

1-8-2019

Deep Learning Method for Hyperspectral Remote Sensing Images with Small Samples

Xiangbin Shi

1. School of Computer, Shenyang Aerospace University, Shenyang 110136, China;;2. College of Information Science and Technology, Liaoning University, Shenyang 110036, China;

Zhong Jian

1. School of Computer, Shenyang Aerospace University, Shenyang 110136, China;;

Cuiwei Liu

1. School of Computer, Shenyang Aerospace University, Shenyang 110136, China;;

Liu Fang

1. School of Computer, Shenyang Aerospace University, Shenyang 110136, China;;

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Deep Learning Method for Hyperspectral Remote Sensing Images with Small Samples

Abstract

Abstract: In order to solve the problem of large information dimension and fewer labeled training samples of hyperspectral remote sensing images, this paper *proposes a hyperspectral remote sensing image classification framework HSI-CNN, which reduces the number of model parameters while maintaining the depth of neural network.* Image pattern invariance and spectral channel contribution rate are analyzed, and the spectral redundancy information is reduced by principal component analysis. *A full convolution neural network structure suitable for small sample hyperspectral remote sensing images is designed and the amount of network parameters is effectively reduced. Three kinds of HSI-CNN structures are proposed and compared.* The experimental results on Pavia University and Salinas hyperspectral remote sensing data sets show that HSI-CNN can extract the spectral feature information only by using a small amount of training samples effectively.

Keywords

hyperspectral remote sensing image classification, deep learning, convolution neural network, spectral redundancy, principal component analysis

Authors

Xiangbin Shi, Zhong Jian, Cuiwei Liu, Liu Fang, and Deyuan Zhang

Recommended Citation

Shi Xiangbin, Zhong Jian, Liu Cuiwei, Liu Fang, Zhang Deyuan. Deep Learning Method for Hyperspectral Remote Sensing Images with Small Samples[J]. Journal of System Simulation, 2018, 30(7): 2744-2752.

小样本高光谱遥感图像深度学习的方法

石祥滨^{1,2}, 钟健¹, 刘翠微¹, 刘芳¹, 张德园¹

(1. 沈阳航空航天大学 计算机学院, 辽宁 沈阳 110136; 2. 辽宁大学 信息科学与技术学院, 辽宁 沈阳 110036)

摘要: 针对高光谱遥感图像光谱信息维度大, 标注训练样本较少的问题, 提出适合小训练样本的高光谱遥感图像分类框架 HSI-CNN, 减少模型参数数量的同时保持神经网络深度。通过主成分分析方法进行图像模式不变性以及光谱通道贡献率分析, 消除光谱冗余信息。设计了适用于小样本高光谱遥感图像的全卷积神经网络结构, 有效降低网络参数数量。提出 3 种 HSI-CNN 结构, 并对不同结构进行了比较分析。在高光谱遥感数据集 Pavia University 和 Salinas 上的实验结果表明, HSI-CNN 能够利用少量训练样本有效地提取光谱特征信息, 取得了较优的分类性能。

关键词: 高光谱遥感图像分类; 深度学习; 卷积神经网络; 光谱冗余; 主成分分析

中图分类号: TP391.4

文献标识码: A

文章编号: 1004-731X(2018)07-2744-09

DOI: 10.16182/j.issn1004731x.joss.201807039

Deep Learning Method for Hyperspectral Remote Sensing Images with Small Samples

Shi Xiangbin^{1,2}, Zhong Jian¹, Liu Cuiwei¹, Liu Fang¹, Zhang Deyuan¹

(1. School of Computer, Shenyang Aerospace University, Shenyang 110136, China;

2. College of Information Science and Technology, Liaoning University, Shenyang 110036, China)

Abstract: In order to solve the problem of large information dimension and fewer labeled training samples of hyperspectral remote sensing images, this paper proposes a hyperspectral remote sensing image classification framework HSI-CNN, which reduces the number of model parameters while maintaining the depth of neural network. Image pattern invariance and spectral channel contribution rate are analyzed, and the spectral redundancy information is reduced by principal component analysis. A full convolution neural network structure suitable for small sample hyperspectral remote sensing images is designed and the amount of network parameters is effectively reduced. Three kinds of HSI-CNN structures are proposed and compared. The experimental results on Pavia University and Salinas hyperspectral remote sensing data sets show that HSI-CNN can extract the spectral feature information only by using a small amount of training samples effectively.

Keywords: hyperspectral remote sensing image classification; deep learning; convolution neural network; spectral redundancy; principal component analysis

引言

高光谱遥感图像(Hyperspectral Remote Sensing



收稿日期: 2017-07-31 修回日期: 2017-12-05;
基金项目: 国家自然科学基金(61170185, 61602320),
辽宁省博士启动基金(201601172, 201601180), 辽宁省
教育厅科学研究一般项目(L2014070, L201607);
作者简介: 石祥滨(1963-), 男, 辽宁, 博士, 教
授, 研究方向为虚拟现实、视频与图像理解。

Image, HSI)在地质勘探、环境检测、植被生态监测等诸多领域应用广泛。利用高光谱图像分类可以获取高光谱图像重要信息, 其具有以下 3 方面的挑战: (1) “维数灾难”: 光谱信息变化大, 图像的分类精度随波段数目的增加而呈下降趋势^[1]; (2) 标记训练样本数量有限: 由于高光谱遥感数据的空间分辨率较低, 一个像素可以代表几米区域的地物信

<http://www.china-simulation.com>

• 2744 •

息,使得对高光谱遥感图像的标记十分困难,导致标记样本数量较少^[1]; (3)“同谱异物”、“同物异谱”现象:在某一个谱段区,两个不同地物可能呈现相同的谱线特征。同一地物,受光照,天气等影响,也可能呈现不同的谱线特征。

为了应对高光谱图像维度高和样本数据少的问题,传统方法主要通过降低光谱通道维度以及融合空间特征,并采用适合于小样本的分类器进行分类。在降低光谱通道维度上,特征变换^[2]与波段选择^[3]是常用的两种有效提取光谱特征的方法。使用空间信息可以减少样本的不确定性,控制噪声对分类结果的影响^[4],将空间特征与光谱特征相结合,综合考虑地物的空间与光谱信息也能减轻“维数灾难”的影响。常用的小样本图像分类方法包括最近邻法和逻辑回归分析方法,其中,Support Vector Machine (SVM)方法^[5]表现出了较为优越的性能。

近年来基于深度学习的方法已经在计算机视觉领域取得了突破性的进展^[6-7],在充足的训练数据上,卷积神经网络(Convolution Neural Network, CNN)具有越来越深的趋势^[8-9]。CNN能够通过训练获得图像的层次性复杂特征,该特征对噪声鲁棒性高,并具有很强的判别性。然而由于高光谱遥感样本数量较少,并且图像特点和可见光图像不同,因此采用CNN研究高光谱遥感图像领域的工作仍在起步中。相关文献中基于CNN的高光谱遥感图像研究针对遥感图像维度高、训练样本少的特点,通常采用较浅的神经网络以减少训练参数、采用无监督学习方式进行预训练以及融合上下文信息等。文献[10]采用浅层CNN及小样本的遥感数据进行训练,获得了比较理想的分类效果;Chen Y等^[11]通过主成分分析(Principal Component Analysis, PCA)对高光谱图像降维,采用深度自编码架构用于学习高光谱遥感图像的空间特征与光谱特征,并采用逻辑回归模型进行分类。通过高光谱数据分类实验证明了其以深度神经网络为基础的高光谱遥感图像分类框架具有很强的竞争力;文献[12]提出了一种新型的基于上下文分析的深度神经网络图

像分类框架,通过此网络学习到的空间与光谱特征都能对高光谱遥感图像的分类起到很好的作用。可见在高光谱遥感图像分类的神经网络结构中,受限于训练样本数量较少,文献均采用了较浅的神经网络作为折衷。

计算机视觉领域的CNN研究路线表明采用较深的神经网络能够提取更加鲁棒的层次特征,如何针对小样本高光谱遥感图像数据进行更深的CNN研究成为了一个尚未充分探索的问题。

本文提出HSI-CNN,一种用于高光谱遥感图像分类的深度神经网络架构。为了采用较深的CNN结构,同时限制神经网络参数数量,HSI-CNN采用2种手段。首先,针对高光谱遥感图像光谱冗余特性,采用PCA方法对高光谱图像进行降维,有效保留光谱判别性信息,同时去除噪声。其次,针对降维后的图像,采用CNN进行训练。与传统的CNN目的不同,本文采用CNN是通过CNN权重共享机制来降低参数数量,保证较深的神经网络,由局部映射获得全局的特征映射。通过与传统方法以及经典深度CNN在图像分类问题上性能的对比与分析,证明了HSI-CNN在小样本高光谱遥感图像分类方面应用的优越性。

1 高光谱图像光谱冗余分析

高光谱遥感图像光谱信息变化大,其较高的光谱分辨率使得波段之间具有较强的相关性,图像中某一波段的信息可以部分或完全由其它波段预测,由此产生了光谱冗余,严重影响分类效果。

考虑到冗余信息的存在,光谱中主要成分的提取对图像分类就显得尤为重要。采用PCA方法可以通过线性变换将原始数据变换为一组各维度线性无关的表示,能在保留数据集中对方差贡献率最大的主成分的同时去除次成分中存在的噪声^[13]。

为了分析光谱冗余信息,本文选取103光谱维度的高光谱数据集Pavia University(PaviaU)中某种类别的200个样本,绘制出二维光谱曲线以及PCA变换之后的光谱曲线图,如图1所示。

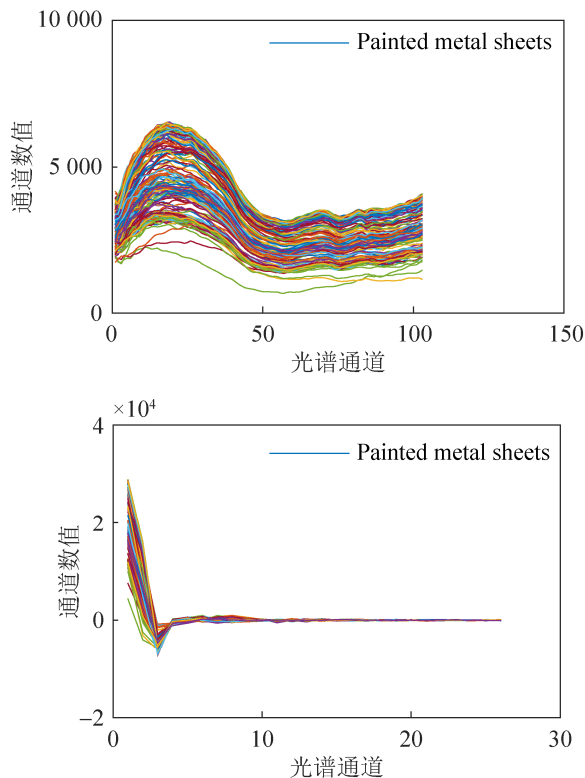


图1 样本原始的光谱曲线以及 PCA 变换后的光谱曲线
Fig. 1 Spectral curve of original sample and spectral curves transformed by PCA

可以看出, 光谱信息在经过 PCA 变换之后(图 1 右), 最初的光谱通道能够保留一定的识别模式, 但随着维度的增加, 有很大一部分的信息呈现出平坦的趋势, 没有具体的模式, 而这部分正是无法区分图像类别的冗余通道信息。

通过图 1 看出, PCA 能够区分主成分信息和冗余信息, 但为了提取具体的主成分通道, 光谱通道的累计贡献率是重要标准。图 2 为 PaviaU 与 Salinas 数据集经过 PCA 变换之后的光谱通道贡献率图。

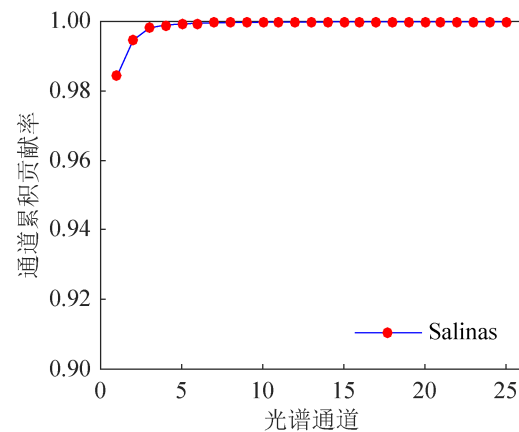



图 2 PaviaU 和 Salinas 的光谱通道贡献率图
Fig. 2 Spectrum channel contribution rate of PaviaU and Salinas

图 2 的贡献率曲线反映了光谱通道对分类的重要程度, 趋于平坦的部分累积贡献率变化小, 说明这部分通道对分类贡献非常小, 因此本文保留了每个样本贡献率 0.999 以上的 26 维主成分通道, 去除贡献小的冗余通道。

2 HSI-CNN 图像分类框架

2.1 HSI-CNN 整体结构

HSI-CNN 主要基于构建块的方式进行设计, 网络的整体结构如图 3 所示, 首先对原始光谱图像采用 PCA 变换提取主要成分, 然后利用本文提出的深度神经网络 HSI-CNN 提取图像主成分特征, 利用主成分特征实现图像分类。




图 3 HSI-CNN 网络整体结构图
Fig. 3 Overall structure of HSI-CNN network

图 3 中, 每个构建块中的图像仅仅需要一个卷积核的滑动特征提取即可完成特征映射关系, 即图像的局部单元共享一个卷积核权重, 相比于全连接网络可以大幅缩小参数数量, 同时构建块的思想也使得网络设计简洁易懂, 有效降低模型复杂度, 从

而高效的训练 CNN。

2.2 HSI-CNN 构建块介绍

高光谱图像在经过 PCA 变换之后, 使得图像的主成分特征集中在少量维度, 因此, 本文采取全卷积网络形式, 利用构建块方法于有规律的组合 CNN 中常用隐藏层构成了 HSI-CNN 图像分类框架, 去除 CNN 中的常用池化操作层, 采用统一卷积步长提取图像特征, 有效降低了网络参数, 其核心构建块内部结构如下:

(1) c-b-el: 卷积构建块

c-b-el 为底层特征提取器, 由卷积层 (Convolution Layer, 简称 c)-批规范化层 (Batch Normalization Layer, 简称 b)^[14]-指数线性激活层 (Exponential Linear Units, ELUs, 简称 el)^[15]组成。

卷积层利用卷积核对原始图像像素做线性乘法运算, 滑动提取图像局部区域特征, 如公式(1):

$$y_l^{i',j',d'} = b_l^{d'} + \sum_{i=1}^{H'} \sum_{w=1}^{W'} \sum_{d=1}^{D'} f_l^{i,j,d} \times x_l^{i',j',d,d'} \quad (1)$$

式中: l 代表网络层数, 图像输入数据为 $x_l \in R^{H \times W \times D}$; 卷积核为 $f_l \in R^{H' \times H' \times D'}$, 可以看成是一个滑动窗口, 数值大小为权值; 输出特征图为 $y_l \in R^{H'' \times H'' \times D''}$ 。

批规范化层是对特征图做归一化处理, 防止反向传播的过程中对特征图的修改。

高光谱图像分类的训练中, 由于光谱信息比较大以及训练数据的数量限制, 常常出现梯度爆炸现象, 导致训练过程崩溃, ELUs 激活单元可以有效的控制这种情况, 计算方法如公式(2)所示:

$$y_l(r) = \begin{cases} y_l & x > 0 \\ a(\exp(x) - 1) & x \leq 0 \end{cases} \quad (2)$$

卷积构建块能够提取图像的局部区域特征, 保证下一构建块输入特征的不变性。

(2) residual_block: 残差构建块

图像分类中, CNN 在不断加深的同时会出现 Degradation 的问题^[10]。residual_block 通过直接将输入的特征信息绕道传到输出, 在某种程度上能解

决这个问题, 此时 CNN 需要学习的目标变为输出 $H(x)$ 与输入 x 之间的‘差别’, 如公式(3), H 为构建块运算, 这种‘差别’即为残差, 后面的网络层可以直接学习残差, 从而保护信息的完整性。

$$F(x) = H(x) - x \quad (3)$$

本文采用的新型 residual_block 基于公式(4), 针对光谱特征的特点, 由 3 种卷积构建块组成, 结构如图 4 所示, c 为卷积操作, 冒号后为卷积核大小, fm 为生成的特征图, m, n 代表数量, b 为批规范化操作, r 为非线性激活操作。

$$y_{l+1} = r[H(y_l) + y_l] \quad (4)$$




图 4 残差构建块
Fig. 4 Residual block

(3) fc-el: 预测构建块

fc-el 是一组全连接组合, 由卷积层(c)-非线性激活层(r)组成, 基于公式(1), (3), 可提取特征线性空间关系, 输出对每个类别标签的预测值。

2.3 HSI-CNN 分类框架

2.3.1 HSI-AlexNet 分类框架


HSI-AlexNet 网络由 4 个构建块组成: 2 个卷积构建块(c-b-el)、一个全连接卷积构建块(c-b-el)和一个预测构建块(fc-el), 如表 1 所示。前 2 个构建块为卷积操作, 采用 1×7 的卷积核获取光谱图像上的局部信息, 后两个部分为全连接操作, 首先用全连接卷积构建块获得整张图像的特征, 输出 128 维向量, 后面的预测构建块输出对应于训练集类别总数的预测向量, 预测向量通过 softmax 层的计算得到图像属于每个类别的后验概率。

表1 HSI-AlexNet 网络结构
Tab. 1 Network structure of HSI-AlexNet

block	name	kernel	stride	pad
c-b-el	conv_block_1	1×7×1×32	1	0
c-b-el	conv_block_2	1×7×32×64	1	0
c-b-el	conv_block_3	1×14×64×128	1	0
fc-el	fc_block_1	1×1×128×9or11	1	0

2.3.2 HSI-VggNet 分类框架

HSI-VggNet 网络的搭建类似于 HSI-AlexNet, 主要由 5 个构建块组成: 3 个卷积构建块(c-b-el)、一个全连接卷积构建块(c-b-el)和一个预测构建块(fc-el), 如表 2 所示。不同的是, 在卷积构建块(c-b-el)中, 采用的是 1×3 的卷积核。依据第 1 章分析, 相邻光谱曲线具有一定的相似性, 所以在 HSI-Alexnet 中采取稍大的卷积核是希望尽可能的消除相邻光谱相似性的干扰, 但是在对原始图像采取 PCA 变换之后, 很大程度上消除了光谱之间的相似性, 所以采取小卷积核对于特征提取便是更好的选择, 并且 3 个 1×3 卷积层的串联相当于 1 个 1×7 的卷积层(如图 5 所示), 但 3 个 1×3 的卷积层要比 1 个 1×7 的卷积层有更多的非线性变换(r), 使得 CNN 对特征的学习能力更强。

图5 2种不同大小的卷积核的类似功能
Fig. 5 Similar functions of two convolution kernels with different size表2 HSI-VggNet 网络结构
Tab. 2 Network structure of HSI-VggNet

block	name	kernel	stride	pad
c-b-el	conv_block_1	1×3×1×16	1	0
c-b-el	conv_block_2	1×3×16×32	1	0
c-b-el	conv_block_3	1×3×32×32	1	0
c-b-el	conv_block_4	1×20×32×64	1	0
fc-el	fc_block_1	1×1×64×9or11	1	0

2.3.3 HSI-ResNet 分类框架

HSI-ResNet 利用残差构建块设计方式减少网

络参数, 同时获得比 HSI-AlexNet 和 HSI-VggNet 更深的神经网络, 利用平均池化层(Average Pooling)代替全连接卷积构建块获得全局特征的均值。

表3 HSI-ResNet 网络结构
Tab. 3 Network structure of HSI-ResNet

block	name	kernel	stride	pad
c-b-el	conv_block_1	1×7×1×16	1	0
c-b	conv_1	1×1×16×32	2	0
c-b	bnorm_1	-	-	-
residual_block	Res_block_1	m=32,n=64	1	0
c-b	conv_2	1×1×32×64	2	0
c-b	bnorm_2	-	-	-
residual_block	Res_block_2	m=64,n=64	1	0
average pooling	avg_pool_block_1	1×5×64×96	1	0
fc-el	fc_block_1	1×1×96×9or11	1	0

表 4 为 HSI-CNN 参数数量对比。可以看出, 在保持较深的 CNN 的同时, 本文提出的基于全卷积网络的 HSI-CNN 结构的参数较少, 降低了模型复杂性, 又可以防止过拟合, 从而提高图像识别率与模型的泛化性。

表4 不同分类方法的参数数量对比
Tab.4 Comparison of the number of parameters for different classification methods

Dataset	Method		
	HSI-AlexNet	HSI-VggNet	HSI-ResNet
PaviaU	31728	33168	23504
Salinas	31984	33424	23760

3 实验与分析

3.1 实验设置

本文选取了高光谱遥感数据集 Pavia University(PaviaU)与 Salinas^[10]。PaviaU 通过 ROSIS 传感器在北意大利的帕维亚大学上空拍摄, 包含 610×340 个 103 谱段的样本, 分为 9 种类别; Salinas 数据集由 224 波段的 AVIRIS 传感器在加利福尼亚的萨利纳斯山谷上空收集, 包含 512×217 个样本, 分为 16 种类别, 本文选取具有代表性的 11 种类别。

数据集基本信息如表 5 所示。

表 5 数据集介绍

数据集	类别数	样本总数	谱段数	实验选取谱段
PaviaU	9	42776	103	26
Salinas	11	36458	224	26

3.2 训练细节

本文的程序设计基于 MatConvNet 工具箱, 利用 GTX1070 显卡实现 GPU 编程加速。采用实验预测值与实际标签之间的对数交叉熵损失(Log Cross Entropy Loss)作为优化目标函数, 使用基于动量的随机梯度下降方法进行参数优化。将训练集中每 256 个样本划分为一个数据块(mini batch), 设置迭代 60 轮寻找最优网络参数。采用正态分布的随机采样初始化参数, 偏置系数初始化为 0, 学习率设置为 0.05, 0.01, 0.001, 每 20 轮更换一次学习率, 便于找到目标函数的最优值, 动量值设置为 0.9。

采用两种数据增强方法:

(1) 光谱通道值随机置 0: 高光谱遥感图像光谱中含有大量冗余信息, 随机选取少量的(5 和 10)光谱通道值置 0, 既能区别于原始数据, 又不会对图像分类性能产生大的影响; (2) 添加噪声扰动: 高光谱图像本身会有噪声扰动, 对图像的光谱通道添加噪声也可以起到数据增强作用, 本文加入了 $(\mu, \sigma)=(0,0.1)$ 的高斯噪声。

3.3 实验结果分析

为了证明算法的有效性, 本文与如下方法进行性能的比较与分析:

(1) SVM: 采用径向基核函数的 SVM 方法;

(2) Neural Networks(NN): 传统的 3 层神经网络;

(3) 经典的深度学习 AlexNet, VggNet^[16], ResNet: 输入原始光谱信息, 加入数据增强。

3.3.1 HSI-CNN 与传统方法分类性能比较与分析

实验中, 分别选取原始数据的 20%, 40%, 60%, 80% 为训练集, 固定原始数据的 10% 为验

证集, 剩下的用作测试集。通过 5 组实验获取分类精度的平均值, 不同方法的分类精度见表 6~7。

表 6 PaviaU 数据集分类精度比较

Method	Train			
	20	40	60	80
SVM+PCA	89.15	93.30	93.55	94.35
NN+PCA	90.58	92.89	93.11	93.33
HSI-AlexNet	94.65	94.83	94.96	95.91
HSI-VggNet	94.84	94.88	95.20	95.73
HSI-ResNet	95.39	95.70	95.80	96.17

表 7 Salinas 数据集分类精度比较

Method	Train			
	20	40	60	80
SVM+PCA	93.21	92.44	92.78	93.54
NN+PCA	84.65	85.95	86.59	88.25
HSI-AlexNet	94.82	95.29	95.53	96.17
HSI-VggNet	94.71	94.73	95.18	95.55
HSI-ResNet	95.82	95.66	96.48	96.92

从表 6 和表 7 中可以看出, 对于不同比例的训练样本, 本文提出的 3 种 HSI-CNN 结构在 2 种数据集上都达到了较高的分类精度, 均超越了传统的 SVM 和 NN 方法, 特别在小样本训练时, 基于残差构建块的 HSI-ResNet 效果更为明显。

图 6~7 为 20% 训练数据的 PaviaU 数据集以及 Salinas 数据集分类迷惑矩阵(基于 HSI-Alexnet), 每列表示样本真实的类别, 每行为该样本被预测的类别, 表格内数值代表每一类数据预测成其他类别的正确率。

在图 6 的 PaviaU 数据集分类迷惑矩阵中, 类别 Gravel(3)被错分成类别 Bricks(8)的概率相对较高, 图 8 为类别 Gravel 与 Bricks 的原始光谱图与 PCA 光谱图, 可以看出两种类别的光谱曲线模式比较接近, 即“同谱异物”, 因此导致提取到的特征相似, 分类器较难区分这两类样本。类别 Gravel 错分比类别 Bricks 错分的概率要高, 可能的原因是 Gravel 类别训练样本相对于 Bricks 要少一半,

导致网络倾向于分为 Bricks 类别。

	1	2	3	4	5	6	7	8	9
1	95.63	0.13	0.72	0.00	0.00	0.17	1.62	1.73	0.00
2	0	98.51	0	0.42	0	1.05	0	0.01	0
3	1.96	0.30	81.25	0.00	0	0.00	0.00	16.49	0
4	0	3.22	0	96.33	0	0.41	0	0	0
5	0	0	0	0.00	99.72	0.00	0	0	0
6	0.15	6	0	0.12	0	93.61	0	0.17	0
7	12.69	0	0	0.00	0	0.00	87.03	0.19	0
8	2.95	0.37	6.75	0.00	0	0.10	0.20	89.61	0
9	0.26	0	0	0	0	0	0	0	99.74

图 6 基于 HSI-AlexNet 的 PaviaU 数据集分类迷惑矩阵
Fig. 6 Confusion matrix of PaviaU data set based on HSI-AlexNet

	1	2	3	4	5	6	7	8	9	10	11
1	99.91	0	0.04	0	0	0	0	0	0	0	0.04
2	0	82.46	0	0	0	0	1.28	18.81	0	0	0
3	0	20.59	78.34	0.06	0	0.56	0.45	0	0	0	0
4	0.32	0.00	0	99.68	0	0	0	0	0	0	0
5	0	0	0.14	0	99.57	0	0	0.10	0	0.19	0
6	0	0	0	0	0	99.93	0.05	0.02	0	0	0
7	0	0.44	0.51	0	0	0.25	97.21	1.39	0.13	0.06	0
8	0	0.95	0.14	0	0	0	2.44	96.47	0	0	0
9	0	0	0	0	0	0	0	0	100.00	0	0
10	0	0.38	0.33	0	0	0	0.98	0.03	0	98.28	0
11	0	0.07	2.42	0	0	0	0.35	0.69	0	0	96.47

图 7 基于 HSI-AlexNet 的 Salinas 数据集分类迷惑矩阵
Fig. 7 Confusion matrix of Salinas data set based on HSI-AlexNet

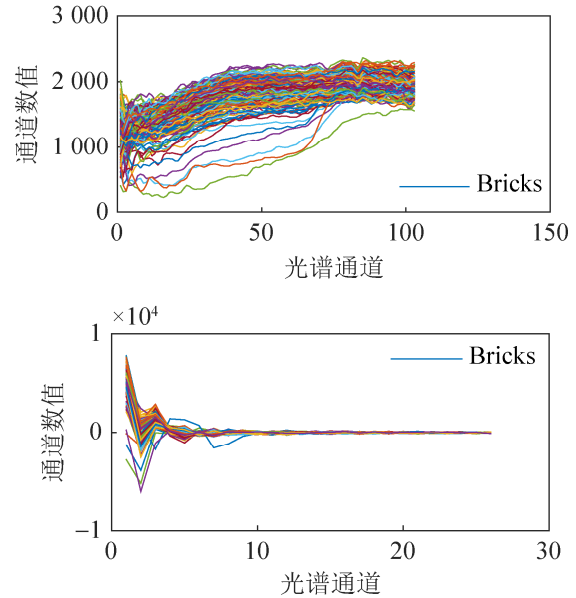
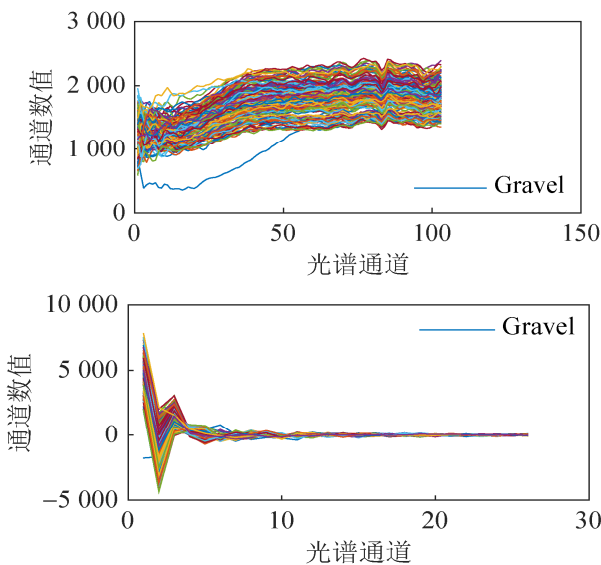


图 8 PaviaU 中类别 3 与 8 的原始光谱图与 PCA 变换图
Fig. 8 Original spectrogram and PCA transformation spectrogram of class 3 and class 8 of PaviaU data set

3.3.2 HSI-CNN 与经典深度 CNN 方法分类性能比较与分析

经典的深度 CNN(AlexNet, VggNet, ResNet) 在普通图像分类方面显示出了强大的性能优势, 本文对比了经典的深度 CNN 与 HSI-CNN 在高光谱遥感图像分类方面的性能, 采用数据增强技术扩充数据, 数据分配参照 3.2.1, 分类结果如表 8, 9 所示。

表 8 基于经典深度 CNN 的 PaviaU 数据集分类精度比较
Tab.8 Classification accuracy comparison of PaviaU datasets based on classical deep CNN %

Method	Train			
	20	40	60	80
AlexNet	88.25	90.68	90.66	91.69
VggNet	91.60	92.16	92.24	92.85
ResNet	91.42	93.74	93.77	94.80
AlexNet+PCA	91.10	91.33	91.59	92.28
VggNet+PCA	91.52	91.84	92.47	92.85
ResNet+PCA	92.42	93.98	94.25	94.98

表 9 基于经典深度 CNN 的 Salinas 数据集分类精度比较
Tab. 9 Classification accuracy comparison of Salinas datasets based on classical deep CNN %

Method	Train			
	20	40	60	80
AlexNet	89.22	90.40	90.21	91.65
VggNet	90.10	91.82	91.95	92.15
ResNet	91.55	91.35	92.67	93.35
AlexNet+PCA	90.08	90.83	91.23	92.96
VggNet+PCA	90.46	92.13	92.54	92.67
ResNet+PCA	92.51	92.78	93.38	93.64

分别对比表 8 与表 9 中不同数据集在有无 PCA 变换条件下的实验结果, 可以发现在对原始数据进行 PCA 变换之后, 深度 CNN 对高光谱遥感图像分类精度有所提高, 但是提高不显著, 说明了 PCA 操作在采集原始数据主成分的重要性, 但是由于高光谱图像的小样本条件, 网络参数的增多可能是阻碍图像分类的效果的重要原因(容易导致过拟合), 同时网络结构的设计也会影响图像分类效果。

对比表 6 与表 8 以及表 7 与表 9 中的基于 HSI-CNN(PCA 处理)与经典深度 CNN 网络(PCA 处理)的图像分类效果, 我们发现尽管是基于小样本训练, HSI-CNN 分类效果依然更优越。随着训练样本的增加, 基于同一种 HSI-CNN 的图像分类精度变化波动不大, 说明 HSI-CNN 更适合小样本的图像分类。实际上, 得益于 PCA 降维方法以及全卷积网络权重共享机制的应用, HSI-CNN 的网络比经典的深度 CNN 训练参数更少, 而网络性能以及图像分类效率却进一步提高。

4 讨论

高光谱图像的光谱信息维度大, 但是可用样本数量少, 降低光谱维度正是本文的首要考虑的问题, PCA 在图像分类中是一种常用的处理方法, 其可以保留图像的主成分特征, 同时降低图像数据的维度, 同时其优势在于 PCA 处理后的高光谱图像依旧保持着用于识别的模式。

CNN 用于在图像分类中的特征提取中主要是

基于图像局部区域的特征信息的相关性, 而图像在经过 PCA 变换之后, 特征之间的光谱波长的邻接性已经破坏, 但是实验验证与分析中, HSI-CNN 依旧可以在高光谱遥感图像分类中获得比较高的实验效果, 因此需要进一步分析原始数据集以及图像分类过程中参数。

传统 CNN 中池化操作的目的是保持特征的不变性同时能够找出一块区域中最适合表达图像的特征, 删除其余特征, 但是在高光谱图像数据经过 PCA 变换之后, 图像主成分特征已经全部保留, 如果采用池化操作会丢失区域中部分重要的主成分特征, 考虑到这个问题, 本文决定去除池化操作。

本文选取了两种常用高光谱遥感数据集验证 HSI-CNN 方法的有效性, 从实验分析中看出, HSI-CNN 在小样本训练的情况下(20%)就可以达到十分稳定的分类效果, HSI-CNN 在实验数据集上的实验效果有待进一步验证。

5 结论

本文提出了 HSI-CNN, 一种适用于小样本的高光谱遥感图像分类算法。首先, 验证了高光谱图像中存在光谱冗余, 并利用 PCA 方法消除了高光谱遥感数据的冗余信息。通过对深度神经网络特征提取操作的分析, 采用全卷积网络特性, 去除常规池化操作, 设计了高光谱遥感图像分类的卷积神经网络 HSI-CNN。在常用的 PaviaU 以及 Salinas 上的实验结果表明, HSI-CNN 可以有效提取小样本光谱特征, 获得较高的图像分类性能, 由此证明了深度神经网络在小样本训练情况下高光谱遥感图像分类方面应用的可能性。

参考文献:

- [1] Camps-Valls G, Bruzzone L. Kernel-based methods for hyperspectral image classification[J]. IEEE Transactions on Geoscience & Remote Sensing (S0196-2892), 2005, 43(6): 1351-1362.
- [2] Cao X, Xu L, Meng D, et al. Integration of

- 3-dimensional discrete wavelet transform and Markov random field for hyperspectral image classification[J]. *Neurocomputing* (S0925-2312), 2017, 226(C): 90-100.
- [3] Wang Q, Lin J, Yuan Y. Salient band selection for hyperspectral image classification via manifold ranking[J]. *IEEE transactions on neural networks and learning systems* (S2162-237X), 2016, 27(6): 1279-1289.
- [4] Ghamisi P, Benediktsson J A, Sveinsson J R. Automatic Spectral-Spatial Classification Framework Based on Attribute Profiles and Supervised Feature Extraction[J]. *IEEE Transactions on Geoscience & Remote Sensing* (S0196-2892), 2014, 52(9): 5771-5782.
- [5] Xia J, Chanussot J, Du P, et al. Rotation-based support vector machine ensemble in classification of hyperspectral data with limited training samples[J]. *IEEE Transactions on Geoscience and Remote Sensing* (S0196-2892), 2016, 54(3): 1519-1531.
- [6] Wang W, Shen J, Shao L. Video Salient Object Detection via Fully Convolutional Networks[J]. *IEEE Transactions on Image Processing*, 2017, 27(1): 38-49.
- [7] W Wang, J Shen. Deep cropping via attention box prediction and aesthetics assessment[C]//The IEEE International Conference on Computer Vision(ICCV), Piscataway: NJ, 2017: 2186-2194.
- [8] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[J]. 2015:770-778.
- [9] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C]//International Conference on Neural Information Processing Systems. Curran Associates Inc. 2012: 1097-1105.
- [10] Hu W, Huang Y, Wei L, et al. Deep Convolutional Neural Networks for Hyperspectral Image Classification [J]. *Journal of Sensors* (S1530-437X), 2015, 2015(2): 1-12.
- [11] Chen Y, Lin Z, Zhao X, et al. Deep Learning-Based Classification of Hyperspectral Data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing* (S1939-1404), 2014, 7(6): 2094-2107.
- [12] Ma X, Geng J, Wang H. Hyperspectral image classification via contextual deep learning[J]. *Eurasip Journal on Image & Video Processing* (S1687-5176), 2015, 2015(1): 20.
- [13] 霍雷刚, 冯象初. 基于主成分分析和字典学习的高光谱遥感图像去噪方法[J]. *电子与信息学报*, 2014, 36(11): 2723-2729.
- Huo Leigang, Feng Xiangchu. Denoising of Hyperspectral Remote Sensing Image Based on Principal Component Analysis and Dictionary Learning [J]. *Journal of Electronics and Information Technology*, 2014, 36(11): 2723-2729.
- [14] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]//International Conference on Machine Learning, 2015: 448-456.
- [15] Clevert D A, Unterthiner T, Hochreiter S. Fast and accurate deep network learning by exponential linear units (elus)[J]. *arXiv preprint arXiv:1511.07289*, 2015.
- [16] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. *arXiv preprint arXiv:1409.1556*, 2014.
-
- (上接第 2743 页)
- [18] Böttger J, Schäfer A, Lohmann G, et al. Three-dimensional Mean-shift Edge Bundling for The Visualization of Functional Connectivity in The Brain [J]. *IEEE Transactions on Visualization & Computer Graphics* (S1077-2626), 2014, 20(3): 471-480.
- [19] Zachary W W. An Information Flow Model for Conflict and Fission in Small Groups [J]. *Journal of Anthropological Research* (S0091-7710), 1977, 33(5): 452-473.
- [20] 林定, 徐颖, 黄国新, 等. 基于 Louvain 算法的图数据三维树形可视化. *计算机工程与应用*, 待刊.
- Lin Ding, Xu Ying, Huang Guoxin, et al. Visualizing Graph Data in 3D Tree-Style Based on the Louvain Algorithm. *Computer Engineering and Applications*. In press.