

SSCDenseNet:一种空-谱卷积稠密网络的 高光谱图像分类算法

刘启超,肖亮,刘芳,徐金环
(南京理工大学计算机科学与工程学院,江苏南京 210094)

摘要: 基于深度学习的高光谱遥感图像地物分类是目前研究的热点.但由于其参数规模大以及结构复杂,深度网络通常需要大量训练样本和较长训练时间,如何在小规模样本下建立深度学习监督分类模型是需要解决的关键问题.本文提出了一种小规模样本下高光谱图像分类的空-谱卷积稠密网络算法,称为SSCDenseNet,其包含三种新颖的架构策略:(1)空-谱分离卷积,即采取光谱维一维卷积和空间维二维卷积的分离卷积结构构成隐层单元,并通过多个隐层单元堆叠构造深度网络;(2)隐层单元中使用批归一化,减少数据协方差漂移及加速网络训练;(3)隐层单元间构建稠密连接,缓解梯度消失问题并实现特征复用.通过Indian Pines、Pavia University与Salinas数据集进行综合测评,表明该方法优于若干最新深度学习方法,特别在小规模样本下具有优异的分类性能.

关键词: 高光谱图像;监督分类;深度学习;稠密网络;空-谱卷积

中图分类号: TP751 **文献标识码:** A **文章编号:** 0372-2112 (2020)04-0751-12

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.04.017

SSCDenseNet: A Spectral-Spatial Convolutional Dense Network for Hyperspectral Image Classification

LIU Qi-chao, XIAO Liang, LIU Fang, XU Jin-huan

(School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China)

Abstract: Due to the massive parameters and complex structure, deep learning networks are usually trained in a long time with large-scale training samples. In this paper, we propose a spatial-spectral convolutional dense network (SSCDenseNet) which mainly targets limited samples for hyperspectral image classification. Three novel strategies are proposed to construct the proposed network. First, a spatial-spectral separable convolution method is adopted to make up a hidden layer unit with a spectral one-dimensional convolutional layer and a spatial two-dimensional convolutional layer; then the deep network is constructed by stacking multiple units. Second, we use batch normalization before each hidden layer unit to reduce covariance drift of data and accelerate the network training procedure. Finally, a direct connection between every two units is adopted to reuse hierarchical features, and solve the problem of gradient vanishing. The comprehensive evaluation of experiments on different datasets such as Indian Pines, Pavia University and Salinas are conducted to show the performance of the SSCDenseNet, and the results show that the proposed method outperforms several state-of-the-art deep learning based methods in terms of classification performance, especially under small-scale samples.

Key words: hyperspectral image; supervised classification; deep learning; dense network; spectral-spatial convolution

1 引言

高光谱相机能获取物质信息丰富的立方体“图谱合一”数据,在可见光-近红外、短波红外甚至中红外和热红外波段范围内可具有纳米(nm)级光谱分辨率,广泛应用于军事侦察、环境监测、地质勘探和目标探测等

领域^[1-4].其中高光谱图像监督分类是该领域中最重要
的研究内容之一.

近十年里,研究者提出了许多高光谱图像监督分类方法.这些方法可大致分为两类:基于光谱信息的方法和基于空-谱信息联合的方法.在第一类方法中,大多数方法关注光谱数据的紧致表达和鉴别性特征抽取,进而提升子空间

收稿日期:2018-11-12;修回日期:2019-09-09;责任编辑:孙瑶

基金项目:国家自然科学基金(No. 61871226, No. 61571230, No. 61802190);国家自然科学基金重点项目(No. 11431015);江苏省社会发展重点研发计划(No. BE2018727);江苏省自然科学基金(No. BK20161500);中央高校基本科研业务费专项资金(No. 30918014108)

分类能力.代表性方法包括:主成分分析(Principal Component Analysis, PCA)^[5,6]、线性判别分析(Linear Discriminant Analysis, LDA)^[7,8]、表示多核学习(Representative Multiple Kernel Learning, RMKL)^[9]以及稀疏表示(Sparse Representation)^[10,11]等.但仅仅利用像元光谱信息,分类精度较低且不具有较好的噪声鲁棒性.而第二类空-谱联合分类方法,由于能充分挖掘和利用高光谱图像内局部像元依赖关系^[12-14],通过利用地物邻域内聚集属性提升小样本下的高光谱图像监督分类性能.代表性方法包括:空-谱组合核滤波器^[15]、核 Hilbert 空间嵌入^[16]、局部区域像元投票^[17]、空-谱小波特征联合马尔科夫随机场^[18]等.相较于仅利用光谱信息的方法,该类方法可大幅提升高光谱图像的分类精度.此外,由于邻域像元块相较于单个像元所包含更多冗余信息,研究者还提出了结合低秩矩阵分解^[19]、字典学习^[20]等子空间学习分类方法.

无论是基于光谱信息还是基于空-谱信息联合的高光谱图像分类方法,其分类精度很大程度上依赖于所提取的特征.然而,由于高光谱图像中的地物分布多样性,同时成像受光照、角度等多方面因素影响,人工特征提取方法难以适用于所有类型的高光谱数据.由于深度学习可以直接从原始数据中学习数据的分层特征表示,摒弃了基于人工设计的特征提取方式,为特征提取提供了另一种有效的解决方案.例如,卷积神经网络(Convolutional Neural Network, CNN)^[21,22]、深度置信网络(Deep Belief Network, DBN)^[23]以及堆叠自编码器(Stacked Autoencoder, SAE)^[24]等典型的深度学习网络模型已被逐步引入到了高光谱图像分类领域中.然而,深度模型中动辄几十上百万的参数,相对于传统方法,需要更多的有标签样本和更长的训练时间以完成网络训练.另一方面,对高光谱数

据进行人工标注需要耗费大量的人力物力,通常情况下只有少量的有标签样本可使用,严重影响深度网络的训练过程.因此,如何在小规模样本下建立深度学习监督分类模型,是基于深度学习高光谱分类的研究热点.

本文通过对高光谱数据结构以及深度学习方法的分析,提出了一种小样本下高光谱图像分类的空-谱卷积稠密网络算法,称为 SSCDenseNet.在该网络中,为了降低网络对大量训练样本的依赖性,2D 卷积层被分离为光谱维卷积层与空间维卷积层,其中:光谱维卷积层采用一维卷积核对输入特征图执行逐像元卷积,以提取光谱特征;而空间维卷积层则使用二维卷积核对输入特征图执行逐通道卷积,以提取空间特征.通过将光谱维卷积层与空间维卷积层组合为隐层单元,并以此隐层单元为基本结构构建深度网络.通过在隐层单元中使用批归一化,可减少隐层数据的协方差漂移,加速网络训练.此外,为了解决网络中的梯度消失问题,SSCDenseNet 在隐层单元间建立稠密连接,解决梯度消失的同时实现特征复用.与同样基于稠密网络^[25]的 FDSSC^[26]所采取的在隐层间建立稠密连接的方式不同,SSCDenseNet 仅在隐层单元间建立稠密连接,而隐层单元内部无稠密连接,因此 SSCDenseNet 可在保持复用特征规模不变的条件下,增强每组复用特征的表达能力,进而提升网络整体的分类性能.此外,结合 SSCDenseNet 网络结构特性而设计的类别加权全局交叉熵损失函数可以有效缓解类别不平衡问题.通过实验表明,基于以上架构策略所提出的 SSCDenseNet 分类框架(如图 1 所示),在三组基准数据集不同规模训练样本下分类精度均超过了对比算法,包括最新提出的 SSRN 方法^[27]以及 FDSSC 方法^[26].此外,所提出的方法在线分类时间短,远小于其它同类方法.

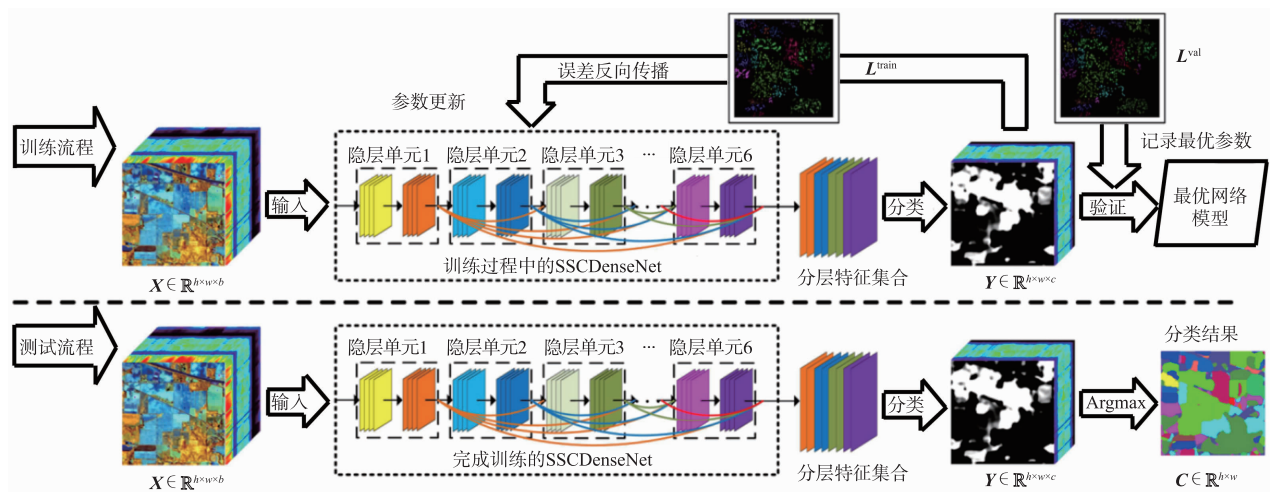


图1 基于SSCDenseNet的高光谱图像分类框架

其中 X 为高光谱图像, Y 为像元类属概率, C 为分类结果, L^{\min} 为训练集标签, L^{val} 为验证集标签, h 、 w 、 b 、 c 分别为高光谱图像高、宽、波段数和样本类别数

2 相关工作

得益于其强大的分层分布式特征表达能力,深度学习在高光谱图像分类领域中取得了较好进展,其网络结构已经由 1D、2D 深度网络逐步发展到了 3D 深度网络. 在 1D 深度网络中,多层前馈神经网络(Multilayer Feedforward Neural Network)^[28]是常用方法之一. 多层前馈神经网络是由多层全连接层构成,每层均通过对像元的所有输入数据加权求和并激活,以提取光谱特征,如图 2(a)所示. 而 1D 卷积神经网络(1D-CNN)^[29]则通过使用一维卷积核在光谱数据上做卷积运算,以提取光谱特征,如图 2(b)所示. 相对于前馈神经网络,1D-CNN 参数规模更小,同时训练速度更快,但较小的感受野破坏了光谱的结构完整性.




图2 前馈神经网络与1D-CNN的隐层变换

由于高光谱数据具有“图谱合一”特性,而 1D 深度网络无法有效利用空间结构信息,因此研究人员引入了 2D 深度网络. 如图 3(a)所示,2D 卷积神经网络(2D-CNN)通过将 2D 卷积核同时作用于所有特征图的同一区域,可以有效提取空间特征. 但由于高光谱图像的光谱维度普遍较高,信息冗余且含有较多噪声,因此基于 2D-CNN 的深度学习分类框架^[21,22]常结合 PCA、鲁棒 PCA (Robust PCA, RPCA)等降维算法对高光谱图像进行预处理. 然而高光谱图像不同于自然图像,其光谱信息丰富而空间分辨率相对较低,数据整体呈现三维结构. 同时,为了避免 2D-CNN 中卷积核参数数量过大而应用的降维算法,会导致部分光谱信息的丢失,降低样本间的可区分性. 这表明,在基于 2D-CNN 的高光谱图像分类方法中,较小的参数规模与较高的输入维度是难以调和的主要矛盾之一,并且严重影响模型的泛化能力.

为了解决 2D-CNN 对高光谱图像“立方体”数据的不匹配性,文献[30]提出了 3D 卷积神经网络模型(3D-CNN). 如图 3(b)所示,3D 卷积在保留 2D 卷积的空间特征提取能力的同时,大幅度减少了卷积核的参数规模,同时卷积核参数数量不受输入特征图通道数的影响. 因此,3D-CNN 拥有可直接处理高维数据的能力,摒弃了预先对高光谱图像进行降维处理的步骤. 然而,由于 3D 卷积会在光谱维度产生大量特征,尤其当输入光谱维度较高时,其光谱特征维度将成指数级增长. 为了缩减 3D 卷积带来的维度灾难,通常 3D 网络中仅使用少量 3D 卷积核,但较少的卷积核又会造成所提取的特征

鉴别能力不足.




图3 2D-CNN与3D-CNN中的隐层变换

除了单一结构的深度网络模型外,研究者还探索了具有多种网络结构的混合深度网络模型,如结合 1D-CNN 与 2D-CNN 的双通道卷积神经网络模型(DC-CNN)^[31],以及同时结合了 1D-CNN、2D-CNN 与 3D-CNN 的多通道卷积神经网络模型(MC-CNN)^[32],相较于单独使用一种卷积结构的深度网络,其分类性能均具有一定的提升.

为了进一步提升网络模型的特征提取能力,更深的网络层数是必要的. 然而,随着网络模型深度的增加,其庞大的参数规模将导致需要更多的标注样本以训练深度网络,因此在少量样本下的深度网络分类性能往往急剧下降. 针对该问题,研究人员探索了小样本下的深度网络分类模型. Zhong 等基于残差网络^[33]提出了深度空-谱残差网络模型(SSRN)^[27],通过构建 1D-CNN 残差块与 2D-CNN 残差块并串联为深度网络,利用残差网络的高效训练能力,有效缓解了深度网络在小样本下分类性能不足的问题. Wang 等则基于稠密网络^[25]提出一种快速稠密空-谱卷积网络模型(FDSSC)^[26],与 SSRN 类似,通过构建 1D-CNN 稠密块与 3D-CNN 稠密块并串联为深度网络,结合稠密网络的优势,取得了较好的效果. 通过分析发现,以上深度网络方法均通过构建拥有较多隐层的网络模型以提取深层特征,同时结合 1D、2D 以及 3D 卷积等方式增强其特征表达能力并减少网络参数规模,并使用大量跳层连接来缓解深度网络中的梯度消失问题,进一步降低网络训练对大量有标签样本的依赖性. 受此启发,本文提出了一种新型空-谱卷积稠密网络算法,在三组真实数据集不同比例训练样本下均取得了对比算法中的最高分类精度,特别在小规模样本下具有优异的分类性能. 尽管本文算法与 FDSSC 均是基于稠密网络的深度学习方法,但采取了不同的网络架构改进方法.

(1) FDSSC 由光谱 1D 卷积稠密块和空间 3D 卷积稠密块级联构成,先后提取光谱特征和空间特征,而本文网络采取空-谱分离卷积构成隐层单元,每个隐层单元可提取同时包含光谱与空间信息的“空-谱特征”,形成更为紧致与富有鉴别性的快速特征提取模式.

(2) FDSSC 分别在光谱 1D 卷积块和空间 3D 卷积块内部独立建立稠密连接,不同维度卷积块之间无稠密连接,而本文算法采取在隐层单元间建立稠密连接

而隐层单元内部无稠密连接的方式,并将每个隐层单元的输出特征进行拼接,形成包含由浅到深的分层特征集合并送入分类器.该分层特征集合有助于提升小样本下分类精度的鲁棒性,同时在训练阶段亦有助于梯度的反向传播.

(3)不同于 FDSSC 以局部像元块作为输入的传统空-谱分类方式,本文方法以全局图像作为输入,并形成端到端分类网络,无须考虑局部像元块的切分方式.此外,结合本文网络结构特性而构建的类别加权全局交叉熵损失函数可以有效缓解类别不均衡问题,实验表明该端到端网络可对高光谱图像进行大规模快速分类,具有吞吐量高、推理耗时少等优点.

3 空-谱卷积稠密网络的高光谱图像分类

令待处理的高光谱图像记 $\mathbf{X} \in \mathbb{R}^{h \times w \times b}$,其中 h 、 w 、 b 分别为高光谱图像的三个维度,即高、宽和波段数.所提出的基于空-谱卷积稠密网络(以下简称 SSC-DenseNet)的高光谱图像分类算法,其整体框架结构如图 1 所示. SSC-DenseNet 是一种端到端的分类模型,网络输入即为原始高光谱图像 \mathbf{X} ,对应的输出即为图像中每个像元的类属概率,记为 $\mathbf{Y} \in \mathbb{R}^{h \times w \times c}$,其中 c 表示像元可划分的类别数.

3.1 隐层单元

2D-CNN 由于可高效地提取空间上下文表示特征,因此在自然图像领域得到广泛关注.2D 卷积操作如图 3(a)所示,具体公式为:

$$F_{lij}^{x,y} = f\left(\sum_m \sum_{h=0}^{H_l-1} \sum_{w=0}^{W_l-1} s_{lij,m}^{h,w} F_{(l-1)lm}^{(x+h),(y+w)} + b_{lij}\right) \quad (1)$$

式中, $s_{lij,m}^{h,w}$ 表示第 l 层第 j 个卷积核第 m 个通道在 (h, w) 位置的具体值, H_l 和 W_l 分别表示卷积核的高和宽, b_{lij} 表示第 l 层第 j 个特征图的偏置, $F_{(l-1)lm}^{(x+h),(y+w)}$ 表示第 $(l-1)$ 层中第 m 个特征图在 $(x+h, y+w)$ 位置的具体值, $F_{lij}^{x,y}$ 表示第 l 层第 j 个特征图在 (x, y) 位置的输出数据, $f(\cdot)$ 为激活函数.

然而,由于高光谱图像的光谱维度较高,将 2D 卷积直接应用于高光谱图像将导致其卷积核参数量过于庞大,进而导致过拟合.虽然 3D 卷积可以大幅度减少网络参数规模,但只能同时作用于输入特征图的部分通道,其感受野受到限制.为了权衡二者,本文将 2D 卷积层分离为两个独立卷积层的组合,提出了一种新型的复合卷积,即空-谱卷积.空-谱卷积分为两步:光谱维卷积与空间维卷积,如图 4 所示.此外,为了区分不同卷积输出的特征图,光谱维卷积层输出特征图被命名为光谱特征图,空间维卷积层输出特征图被命名为空-谱特征图,同时为了网络结构的描述便捷,本文将空-谱卷积中的两个独立卷积层组合为隐




图4 SSC-DenseNet中的空-谱分离卷积过程

层单元.在光谱维卷积层中,仅使用 1×1 卷积核对输入特征图中的每个像元做非线性变换,并输出光谱特征图,具体公式为:

$$mid_{lij}^{x,y} = f\left(\sum_m s_{lij,m} F_{(l-1)lm}^{x,y} + b_{lij}\right) \quad (2)$$

式中, $s_{lij,m}$ 表示第 l 个隐层单元第 j 个光谱维卷积核在 m 位置的具体值, $F_{(l-1)lm}^{x,y}$ 表示第 $(l-1)$ 个隐层单元第 m 个空-谱特征图在 (x, y) 位置的具体值, b_{lij} 表示第 l 个隐层单元第 j 个光谱特征图的偏置, $mid_{lij}^{x,y}$ 表示第 l 个隐层单元第 j 个光谱特征图在 (x, y) 位置的输出数据, $f(\cdot)$ 为激活函数.通过使用 1×1 卷积核对高光谱图像进行卷积变换,可以使用较少的参数提取光谱特征.紧随其后的空间维卷积层使用二维卷积核对光谱维卷积层输出的每个光谱特征图执行 2D 卷积,并输出空-谱特征图,具体公式为:

$$F_{lij}^{x,y} = f\left(\sum_{h=0}^{H_l-1} \sum_{w=0}^{W_l-1} k_{lij}^{h,w} mid_{lij}^{(x+h),(y+w)} + p_{lij}\right) \quad (3)$$

式中, $k_{lij}^{h,w}$ 表示第 l 个隐层单元第 j 个空间维卷积核在 (h, w) 位置的具体值, $mid_{lij}^{(x+h),(y+w)}$ 表示第 l 个隐层单元第 j 个光谱特征图在 $(x+h, y+w)$ 位置的具体值, H_l 和 W_l 分别表示 2D 卷积核的高和宽, p_{lij} 为偏置, $F_{lij}^{x,y}$ 代表第 l 个隐层单元第 j 个空-谱特征图在 (x, y) 位置的输出数据.相对于 2D-CNN 中的 2D 卷积层,隐层单元可在提取像元空-谱特征的同时大幅度缩减卷积核的参数量.同时,相对于 3D-CNN 中的 3D 卷积层,隐层单元除了拥有同样可以处理高维数据的能力外,在特征提取过程中可同时利用到像元的所有通道数据,其光谱维感受野不受限制,可更加有效地提取空-谱特征.

为了减少隐层单元数据的协方差漂移并加速网络训练,本文在隐层单元中引入了批归一化(Batch Normalization, BN)^[34].BN 是深度学习常使用的技巧之一,通过将隐层数据归一化,可以重新调整数据分布,更有利于特征的提取.设第 l 个隐层单元的输入为 $\mathbf{I}_l \in \mathbb{R}^{h \times w \times u}$,则规范化的隐层数据 $\tilde{\mathbf{I}}_l \in \mathbb{R}^{h \times w \times u}$ 计算如下:

$$\tilde{\mathbf{I}}_l = \frac{\mathbf{I}_l - \mathbf{E}(\mathbf{I}_l)}{\sqrt{\mathbf{Var}(\mathbf{I}_l)}} \quad (4)$$

式中, $\mathbf{E}(\cdot)$ 与 $\mathbf{Var}(\cdot)$ 分别表示均值函数与方差函

数. 然后将归一化后的隐层数据输入到其后的空-谱卷积中, 以提取空-谱特征. 由式(4)可得第 l 个隐层单元的规范化输入为 \bar{I}_l , 记隐层单元输出为 $O_l \in \mathbb{R}^{h \times w \times v}$, 则式(2)、式(3)可重写为:

$$mid_{lij}^{x,y} = f\left(\sum_{m=1}^u s_{lij,m} \bar{I}_{lm}^{x,y} + b_{lij}\right) \quad (5)$$

$$O_{lij}^{x,y} = f\left(\sum_{h=0}^{H_l-1} \sum_{w=0}^{W_l-1} k_{lij}^{h,w} mid_{lij}^{(x+h),(y+w)} + p_{lij}\right) \quad (6)$$

式中, $\bar{I}_{lm}^{x,y}$ 表示 \bar{I}_l 中第 m 个特征图在 (x,y) 位置的具体值, $O_{lij}^{x,y}$ 表示 O_l 中第 j 个空-谱特征图在 (x,y) 位置的输出数据. 此外, 所提出的深度网络采用广泛使用的 Sigmoid 函数作为非线性激活函数.

3.2 网络结构

单个隐层单元的特征提取能力有限, 因此本文使用多个隐层单元堆叠构成深度网络, 以实现提取深层空-谱特征的目的. 为了充分利用浅层与深层空-谱特征并解决梯度消失问题, SSCDenseNet 中每两个隐层单元间均建立直接连接. 如图 5 所示, 网络中每个隐层单元的输入都为前面所有隐层单元输出的并集, 而该隐层单元所学习到的特征图也会被直接传给后面所有隐层单元作为输入. 记第 l 个隐层单元的输入为 I_l , 输出为 O_l , 则 I_l 的计算式为:

$$I_l = [O_1, O_2, \dots, O_{l-1}] \quad (7)$$

式中, $[\dots]$ 表示在光谱维度进行拼接.




图5 SSCDenseNet网络结构

其中 X 、 Y 、 b 、 c 分别表示输入高光谱图像、输出类属概率、波段数以及类别数

SSCDenseNet 为面向高光谱图像分类的端到端网络模型, 其输出为输入高光谱图像的各像元的类属概率. 与使用 Softmax 分类层作为网络最后一层进行分类的常规方法原理上相同, SSCDenseNet 在提取分层空-谱特征后首先使用 c 个 1×1 卷积核特征图执行逐像元卷积, 然后使用 Softmax 函数将结果转化为类属概率, 其中 c 为样本类别数. 设网络由 $L (1 \leq L)$ 个隐层单元堆叠而成, 记第 $l (1 \leq l \leq L)$ 个隐层单元的输出为 O_l , 分类层输入为 I , 则 I 的计算式为:

$$I = [O_1, O_2, \dots, O_L] \quad (8)$$

式中, $[\dots]$ 表示在光谱维度进行拼接. SSCDenseNet 的分类层是将其前面所有隐层单元输出的空-谱特征图的并集作为输入, 同时利用由浅到深的分层特征集合进行分类, 以提高分类精度. 记分类层的卷积输出为 \bar{Y} , 则 \bar{Y} 的计算式为:

$$\bar{Y}_j^{x,y} = \sum_m s_{j,m} I_m^{x,y} + b_j \quad (9)$$

式中, $s_{j,m}$ 表示第 j 个卷积核在 m 位置的具体值, $I_m^{x,y}$ 表示 I 中第 m 个空-谱特征图在 (x,y) 位置的具体值, b_j 表示第 j 个偏置, $\bar{Y}_j^{x,y}$ 表示 \bar{Y} 中第 j 个特征图在 (x,y) 位置的输出数据. \bar{Y} 为分类层的分类数据, 需要转化为类属概率, 则类属概率 Y 的计算式为:

$$Y_{x,y,k} = \frac{\exp(\bar{Y}_{x,y,k})}{\sum_m \exp(\bar{Y}_{x,y,m})} \quad (10)$$

中, $\bar{Y}_{x,y,k}$ 与 $Y_{x,y,k}$ 分别表示 \bar{Y} 与 Y 在 (x,y,k) 位置的具体

数据. $Y_{x,y,k}$ 即高光谱图像 X 在 (x,y) 位置的像元属于类别 $k (1 \leq k \leq c)$ 的概率.

在本文中, SSCDenseNet 由 6 个隐层单元组成, 如图 5 所示. 第 1 个隐层单元中的光谱维卷积层包含 150 个大小为 $1 \times 1 \times b$ 的一维卷积核, 输入的高光谱图像 X 经过该卷积变换后的光谱维变为 150, 而紧跟其后的空间维卷积层拥有 150 个大小为 $5 \times 5 \times 1$ 的二维卷积核, 执行逐通道卷积, 并输出共 150 通道的特征图. 而第 2 ~ 6 个隐层单元分别接收前面所有隐层单元的输出作为输入, 并同样通过光谱维卷积层与空间维卷积层, 输出对应特征图. 而最后的分类层将第 1 ~ 6 个隐层单元输出的所有空-谱特征图进行集中拼接, 组成大小为 $h \times w \times 400$ 的分层特征集合, 最后使用 Softmax 分类器对该特征集合进行分类并输出每个像元对应的类属概率 Y .

3.3 类别加权交叉熵损失函数与网络训练

在基于 SSCDenseNet 的高光谱图像分类框架中(图 1), 标注样本被分为三部分: 训练集、验证集以及测试集, 其中训练集用于训练网络, 验证集用于网络模型调优以防止过拟合, 而测试集用于网络性能的评价.

SSCDenseNet 使用交叉熵作为损失函数. 在该网络中, 训练集由输入层高光谱图像中带类别标注的像元组成, 记为 D_{train} . 记 $Z^{(x,y)}$ 为对应训练样本 $X_{x,y} \in D_{train}$ 的类属概率向量, 即, 若 $X_{x,y}$ 属于类别 $k (1 \leq k \leq c)$, 则对应的类属概率向量 $Z^{(x,y)}$ 中第 k 个位置元素值为 1, 其余为

0. 将训练样本对应的标签转化为对应网络输出 Y 的类属概率标签, 记为 $L^{\text{train}} \in \mathbb{R}^{h \times w \times c}$, 则 L^{train} 中的元素满足:

$$L_{x,y}^{\text{train}} = \begin{cases} Z^{(x,y)}, & \text{if } X_{x,y} \in D_{\text{train}} \\ \mathbf{0}, & \text{otherwise} \end{cases} \quad (11)$$

其中 $\mathbf{0}$ 表示元素全为 0 的向量, $L_{x,y}^{\text{train}}$ 表示 L^{train} 在 (x, y) 位置的类属概率向量. 此外, 为了缓解类别不平衡导致的小样本类别分类较差的问题, 本文将一组类别权重引入到损失函数中. 具体而言, 记第 k ($1 \leq k \leq c$) 类训练样本数为 N_k , 则该类对应的损失加权为 N_k^{-1} , 即在网络迭代训练中优先优化具有较少样本量的类别. 综上, 该网络的类别加权交叉熵损失函数为:

$$\mathcal{L}^{\text{train}} = - \sum_{x=1}^h \sum_{y=1}^w \sum_{k=1}^c N_k^{-1} L_{x,y,k}^{\text{train}} \log(Y_{x,y,k}) \quad (12)$$

其中, $Y_{x,y,k}$ 与 $L_{x,y,k}^{\text{train}}$ 分别表示 Y 和 L^{train} 在 (x, y, k) 位置的具体值. 同理, 验证集所对应的类属概率标签记为 L^{val} , 其所对应的网络损失记为 \mathcal{L}^{val} . 记模型最终输出的各像元类别标签为 $C \in \mathbb{R}^{h \times w}$, 则 C 计算如下:

$$C_{x,y} = \arg \max_k Y_{x,y,k} \quad (13)$$

式中, $Y_{x,y,k}$ 表示 Y 在 (x, y, k) 位置的具体值, $C_{x,y}$ 表示 C 在 (x, y) 位置的输出数据. $C_{x,y}$ 即为同位置像元 $X_{x,y}$ 所对应的类别标签.

在该分类框架下, 网络的训练与验证为同时进行. 在每次迭代训练过程中, 训练集所对应的网络损失 $\mathcal{L}^{\text{train}}$ 通过反向传播 (Back Propagation, BP) 算法更新每一层的参数, 同时利用验证集记录使得 \mathcal{L}^{val} 最小的网络模型, 在有限次迭代中选取最优网络模型.

4 实验与分析

本文采用三组真实高光谱数据集 Indian Pines、Pavia University 以及 Salinas 检验 SSCDenseNet 算法的分类性能, 该三组数据集广泛应用于高光谱图像分类算法的性能测试. 采用的评价指标包括总分类精度 (Overall Accuracy, OA)、平均分类精度 (Average Accuracy, AA) 以及 Kappa 系数. 为测试算法性能, 实验对比分析了本文算法与目前国际上流行的 4 种基于深度学习的高光谱图像分类框架的分类性能. 对比方法包括: 2D 卷

积神经网络 (2D-CNN) 方法^[21]、3D 卷积神经网络 (3D-CNN) 方法^[30]、深度空-谱残差网络 (SSRN) 方法^[27] 以及快速稠密空-谱卷积深度网络 (FDSSC) 方法^[26].

4.1 网络参数配置

实验中, SSCDenseNet 的网络结构参数设置如图 5 所示. 在三组不同数据集上的实验中, 除输入输出层等必要改动外, 其余网络参数均相同. 网络中所有隐层单元中的空间维卷积运算均使用边界填充以保持空间维大小一致, 卷积步长均为 1, 激活函数统一使用 Sigmoid 函数. 此外, 在网络训练过程中, 使用 Adam 优化器进行相应的误差更新, 其中学习率设置为 0.001, 一阶矩估计指数衰减率 β_1 设置为 0.9, 二阶矩估计指数衰减率 β_2 设置为 0.99, 迭代次数设置为 1000.

4.2 分类性能分析

4.2.1 Indian Pines 数据集

Indian Pines 数据集为机载可见红外成像光谱仪 (AVIRIS) 在美国印第安纳州 Indian Pines 实验区采集的高光谱遥感图像. 该图像共包含 220 个波段, 空间分辨率为 20m, 图像大小为 145×145 . 去除 20 个水汽吸收和低信噪比波段后 (波段号为 104-108, 150-163, 220), 选择剩下的 200 个波段作为研究对象^[2]. 该地区共包含 16 种已知地物共 10366 个样本.

实验中, 训练集、验证集、测试集分配的样本比例分别为 5%、1%、94%, 每个实验重复 5 次取均值及标准差作为指标, 实验结果总结在表 1 中. 该结果表明, 在同条件下 SSCDenseNet 相较于 SSRN 在指标 OA、AA、Kappa 上分别提升了 2.69%、10.07%、3.07%, 相较于 FDSSC 分别提升 0.5%、5.21%、0.43%, 并相较于 2D-CNN 及 3D-CNN 提升显著. 不难发现, 本文算法相对于 FDSSC 在指标 AA 上提升较大, 而在指标 OA 以及 Kappa 上提升较小. 经分析, 造成该结果的原因在于 SSCDenseNet 使用了类别加权交叉熵损失函数, 在处理类别不平衡问题上表现突出, 表明了本文所提出的类别加权损失函数的有效性. 图 6 展示了不同算法对 Indian Pines 数据集的分类结果.

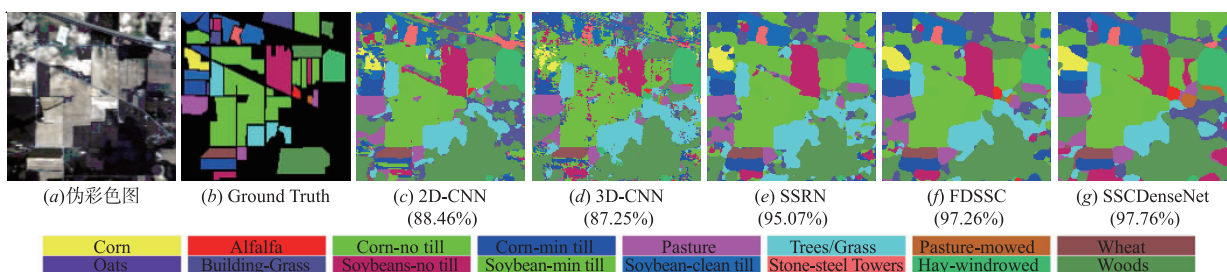


图6 不同算法在Indian Pines数据集上的分类结果

表 1 在 Indian Pines 数据集上 5% 训练样本下不同方法的分类精度 (%)

物质类别	样本数量			2D-CNN ^[21]	3D-CNN ^[30]	SSRN ^[27]	FDSSC ^[26]	SSCDenseNet
	训练	验证	测试					
Alfalfa	3	1	50	100 ± 0	97.93 ± 2.75	98.18 ± 3.63	98.36 ± 2.56	96.82 ± 2.37
Corn-notill	72	15	1347	85.15 ± 3.37	82.99 ± 5.07	93.34 ± 7.53	96.57 ± 2.12	97.32 ± 1.12
Corn-mintill	42	9	783	79.32 ± 3.61	79.78 ± 5.57	94.10 ± 3.63	95.88 ± 1.99	96.88 ± 2.39
Corn	12	3	219	90.62 ± 6.91	90.58 ± 2.40	95.69 ± 7.45	97.17 ± 2.30	96.35 ± 2.71
Pasture	25	5	467	95.88 ± 1.06	95.09 ± 1.85	98.29 ± 0.78	97.70 ± 1.01	95.83 ± 3.58
Trees/Grass	38	8	701	94.35 ± 2.91	93.45 ± 2.17	96.81 ± 1.59	98.54 ± 0.94	99.54 ± 0.35
Pasture-mowed	2	1	23	100 ± 0	98.00 ± 4.00	58.88 ± 48.12	96.42 ± 7.14	94.16 ± 6.23
Hay-windrowed	25	5	459	93.80 ± 1.54	93.43 ± 0.20	96.68 ± 1.19	99.52 ± 0.74	100 ± 0
Oats	1	1	18	40 ± 48.98	100 ± 0	0 ± 0	20 ± 40	100 ± 0
Soybeans-notill	49	10	909	87.69 ± 3.37	84.38 ± 5.06	93.34 ± 3.73	96.73 ± 1.56	95.68 ± 1.96
Soybean-mintill	124	25	2319	86.69 ± 2.01	84.97 ± 1.72	94.99 ± 3.43	97.75 ± 1.40	97.55 ± 0.69
Soybean-cleantill	31	7	576	82.27 ± 6.77	79.48 ± 5.23	95.01 ± 3.05	96.70 ± 2.37	97.75 ± 1.15
Wheat	11	3	198	97.20 ± 2.02	97.68 ± 0.51	98.52 ± 1.43	98.71 ± 1.41	99.29 ± 0.68
Woods	65	13	1216	94.59 ± 2.24	94.35 ± 2.74	97.15 ± 2.08	98.77 ± 1.22	99.31 ± 0.28
Building-Grass-Tress-Drives	19	4	357	89.90 ± 2.81	91.15 ± 2.21	96.93 ± 3.01	98.73 ± 0.71	99.05 ± 1.75
Stone-steelTowers	5	1	89	92.47 ± 3.05	94.24 ± 2.33	94.48 ± 5.11	95.38 ± 4.03	97.95 ± 1.81
Overall Accuracy (%)				88.46 ± 0.51	87.25 ± 1.86	95.07 ± 0.78	97.26 ± 0.49	97.76 ± 0.18
Average Accuracy (%)				88.12 ± 3.62	91.09 ± 1.32	87.65 ± 3.79	92.51 ± 2.58	97.72 ± 0.52
Kappa × 100				86.80 ± 0.59	85.41 ± 2.14	94.38 ± 0.89	97.02 ± 0.56	97.45 ± 0.20

4.2.2 Pavia University 数据集

Pavia University 数据集为反射光学成像光谱仪 (ROSIS) 采集的城区高光谱图像, 共包含 115 个波段, 波长范围为 0.43-0.86 μm, 空间分辨率为 1.3 m, 图像大小为 610 × 340. 在去除噪声波段之后, 选择剩下的 103 个波段作为研究对象^[2]. 该数据集共包含 9 种典型地物, 共 42776 个样本.

实验中, 训练集、验证集、测试集分配的样本比例分别为 1%、1%、98%, 并同样以 OA, AA, Kappa 等作为性能

评价指标. 每个实验同样重复 5 次, 结果总结在表 2 中. 该结果表明, 在同条件下 SSCDenseNet 相较于 SSRN 在指标 OA, AA, Kappa 上分别提升了 1.54%、1.19%、2.04%, 相较于 2D-CNN 及 3D-CNN 提升显著. 此外, 相较于 FDSSC, 本文方法在指标 OA, Kappa 上均有提升, 分别为 0.14% 和 0.18%, 而 AA 较 FDSSC 低 0.14%. 综合来看, SSCDenseNet 在该数据集上与 FDSSC 表现接近但稍有提升, 较其它方法提升较大. 图 7 展示了不同算法对 Pavia University 数据集的分类结果.

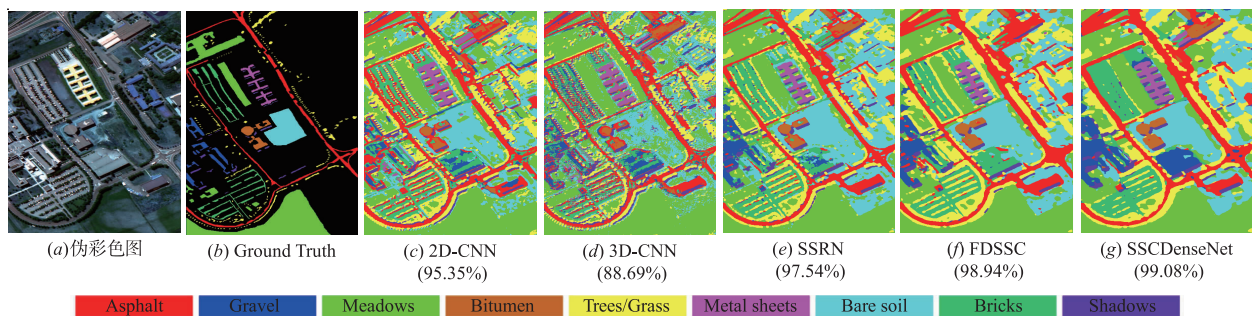


图 7 不同算法在 Pavia University 数据集上的分类结果

表 2 在 Pavia University 数据集上 1% 训练样本下不同方法的分类精度 (%)

物质类别	样本数量			2D-CNN ^[21]	3D-CNN ^[30]	SSRN ^[27]	FDSSC ^[26]	SSCDenseNet
	训练	验证	测试					
Asphalt	67	67	6497	92.72 ± 1.02	87.21 ± 3.39	99.66 ± 0.24	99.22 ± 0.67	98.54 ± 1.55
Meadows	187	187	18275	97.14 ± 0.59	94.10 ± 2.04	98.70 ± 1.02	99.62 ± 0.27	99.97 ± 0.03
Gravel	21	21	2057	87.91 ± 3.40	64.08 ± 6.46	93.95 ± 5.15	97.54 ± 1.96	98.06 ± 1.60
Trees/Grass	31	31	3002	99.35 ± 0.90	96.82 ± 1.76	99.72 ± 0.27	99.89 ± 0.09	95.27 ± 2.01
Metalsheets	14	14	1317	98.92 ± 1.61	95.13 ± 4.87	99.93 ± 0.08	99.29 ± 1.22	99.98 ± 0.03
Baresoil	51	51	4927	97.41 ± 0.77	94.07 ± 1.98	98.52 ± 2.11	99.56 ± 0.48	99.63 ± 0.31
Bitumen	14	14	1302	91.99 ± 4.80	58.80 ± 5.37	96.84 ± 2.22	98.52 ± 2.25	98.63 ± 2.50
Bricks	37	37	3608	88.41 ± 1.07	77.11 ± 2.78	88.85 ± 5.74	94.29 ± 2.27	98.83 ± 1.09
Shadows	10	10	927	99.41 ± 0.59	84.19 ± 4.87	99.53 ± 0.55	99.72 ± 0.23	97.52 ± 0.60
Overall Accuracy (%)				95.35 ± 0.17	88.69 ± 1.99	97.54 ± 0.58	98.94 ± 0.21	99.08 ± 0.35
Average Accuracy (%)				94.81 ± 0.56	83.50 ± 2.14	97.30 ± 0.55	98.63 ± 0.47	98.49 ± 0.49
Kappa × 100				93.81 ± 0.23	84.86 ± 2.72	96.74 ± 0.77	98.60 ± 0.28	98.78 ± 0.46

4.2.3 Salinas 数据集

Salinas 数据集为机载可见红外成像光谱仪 (AVIRIS) 在加利福尼亚州的萨利纳斯山谷采集的高光谱遥感图像。该图像共包含 224 波段, 空间分辨率为 3.7m, 图像大小为 512 × 217。去除 20 个水汽吸收和低信噪比波段后 (波段号为 108-112, 150-163, 224), 选择剩下的 204 个波段作为研究对象^[2]。该地区共包含蔬菜、裸露的土壤、葡萄园田地等 16 种已知地物共 54129 个标注样本。

实验中, 训练集、验证集、测试集分配的样本比例分别为 1%、1%、98%, 并同样以 OA, AA, Kappa 等作为性能评价指标。每个实验同样重复 5 次, 结果总结在表 3 中。该结果表明, 在同条件下 SSCDenseNet 相较于 FDSSC 在指标 OA、AA、Kappa 上分别提升 1.06%、0.41%、1.18%, 相较于 SSRN 分别提升 3.06%、1.17%、3.4%, 并相较于 2D-CNN 及 3D-CNN 提升显著。图 8 展示了不同算法对 Salinas 数据集的分类结果。

表 3 在 Salinas 数据集上 1% 训练样本下不同方法的分类精度 (%)

物质类别	样本数量			2D-CNN ^[21]	3D-CNN ^[30]	SSRN ^[27]	FDSSC ^[26]	SSCDenseNet
	训练	验证	测试					
Brocoli_green_weeds_1	21	21	1967	99.97 ± 0.04	98.80 ± 1.35	100 ± 0	100 ± 0	100 ± 0
Brocoli_green_weeds_2	38	38	3650	99.68 ± 0.57	98.60 ± 1.23	100 ± 0	100 ± 0	100 ± 0
Fallow	20	20	1936	96.23 ± 1.19	92.97 ± 4.24	98.54 ± 1.07	99.70 ± 0.37	99.75 ± 0.49
Fallow_rough_plow	14	14	1366	97.48 ± 2.22	94.74 ± 4.11	98.39 ± 2.24	99.19 ± 1.21	99.25 ± 0.36
Fallow_smooth	27	27	2624	99.48 ± 0.22	98.26 ± 0.62	99.74 ± 0.12	99.87 ± 0.12	98.03 ± 1.41
Stubble	40	40	3879	99.49 ± 0.73	99.35 ± 0.45	99.98 ± 0.01	100 ± 0	99.91 ± 0.16
Celery	36	36	3507	98.96 ± 0.94	97.83 ± 1.80	99.98 ± 0.02	100 ± 0	99.97 ± 0.04
Grapes_untrained	113	113	11045	89.55 ± 0.83	86.18 ± 3.79	89.21 ± 5.45	97.62 ± 1.99	97.63 ± 1.23
Soil_vinyard_develop	63	63	6077	99.66 ± 0.10	99.10 ± 0.67	99.78 ± 0.16	99.70 ± 0.15	100 ± 0
Corn_senesced_green_weeds	33	33	3212	91.96 ± 4.35	91.46 ± 3.69	98.47 ± 0.66	99.59 ± 0.24	98.22 ± 2.00
Lettuce_roumaine_4wk	11	11	1046	93.93 ± 1.19	88.16 ± 6.97	97.95 ± 1.86	98.01 ± 1.84	100 ± 0
Lettuce_roumaine_5wk	20	20	1887	98.32 ± 0.60	97.25 ± 1.19	98.71 ± 1.55	99.48 ± 0.69	100 ± 0
Lettuce_roumaine_6wk	10	10	896	98.74 ± 1.42	97.91 ± 2.49	99.12 ± 1.53	99.86 ± 0.26	100 ± 0
Lettuce_roumaine_7wk	11	11	1048	99.03 ± 0.56	94.83 ± 4.19	99.65 ± 0.47	99.58 ± 0.47	99.38 ± 0.36
Vinyard_untrained	73	73	7122	85.28 ± 1.33	80.34 ± 3.56	92.01 ± 5.82	91.03 ± 3.80	98.96 ± 0.68
Vinyard_vertical_trellis	19	19	1769	99.56 ± 0.25	98.42 ± 1.57	99.93 ± 0.13	100 ± 0	99.23 ± 0.81
Overall Accuracy (%)				94.72 ± 0.63	92.50 ± 1.81	96.03 ± 0.69	98.03 ± 0.52	99.09 ± 0.17
Average Accuracy (%)				96.71 ± 0.58	94.64 ± 1.73	98.22 ± 0.30	98.98 ± 0.18	99.39 ± 0.12
Kappa × 100				94.12 ± 0.70	91.65 ± 2.02	95.58 ± 0.77	97.80 ± 0.58	98.98 ± 0.18

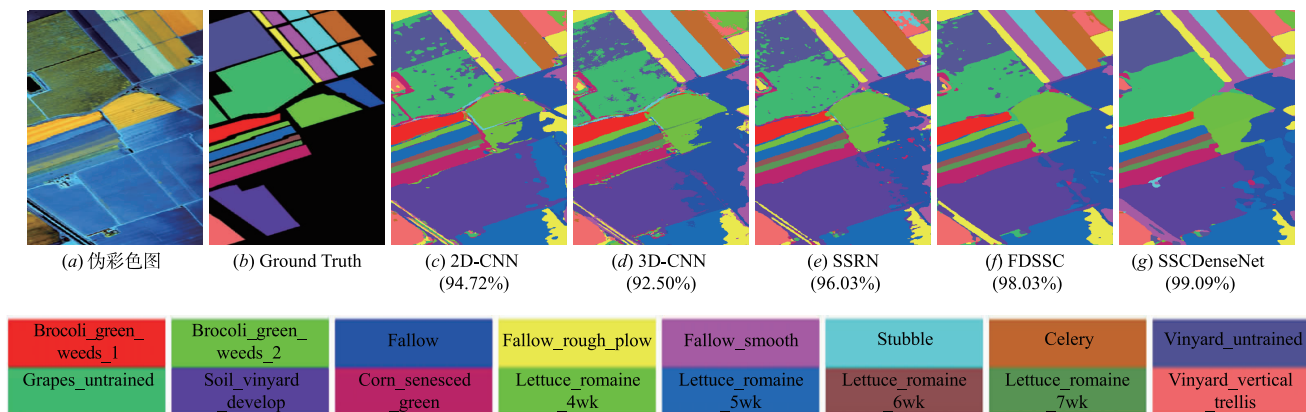


图8 不同算法在Salinas数据集上的分类结果

4.2.4 收敛性分析

不同深度学习算法的收敛性相似而不同,其是否充分收敛决定了算法能否达到当前最优性能.为了验证各个算法的收敛性,以 Indian Pines 数据集为例,本节分别可视化了每个算法在该数据集上的训练损失、验证损失与迭代次数的变化关系图,如图 9 所示.由于不同方法的批大小 (Batch Size) 以及轮次 (Epoch) 设置不同,本文统一使用迭代次数 (Iterations) 作为各个损失曲线的横坐标轴,其计算为:

$$\text{Iterations} = \text{Epochs} \times \left\lceil \frac{\text{Training Size}}{\text{Batch Size}} \right\rceil$$




图9 不同方法在Indian Pines数据集上的训练损失、验证损失随迭代次数的变化关系图

4.3 小样本下的分类性能分析

为了分析 SSCDenseNet 随着训练样本规模不断减少时的分类鲁棒性,实验中对三组真实地物数据集 Indian Pines、Pavia University 以及 Salinas 分别选取不同规模的训练样本进行测试,并同样将结果与 2D-CNN^[21]、3D-CNN^[30]、SSRN^[27]、FDSSC^[26] 等方法进行对比.对于三组基准数据集,每组均分别随机选取每类 5、10、15、20、25 个标注样本作为训练集(若样本量不足,则取最大数量样本),1 个样本作为验证集,剩余样本作为测试集,并以 OA 作为评价指标,每个实验重复 5 次并取其均值及标准差作为评价结果,不同算法的对比实验结果展现在图 10 中.

在 Indian Pines 数据集上的实验结果(a)表明,SS-

其中, $\lceil \cdot \rceil$ 表示上取整.根据该换算方式,2D-CNN^[21]、3D-CNN^[30]、SSRN^[27]、FDSSC^[26]以及 SSCDenseNet 方法在该数据集上的迭代次数分别为:2040、2550、6600、1360 以及 1000.其它数据集计算方式相同.

由图 9 可知,不同深度学习方法的训练损失以及验证损失在有限次迭代次数内均可达到平稳状态,证明了各个对比算法均可收敛到当前最优结果.此外,由于文本方法采用整幅高光谱图像作为网络输入,其损失曲线光滑平整,约 400 次迭代后便已接近模型最优解,说明本文方法收敛稳定,且收敛速度较快.

CDenseNet 在不同规模训练样本下分类性能较 FDSSC 稍有提升,较其它算法提升明显.在每类 5 个训练样本下 2D-CNN、3D-CNN、SSRN、FDSSC 以及提出的 SSCDenseNet 的总分类精度分别为 42.28%、43.70%、62.61%、68.42%、71.22%,且随着训练样本规模的减少 SSCDenseNet 分类性能优势逐渐增大.在 Pavia University 数据集上的实验结果(b)表明,SSCDenseNet 在不同规模训练样本下分类性能与 FDSSC 以及 SSRN 接近,而较其它对比方法优势明显,在每类 5 个训练样本下各方法的分类精度按顺序分别为 61.07%、53.23%、74.96%、76.15%、77.89%.而在 Salinas 数据集上的实验结果(c)表明,SSCDenseNet 在不同规模训练样本下分类精度均明显优于其它对比方法,在每类 5 个训练

样本下各方法的分类精度按顺序分别为 74.24%、74.80%、86.57%、85.30%、91.64%。




图10 不同算法在不同数据集上随训练样本数量下降时的分类精度变化带状图
其中实线部分表示均值, 阴影部分表示标准差: (a)Indian Pines; (b)Pavia University; (c)Salinas

以上结果表明,SSCDenseNet 在不同数据集、不同规模训练样本条件下均具有较高的分类精度,且在小规模训练样本条件下,本文方法优势更为明显.此外,SSCDenseNet 在不同规模训练样本条件下的分类精度变化平稳,表明本文方法具有较高的鲁棒性.

4.4 运行性能分析

为了综合比较所提出的 SSCDenseNet 与 2D-CNN^[21]、3D-CNN^[30]、SSRN^[27] 以及 FDSSC^[26] 方法的计算时间,本文在统一的 GPU 环境进行了算法性能测试.实验中计算平台配置为 CPU: i7-8700K、GPU:

GTX1080Ti、内存:32GB. 实验中条件设置与 4.2 节相同.不同网络模型在三组基准数据集 Indian Pines、Pavia University 以及 Salinas 执行训练与测试的时间开销总结在表 4 中.该结果表明,本文提出的 SSCDenseNet 在对比算法中拥有最高分类性能的同时,也具有最小的测试时间开销,在三组基准数据集上的测试时间分别仅为 0.1s、0.27s、0.34s.考虑到实际情况,由于训练好的模型需要被大规模部署与应用,因此网络模型测试时间远比训练时间重要.由此可表明,SSCDenseNet 具有很好的工程应用前景.

表 4 不同网络模型的运行时间与分类时间对比(单位:s)

模型	Indian Pines		Pavia University		Salinas	
	训练时间	测试时间	训练时间	测试时间	训练时间	测试时间
2D-CNN ^[21]	29.61	2.23	25.46	5.67	26.47	6.83
3D-CNN ^[30]	26.16	1.63	21.19	4.55	40.42	9.38
SSRN ^[26]	185.78	4.52	173.79	23.92	176.68	24.36
FDSSC ^[27]	111.62	9.79	70.12	18.84	142.48	42.78
SSCDenseNet	85.65	0.10	522.55	0.27	467.61	0.34

5 结语

本文针对小样本下高光谱图像分类模型性能不足的问题,提出了一种空-谱卷积稠密网络的高光谱图像分类算法,称为 SSCDenseNet.该网络框架未使用任何人工设计特征,而直接以原始高光谱图像作为网络输入,由网络自身完成深层空-谱表示特征的提取.SSCDenseNet 的网络架构有如下策略:(1)通过使用光谱维一维卷积层与空间维二维卷积层构成隐层单元,相较于传统卷积层,隐层单元在保持特征提取能力的同时大幅度减少所需的参数量;(2)通过使用多个隐层单元构成深度网络,并在隐层单元间建立稠密连接,有效解决了梯度消失问题;(3)通过采取隐层单元中的批归一化处理,减少数据协方差漂移并加速网络训练.

实验表明,本文方法在三组真实数据集上不同规模训练样本下均达到了最佳分类精度,且随着训练样本规模的缩小,SSCDenseNet 的分类性能相较于对比算法优势更为明显.同时,我们发现类别加权交叉熵损失函数有助于解决高光谱图像分类中的类别不均衡问题;而全局图像空-谱分离卷积方式,提升了 SSCDenseNet 的在线分类速度,开销时间远小于同类方法.综合性能分析表明:SSCDenseNet 是一种性能优越的高光谱图像分类算法.后续工作可尝试通过构建轻量化深度网络以及研发具有域自适应能力的小样本学习方法,提升高光谱图像分类的泛化性能和迁移学习能力.

参考文献

[1] 唐意东,黄树彩,薛爱军.面向目标检测基于稀疏表示的

- 波段选择方法[J]. 电子学报, 2017, 45(10): 2368-2374.
- TANG Yi-dong, HUANG Shu-cai, XUE Ai-jun. Sparserepresentation based band selection for hyperspectral imagery target detection [J]. Acta Electronica Sinica, 2017, 45(10): 2368-2374. (in Chinese)
- [2] 徐金环, 沈煜, 刘鹏飞, 肖亮. 联合核稀疏多元逻辑回归和 TV-L1 错误剔除的高光谱图像分类算法[J]. 电子学报, 2018, 46(1): 175-184.
- XU Jin-huan, SHEN Yu, LIU Peng-fei, XIAO Liang. Hyperspectral image classification combining kernel sparse multinomial logistic regression and TV-L1 Error rejection [J]. Acta Electronica Sinica, 2018, 46(1): 175-184. (in Chinese)
- [3] 陈雷, 郭艳菊, 葛宝臻. 基于微分搜索的高光谱图像非线性解混算法[J]. 电子学报, 2017, 45(2): 337-345.
- CHEN Lei, GUO Yan-ju, GE Bao-zhen. Nonlinear unmixing of hyperspectral images based on differential search algorithm [J]. Acta Electronica Sinica, 2017, 45(2): 337-345. (in Chinese)
- [4] 张号远, 李映, 姜晔楠. 深度学习在高光谱图像分类领域的研究现状与展望[J]. 自动化学报, 2018, 44(6): 961-977.
- ZHANG Hao-kui, LI Ying, JIANG Ye-nan. Deep Learning for Hyperspectral Imagery Classification: The State of the Art and Prospects [J]. Acta Automatica Sinica, 2018, 44(6): 961-977. (in Chinese)
- [5] Licciardi G, Marpu P R, Chanussot J, et al. Linear versus nonlinear pca for the classification of hyperspectral data based on the extended morphological profiles [J]. IEEE Geoscience and Remote Sensing Letters, 2012, 9(3): 447-451.
- [6] Fauvel M, Chanussot J, Benediktsson J A. Kernel principal component analysis for the classification of hyperspectral remote sensing data over urban areas [J]. Eurasip Journal on Advances in Signal Processing, 2009, 2009(1): 783194.
- [7] Bandos TV, Bruzzone L, Camps-Valls G. Classification of hyperspectral images with regularized linear discriminant analysis [J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(3): 862-873.
- [8] Peng J, Luo T. Sparse matrix transform-based linear discriminant analysis for hyperspectral image classification [J]. Signal Image and Video Processing, 2016, 10(4): 761-768.
- [9] Gu Y, Wang C, You D, et al. Representative multiple kernel learning for classification in hyperspectral imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(7): 2852-2865.
- [10] Cui M, Prasad S. Class-dependent sparse representation classifier for robust hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(5): 2683-2695.
- [11] Chen Y, Nasrabadi N M, Tran T D. Hyperspectral image classification using dictionary-based sparse representation [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(10): 3973-3985.
- [12] Fauvel M, Tarabalka Y, Benediktsson J A, et al. Advances in spectral-spatial classification of hyperspectral images [J]. Proceedings of the IEEE, 2013, 101(3): 652-675.
- [13] Chen C, Li W, Su H, et al. Spectral-spatial classification of hyperspectral image based on kernel extreme learning machine [J]. Remote Sensing, 2014, 6(6): 5795-5814.
- [14] Li W, Prasad S, Fowler J E. Hyperspectral image classification using gaussian mixture models and Markov random fields [J]. IEEE Geoscience and Remote Sensing Letters, 2013, 11(1): 153-157.
- [15] Li H, Ye Z, Xiao G. Hyperspectral image classification using spectral-spatial composite kernels discriminant analysis [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6): 2341-2350.
- [16] Gurram P, Kwon H. Contextual SVM using hilbert space embedding for hyperspectral classification [J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(5): 1031-1035.
- [17] Tarabalka Y, Benediktsson J A, Chanussot J. Spectral-spatial classification of hyperspectral imagery based on partitioned clustering techniques [J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(8): 2973-2987.
- [18] 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, 2017, 226: 90-100.
- [19] Xu Y, Wu Z, Wei Z. Spectral-spatial classification of hyperspectral image based on low-rank decomposition [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6): 2370-2380.
- [20] Soltani-Farani A, Rabiee H R, Hosseini S A. Spatial-aware dictionary learning for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 53(1): 527-541.
- [21] Makantasis K, Karantzas K, Doulamis A D, et al. Deep supervised learning for hyperspectral data classification through convolutional neural networks [A]. IEEE International Geoscience and Remote Sensing Symposium [C]. US: IEEE, 2015. 4959-4962.
- [22] Yue J, Zhao W, Mao S, et al. Spectral-spatial classification of hyperspectral images using deep convolutional neural

- networks[J]. Remote Sensing Letters, 2015, 6(6): 468-477.
- [23] Chen Y, Zhao X, Jia X, et al. Spectral-spatial classification of hyperspectral data based on deep belief network[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6): 2381-2392
- [24] 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 and Remote Sensing, 2017, 7(6): 2094-2107.
- [25] Huang G, Liu Z, Maaten L V D, et al. Densely connected convolutional networks[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. US: IEEE, 2017. 2261-2269.
- [26] Wang W, Dou S, Jiang Z, et al. A fast dense spectral-spatial convolution network framework for hyperspectral images classification[J]. Remote Sensing, 2018, 10(7): 1068.
- [27] Zhong Z, Li J, Luo Z, et al. Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 56(2): 847-858.
- [28] Fernandez-Redondo M, Hernandezespinoza C, Torresospedra J, et al. Hyperspectral image classification by ensembles of multilayer feedforward networks[A]. IEEE International Symposium on Neural Networks[C]. US: IEEE, 2004. 1145-1149.
- [29] Hu W, Huang Y, Wei L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015, 2015(2): 1-12.
- [30] Li Y, Zhang H, Shen Q, et al. Spectral-spatial classification of hyperspectral imagery with 3d convolutional neural network[J]. Remote Sensing, 2017, 9(1): 67.
- [31] Zhang H, Li Y, Zhang Y, et al. Spectral-spatial classification of hyperspectral imagery using a dual-channel convolutional neural network[J]. Remote Sensing Letters, 2017, 8(5): 438-447.
- [32] Chen C, Zhang J J, Zheng C H, et al. Classification of hyperspectral data using a multi-channel convolutional neural network[A]. International Conference on Intelligent Computing[C]. Cham: Springer, 2018. 81-92.
- [33] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. US: IEEE, 2016. 770-778.
- [34] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[A]. International Conference on Machine Learning[C]. US: DBLP, 2015. 448-456.

作者简介



刘启超 男, 1992 年 10 月出生, 江苏连云港人。2015 年毕业于南京理工大学计算机科学与技术系, 现为南京理工大学计算机科学与工程学院硕博连读生, 从事高光谱遥感图像分类及深度学习方面的研究。

E-mail: qc.l@qq.com



肖亮(通讯作者) 男, 1976 年 2 月出生, 湖南宁乡人, 南京理工大学计算机科学与工程学院教授、博士生导师, 江苏省“光谱成像与智能感知”重点实验室和教育部“高维信息智能感知与系统”重点实验室副主任。主要研究领域为: 图像处理与计算机视觉、机器学习与模式识别。

E-mail: xiaoliang@mail.njust.edu.cn