	基于 FRST 的 CNN	net_c2	1.297 1
	实验组 2		net_c3	1.129 8
1	对照组 1	仅采用 CNN	net_c2	1.679 3
	对照组 2		net_c3	1.408 5
	实验组 1	基于 FRST 的 CNN	net_c2	1.309 6
	实验组 2		net_c3	1.125 4

注: 加粗字体为每个随机种子下的最优值。

表 4 不同网络的预测误差及计算效率

Table 4 Prediction error and calculation efficiency of different networks

方式	参数	在 net_c3 基础上额外添加的卷积层数		
		0	5	15
仅采用 CNN	参数量	2.357	3.095	4.571
	MAC	30.42	174.9	463.9
	预测误差/像素	1.21	1.07	0.95
方式	参数	在 net_c3 基础上额外添加的卷积层数		
		0	4	8
基于 FRST 的 CNN	参数量	2.357	2.947	3.538
	MAC	30.42	146	261.6
	预测误差/像素	1.18	0.97	0.91

结合表 4 和图 15 可以看到:

1) 额外添加层数为 0 的参数量和计算量相同, 但基于 FRST 的 CNN 方法的预测误差小于仅基于 CNN 的方法。

2) 基于 FRST 的 CNN 方法下添加 4 层的预测误差与基于 CNN 的方法下添加 15 层的预测误差相

接近, 但后者的参数量是前者的 1.6 倍, 计算量是前者的 3.2 倍。

3) 在两种方法下, 参数量和计算量均随着网络层数的增加而增长, 但是基于 FRST 的 CNN 的方法明显增长得更慢, 因此, 该方法有效地降低了参数量和计算量, 即提升了计算效率。




图15 不同网络的预测误差及计算效率

Fig. 15 Prediction error and calculation efficiency of different networks

3 结 论

为了提升遥感图像油罐目标定位和参数提取的精准度和稳定性,本文提出了基于 FRST 的 CNN 方法。基于 SkySat 数据库的 4 个实验结果表明:

1) 基于 FRST 的 CNN 方法相比普通 CNN 方法,平均预测误差降低了 17.42%,该方法有效提升了精度。

2) 浅层网络中,平均预测误差降低了 19.19%,较深层网络中,平均预测误差降低了 15.66%。说明提出的方法在网络层数增加时仍优于仅采用 CNN 的方法。

本文的主要工作和创新点在于:讨论了 FRST 和 CNN 方法各自的优缺点,设计了基于 FRST 的 CNN 方法,有别于传统深度学习通过牺牲分辨率或增大模型来扩张感受野的方式,只需要增加一些计算量,即可高效聚合空间特征,有效提升油罐目标定位和参数提取的精度和稳定性,也提升了实际应用中的实时性。

本文的不足之处在于:只设计了一种结合方式,在今后的工作中,将继续探索传统参数化特征提取算法与深度学习算法的结合方式。

参考文献 (References)

Cai X Y and Sui H G. 2015. A saliency map segmentation oil tank detection method in remote sensing image. *Electronic Science and Technology*, 28(11): 154-156, 160 (蔡肖芋, 眭海刚. 2015. 一种显著图分割的遥感油库检测方法. *电子科技*, 28(11): 154-156, 160) [DOI: 10.16180/j.cnki.issn1007-7820.2015.11.041]

Duda R O and Hart P E. 1972. Use of the Hough transformation to detect lines and curves in pictures. *Communications of the ACM*, 15(1): 11-15 [DOI: 10.1145/361237.361242]

Gong R. 2016. "Sky Sat". *Satellite Application*, (7): 82 (龚燃. 2016. "天空卫星". *卫星应用*, (7): #82)

Han X W, Fu Y L and Li G. 2011. Oil depots recognition based on improved Hough transform and graph search. *Journal of Electronics and Information Technology*, 33(1): 66-72 (韩现伟, 付宜利, 李刚. 2011. 基于改进 Hough 变换和图搜索的油库目标识别. *电子与信息学报*, 33(1): 66-72) [DOI: 10.3724/SP.J.1146.2010.00112]

He K M, Zhang X Y, Ren S Q and Sun J. 2015. Deep residual learning for image recognition [EB/OL]. [2020-10-01]. <https://arxiv.org/pdf/1512.03385.pdf>

Hinton G E, Osindero S and Teh Y W. 2006. A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7): 1527-1554 [DOI: 10.1162/neco.2006.18.7.1527]

Kimme C, Ballard D and Sklansky J. 1975. Finding circles by an array of accumulators. *Communications of the ACM*, 18(2): 120-122 [DOI: 10.1145/360666.360677]

Krizhevsky A, Sutskever I and Hinton G E. 2012. ImageNet classification with deep convolutional neural networks//*Proceedings of the 25th International Conference on Neural Information Processing Systems*. Lake Tahoe, USA: Curran Associates Inc.: 1097-1105

LeCun Y, Boser B, Denker J S, Henderson D, Howard R E, Hubbard W and Jackel L D. 1989. Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1(4): 541-551 [DOI: 10.1162/neco.1989.1.4.541]

LeCun Y, Bengio Y and Hinton G. 2015. Deep learning. *Nature*, 521(7553): 436-444 [DOI: 10.1038/nature14539]

Loy G and Zelinsky A. 2003. Fast radial symmetry for detecting points of interest. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 25(8): 959-973 [DOI: 10.1109/TPAMI.2003.1217601]

Meng F S. 2012. Review of change detection methods based on remote sensing images. *Technology Innovation and Application*, (24): 57, 58 (孟繁烁. 2012. 基于遥感影像的变化检测方法综述. *科技创新与应用*, (24): 57, 58)

Ok A O and Başeski E. 2015. Circular oil tank detection from panchromatic satellite images; a new automated approach. *IEEE Geoscience and Remote Sensing Letters*, 12(6): 1347-1351 [DOI: 10.1109/LGRS.2015.2401600]

Reisfeld D, Wolfson H and Yeshurun Y. 1995. Context-free attentional operators: the generalized symmetry transform. *International Journal of Computer Vision*, 14(2): 119-130 [DOI: 10.1007/BF01418978]

Sela G and Levine M D. 1997. Real-time attention for robotic vision. *Real-Time Imaging*, 3(3): 173-194 [DOI: 10.1006/rtim.1996.0057]

Shin B G, Park S Y and Lee J J. 2007. Fast and robust template mat-


- hing algorithm in noisy image//Proceedings of 2007 International Conference on Control, Automation and Systems. Seoul, Korea (South): IEEE; 6-9 [DOI: 10.1109/iccas.2007.4406869]
- Sui X L, Zhang T and Qu Q X. 2019. Application of deep learning in target recognition and position in remote sensing images. Technology Innovation and Application, (34): 180-181 (隋雪莲, 张涛, 曲乔新. 2019. 深度学习在遥感影像目标识别与定位中的应用研究. 科技创新与应用, (34): 180-181)
- Sun Z J, Xue L, Xu Y M and Wang Z. 2012. Overview of deep learning. Application Research of Computers, 29(8): 2806-2810 (孙志军, 薛磊, 许阳明, 王正. 2012. 深度学习研究综述. 计算机应用研究, 29(8): 2806-2810) [DOI: 10.3969/j.issn.1001-3695.2012.08.002]
- Wang Y J, Zhang Q, Zhang Y M, Meng Y and Guo W. 2019. Oil tank detection from remote sensing images based on deep convolutional neural network. Remote Sensing Technology and Application, 34(4): 727-735 (王颖洁, 张莽, 张艳梅, 蒙印, 郭文. 2019. 基于深度卷积神经网络的油罐目标检测研究. 遥感技术与应用, 34(4): 727-735) [DOI: 10.11873/j.issn.1004-0323.2019.4.0727]
- Wu X D, Feng W F, Feng Q Q, Li R S and Zhao S. 2015. Oil tank extraction from remote sensing images based on visual attention mechanism and Hough transform. Journal of Information Engineering University, 16(4): 503-506 (吴晓东, 冯伍法, 冯倩倩, 李润生, 赵爽. 2015. 基于视觉注意机制和 Hough 变换融合的遥感影像油罐提取. 信息工程大学学报, 16(4): 503-506) [DOI: 10.3969/j.issn.1671-0673.2015.04.021]
- Xu H P, Chen W, Sun B, Chen Y F and Li C S. 2014. Oil tank detection in synthetic aperture radar images based on quasi-circular shadow and highlighting arcs. Journal of Applied Remote Sensing, 8(1): #083689 [DOI: 10.1117/1.JRS.8.083689]
- Yu S T. 2019. Research on Oil Tank Volume Extraction Based on High Resolution Remote Sensing Image. Dalian: Dalian Maritime University (于圣涛. 2019. 基于高分辨率遥感影像的油罐体积求取研究. 大连: 大连海事大学)
- Zhang J F, Wang Q Q, Wang S Y, Zhang H, Hu X H and Wang R. 2017. Oil tank detection and reserve analysis method based on high-resolution optical remote sensing image. China, 201710727161.4 (张金芳, 王庆全, 王思雨, 张慧, 胡晓惠, 王瑞. 2017. 基于高分辨率光学遥感图像的油罐检测和储量分析方法. 中国, 201710727161.4)
- Zhang W S, Wang C, Zhang H, Wu F, Tang Y X and Mu X P. 2006. An automatic oil tank detection algorithm based on remote sensing image. Journal of Astronautics, 27(6): 1298-1301 (张维胜, 王超, 张红, 吴樊, 汤益先, 穆湘萍. 2006. 基于遥感影像的油罐自动检测算法. 宇航学报, 27(6): 1298-1301) [DOI: 10.3321/j.issn:1000-1328.2006.06.035]

作者简介



江晗, 1997 年生, 女, 硕士研究生, 主要研究方向为深度学习和图像处理。

E-mail: jianghan191@mails.ucas.ac.cn



张月婷, 通信作者, 女, 副研究员, 主要研究方向为合成孔径雷达图像解释、SAR 图像模拟和散射计算。

E-mail: zhangyueying06@mails.gucas.ac.cn

郭嘉逸, 男, 助理研究员, 主要研究方向为 SAR 三维重建、深度学习。E-mail: 1047247844@qq.com

赵鑫, 男, 硕士研究生, 主要研究方向为深度学习和 SAR 图像处理。E-mail: zhaoxin195@mails.ucas.ac.cn

李芳芳, 女, 副研究员, 主要研究方向为干涉 SAR 信号处理、SAR 三维成像。E-mail: fli1@mail.ie.ac.cn

黄丽佳, 女, 副研究员, 主要研究方向为图像处理。

E-mail: iecas8 huanglijia@163.com

胡玉新, 男, 研究员, 主要研究方向为 SAR 图像处理与应用、光学图像处理与应用。E-mail: yxhu@mail.ie.ac.cn

雷斌, 男, 研究员, 主要研究方向为 SAR 图像处理与应用、光学图像处理与应用。E-mail: leibin@mail.ie.ac.cn

丁赤飏, 男, 研究员, 中国科学院院士, 主要研究方向为 SAR 图像处理与应用、光学图像处理与应用。E-mail: cbding@mail.ie.ac.cn