

文章编号: 2095-2163(2022)05-0070-07

中图分类号: TP315

文献标志码: A

基于三通道多尺度密集连接网络的高光谱地物分类研究

邓子青, 杨晨

(贵州大学 大数据与信息工程学院, 贵阳 550025)

摘要: 由于高光谱图像(Hyperspectral Image, HSI)相比于传统图像除了具有空间信息还包含丰富的光谱信息而被广泛应用于各领域中,同时近几年的研究表明使用神经网络可实现良好的分类效果,因此如何构建网络从而有效利用光谱和空间信息并实现高精度分类成为了一个具有挑战性的课题。基于此,为了对 HSI 光谱和空间信息进行有效利用,本文提出三通道多尺度模块用于 HSI 地物分类,该模块充分利用 3D 卷积层构建三通道结构以实现多尺度特征的提取融合。通过多次堆叠该模块以组成骨干网络,使得网络可提取深层次代表性特征;密集连接的引入则减轻了深层次网络的梯度消失问题,从而保证网络的分类性能。本文使用 Indian Pines(IP)、University of Pavia(UP)和 Salinas Valley(SV)三个 HSI 数据集对提出网络进行性能测试。实验结果表明,本文提出网络可有效提取 HSI 光谱空间特征并取得 99.5%以上的分类精确度。

关键词: 高光谱图像分类;密集连接;三通道多尺度架构;光谱空间特征提取

Triple path multi-scale dense connection network for hyperspectral image classification

DENG Ziqing, YANG Chen

(College of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China)

[Abstract] Compared with traditional images, hyperspectral image (HSI) not only has spatial information, but also contains rich spectral information, so it is widely used in various fields. In recent years, the research shows that using neural network can achieve good classification effect. Therefore, how to build a network to realize the effective utilization of spectral and spatial information and achieve high-precision classification has become a challenging topic. In order to use efficiently HSI spectral and spatial information, this paper proposes a triple path multi-scale module for HSI feature classification. This module makes full use of 3D convolution to construct a triple path structure to realize the extraction and fusion of multi-scale features. By stacking the module for several times to form the final network, the network can extract deep-seated representative features; the introduction of dense connections reduces the gradient disappearance problem of deep-seated networks, so as to ensure the classification performance of networks. In this paper, three HSI data sets, Indian pines (IP), University of Pavia (up) and Salinas Valley (SV) are used to test the performance of the proposed network. The experimental results show that the proposed network can effectively extract the spatial features of HSI spectrum and achieve a classification accuracy of more than 99.5%.

[Key words] HSI classification; dense connection; triple path multi-scale structure; spectral-spatial feature extraction

0 引言

HSI 由搭载在不同空间平台上的高光谱传感器、即成像光谱仪捕获,除了包含空间信息外,HSI 还包含从可见光到红外光谱的数百个光谱带。由于其丰富的光谱信息,HSI 已被广泛应用于许多领域,如土地覆盖分类、目标检测和图像分割等^[1-3]。而在 HSI 分类领域,如何充分利用丰富的光谱空间信息是实现高分类精度的关键^[4-6]。

迄今为止,HSI 的分类方法主要分为 2 类:传统方法^[7-9]和基于深度学习的方法^[10-12]。在传统方

法的早期阶段,研究人员倾向于利用丰富的光谱信息,如支持向量机(SVM)^[13]、k-最近邻(KNN)^[14]和多项式逻辑回归(MLR)^[15]。然而,这些基于光谱的方法只考虑光谱信息,实际上空间信息在分类过程中也起着重要作用。在后期,研究人员开始将光谱信息与空间信息相结合,以更好地进行分类。2017年,Lu 等人^[16]提出了 HSI 分类的融合框架。将亚像素、像素和超像素的特征融合为一个复合核,并将复合核送入 SVM 分类器进行分类。基于光谱-空间联合特征的方法取得了令人满意的分类效果,但传统方法主要依靠人工设计的特征,造成了性能

基金项目: 国家自然科学基金(61604046);贵州省科技计划项目(黔科合平台人才[2017]5788号);贵州省科技计划项目(黔科合平台人才[2018]5781号)。

作者简介: 邓子青(1997-),男,硕士研究生,主要研究方向:图像处理。

通讯作者: 杨晨 Email: cilot.c.yang@163.com

收稿日期: 2022-02-17

的局限性。

在过去十年中,由于基于深度学习的方法具有出色的特征提取能力,则已被引入 HSI 分类领域和其他许多图像处理领域。到目前为止,已经提出了许多用于 HSI 分类的深度学习方法。与传统方法一样,研究人员更关注早期的光谱信息。例如, Hu 等人^[17]提出了一种五层 1-D 卷积神经网络(CNN),用于直接分析 HSI 分类的光谱信息。Li 等人^[18]提出了一种像素对方法来学习光谱特征,并通过投票获得最终的分类结果,进一步提高了网络性能。基于 1-D 的方法可以提取光谱信息进行 HSI 分类,此后就开发出基于 2D 和 3D 的方法来利用空间和光谱信息。

目前,研究人员更多地关注基于光谱空间特征的方法,这种方法可以同时利用光谱和空间信息,极大地提高分类精度。Wang 等人^[5]在利用卷积层进行特征提取的基础上添加密集连接缓解深层次网络存在的梯度消失问题,取得了良好的分类结果。Chen 等人^[19]通过减少网络参数使其更易于训练,提出了一种轻量级 CNN,通过使用一维卷积层和二维卷积层来提取光谱和空间特征。为了利用多尺度

感知增强 CNN 的特征提取能力, Pooja 等人^[20]提出了一种用于 HSI 分类的多尺度残差 CNN。研究时使用多尺度扩展卷积来扩展网络的感受野,并取得了令人满意的分类结果。从以上方法来看,基于光谱空间的方法比仅基于光谱信息的方法具有更好的性能,而多尺度感知、密集连接是增强网络特征提取能力的有效手段。

为此,本文提出将多尺度手段和密集连接结构相结合构成一个三通道多尺度特征提取模块,由此可实现 HSI 光谱空间信息的充分利用,并通过多次叠加该模块以提升网络的特征提取能力,从而提高分类精度。

1 实验部分

1.1 三通道多尺度密集连接网络

利用 3D 卷积可以直接提取 HSI 的光谱空间特征,而多尺度手段的引入则使网络可感受不同细节层次的特征。本文将 3D 卷积与多尺度手段相结合构成三通道多尺度模块,以实现光谱空间联合特征的提取。通过堆叠该模块并引入密集连接架构组成最终的分类网络,网络结构如图 1 所示。

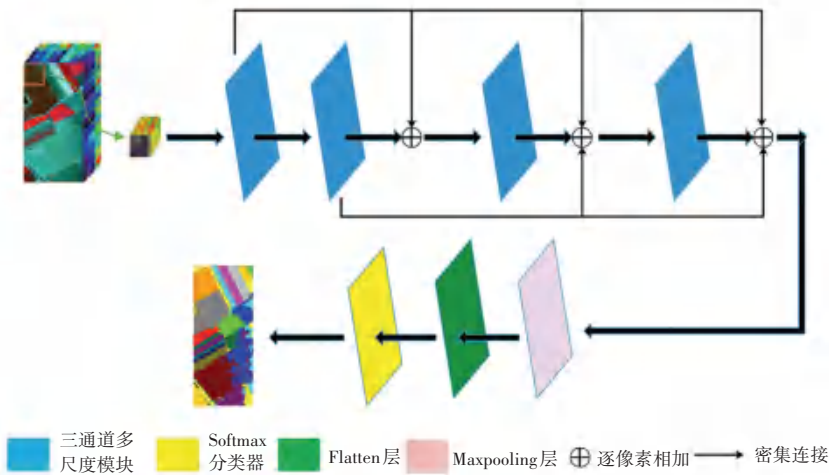


图 1 三通道多尺度特征密集连接网络结构图

Fig. 1 Structure of triple path multi-scale feature dense connection network

首先,将以待分类像素为中心的周围像素块作为输入送入到三通道多尺度模块中。在该模块中,像素块被同时送入并行三通道中进行光谱空间信息的提取。通过改变三通道中卷积核的尺寸,该模块可捕获输入信息的不同细节层次特征。而三通道所提取的特征将通过加法进行特征融合,以得到最终的综合特征。

其次,通过在网络各层引入密集连接以缓解多

次堆叠模块加深网络可能出现的梯度消失问题,不同于其他方法使用级联的方法连接各层,本文将不同层次特征直接相加以降低网络计算量。

最终,在通过多个三通道多尺度模块的特征提取后,深层次综合特征图被送入到最大池化层、平坦层和 Softmax 分类器得到最终分类结果,其分类器可表示为:

$$y^L = \frac{1}{\sum_{j=1}^{numclass} e^{w_j^T f^L}} \begin{pmatrix} \hat{e} \\ e^{w_1^T f^L} \\ \hat{e} \\ e^{w_2^T f^L} \\ \hat{e} \\ \dots \\ \hat{e} \\ e^{w_{numclass}^T f^L} \\ \hat{e} \end{pmatrix} \quad (1)$$

其中, $numclass$ 表示所需分类数量; $e^{w_j^T f^L}$ 表示输入数组值; y^L 表示各样本向量, 而向量值表示样本对应类别的可能性, 并将最大可能性标签作为样本最终分类标签。

该网络通过构建三通道多尺度模块提取 HSI 的

光谱空间综合特征, 模块内使用多尺度策略使得网络可感知不同细节层次上的特征, 而密集连接的引入则缓解了多次堆叠该模块可能导致的梯度消失问题。

1.2 三通道多尺度模块

图 1 给出的结构中, 三通道多尺度模块是网络提取光谱空间综合特征的关键, 该模块主要由 3D 卷积层、并行三通道架构和特征融合组成, 如图 2 所示。

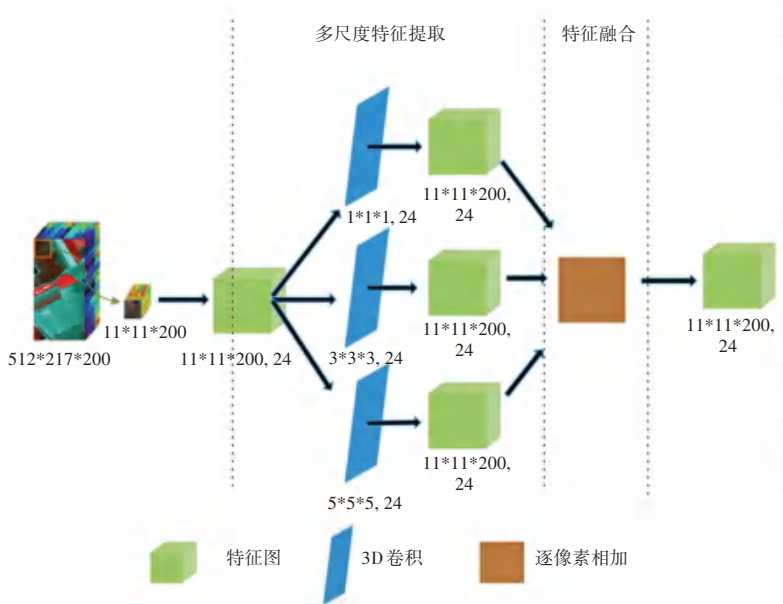


图 2 三通道多尺度模块结构图

Fig. 2 Structure of triple path multi-scale module

设定输入图像尺寸为 $(11 * 11 * 200)$, 在三通道多尺度特征部分, 为实现多尺度光谱空间特征的同时提取, 将图像信息并行输入三通道 3D 卷积层中。其中, 从上到下, 各通道的 3D 卷积核尺寸分别为 $(1 * 1 * 1, 24)$ 、 $(3 * 3 * 3, 24)$ 和 $(5 * 5 * 5, 24)$, 这里的 24 为卷积核数量; 不仅如此, 又使用相同 (same) 填充方式以保证各通道所提取的特征图尺寸维持不变。通过并行三通道的特征提取, 则可获取图像不同感受野下的特征, 三者相互补充。

在特征融合部分, 研究中将三通道得到的光谱空间综合特征图做逐元素相加以实现最终的特征融合。

相比于单独提取光谱和空间特征, 利用 3D 卷积直接提取综合信息加强了 2 种特征间的联系, 使得网络所提取的特征更具鲁棒性。多尺度手段的引入还使得网络可感知不同细节层次上的特征。

1.3 多尺度 3D 卷积

由图 2 可知, 三通道多尺度模块中各通道均使

用不同尺寸的卷积核, 以实现多尺度特征提取。其中, 由于可在 3 个维度上移动进行特征提取, 3D 卷积就常常应用在视频处理、对象识别和 HSI 分类等方面。进一步地, 通过将其与多尺度策略结合, 有利于多感受野的 3D 特征提取, 其原理图如图 3 所示。




图 3 3D 卷积

Fig. 3 3D Convolution

由图 3 可知, 当输入三维数据时, 将其与 3D 卷积核 (Convolution Kernel) 进行卷积, 得到 3D 输出特征图, 研究推得的数学公式可写为:

$$F_j^l = \sum_{i \in M} F_i^{l-1} * k_{ij}^l + b_j^l \quad i = 1, \dots, p \quad j = 1, \dots, q \quad (2)$$

其中, F_j^l, F_i^{l-1} 分别表示 l 和 $l-1$ 层的输出特征图; p, q 分别表示输入和输出特征图的数量; k_{ij}^l 是卷积层的 3D 滤波器; b_j^l 是 l 层输出特征图的偏置量。

2 结果与讨论

2.1 实验数据


为验证网络性能, 实验使用 IP、UP 和 SV 三种不同地物覆盖类型的高光谱数据集作为测试对象, 各数据集介绍如下。

(1) IP 数据集: 印第安纳松树林数据集由 AVIRIS 光谱仪捕获, 具有 145×145 个像素, 空间分辨率为 $20 \text{ m}/\text{像素}$, 其有效频带数为 200 个, 范围从 400 nm 到 2500 nm 。总共有 16 个类别, 其中包含谷物、燕麦和森林等自然植被。

(2) UP 数据集: 帕维尔大学数据集由光学成像仪捕获, 具有 610×340 个像素, 空间分辨率为 $1.3 \text{ m}/\text{像素}$, 其有效波段数为 103 个。总共有 9 个类别, 其中包含柏油路、建筑和草地等城市土地覆盖类型。

(3) SV 数据集: 萨利纳斯山谷由 AVIRIS 传感器获得, 具有 512×217 个像素, 空间分辨率为 $3.7 \text{ m}/\text{像素}$, 其有效频带数为 204 个。总共有 16 个类别, 其中包含芹菜、耕地和残茎等地物覆盖类型。

各数据集伪彩色图像如图 4 所示。



(a) IP (b) UP (c) SV

图 4 3 种数据集影像

Fig. 4 Pictures of three datasets

实验所使用硬件配置为酷睿 i5-3470 处理器、Tesla K40c 科学计算显卡; 网络代码搭建基于 Python 的 Tensorflow 深度学习框架。其中, IP 数据集使用 20% 的样本进行训练, UP 和 SV 使用 10% 的样本进行训练; 网络学习率设置为 0.003; 输入像素块空间尺寸为 $(11 * 11)$ 。量化分类效果, 研究使用 3 种精度指标: OA (Overall Accuracy)、 AA (Average Accuracy) 和 K (Kappa)。其中, OA 表示总体分类精度; AA 表示所有类别的平均分类精度以及 K 表示分类结果与真实标签间的符合程度。

2.2 分类结果


为验证本文提出网络架构有效性, 将本文提出三通道多尺度特征密集网络与基于传统方法的 SVM^[13] 以及基于深度学习方法的堆叠自动编码网络 (SAE)^[21]、3DCNN^[22] 以及 SSRN^[23] 进行对比。研究中在 IP、UP 和 SV 数据集获得的测试结果见表 1~表 3 以及最终的分类结果如图 5~图 7 所示。



(a) 伪彩色图像 (b) 真实标签 (c) SVM (d) 3DCNN (e) SSRN (f) 提出网络

图 5 IP 数据集上的分类结果


Fig. 5 Classification maps for IP datasets



(a) 伪彩色图像 (b) 真实标签 (c) SVM (d) 3DCNN (e) SSRN (f) 提出网络

图 6 UP 数据集上的分类结果

Fig. 6 Classification maps for UP datasets



(a) 伪彩色图像 (b) 真实标签 (c) SVM (d) 3DCNN (e) SSRN (f) 提出网络

图7 SV数据集上的分类结果

Fig. 7 Classification maps for SV datasets

表1 IP数据集上各网络精确度以及训练时间对比

Tab. 1 Classification results and training time of different networks on IP dataset

方法	Results			
	OA/ %	AA/ %	K	Training time/(s · (per epoch) ⁻¹)
SVM	82.67	78.84	0.777 6	6
SAE	92.99	90.76	0.911 8	20
3DCNN	97.08	95.09	0.967 4	34
SSRN	99.39	98.92	0.991 7	92
The proposed	99.63	99.67	0.996 1	40

表2 UP数据集上各网络精确度以及训练时间对比

Tab. 2 Classification results and training time of different networks on UP dataset

方法	Results			
	OA/ %	AA/ %	K	Training time/(s · (per epoch) ⁻¹)
SVM	89.08	89.99	0.872 1	4
SAE	86.10	77.09	0.840 9	25
3DCNN	97.85	97.04	0.974 7	38
SSRN	99.69	99.66	0.995 2	61
The proposed	99.83	99.74	0.997 7	52

表3 SV数据集上各网络精确度以及训练时间对比

Tab. 3 Classification results and training time of different networks on SV dataset

方法	Results			
	OA/ %	AA/ %	K	Training time/(s · (per epoch) ⁻¹)
SVM	92.16	93.09	0.868 0	6
SAE	94.01	95.56	0.931 0	46
3DCNN	96.19	95.35	0.945 3	72
SSRN	99.75	99.77	0.997 5	302
The proposed	99.91	99.81	0.998 9	104

从表1~表3可以看出,本文提出网络架构无论是在分类自然覆盖类型、还是城市建筑覆盖类型均能取得优秀的分类结果。对比其他方法,本文提出网络取得了最优的分类精度。其中,传统算法 SVM 虽然不能取得较高精度的分类结果,但所需训练时间最短;相比于传统算法,虽然 SAE 和 3DCNN 网络的训练时间有所增加,但在各数据集上取得的分类精度均有提升;不同于 SAE 和 3DCNN, SSRN 是专门针对 HSI 分类提出的,故该网络相比较其他均取得了最优的分类精度,在时间上却呈现大幅上升;而与 SSRN 相比,本文提出网络在实现精度提升的同时,显著减少了训练时间。

由图5~图7的分类结果分析可知,研究提出的网络取得了更优的分类结果。在 IP 分类图上分析可知,各分类区域边缘更加平滑且噪点更少;对比各分类区域,UP 分类图上噪点都有所减少;在 SV 分类图上,各分类区域内部基本无错误分类像素点,与真实标签图保持一致。

3 结束语

HSI 拥有丰富的光谱、空间信息,将 2 种信息进行有效结合是实现网络高精度分类的关键。为实现 HSI 光谱空间综合信息的充分利用,本文构建了三通道多尺度特征模块用于光谱和空间域信息的特征提取,多尺度手段的引入使得网络可感知不同感受野下的特征,从而进一步加强所提取特征的代表性。通过多次堆叠该模块以及引入密集连接,使得最终网络可以提取深层次抽象特征。在此基础上,仿真分类结果表明,本文提出网络在 3 个不同地物覆盖类型数据集上取得了 99.5% 以上的分类准确率,对比其他分类网络,本文提出网络在可接受的训练时间范围内取得了最优的分类结果。

参考文献

[1] MAHDIANPARI M, SALEHI B, REZAEI M, et al. Very deep Convolutional Neural Networks for complex land cover mapping using multispectral remote sensing imagery [J]. REMOTE SENSING, 2018, 10(7):1119.

[2] MA Wenping, XIONG Yunta, WU Yue, et al. Change detection in remote sensing images based on image mapping and a deep capsule network [J]. Remote Sensing, 2019, 11(6): 626.

[3] LUO Fulin, DU Bo, ZHANG Liangpei, et al. Feature learning using spatial-spectral hypergraph discriminant analysis for hyperspectral image [J]. IEEE Transactions on Cybernetics, 2019, 49(7): 2406-2419.

[4] ZHU Minghao, JIAO Licheng, LIU Fang, et al. Residual spectral-spatial attention network for hyperspectral image classification

[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(1): 449-462.

[5] WANG Di, DU Bo, ZHANG Lianpei, et al. Adaptive spectral-spatial multiscale contextual feature extraction for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59: 2461-2477.

[6] FAUVEL M, CHANUSSOT J, BENEDIKTSSON J A, et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles [C]// 2007 IEEE International Geoscience and Remote Sensing Symposium. Barcelona, Spain: IEEE, 2007:4834-4837.

[7] JIANG Junjun, MA Jiali, CHEN Chen. SuperPCA: A superpixelwise PCA approach for unsupervised feature extraction of hyperspectral imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(8):4581-4593.

[8] FANG Leyuan, HE Nanjun, LI Shutao, et al. A new spatial-spectral feature extraction method for hyperspectral images using local covariance matrix representation [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(6):3534-3546.

[9] BENEDIKTSSON J A, PALMASON J A, SVEINSSON J R. Classification of hyperspectral data from urban areas based on extended morphological profiles [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3):480-491.

[10] SONG Weiwei, LI Shutao, FANG Leyuan, et al. Hyperspectral image classification with deep feature fusion network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(8): 3173-3184.

[11] PAN Erting, MA Yong, MEI Xiaoguang, et al. Spectral-spatial classification of hyperspectral image based on a joint attention network [C]// IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium. Yokohama, Japan:IEEE, 2019: 413-416.

[12] KANG Xudong, ZHUO Binbin, DUAN Pudong. Dual-path network-based hyperspectral image classification [J]. Geoscience and Remote Sensing Letters, 2019, 16(3): 447-451.

[13] MELGANI F, BRUZZONE L. Classification of hyperspectral remote sensing images with support vector machines [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(8): 1778-1790.

[14] MA Li, CRAWFORD M M, TIAN Jinwen. Local manifold learning-based k-Nearest-Neighbor for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(11):4099-4109.

[15] LI Jun, BIOUCAS-DIAS J M, PLAZA A. Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(11):4085-4098.

[16] LU Ting, LI Shutao, FANG Leyuan, et al. From subpixel to superpixel: A novel fusion framework for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(8):4398-4411.

[17] HU Wei, HUANG Yangyu, WEI Li, et al. Deep Convolutional Neural Networks for hyperspectral image classification [J]. Journal of Sensors, 2015(10): 1-12.

[18] LI Wei, WU Guodong, ZHANG Fan, et al. Hyperspectral image classification using deep pixel-pair features [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(2): 844-853.