




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

中国图象图形学报

2021
08
VOL.26

ISSN1006-8961
CN11-3758/TB



“高光谱图像处理与应用”专刊



第26卷第8期 (总第304期)

2021年8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



高光谱图像在生物医学中的应用(第1764页)



HSRS-SC:面向遥感场景分类的高光谱图像数据集(第1809页)



多尺度超像素分割和奇异谱分析的高光谱影像分类(第1978页)

序言 何明一 I

编者按 II

综述

高光谱图像空谱特征提取综述

叶珍, 白璘, 何明一 1737

高光谱图像在生物医学中的应用

李伟, 吕蒙, 陈天虹, 楚照耀, 陶然 1764

高光谱成像技术新进展

近红外高光谱图像数据预测技术

梅少辉, 张博威, 马明阳, 贾森 1786

低成本便携式多光谱成像系统的研发及优化

朱豪男, 胡孟晗, 张健, 李庆利 1796

数据集论文

HSRS-SC:面向遥感场景分类的高光谱图像数据集

徐科杰, 邓培芳, 黄鸿 1809

高光谱医学诊断

膜性肾病诊断的高光谱图像张量嵌入分析

吕蒙, 陈天虹, 李伟, 杨悦, 涂天琪, 李文歌 1823

傅里叶变换通道注意力网络的胆管癌高光谱图像分割

郑少佳, 邱崧, 李庆利, 周梅, 胡孟晗, 于观贞 1836

高光谱图像目标检测与识别

局部梯度轮廓变换的高光谱异常检测

胡静, 张钰婧, 赵明华, 李鹏, 李云松 1847

结合孪生网络和像素配对的高光谱图像异常检测

王德港, 饶伟强, 孙旭, 渠瀛, 刘雪梅, 高连如 1860

粗定位和协同表示的高光谱图像异常检测

胡静, 赵明华, 李鹏, 李云松 1871

高光谱图像深度模糊核聚类的洋底锰结核识别

张启忠, 郑恩迪, 王叶剑, 高发荣 1886

高光谱图像融合与恢复

波段自适应细节注入的高分五号与Sentinel-2遥感影像空谱融合

王海荣, 郭擎, 李安 1896

基于频率加权张量核范数的高光谱图像复原

刘盛, 曾海金, 孔文凤, 张鹏丹 1910

高光谱图像分类

面向高光谱图像分类的内容引导卷积深度网络并行实现

刘启超, 肖亮, 杨劲翔 1926

增强类可分性的高光谱图像分类

方帅, 张坤, 张晶, 曹洋, 石为开 1940

高光谱图像分类的自适应决策融合方法

叶珍, 董睿, 陈浩鑫, 白璘 1952

跨数据集评估的高光谱图像分类

潘尔婷, 马泳, 黄珺, 樊凡, 李峰, 马佳义 1969

多尺度超像素分割和奇异谱分析的高光谱影像分类

付航, 孙根云, 赵云华, 潘兆杰, 胡光, 张爱竹 1978

结合倒置特征金字塔和U-Net的高光谱图像分类

程嵩阳, 熊玉洁, 姚瑶, 李庆利 1994

高光谱图像小样本分类的卷积神经网络方法

吴鸿昊, 王立国, 石瑶 2009


3D卷积自编码器高光谱图像分类模型

石延新, 何进荣, 李照奎, 曾志高 2021

封面素材由重庆大学光电工程学院黄鸿教授提供

CONTENTS

JOURNAL OF IMAGE AND GRAPHICS



Application of a hyperspectral image in medical field: a review (P1764)



HSRS-SC: a hyperspectral image dataset for remote sensing scene classification (P1809)



Combining multiscale superpixel segmentation and singular spectral analysis for hyperspectral image classification (P1978)

Review

- Review of spatial-spectral feature extraction for hyperspectral image
Ye Zhen, Bai Lin, He Mingyi 1737
- Application of a hyperspectral image in medical field: a review
Li Wei, Lyu Meng, Chen Tianhong, Chu Zhaoyao, Tao Ran 1764

Advances in Hyperspectral Imaging

- Predicting near-infrared hyperspectral images from visible hyperspectral images
Mei Shaohui, Zhang Bowei, Ma Mingyang, Jia Sen 1786
- Development and optimization of a low-cost and portable multispectral imaging system
Zhu Haonan, Hu Menghan, Zhang Jian, Li Qingli 1796

Dataset

- HSRS-SC: a hyperspectral image dataset for remote sensing scene classification
Xu Kejie, Deng Peifang, Huang Hong 1809

Medical Hyperspectral Imagery

- Tensor-based graph embedding for discriminant analysis of membranous nephropathy hyperspectral data
Lyu Meng, Chen Tianhong, Li Wei, Yang Yue, Tu Tianqi, Li Wen'ge 1823
- Fourier transform channel attention network for cholangiocarcinoma hyperspectral image segmentation
Zheng Shaojia, Qiu Song, Li Qingli, Zhou Mei, Hu Menghan, Yu Guanzhen 1836

Hyperspectral Target Detection and Recognition

- Transformation of local gradient profiles for hyperspectral anomaly detection
Hu Jing, Zhang Yujing, Zhao Minghua, Li Peng, Li Yunsong 1847
- Siamese network with pixel-pair for hyperspectral image anomaly detection
Wang Degang, Rao Weiqiang, Sun Xu, Qu Ying, Liu Xuemei, Gao Lianru 1860
- Rough location and collaborative representation for hyperspectral image anomaly detection
Hu Jing, Zhao Minghua, Li Peng, Li Yunsong 1871
- Recognition of ocean floor manganese nodules by deep kernel fuzzy C-means clustering of hyperspectral images
Zhang Qizhong, Zheng Endi, Wang Yejian, Gao Farong 1886

Hyperspectral Image Fusion and Restoration

- Spatial-spectral fusion based on band-adaptive detail injection for GF-5 and Sentinel-2 remote sensing images
Wang Hairong, Guo Qing, Li An 1896
- Hyperspectral image restoration based on frequency-weighted tensor nuclear norm
Liu Sheng, Zeng Haijin, Kong Wenfeng, Zhang Pengdan 1910

Hyperspectral Image Classification

- Parallel implementation of content-guided deep convolutional network for hyperspectral image classification
Liu Qichao, Xiao Liang, Yang Jinxiang 1926
- Hyperspectral image classification with enhanced class separability
Fang Shuai, Zhang Kun, Zhang Jing, Cao Yang, Shi Weikai 1940
- Adjustive decision fusion approaches for hyperspectral image classification
Ye Zhen, Dong Rui, Chen Haoxin, Bai Lin 1952
- Hyperspectral image classification evaluated across different datasets
Pan Erting, Ma Yong, Huang Jun, Fan Fan, Li Hao, Ma Jiayi 1969
- Combining multiscale superpixel segmentation and singular spectral analysis for hyperspectral image classification
Fu Hang, Sun Genyun, Zhao Yunhua, Pan Zhaojie, Hu Guang, Zhang Aizhu 1978
- Hyperspectral image classification using an inverted feature pyramid network with U-Net
Cheng Songyang, Xiong Yujie, Yao Yao, Li Qingli 1994
- Convolution neural network method for small-sample classification of hyperspectral images
Wu Honghao, Wang Liguang, Shi Yao 2009
- Hyperspectral image classification model based on 3D convolutional auto-encoder
Shi Yanxin, He Jinrong, Li Zhaokui, Zeng Zhigao 2021

中图法分类号: TP751.1 文献标识码: A 文章编号: 1006-8961(2021)08-1786-10

论文引用格式: Mei S H, Zhang B W, Ma M Y and Jia S. 2021. Predicting near-infrared hyperspectral images from visible hyperspectral images. Journal of Image and Graphics, 26(08): 1786-1795 (梅少辉, 张博威, 马明阳, 贾森. 2021. 近红外高光谱图像数据预测技术. 中国图象图形学报, 26(08): 1786-1795) [DOI:10.11834/jig.210184]

近红外高光谱图像数据预测技术

梅少辉^{1*}, 张博威¹, 马明阳¹, 贾森²

1. 西北工业大学电子信息学院, 西安 710129; 2. 深圳大学计算机与软件学院, 深圳 518060

摘要: **目的** 受到传感器光谱响应范围的影响, 可见光区域和近红外区域(400 ~ 2 500 nm)的高光谱数据通常使用不同的感光芯片进行成像, 现有这一光谱区域典型的高光谱成像系统, 如 AVIRIS (airborne visible infrared imaging spectrometer) 成像光谱仪, 通常由多组感光芯片组成, 整个成像系统成本和体积通常比较大, 严重限制了该波段高光谱探测技术的发展。为了能够扩展单感光芯片成像系统获得的高光谱图像的光谱范围, 本文探索基于卷积神经网络的近红外光谱数据预测技术。**方法** 结合 AVIRIS 成像光谱仪的光谱配置, 设计了基于残差学习的红外波段图像预测网络, 利用计算成像的方式从可见光范围的高光谱图像预测出近红外波段的光谱图像, 并在典型的卫星高光谱遥感数据上进行红外光谱预测重构和基于重构的数据分类实验, 以验证论文提出的红外光谱数据预测技术的可行性以及有效性。**结果** 本文设计的预测网络在 Cuprite 数据集上得到的预测近红外图像峰值信噪比为 40.145 dB, 结构相似度为 0.996, 光谱角为 0.777 rad; 在 Salinas 数据集上得到的预测近红外图像峰值信噪比为 39.55 dB, 结构相似度为 0.997, 光谱角为 1.78 rad。在分类实验中, 相比于只使用可见光图像, 利用预测的近红外图像使得支持向量机 (support vector machine, SVM) 的准确率提升了 0.6%, LeNet 的准确率提升了 1.1%。**结论** 基于 AVIRIS 传感器获取的两组典型卫星高光谱数据实验表明, 本文提出的红外光谱数据预测技术不仅可基于计算成像的方式扩展可见光光谱成像系统的光谱成像范围, 对于减小成像系统体积和质量具有重要意义, 而且可有效提高可见光区域光谱图像数据在典型应用中的处理性能, 对于提高高光谱数据处理精度提供新的技术支撑。

关键词: 深度学习; 卷积神经网络 (CNN); 高光谱图像; 光谱预测; 高光谱分类

Predicting near-infrared hyperspectral images from visible hyperspectral images

Mei Shaohui^{1*}, Zhang Bowei¹, Ma Mingyang¹, Jia Sen²

1. School of Electronics and Information, Northwestern Polytechnical University, Xi'an 710129, China;

2. College of Computer Science and Software Engineering, Shenzhen University, Shenzhen 518060, China

Abstract: **Objective** Hyperspectral remote sensing method is a major development in remote sensing field. It uses a lot of narrow band electromagnetic bands to obtain spectral data. It covers visible, near infrared, middle infrared, and far infrared bands, and its spectral resolution can reach the nanometer level. Therefore, hyperspectral remote sensing can find more surface features and has been widely used in covering global environment, land use, resource survey, natural disasters, and even interstellar exploration. Compared with RGB and multispectral images, hyperspectral images not only can improve the information richness but also can provide more reasonable and effective analysis and processing for the related tasks. As a

收稿日期: 2021-03-19; 修回日期: 2021-04-22; 预印本日期: 2021-04-29

* 通信作者: 梅少辉 meish@nwpu.edu.cn

基金项目: 国家自然科学基金项目 (61671383); 中央高校基本科研业务费专项资金资助

Supported by: National Natural Science Foundation of China (61671383)

result, they have important application value in many fields. However, the cost of spectral detection systems is relatively high, especially the optical detector that is used to acquire high spectral data. At present, most of the spectrometers can support the spectral imaging from 400 nm to 1 000 nm, while few of them support that from 1 000 nm to 2 500 nm. The reason is that the spectrometer is harder to produce and more expensive with the increase in spectra. The bands of hyperspectral images have internal relations. The performance of low-spectrum spectrometer can be improved by fully utilizing the low spectra to predict high spectra. In other words, the low spectrum spectrometer can be used to obtain the high spectra that are near the spectra which are usually obtained by high-spectrum spectrometer. The cost of getting hyperspectral images will be greatly reduced. Therefore, high spectra prediction has promising applications and prospects in improving spectrometer performance. Nowadays, a single sensor can generally take a limited number of spectra. Thus, the commonly used spectrometers contain multiple sensors. If one of these sensors suffers from a sudden situation and cannot work normally in the process of flight aerial photography, then the data we can obtain will be unusable and we will have to have a flight again, which will cause cost increase and resource waste. Similarly, if a spectrometer mounted on a satellite fails to work normally in case of emergency, then it will suffer much greater loss. However, if we can fully utilize the low spectra to predict high spectra, which means using the low-spectrum spectrometer to obtain the hyperspectral image that is near the spectra from real high-spectrum spectrometer, the loss caused by these situations can be compensated in a great extent. **Method** In recent years, convolutional neural networks (CNNs) have been widely used in various image processing tasks. We propose a hyperspectral image prediction framework based on a CNN as inspired by the great achievements of deep learning in the field of image spatial super resolution. The designed network is based on the residual network, which can fully use multi-scale feature maps to obtain better performance and ensure fast convergence. In the CNN, 2D convolution layers use convolution kernels to obtain feature maps, and convolution kernels use relation between space and spectra, which is also helpful to obtain better results. In our network, each of the convolution layers has an activation layer, in which the rectified linear unit function is used. Batch normal layers are used to normalize the feature map, which can improve the feature extracting ability of CNN. Given an input, the proposed network extracts the low-band data features of the hyperspectral image. Then, it uses the extracted features together with the original low-spectra data to predict the high-spectra data for predicting the high spectra with the low spectra. We also design an evaluation system to prove the feasibility and effectiveness of the infrared spectrum prediction. The feasibility is evaluated by three classical image quality evaluation indices (peak signal-to-noise ratio (PSNR), structural similarity (SSIM), and spectral angle (SA)). The feasibility is also evaluated by two classical classification evaluation indices (accuracy and average accuracy) by applying our predicted infrared spectrum to classification tasks. **Result** Experiments on Cuprite and Salinas datasets are conducted to validate the effectiveness of the proposed method. On Cuprite dataset, we directly measure the quality of the predicted image through PSNR, SSIM, and SA. On Salinas dataset, we mainly use the predicted image data for classification tasks with support vector machine (SVM) and LeNet. All the experiments are implemented using Torch 1.3 platform with Python 3.7. In our experiments on Cuprite dataset, we use the spectra of the first two sensors to predict the spectra of the third sensor. Five hyperspectral images are present in the original data of Cuprite. The first three spectra of Cuprite are spliced into a large image as the training dataset, and the last two spectra are spliced as the test dataset. In this experiment, 30 training epochs are conducted. The PSNR, SSIM, and SA of the predicted images by the trained network on the test set are 40.145 dB, 0.996, and 0.777 rad, respectively, which indicates that the proposed method can predict high spectra from low spectra, which is near the ground truth. The PSNR, SSIM, and SA on the Salinas dataset are 39.55 dB, 0.997, and 1.78 rad, respectively. The accuracy and average accuracy of SVM and LeNet by using the predicted high-spectra data for classification are both improved by approximately 1% compared with the results which use only low-spectra data. **Conclusion** Although many CNN methods have been proposed to realize spatial super resolution, few of them realize spectral super resolution, which is also important. Therefore, we propose the new application in remote sensing field called spectrum prediction, which uses a CNN to predict high spectra from low spectra. The proposed method can expand the use efficiency of sensor chips and also help deal with spectrometer failure and improve the quality of spectral data.

Key words: deep learning; convolutional neural network (CNN); hyperspectral image; spectrum prediction; hyperspectral classification

0 引言

高光谱遥感影像具有光谱分辨率高及图谱合一等特点,其光谱分辨率可达到纳米级,提供了比常规图像传感器更丰富且更精确的光谱信息,使得本来在宽波段范围内不可探测的物质在高光谱遥感中可以被探测到。与其他技术相比,高光谱遥感所携带的光谱信息提供了区别地物光谱细微差别的能力,使人们可以识别诸如树木的种类、道路的类型和不同湿润度的土壤等地物以及鉴别伪装和诱饵目标等。基于高光谱影像从图像空间、光谱空间和特征空间分别进行或综合进行探测和识别,能够提高目标和背景的区别能力。因此,目前高光谱遥感已广泛应用于全球环境、土地利用、资源调查、自然灾害甚至星际探测等领域(Huang 和 Zhang,2013;Li 等,2013;Li 等,2015)。

受光电传感器光谱响应范围的限制,目前单片感光成像芯片的光谱响应范围有限,其所组成的高光谱成像系统的成像光谱范围也通常有限,例如目前可见光和近红外范围内的感光芯片,通常最多可支持400~1 000 nm的光谱范围。为了提高高光谱成像系统的光谱范围,目前典型的做法是选用具有多片不同光谱响应范围的感光芯片进行拼接。以国外典型的 AVIRIS (airborne visible infrared imaging spectrometer)传感器为例,其光谱波段范围为400~2 500 nm,共224个波段。实际上该系统由4个感光传感器组成,各感光传感器参数如表1所示。

表1 AVIRIS 传感器参数

Table 1 The parameters of AVIRIS sensors

	波段范围/nm	波段数
传感器 A	360 ~ 670	32
传感器 B	660 ~ 1 280	64
传感器 C	1 260 ~ 1 880	64
传感器 D	1 880 ~ 2 500	64

而同样包含可见光和近红外波段的 HYDICE (hyperspectral digital image collection experiment)传感器由3个感光传感器组成,其光谱范围为400~2 500 nm,共210个波段,各感光传感器参数如表2所示。因此,目前能够覆盖400~2 500 nm波段范

围的高光谱成像仪系统体积通常比较大,研制成本非常高,严重制约了高光谱遥感的应用深度和广度。

表2 HYDICE 传感器参数

Table 2 The parameters of HYDICE sensors

	波段范围/nm	波段数
传感器 A	400 ~ 1 000	60
传感器 B	1 000 ~ 1 900	90
传感器 C	1 900 ~ 2 500	60

机器学习技术(Huang 等,2017)可以利用现有数据对其关联的未知数据进行预测,尤其是深度学习等智能信号处理技术(Koundinya 等,2018)的不断发展,基于大数据的预测技术可以对未知数据进行更加准确的预测(Mei 等,2017)。目前市场上400~1 000 nm范围的感光芯片比较成熟,其所组成的高光谱成像仪具有成本低、体积小等特点;而1 000~2 500 nm范围的感光芯片国产化程度低,成本非常高,且进口芯片空间分辨率非常低。如果能够利用400~1 000 nm范围区域的高光谱数据采用计算成像的方式预测出近红外域(1 000~2 500 nm)高光谱数据,可大幅度降低可见光—近红外域高光谱图像获取成本,简化可见光—近红外域高光谱成像光谱仪系统的复杂度,对于高光谱遥感技术的推广应用具有重要意义。此外,现有的典型可见光—近红外域成像光谱仪在卫星等平台已经获取了大量图像数据,为利用可见光域高光谱数据预测近红外域高光谱数据提供了大数据基础。

针对这些典型的应用背景,本文拟基于卷积神经网络在大数据信息挖掘以及预测方面的优势,探索从可见光域高光谱数据预测近红外域高光谱数据的可能性,并进一步验证这些预测出的数据对于典型图像处理如高光谱图像分类等的影响。

1 近红外高光谱数据预测技术

高光谱数据包含2维空间信息和1维光谱信息,而本文研究的红外光谱数据预测问题需要预测大量近红外波段图像,问题复杂度非常高。深度神经网络通常包含数以万计的权重等参数,具有很大的容量,可以有效解决这一复杂度非常高的机器学习问题(Xu 等,2021)。据此,本文通过构建卷积神

神经网络从可见光域高光谱数据预测近红外域高光谱数据。

1.1 高光谱波段配置

高光谱图像的波段数量、波段范围、每一个波段对应的中心波长以及光谱宽度均与成像光谱仪的配置有关,包括感光芯片性能和光谱镜头设计等,而且可能会随时间推移有所变化。不同的成像光谱仪,即使成像光谱范围相同,其获取的图像参数也不尽相同。

为了能够探索利用可见光区域高光谱数据预测近红外区域高光谱图像的可能性,本文结合典型的AVIRIS传感器的波段配置进行研究。在本文所使用的数据集中,AVIRIS的传感器D存在较多的噪声波段和无效波段,所以使用传感器A、B的数据来预测传感器C的数据。

1.2 面向光谱预测的卷积神经网络设计

卷积神经网络在图像处理方面有着广泛的应用,如医学图像的识别(陈弘扬等,2021)和目标识别与跟踪等(王献海等,2021),在图像空间超分辨(程德强等,2021)和近红外光谱超分辨(Li等,

2020a)任务中卷积神经网络同样取得了很好的效果。在图像空间超分辨任务中,研究人员提出了诸如多尺度医学图像超分辨(Pan等,2021)、基于残差尺度的注意力神经网络(Fu等,2021)、基于深度学习超分辨网络头部的改进(Koktzoglou等,2021)、轻量化超分辨网络MADNet(Lan等,2021)等研究成果;在近红外光谱超分辨任务中,研究人员提出使用神经网络进行单幅遥感图像光谱超分辨(Liebel和Körner,2016)、2D和3D卷积混合的光谱超分辨网络(Li等,2020b)、3D全连接网络(Mei等,2017)、空谱联合超分辨(Mei等,2020)等基于神经网络的成果。

受这些成果启发,本文提出如图1所示的卷积神经网络模型框架,该网络能够利用高光谱图像的可见光波段数据预测近红外波段数据。网络的输入是除噪声波段外的所有传感器A、B数据;输出是预测的除噪声波段外的所有传感器C数据。本文采用2维卷积网络,每个2维卷积层后接有线性整流函数层(rectified linear unit, ReLU)和归一化层。




图1 近红外光谱预测流程图

Fig. 1 Overview of the proposed near-infrared prediction strategy

图1给出了近红外光谱预测网络结构和流程,本文的预测流程是一个线性的流程,先从原始数据中得到可见光部分的数据,再把可见光数据输入到本文的卷积神经网络中,最后卷积神经网络的输出就是预测的近红外光谱数据。本文的卷积神经网络框架由两部分组成:第1部分由3个卷积层组成,输入除噪声波段外的所有传感器A、B数据;输出提取的各波段特征图;第2部分由两个卷积层组成,输入除带噪声波段外的所有传感器A、B数据与第1部分输出的特征图在光谱维上的连接;输出预测的除噪声波段外的所有传感器C数据。在整个网络的卷积运算中没有改变空间维度的大小。

每一个卷积层后都有一个激活层,本文在激活层中选择使用ReLU(Hu等,2018)函数。因为ReLU函数不仅可以解决梯度消失的问题,改进模型的拟合,而且不需要额外的计算成本,可以降低过拟合风险。假设激活层神经元的输入用 I_i 表示,则输出 O_i 定义为

$$O_i = \max\{I_i, 0\}, \quad i = 1, 2, 3, \dots \quad (1)$$

本文利用批量归一化方法对特征图进行归一化处理,批量归一化层可以提高卷积神经网络的特征提取能力。同时采用均方误差损失(mean-square error, MSE)(Löhdefink等,2020)作为损失函数。均方误差损失函数计算两个光谱对应像素差值平方的均值,均方误差损失定义为

$$MSE = \frac{1}{mn} \sum_{i=1}^n \sum_{j=1}^m \|K(i,j) - I(i,j)\|^2 \quad (2)$$

式中, m, n 为图像的长和宽, $K(i, j)$ 为目标光谱图像第 i 行 j 列的像素, $I(i, j)$ 为预测光谱图像第 i 行 j 列的像素。

表 3 列出了本文设计的卷积神经网络参数的详细信息。实验中采用反向传播算法对所提出的卷积神经网络进行训练。

表 3 各卷积层参数

Table 3 The parameters involved in the CNN

卷积层	输入通道数	输出通道数	核大小	步长	填充
Conv1	76	166	3	1	1
Conv2	166	64	3	1	1
Conv3	64	38	3	1	1
Conv4	114	76	3	1	1
Conv5	76	38	3	1	1

1.3 红外光谱预测评价体系

为了验证红外光谱预测的可行性和有效性, 本文提出了一种红外光谱预测评价体系, 体系结构如图 2 所示。首先把图像数据分为可见光数据和近红外数据, 再基于可见光数据利用红外光谱预测网络得到预测近红外数据, 然后分别用可见光数据和可见光数据加上预测近红外数据进行分类实验, 最后通过图像质量评价指标分析预测近红外数据和真实近红外数据验证可行性, 通过分类结果评价指标分析两次分类结果可验证有效性。

1.3.1 图像质量评价指标

峰值信噪比 (peak signal to noise ratio, PSNR) 是评价光谱质量最常用的标准之一。它表示信号的最大可能功率和影响其表示精度的破坏性噪声功率之间的比率。峰值信噪比采用均方误差计算, 具体为

$$f_{\text{PSNR}} = 10 \times \lg \frac{MAX^2}{MSE} \quad (3)$$




图 2 红外光谱预测评价体系结构图

Fig. 2 The architecture of infrared spectrum prediction and evaluation system

式中, MAX 是目标光谱图像中像素点的最大值, MSE 是两个光谱之间的均方误差。峰值信噪比值一般为 $30 \sim 40$ dB。值越高, 光谱质量越好。

结构相似性 (structural similarity, SSIM) 主要用来衡量预测光谱图像的结构质量。对于 x, y 两幅光谱图像, SSIM 定义为

$$f_{\text{SSIM}}(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (4)$$

式中, μ_x 是图像 x 的平均值, μ_y 是图像 y 的平均值, σ_x^2 是图像 x 的方差, σ_y^2 是图像 y 的方差, σ_{xy} 是图像 x 和图像 y 的协方差, c_1, c_2 是稳定的常数。当两个光谱图像相同时, SSIM 的值为 1。

光谱角 (spectral angle, SA) 指标将图像每个像素的光谱维度作为一个向量, 通过计算两个向量之间的夹角来度量光谱之间的相似性。角度越小, 两个光谱越相似。两个向量 (X^* 表示未知向量, X_i 表示已知向量) 之间的夹角是根据两个向量的余弦值计算的, 具体为

$$\theta(X^*, X_i) = \cos^{-1} \left(\frac{X_i^T X^*}{(\|X_i\|)(\|X^*\|)} \right) \quad (5)$$

1.3.2 分类结果评价指标

总体准确率和平均准确率是最常用的分类结果评价指标。对于共有 m 类的数据集, 第 i 类的样本数为 N_i , 第 i 类分类正确的结果为 n_i , 则平均准确率 (average accuracy, AA) 和总体准确率 (accuracy, A)

OA) 可以表示为

$$f_{AA} = \frac{1}{m} \sum_{i=1}^m \frac{n_i}{N_i} \quad (6)$$

$$f_{OA} = \frac{\sum_{i=1}^m n_i}{\sum_{i=1}^m N_i} \quad (7)$$

2 实验验证

实验使用 Cuprite 数据集 (<http://aviris.jpl.nasa.gov/>) 来验证网络预测的性能。而分类实验使用 Salinas 数据集来验证预测近红外光谱图像的可用性。本文实验使用 Ubuntu18、Pytorch 1.3 平台和 Python 3.7 实现。

2.1 近红外光谱图像预测实验

Cuprite 数据集由 AVIRIS 光谱仪采集, 覆盖美国拉斯维加斯地区, 共包含 224 个波段。剔除所有噪声波段和失真严重的波段后, 共 166 个波段。传感器 A 包含 29 个波段, 传感器 B 包含 50 个波段, 传感器 C 包含 35 个波段, 传感器 D 包含 38 个

波段。

在实验中, 本文基于 Pytorch 框架训练如图 1 所示的网络, 并使用前两个传感器的光谱图像来预测第 3 个传感器的光谱图像。Cuprite 原始数据中有 5 幅高光谱图像, 将前 3 幅光谱图像拼接成一个大的图像作为训练数据集。所得的训练数据集在空间维度上是 614×1536 像素。最后两幅光谱图像被拼接成一幅大的图像作为测试数据集。在训练过程中, 从训练数据集中截取一幅 100×100 像素的图像作为训练数据输入, 移动步长为 10 像素。测试过程中使用整个测试数据集作为测试输入。训练网络采用随机梯度下降 (stochastic gradient descent, SGD) (Wang 和 Dai, 2012) 优化策略, 学习率为 0.01, 并以遍历整个训练图像作为一个训练周期。

本次实验共进行了 30 个训练周期。训练后的网络在测试集上的性能结果为 PSNR: 40.145 dB, SSIM: 0.996, SA: 0.777 rad。实验结果表明, 本文的神经网络可以根据传感器 A、B 的数据预测出传感器 C 波段数据。训练过程中 PSNR 和损失的变化如图 3 所示, 从图 3 可以看出, PSNR 快速增加, 损失快速收敛。




图3 峰值信噪比 PSNR 和 MSE 损失变化

Fig.3 The PSNR and MSE loss during training((a) PSNR;(b) MSE loss)

图 4 显示了测试数据集中每个像素的均方根误差 (root mean square error, RMSE) 结果。均方根误差由每个像素的预测谱和相应的真值谱计算得出。从图 4 中可以看出, 大多数像素的均方根误差都很低。图 5 给出了预测红外图像波长与峰值信噪比之间的关系, 可以看出, 随着波长的增加峰值信噪比在下降, 这是由于随着红外波长的增加, 预测图像与已有可见光光谱图像之间的相关性下降, 必然造成预

测精度的下降。图 6 为原始波段图像与预测波段图像对比图。本文选择 4 个预测谱及其对应的真值谱进行直观比较, 还将其均方根误差显示为带有色度条的图像。

在近红外光谱预测中, 光谱维度信息主要影响预测结果, 但空间信息也会在一定程度上影响预测结果。卷积神经网络使用卷积核来预测光谱, 卷积核会在一定程度上使用空间信息, 因此, 本文的




图4 每个像素点的均方根误差
Fig.4 Per-pixel RMSE in test dataset




图5 峰值信噪比随预测波长变化图
Fig.5 The PSNR for the predicted infrared image of different wavelength




图6 原始波段图像与预测波段图像对比
Fig.6 Comparison of the original spectra and the prediction spectra
((a) ground near-infrared images ; (b) predicted results ; (c) RMSE loss)

预测近红外光谱图像方法不仅充分利用了光谱信息,而且利用了空间信息。卷积核的大小和层数都影响预测的光谱图像像素点所采用的原始像素个数,即利用的空间信息范围的大小。本文在相同卷积层数下选择4个不同大小的卷积核来证明空间信息对预测结果的影响。不同卷积核大小下的最佳效果如表4所示。

表4 不同卷积核大小所对应的实验结果
Table 4 Experimental results for different convolution kernels

卷积核大小	训练损失	测试损失	PSNR/dB	SSIM	SA/rad
5×5	0.006 5	0.012 6	37.027	0.993	0.825
7×7	0.007 5	0.011 4	37.950	0.992	0.874
11×11	0.005 4	0.008 8	40.145	0.996	0.777
15×15	0.003 7	0.009 0	40.013	0.996	0.675

本文随机选择一个像素点绘制了如图7所示的光谱曲线图。从图7中可以直接看到不同卷积核大小对应的不同预测结果。从表4和图7很明显可以看出,增大卷积核大小对提高预测光谱的效果有好处,但其所对应的计算量是以平方数量级增长的,所以本次实验采用的卷积核大小为11×11。




图7 不同卷积核大小的预测结果和真值比较

Fig. 7 Comparison of different view predicted spectra and used spectra

2.2 预测近红外光谱图像分类实验

在分类验证任务中,本文选用两种典型的分类器进行验证:1)支持向量机(support vector machine, SVM)(丁世飞等,2018);2)卷积神经网络分类器 LeNet-5(Sun等,2018),LeNet 网络是 LeCun 等人(1998)提出的一种经典的卷积神经网络结构,其架构如图8所示。




图8 LeNet-5 结构图(LeCun 等,1998)

Fig. 8 The architecture of LeNet-5(LeCun et al. , 1998)

本文使用 Salinas 数据集对网络预测的近红外光谱图像进行分类测试。Salinas 利用 AVIRIS 航空高光谱仪获得了美国加利福尼亚州 Salinas 山谷的高空间分辨率高光谱数据。该图包含 224 个波段,本次实验使用去除波段 108~112,154~167 和不能被水反射的 224 波段后剩下的 204 个波段。由于图像的大小为 512×217 像素,所以总共包含 111 104 像素,其中背景为 56 975 像素,可以用于分类的像素为 54 129 像素,总共包含 16 类。

该实验共有 3 个步骤:

1)使用 Salinas 数据集将卷积神经网络权值从 Cuprite 数据集迁移到 Salinas 数据集。

2)使用卷积神经网络来预测 Salinas 数据集的高波段光谱图像。

3)在相同的条件下,用 Salinas 数据集的传感器 A、B 的光谱图像进行分类任务;用 Salinas 数据集的传感器 A、B 的光谱图像和预测的近红外光谱图像进行分类任务;用 Salinas 数据集的传感器 A、B、C 的光谱图像进行分类任务。

本次实验使用 1~96 波段的光谱图像来预测 97~149 波段的光谱图像,同时使用 Salinas 数据集的一半作为权值迁移训练数据集。在步骤 1)中,取训练数据集的 11×11 像素的空间领域作为输入;输出也是 11×11 像素。在步骤 3)中,制作用于 LeNet-5 分类的数据集时,空间领域选取为 3×3 像素。本次分类实验使用每个类的 10% 作为分类训练数据集,其他的用做测试数据集,学习速率设定为 0.01,所使用的批量大小是 128,训练周期数为 5 000。

在步骤 1)之后,得到了迁移后的卷积神经网络,用它来预测 Salinas 数据集从 97~149 波段的光谱图像。所得的预测光谱图像的测试损失值为 0.003 2,峰值信噪比值为 39.55 dB,结构相似性值为 0.997,光谱角值为 1.780 rad。表5展示了 SVM 和 LeNet-5 在 Salinas 数据集上的分类精度。在 SVM 方法分类结果的平均准确率和总体准确率分别从

96.73%和93.26%提高到了97.03%和93.91%,非常接近使用真实近红外数据的97.08%和94.09%,并在大多数类别中得到了分类精度的提升。在LeNet方法分类结果的平均准确率和总体准确率分别提升了0.57%和1.05%,并在大多数类别中实现了分类精度的提升。从这些结果可以看出,使用预测的近红外光谱图像明显提高了分类精度,说明近红外光谱图像预测在分类等应用中对提高性能是非常有效的。

表5 不同方法在Salinas数据集上不同类别的分类准确率
Table 5 The experiment results of different categories over Salinas dataset by different methods

	SVM/LeNet-5		
	不用红外数据	用预测数据	用真实数据
Brocol-1	99.88/98.72	99.61/99.33	99.88/99.83
Brocol-2	99.19/99.17	99.40/99.26	99.79/99.35
Fallow	99.43/99.62	99.32/99.31	99.38/99.31
Fallow-plow	99.60/99.74	99.20/99.74	99.20/99.58
Fallow-smooth	97.84/92.51	99.08/97.79	99.08/97.53
Stubble	99.66/99.37	99.63/99.56	99.88/99.84
Celery	99.65/99.78	99.56/99.65	99.50/99.50
Grapes	83.26/88.21	85.49/88.39	87.17/88.65
Soil	98.45/99.11	98.76/98.89	99.64/99.35
Corn-weeds	95.66/96.88	96.23/95.58	96.00/96.53
Lettuce-4wk	97.92/98.49	97.60/98.08	98.75/96.16
Lettuce-5wk	99.82/99.88	99.94/99.88	99.94/100.00
Lettuce-6wk	99.51/99.58	99.87/100.00	99.45/99.86
Lettuce-7wk	96.88/96.70	97.09/96.18	98.33/99.17
Vinyard-untrained	81.96/58.55	82.39/64.19	80.11/74.22
Vinyard-trellis	99.01/99.80	99.26/99.40	99.13/100.00
平均准确率	96.73/95.38	97.03/95.95	97.08/96.81
总体准确率	93.26/90.36	93.91/91.41	94.09/91.92

3 结 论

本文探索基于可见光光谱数据预测近红外光谱数据的可能性,设计了一个卷积神经网络,根据现有典型卫星遥感数据的可见光部分波段数据预测出近

红外波段数据,并设计了一种红外光谱预测评价体系,验证了近红外光谱图像预测的可行性和有效性。值得注意的是,本文提出的基于深度神经网络的预测算法并不能完全重构出近红外的光谱数据,但通过该预测模型估计出的近红外光谱,可以有效提高仅基于可见光部分光谱数据应用的处理精度,也说明了这种预测研究的有效性。

此外,本文提出的这种光谱预测算法也可以应用于现有多传感器组成的高光谱成像系统,如果其在使用过程中任一成像传感器发生故障,可基于卫星运行过程中已获取的大数据,结合未发生故障传感器获取的光谱数据,预测出故障传感器的光谱数据,可在一定程度上弥补传感器故障造成的损失,这一研究方向值得进一步的探究。

致 谢 本研究得到西北工业大学何明一教授和美国密西西比州立大学杜谦教授的指导和帮助,在此表示感谢。

参考文献 (References)

Chen H Y, Gao J Y, Zhao D, Wang H Z, Song H and Su Q H. 2021. Review of the research progress in deep learning and biomedical image analysis till 2020. Journal of Image and Graphics, 26(3): 475-486 (陈弘扬, 高敬阳, 赵地, 汪红志, 宋红, 苏庆华. 2021. 深度学习与生物医学图像分析2020年综述. 中国图象图形学报, 26(3): 475-486) [DOI: 10.11834/jig.200351]

Cheng D Q, Guo X, Chen L L, Kou Q Q, Zhao K and Gao R. 2021. Image super-resolution reconstruction from multi-channel recursive residual network. Journal of Image and Graphics, 26(3): 605-618 (程德强, 郭昕, 陈亮亮, 寇旗旗, 赵凯, 高蕊. 2021. 多通道递归残差网络的图像超分辨率重建. 中国图象图形学报, 26(3): 605-618) [DOI: 10.11834/jig.200108]

Ding S F, Zhang J, Zhang X K and An Y X. 2018. Survey on multi class twin support vector machines. Journal of Software, 29(1): 89-108 (丁世飞, 张健, 张谢锴, 安悦瑄. 2018. 多分类孪生支持向量机研究进展. 软件学报, 29(1): 89-108) [DOI: 10.13328/j.cnki.jos.005319]

Fu Y, Chen J, Zhang T and Lin Y G. 2021. Residual scale attention network for arbitrary scale image super-resolution. Neurocomputing, 427: 201-211 [DOI: 10.1016/j.neucom.2020.11.010]

Hu Z, Li Y P and Yang Z Y. 2018. Improving convolutional neural network using pseudo derivative ReLU//Proceedings of the 5th International Conference on Systems and Informatics (ICSAI). Nanjing, China; IEEE: 283-287 [DOI: 10.1109/ICSAI.2018.8599372]

- Huang M W, Chen C W, Lin W C, Ke S W and Tai C F. 2017. SVM and SVM ensembles in breast cancer prediction. *PLoS One*, 12(1): #0161501 [DOI: 10.1371/journal.pone.0161501]
- Huang X and Zhang L P. 2013. An SVM ensemble approach combining spectral, structural, and semantic features for the classification of high-resolution remotely sensed imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1): 257-272 [DOI: 10.1109/TGRS.2012.2202912]
- Koktuzoglu I, Huang R, Ankenbrandt W J, Walker M T and Edelman R R. 2021. Super-resolution head and neck mra using deep machine learning. *Magnetic Resonance in Medicine*, 86(1): 335-345 [DOI: 10.1002/mrm.28738]
- Koundinya S, Sharma H, Sharma M, Upadhyay A, Manekar R, Mukhopadhyay R, Karmakar A and Chaudhury S. 2018. 2D-3D CNN based architectures for spectral reconstruction from RGB images// *Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Salt Lake City, USA: IEEE: 957-964 [DOI: 10.1109/CVPRW.2018.00129]
- Lan R S, Sun L, Liu Z B, Lu H M, Pang C and Luo X. 2021. MAD-Net: a fast and lightweight network for single-image super resolution. *IEEE Transactions on Cybernetics*, 51(3): 1443-1453 [DOI: 10.1109/TCYB.2020.2970104]
- Lecun Y, Bottou L, Bengio Y and Haffner P. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11): 2278-2324 [DOI: 10.1109/5.726791]
- Li J, Marpu P R, Plaza A, Bioucas-Dias J M and Benediktsson J A. 2013. Generalized composite kernel framework for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 51(9): 4816-4829 [DOI: 10.1109/TGRS.2012.2230268]
- Li K, Yang S H, Dong R T, Wang X Y and Huang J Q. 2020a. Survey of single image super-resolution reconstruction. *IET Image Processing*, 14(11): 2273-2290 [DOI: 10.1049/iet-ipr.2019.1438]
- Li Q, Wang Q and Li X L. 2020b. Mixed 2D/3D convolutional network for hyperspectral image super-resolution. *Remote Sensing*, 12(10): #1660 [DOI: 10.3390/rs12101660]
- Li W, Du Q and Zhang B. 2015. Combined sparse and collaborative representation for hyperspectral target detection. *Pattern Recognition*, 48(12): 3904-3916 [DOI: 10.1016/j.patcog.2015.05.024]
- Liebel L and Körner M. 2016. Single-image super resolution for multi-spectral remote sensing data using convolutional neural networks. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B3: 883-890 [DOI: 10.5194/isprs-archives-XLI-B3-883-2016]
- Löhdefink J, Hüger F, Schlicht P and Fingscheid T. 2020. Scalar and vector quantization for learned image compression: a study on the effects of MSE and GAN loss in various spaces// *Proceedings of the 23rd IEEE International Conference on Intelligent Transportation Systems*. Rhodes, Greece: IEEE [DOI: 10.1109/ITSC45102.2020.9294350]
- Mei S H, Jiang R T, Li X and Du Q. 2020. Spatial and spectral joint super-resolution using convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 58(7): 4590-4603 [DOI: 10.1109/TGRS.2020.2964288]
- Mei S H, Yuan X, Ji J Y, Zhang Y F, Wan S and Du Q. 2017. Hyper-spectral image spatial super-resolution via 3D full convolutional neural network. *Remote Sensing*, 9(11): #1139 [DOI: 10.3390/rs9111139]
- Pan C, Ren Z W and Zhang J H. 2021. Super resolution algorithm of color rgb image based on convolutional neural network. *Journal of Medical Imaging and Health Informatics*, 11(4): 1188-1194 [DOI: 10.1166/jmihi.2021.3516]
- Sun L, Wang Y H and Dai L Y. 2018. Convolutional neural network protection method of Lenet-5-Like structure// *Proceedings of the 2nd International Conference on Computer Science and Artificial Intelligence*. Shenzhen, China: ACM: 77-80 [DOI: 10.1145/3297156.3297224]
- Wang B B and Dai J N. 2012. Convergence rates of stochastic gradient descent methods. *Journal of Mathematics*, 32(1): 74-78 [DOI: 10.3969/j.issn.0255-7797.2012.01.010]
- Wang X H, Song H H, Zhang K H and Liu Q S. 2021. Object tracking using enhanced second-order network modulation. *Journal of Image and Graphics*, 26(3): 516-526 (王献海, 宋慧慧, 张开华, 刘青山. 2021. 增强二阶网络调制的目标跟踪. *中国图象图形学报*, 26(3): 516-526) [DOI: 10.11834/jig.200145]
- Xu Z Y, Su C and Zhang X C. 2021. A semantic segmentation method with category boundary for land use and land cover (LULC) mapping of very-high resolution (VHR) remote sensing image. *International Journal of Remote Sensing*, 42(8): 3146-3165 [DOI: 10.1080/01431161.2020.1871100]

作者简介



梅少辉, 1984年生, 男, 副教授, 主要研究方向为高光谱遥感图像处理、人工智能与机器学习。

E-mail: meish@nwpu.edu.cn

张博威, 男, 硕士研究生, 主要研究方向为光谱超分辨。

E-mail: zbw_5413@126.com

马明阳, 男, 博士研究生, 主要研究方向为视频总结。

E-mail: mamingyang@mail.nwpu.edu.cn

贾森, 男, 教授, 主要研究方向为人工智能、机器学习和高光谱遥感信息处理。E-mail: senjia@szu.edu.cn