

引用格式: ZHAO Chunhui, LI Tong, FENG Shou. Hyperspectral Image Classification Based on Dense Convolution and Domain Adaptation[J]. Acta Photonica Sinica, 2021, 50(3):0310001

赵春晖,李彤,冯收. 基于密集卷积和域自适应的高光谱图像分类[J].光子学报,2021,50(3):0310001

基于密集卷积和域自适应的高光谱图像分类

赵春晖,李彤,冯收

(哈尔滨工程大学 信息与通信工程学院, 哈尔滨 150001)

摘 要:针对常规的高光谱图像分类算法不能很好地解决不同图像中的频谱偏移的问题,提出了一种基于密集卷积和域自适应的高光谱图像分类算法,首先在源域中使用密集卷积进行深度特征学习,然后应用域自适应技术转移到目标域。目前的域自适应高光谱图像分类框架中常用卷积神经网络进行特征学习,但是当深度增加时会出现因梯度消失而导致分类精度下降的情况,因此本文通过引入密集卷积进行深度特征学习,提高域自适应高光谱图像分类的精度。在 Indiana 高光谱数据集和 Pavia 高光谱数据集上验证所提算法的有效性,整体分类精度分别为 61.06% 和 89.63%,与其他域自适应高光谱图像分类方法对比,所提方法具有更好的分类精度。

关键词:高光谱图像;分类;密集卷积;域自适应;深度学习

中图分类号: TP751

文献标识码: A

doi: 10.3788/gzxb20215003.0310001

Hyperspectral Image Classification Based on Dense Convolution and Domain Adaptation

ZHAO Chunhui, LI Tong, FENG Shou

(School of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China)

Abstract: As conventional hyperspectral image classification algorithms can not solve the problem of spectral deviation in different images well, a hyperspectral image classification algorithm based on dense convolution and domain adaptive is proposed. First, dense convolution is used in the source domain to perform deep feature learning, and then apply domain adaptive technology to transfer to the target domain. Convolutional neural networks are commonly used for feature learning in the current domain adaptive hyperspectral image classification framework, but when the depth increases, the classification accuracy may decrease due to the disappearance of the gradient. Therefore, this paper introduces dense convolution for deep feature learning, to improve the accuracy of domain adaptive hyperspectral image classification. The effectiveness of the proposed algorithm is verified on the Indiana hyperspectral dataset and Pavia hyperspectral dataset. The overall classification accuracy is 61.06% and 89.63%. Compared with other domain adaptive hyperspectral image classification methods, the proposed method has better classification accuracy.

Key words: Hyperspectral image; Classification; Dense convolution; Domain adaptation; Deep learning

OCIS Codes: 100.4145; 100.5010; 110.4234

基金项目: 国家自然科学基金(Nos.61971153,62002083),中央高校基本科研业务费专项资金(No. 3072020CFJ0805)

第一作者: 赵春晖(1965—),男,教授,博士,主要研究方向为智能遥感图像处理,数据挖掘与机器学习。Email: zhaochunhui@hrbeu.edu.cn

通讯作者: 冯收(1988—),男,讲师,博士,主要研究方向为高光谱图像处理技术。Email: fengshou@hrbeu.edu.cn

收稿日期: 2020-08-24; 录用日期: 2020-11-25

<http://www.photon.ac.cn>

0 引言

高光谱遥感图像是指由多而且很窄的光谱波段组成的遥感图像,它具有纳米级的光谱分辨率,波段数量可达几十甚至上百个,包含丰富的地物描述与识别信息。因此,高光谱遥感技术在精细农业^[1]、环境监测^[2]等方面有广泛的应用价值。图像分类是高光谱遥感影像信息处理的重要部分,如何有效地进行图像分类是当前研究重点^[3]。

目前已经有大量的监督分类算法应用于高光谱图像(Hyperspectral Image, HSI)分类,例如支持向量机^[4]、随机森林^[5]、极限学习机^[6]和神经网络^[7]等。高光谱图像分类在遥感领域占据着很重要的地位,虽然目前研究人员对此进行了大量的研究,但实际应用中仍然存在一些挑战。例如,因为高光谱图像手动标记困难大、成本高,所以在实践中经常会出现标记样本不足而分类精度不高的情况。因此,如何使用少量的训练样本实现令人满意的分类结果成为重要的研究方向之一。为了解决这个问题,一些研究者将主动学习和半监督学习引入高光谱图像分类中。主动学习是一种交互式的信息提取方法,它的目的是找到最有信息的训练样本^[8]。该方法是从一个小的带标记样本集开始训练,通过一定的算法查找最有用的未标记样本,然后用查找到的样本训练分类模型以提高精确度^[9]。相反,半监督方法,例如半监督支持向量机(Support Vector Machine, SVM)^[10]、基于图的半监督学习^[11]和基于流形的半监督学习^[12]等,都是直接利用未标记的数据来增强模型的泛化能力。

大部分高光谱分类方法都假定属于同一地物类别的像素在特征空间中遵循相同的分布。因此,这些方法是通过某幅图像中部分已标记地物类别的样本进行学习,然后对该图中其余样本进行分类。但是在实际的遥感图像应用中,由于高光谱图像标记难度大、成本高,经常会出现一幅高光谱图像中没有标记样本,或者数量非常少,但是另一幅具有相似地物类别的高光谱图像有着足够标记样本的情况。而常规的高光谱图像分类算法不能很好地解决这种情况中不同图像间的频谱偏移问题,因此需要引入域自适应(Domain Adaptation)迁移学习技术^[13-14]。

迁移学习中域(Domain)由数据特征和特征分布组成,是迁移学习的主体,在处理域自适应问题时,两个域分别称为目标域(Target Domain)和源域(Source Domain),其中源域为已有知识的域,目标域为要进行学习的域^[15]。通常,域自适应旨在使用源域中的标记数据构建分类器,从而在目标域中的测试数据上达到良好的分类效果。

在高光谱图像分类域自适应领域中,最大的困难是源像素和目标像素可能具有光谱偏移,即在两个不同图像上属于同一土地覆盖类别的像素的光谱分布可能会有所不同,而这种差异通常是在拍摄图像时由于采样偏差、拍摄时间的变化而引起的^[16]。此外,由于地面坡度、坡向的影响,相同类型的地物会呈现出不同的光谱特征,遥感中称之为“同物异谱”,这也是造成源像素和目标像素出现光谱偏移的原因之一^[17]。

常见的域自适应算法大致分为分类器级域自适应和特征级域自适应。分类器级域自适应指的是通过在训练过程中调整模型的参数,使分类器推广到目标域,典型的分类器级域自适应方法如迁移支持向量机(Transductive SVM, TSVM)^[18]。特征级域自适应是一种常见的域自适应方法,其中心思想是将源图像和目标图像中的特征映射到一个公共的空间中,对两个数据集的特征分布进行匹配,例如,YE M等提出了一种基于字典学习的特征级域自适应方法(Dictionary Learning-Based Feature-Level Domain Adaptation)^[13]。另外,DENG BIN等提出用于高光谱图像分类的基于深度度量学习的无监督域自适应分类算法(Euclidean Distance-Deep Metric Learning-Based Feature Embedding-Unsupervised Domain Adaptation, ED-DMM-UDA)^[16],这也是一种特征级域自适应方法。

ED-DMM-UDA方法在特征提取时采用的是卷积神经网络。但是在卷积神经网络的实际应用中,可能会出现当深度增加时梯度消失的情况,从而导致分类精度下降。为了优化该问题,2017年,HUANG G等提出密集卷积网络(DenseNet),缓解了消失梯度问题,加强了特征传播,鼓励特征重用,并大大减少了参数的数量^[19]。

这种结构可用于从高光谱图像中学习深度光谱和空间特征。例如,WANG W等提出了一种用于高光谱图像分类的端到端快速密集谱-空间卷积(Fast Dense Spectral-Spatial Convolution, FDSSC)框架^[20],FDSSC框架使用不同的卷积核大小分别提取光谱和空间特征,但是该算法并没有应用于域自适应高光谱

图像分类。

受上述文献的启发,针对目前的域自适应高光谱图像分类框架中,用于特征学习的卷积神经网络深度增加时可能会出现梯度消失,从而导致分类精度下降的问题,通过引入密集卷积进行深度特征学习,提高域自适应高光谱图像分类的精度。

本文提出一种基于密集卷积和域自适应高光谱图像分类算法(Hyperspectral Image Classification Based on Dense Convolution and Domain Adaptation, DCDA)。首先,由于密集卷积(Dense Convolution)具有增强特征传播以及减少参数数量的特点,因此在源域中使用密集卷积进行深度特征学习。然后应用域自适应理论,通过将源域和目标域的光谱特征空间转化为一个新的共享空间来减少谱移。

1 基本原理

1.1 密集卷积基本原理

密集卷积网络(DenseNet)是基于 Google Inception^[21]和 Residual Net(ResNet)^[22]提出的一种新的深度网络结构。假设 CNN 具有 i 个卷积层, X_i 是第 i 层的输出,而 H_i 表示第 i 个卷积层中的复杂非线性变换操作。传统 CNN 的连接结构中第 $i-1$ 层的输出是第 i 层的输入,即

$$X_i = H_i(X_{i-1}), i \in N^+ \quad (1)$$

而 DenseNet 与传统 CNN 网络不同,它使用一种密集连接的结构,第 0 层到第 $(i-1)$ 层的输出的特征图作为第 i 层的输入,如图 1 所示。其连接结构公式为

$$X_i = H_i(X_0, X_1, \dots, X_{i-1}) \quad i \in N^+ \quad (2)$$

传统的卷积神经网络模型,都以层叠卷积层的方式提高网络深度,从而提高分类精度。但层叠过多的卷积层会出现梯度下降问题。为了保持前馈特性,DenseNet 的每个层从前面的所有层获得额外的输入,并将自己的特征映射传递给后面的所有层,每一层获得的梯度都是来自前面几层的梯度加成,这样可以缓解梯度下降的问题^[19],因此具有特征复用的密集卷积结构可以更有效地利用特征并增强卷积层之间的特征转移。




图1 有四个密集层的密集卷积网络示例($i=4$)

Fig.1 Example of a DenseNet with four layers ($i = 4$)

1.2 域自适应基本原理

常规的高光谱分类算法大多都是面向单一图像分类,简单来说就是训练集和测试集都来源于同一副图像,这一过程不同于训练集和测试集来源于不同图像的跨图像分类。在跨图像分类时,有标签的源域和无标签的目标域共享相同的类别,但是源与目标的特征分布不同,因此会导致常规的分类算法无法直接应用于跨图分类,这就是域自适应要解决的问题。

在解决特征级域自适应问题时通常从三个角度入手,数据分布角度:通过最小化概率分布距离解决源域和目标域的概率分布问题;特征选择角度:源域和目标域共享着某些特征,选择出这部分公共特征;特征变换角度:源域和目标域共享某些子空间,把两个域变换到相同的子空间,称此方法为子空间学习法(Subspace Learning, SL)^[11],如图 2 所示。本文的域自适应方法属于子空间学习法。

由于源域和目标域可能存在较大差异,因此需要将源域和目标域分别映射到一个公共子空间中。该过

程意在将源特征嵌入 $E_{as}(S)$ 和目标特征嵌入 $E_{at}(T)$ 投影到公共特征空间上,并使源域和目标域样本之间较好地融合,以减小域间的差异。具体做法是鉴别器判别该特征是来源于源域还是目标域,然后通过损失函数更新目标嵌入的参数,使源域和目标域特征之间较好地融合。




图2 子空间特征变换

Fig.2 Subspace feature transformation

2 基于密集卷积和域自适应的高光谱图像分类

2.1 整体框架

当待分类的目标高光谱图像中没有标记样本时,则需要设计一个性能理想的域自适应分类网络来达到跨图像分类的目标。因为当前的特征级域自适应分类算法中卷积神经网络(Convolutional Neural Network, CNN)随着网络深度增加时,梯度会消失,从而导致分类精度下降,而密集卷积可以很好地优化这个问题,因此本文通过引入密集卷积进行深度特征学习,提高域自适应高光谱图像分类的精度。为了实现以上目标,本文设计了基于密集卷积和域自适应的高光谱图像分类网络,如图3所示。

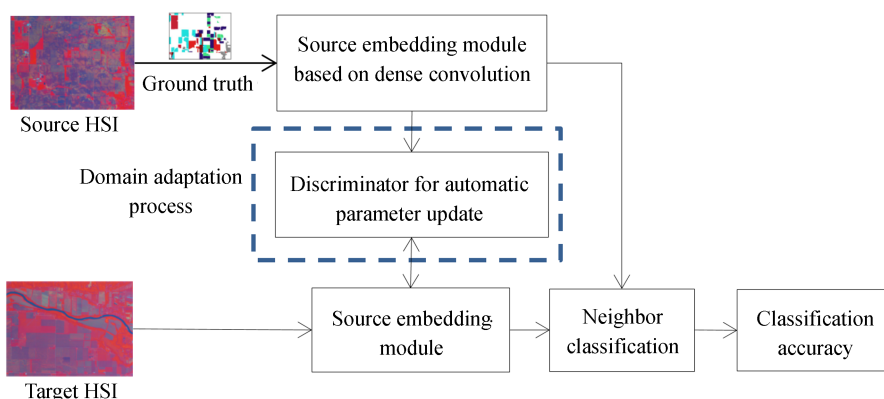


图3 基于密集卷积和域自适应的高光谱图像分类示意

Fig.3 Schematic of the hyperspectral image classification based on DCDA

输入数据为源和目标高光谱图像以及标签文件。首先,将带有标签的源图像作为训练集,在基于密集卷积的源嵌入模块上进行训练,其包含三个密集卷积层。然后,通过将源域和目标域的光谱特征转化到一个新的共享空间来最小化源和目标特征分布的差异,采用对抗性学习策略优化鉴别器来更新目标嵌入模块,使目标域生成与源相似的聚类中心,以达到无监督域自适应训练过程。对无监督域自适应模型进行训练后,本文使用近邻分类器完成分类任务。训练模型完毕后,用测试集对该模型进行测试,得到分类结果。由于密集卷积与域自适应过程是本文的重点研究内容,因此本部分着重介绍基于密集卷积的源嵌入模块以及域自适应过程的原理。

2.2 基于密集卷积的源嵌入模块

为了全面利用光谱和空间信息,取窗口大小为 $w \times w$ 的同一高光谱图像中的像素作为模块的样本输入,因此,每个立方体的大小为 $w \times w \times b$,其中 b 是高光谱图像中的波段数。如图4所示,在嵌入模块中引入第1

节基本原理中的密集卷积理论,加入3个密集卷积层,学习域中的深度特征。为了将密集卷积层学习到的特征嵌入到欧几里得空间中,需要增加平均池化层和全连接层。核大小为 1×1 的卷积可以对空间中每个像素的空间信息进行积分。因此,对于三维高光谱数据,大小为 $1 \times 1 \times k$ 的核可提取光谱特征并完美保留空间特征。另外, 1×1 的卷积核可以使网络中的参数数量大大减少^[20]。




图4 基于密集卷积的嵌入模块示意图(卷积层数为3)

Fig.4 Schematic of the dense convolution-based embedding module (The number of convolutional layers is 3)

2.3 域自适应过程

2.3.1 鉴别器模块

主要通过借鉴ED-DMM-UDA算法^[18]的域自适应过程。在跨域高光谱图像分类中,在源图像中选择标记的像素,任务是对目标图像中的像素进行分类。鉴别器模块的作用是判断输入是来自源数据还是目标数据,其结构如图5,其中softmax被用作最终激活函数。




图5 鉴别器模块示意

Fig.5 Schematic of the discriminator module

2.3.2 参数自动更新

首先,本算法将域自适应损失直接应用于嵌入特征,这样可以在域自适应过程中更新目标嵌入模块中的所有参数。该过程是通过优化式(4)和(5)两个子损失函数来实现的。

$$L(\alpha T, \beta) = L_A(\alpha T, \beta) + L_C(\alpha T) \quad (3)$$

式中, T 是目标域样本集合, αT 是目标嵌入模块 $E_{\alpha T}$ 的参数集,而 β 是鉴别器 D_β 的参数,此处使用它来适应源特征嵌入和目标特征嵌入之间的分布 $E_{as}(S)$ 和 $E_{\alpha T}(T)$ 。优化后的结果为

$$L_A(\alpha T, \beta) = \min_{\beta} \max_{\alpha T} - \sum_{s_i \in S} \log D_\beta [E_{as}(s_i)] - \sum_{t_i \in T} \log \{1 - D_\beta [E_{\alpha T}(t_i)]\} \quad (4)$$

式中, S 是源域样本集合。鉴别器 $D_\beta(\cdot)$ 区分来源于源数据或目标数据的嵌入映射,方法是给源特征向量 $E_{as}(s_i)$ 赋较高的值(接近1),给目标特征向量 $E_{\alpha T}(t_i)$ 赋较低的值(接近0),同时训练参数集 αT 以便同时混淆鉴别器。通过联合优化鉴别器和目标嵌入函数,可以使 $E_{as}(S)$ 和 $E_{\alpha T}(T)$ 两种嵌入特征在分布上得到区分。除了使用上述对抗性学习方法来最大化域混淆之外,还通过最小化中心域损失来实现域自适应。

$$L_C(\alpha T) = \sum_{t_i \in T} \min_n \|E_{\alpha T}(t_i) - C_j\|^2 \quad (5)$$

式中, C 是与源嵌入相对应的聚类中心的集合,式(5)是将示例 t_i 的嵌入引入特征向量 $E_{\alpha T}(t_i)$ 中定义的最接近的聚类中心 C_j ,最小化其特征的差距。每个 C_j 是由属于第 j 类的嵌入特征的平均值计算得到的,例如,Indiana数据集中有7类地物,那么 j 的取值范围为1至7。仅当最小化 $L_A(\alpha T, \beta)$ 时,目标嵌入无法很好地形

成聚类,但是通过同时最小化 $L_c(\alpha T)$,可以更好地形成聚类中心,通过这种方式,源嵌入和目标嵌入的对应分布显然在同一空间中,这也有助于实现域混淆。

3 实验与分析

3.1 对比算法介绍

实验中使用的三个对比算法都是用于高光谱分类的域自适应算法,TSVM^[17]是比较经典的算法,均被SD-MTJDL-SLR^[14]和ED-DMM-UDA^[18]作为对比算法。SD-MTJDL-SLR和ED-DMM-UDA分别于2017年和2020年提出,新颖程度比较高。三个对比算法简介如下。

3.1.1 TSVM

迁移支持向量机(Transductive SVM, TSVM)是一种传统的基于分类器级别的域自适应算法,实现将迁移学习引入支持向量机。在跨图像高光谱图像分类中,首先仅使用源图像中的标记样本来训练TSVM,然后把预先训练的TSVM分配好标签的未标记样本添加到训练集中以重新训练分类器。通过这种方式,可以重新分配未标记样本的标签,并且在每次迭代期间也可以重新训练TSVM。

3.1.2 SD-MTJDL-SLR

基于稀疏逻辑回归的多任务联合共享字典学习域自适应方法(Shared Dictionary-Multitask Joint Dictionary Learning-Sparse Logistic Regression, SD-MTJDL-SLR)。SD-MTJDL-SLR的目标是使用其多任务联合字典学习模型(Multitask Joint Dictionary Learning, MTJDL),通过在源图像和目标图像中的样本来训练共享字典(Shared Dictionary, SD),然后根据提取的特征训练稀疏逻辑回归(Sparse Logistic Regression, SLR)分类器。

3.1.3 ED-DMM-UDA

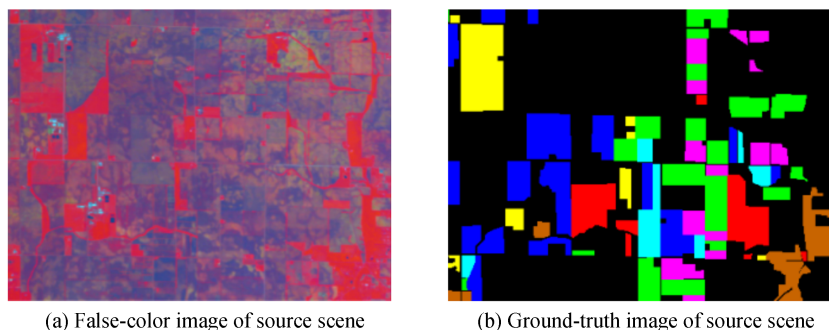
一种基于欧几里得距离深度度量的无监督域自适应方法(Euclidean Distance-Deep Metric Learning-Based Feature Embedding-Unsupervised Domain Adaptation, ED-DMM-UDA)。在源域和目标域之间完成域自适应过程后,选择最近邻算法作为分类器。

3.2 实验数据集

本文验证算法有效性使用的两个数据集分别为Indiana数据集和Pavia数据集,其中Indiana数据集为农业场景,Pavia数据集为城市场景,它们是高光谱分类领域的经典数据集,因此选择这两个数据集对方法性能和有效性进行验证。具体介绍如下。

3.2.1 Indiana数据集

利用机载可见光/红外成像光谱仪获取的来自美国印第安纳州西北部Indiana试验场的高光谱图像。与SD-MTJDL-SLR、ED-DMM-UDA实验数据集相同,选择两个单独的子集作为源和目标场景图像(两幅图像的大小相同,均为 $400 \times 300 \times 220$,具有220个波段)。两幅图像同时包含七类地物,光谱范围为400~2 500 nm。图6为Indiana假彩色图和地面真值图。



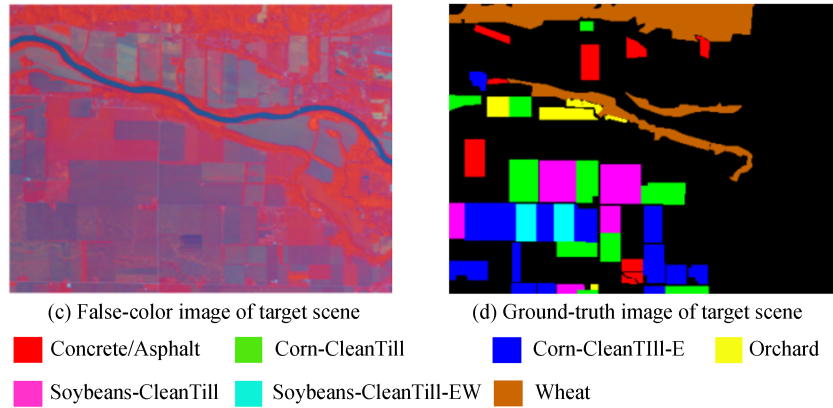


图6 Indiana数据集源与目标图像
Fig.6 Source and target images in Indiana dataset

3.2.2 Pavia数据集

该数据集是由数字机载成像系统传感器在意大利帕维亚市市区上空捕获的。在实验中,与SD-MTJDL-SLR、ED-DMM-UDA相同,选择Pavia University图像的一小部分(尺寸为 $243 \times 243 \times 72$)作为训练的源场景图像,并选择Pavia Center图像的一部分(尺寸为 $400 \times 400 \times 72$)作为用于预测的目标场景图像,空间分辨率为1.3 m。图7为两个场景的假彩色图和地面真值图。

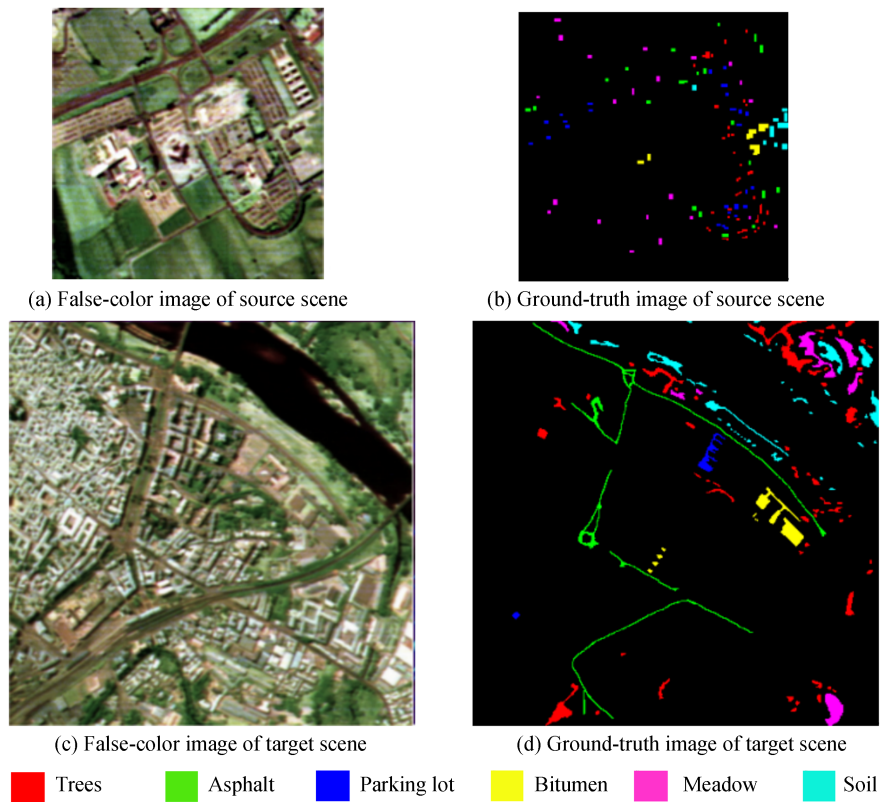


图7 Pavia数据集源与目标图像
Fig.7 Source and target images in Pavia dataset

图8分别给出了Indiana以及Pavia数据集中源与目标图像光谱曲线。其中,分别从源与目标图像的第一类样本中随机抽取5个,并将十条曲线绘制于同一幅图中。从图中可以看出,在实验所用的数据集中,即使是属于同一种地物的样本,其光谱特性仍然存在少许差距。因此会导致常规的分类算法无法直接应用于跨图像分类,这也正是域自适应要解决的问题。

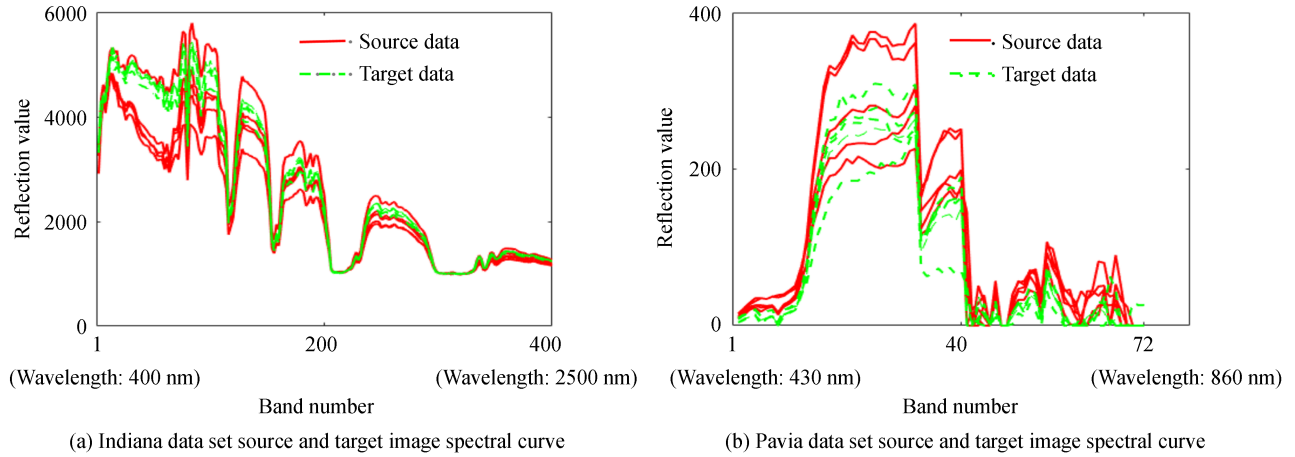


图8 源与目标图像光谱曲线
Fig.8 Source and target image spectral curves

3.3 实验结果及分析

本文算法 DCDA 由 Python 编程实现,实验是在 CPU 3.2 GHz,内存 16 GB,Windows 10 操作系统,Python3.7.3 环境下进行。

为了消除参数设置对实验结果的影响,此处直接与 SD-MTJDL-SLR 和 ED-DMM-UDA 原文中的实验结果进行比较。定量评价指标为总体精度 OA (Overall Accuracy)、平均精度 AA (Average Accuracy)、卡帕系数 κ (Kappa Statistic)。以上三个指标取值区间均为 $[0, 1]$,数值越大,相应实验的分类精度就越高。

3.3.1 Indiana 数据集实验结果

在实验中,每个类别随机地选择了 180 个源域标记像素将其作为训练集,共 1 260 个,并使用测试集中所有标记的像素来评估分类性能。样本类别、数量,以及各类别分类精度如表 1。Indiana 数据集各域自适应算法分类结果评价如表 2,分类结果如图 9。

表 1 Indiana 数据集各类别样本数量及分类精度
Table1 Number of samples in the Indiana dataset and classification accuracy of each category

Class	Name	Training samples	Testing samples	Classification accuracy/%
1	Concrete/Asphalt	180	2 942	53.18
2	Corn-CleanTill	180	6 029	25.01
3	Corn-CleanTill-EW	180	7 999	41.15
4	Orchard	180	1 562	93.90
5	Soybeans-CleanTill	180	4 792	42.29
6	Soybeans-CleanTil-EW	180	1 638	80.72
7	Wheat	180	10 739	82.16
	Total	1 260	35 701	OA=61.60%

表 2 Indiana 数据集分类精度对比
Table2 Comparison of classification accuracy in the Indiana dataset

Algorithm name	OA/%	AA/%	κ
TSVM	39.19	33.82	0.27
SD-MTJDL-SLR	51.34	43.51	0.38
ED-DMM-UDA	56.78	51.68	0.46
DCDA	61.60	61.79	0.53

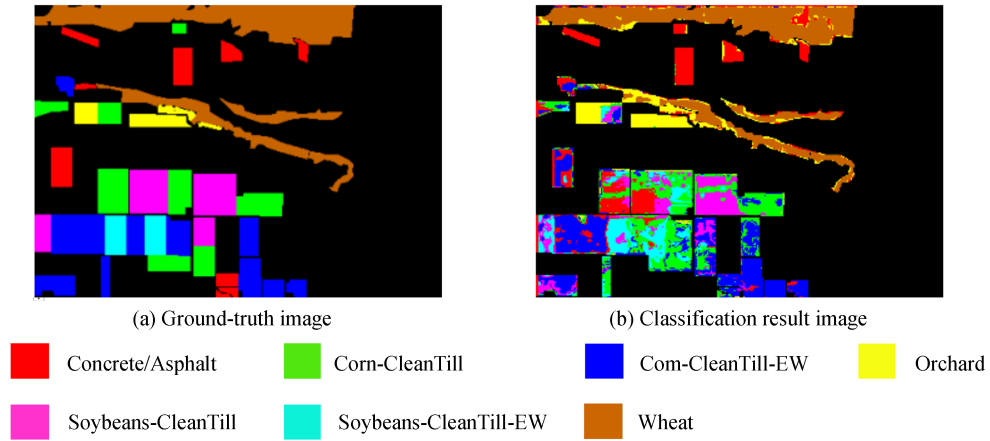


图9 Indiana目标数据集分类结果
Fig.9 Classification result of target Indiana dataset

在该数据下,本文提出的基于密集卷积和域自适应高光谱图像分类算法DCDA运行时间为5.996 4 s,获得了最高的OA、AA、 κ 系数。其中第四、六、七类别表现良好,总体精度OA为61.60%,较ED-DMM-UDA取得56.78%的总体精度和SD-MTJDL-SLR取得51.34%的总体精度有明显的提高。平均精度AA和 κ 系数也有相似的结论。结果表明引入密集卷积的域自适应网络能够取得比基础网络更好的分类结果。

3.3.2 Pavia数据集实验结果

在实验中,每个类别随机地选择了180个源域标记像素将其作为训练集,共1 080个,并使用目标场景图像(测试集)中所有标记的像素来评估分类性能。样本类别、数量,以及各类别分类精度如表3。Pavia数据集各域自适应算法分类结果评价如表4,分类结果如图10。

表3 Pavia数据集样本数量及各类别分类精度
Table 3 Number of samples in the Pavia dataset and classification accuracy of each category

Class	Name	Training samples	Testing samples	Classification accuracy/%
1	Trees	180	2 424	92.14
2	Asphalt	180	1 704	94.36
3	Paking lot	180	287	100
4	Bitumen	180	685	81.35
5	Meadow	180	1 251	95.78
6	Soil	180	1 475	81.99
	Total	1 080	7 826	OA=90.63%

表4 Pavia数据集分类精度对比
Table 4 Comparison of classification accuracy in the Pavia dataset

Algorithm name	OA/%	AA/%	κ
TSVM	61.21	61.50	0.53
SD-MTJDL-SLR	83.52	81.30	0.79
ED-DMM-UDA	90.34	87.87	0.88
DCDA	90.63	90.08	0.88

在该数据下,本文提出的基于密集卷积和域自适应高光谱图像分类算法DCDA运行时间为1.667 3 s,获得了最高的AA、 κ 系数。其中第三、五类别表现良好,整体精度OA为90.63%,比ED-DMM-UDA的整体精度略高。另外,DCDA的平均精度取得最大值,说明在整体精度提升不明显的情况下,DCDA局部表现良好,但是没有Indiana数据集提升明显。

通过对以上两个实验的对比可以发现,四个算法在Indiana上的分类精度较于Pavia数据集相差较明显,

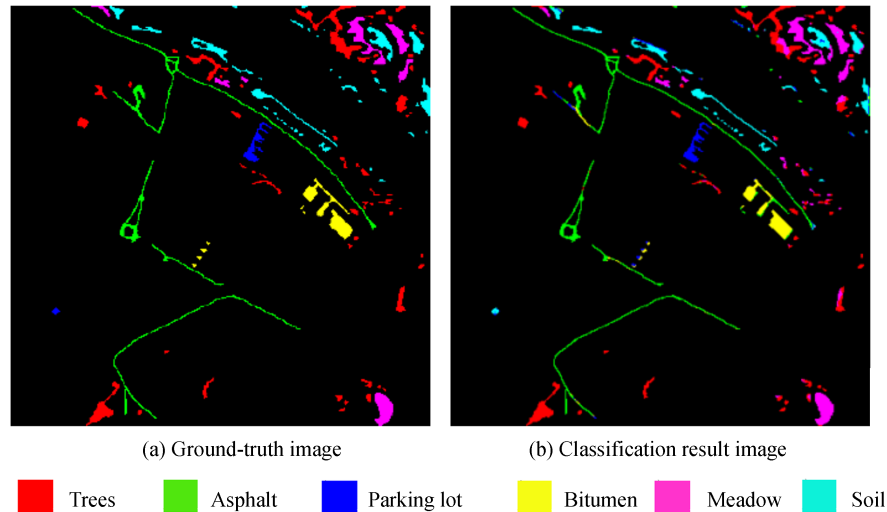


图10 Pavia目标数据集分类结果
Fig.10 Classification result of target Indiana dataset

除数据集场景本身差异因素外,这一问题与两数据的测试集和训练集样本数量有关。Indiana数据集中训练集和测试集的样本数量分别为1 260和35 701,二者比为3.53%。Pavia数据集中训练集和测试集的样本数量分别为1 080和7 826,比为13.8%。对比2个不同数据集各分类算法的分类精度和样本数量发现,引入了密集卷积的域自适应分类算法,在小样本规模的数据下优势明显。

三个对比算法TSVM、SD-MTJDL-SLR、ED-DMM-UDA与本文的DCDA算法都是应用于高光谱图像跨场景域自适应分类的算法,其中第三个对比算法ED-DMM-UDA与本文DCDA算法在域自适应部分采用的都是基于鉴别器更新的子空间域自适应方法。在特征提取部分,ED-DMM-UDA的卷积神经网络共有6层(包括四层卷积+ReLU激活函数层,一层池化层,一层全连接层),DCDA特征提取结构同样包括6层(四层密集卷积复合层,一层池化层,一层全连接层)。由Indiana和Pavia数据集上的OA、AA、 κ 系数最直观的对比可以看出:在层数和样本数量相等的情况下,由于Densenet可以将状态逐层传递,因此增强了特征传播,提高分类精度,因此在高光谱图像域自适应分类的特征提取结构中,DCDA更具优势。

4 结论

本文提出了一种基于密集卷积和域自适应的高光谱图像分类算法,首先通过在源图像上训练基于密集卷积的源嵌入模块,然后将源域和目标域的光谱特征空间转化为一个新的共享空间,优化鉴别器,用以更新目标嵌入模块,以达到无监督域自适应训练过程。对无监督域自适应模型进行训练后,使用近邻分类器完成分类任务。该方法在Indiana和Pavia数据集中得到的整体分类精度分别为61.06%和89.63%,证明了所提方法的分类精度比三个对比算法有了较为明显的提升。下一步的研究将选用更多的数据集验证本文所提算法的效果及性能。

参考文献

- [1] JIAO Q J, ZHANG B, LIU J G, LIU L Y. A novel two-step method for winter wheat-leaf chlorophyll content estimation using a hyperspectral vegetation index[J]. International Journal of Remote Sensing, 2014, 35(21): 7363-7375.
- [2] ZHANG Bing. Advancement of hyperspectral image processing and information extraction[J]. Journal of Remote Sensing, 20(5): 1062-1090.
张兵. 高光谱图像处理与信息提取前沿. 遥感学报, 2016, 20(5): 1062-1090.
- [3] XU Dongdong, CHENG Deqiang, CHEN Liangliang, et al. Hyperspectral image classification based on hierarchical guidance filtering and nearest regularized subspace[J]. Acta Photonica Sinica, 2020, 49(4): 197-209.
徐冬冬,程德强,陈亮亮,等. 基于分层引导滤波与最近邻正则化子空间的高光谱图像分类[J]. 光子学报, 2020, 49(4): 0410004.
- [4] 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.

- [5] KHOSRAVI I, JOUYBARI-MOGHADDAM Y. Hyperspectral imbalanced datasets classification using filter-based forest methods[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(12): 4766-4772.
- [6] PAL M. Extreme-learning-machine-based land cover classification[J]. *International Journal of Remote Sensing*, 2009, 30(14): 3835-3841.
- [7] CHEN Y S, JIANG H L. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(10):6232-6251.
- [8] RAJAN S, GHOSH J, CRAWFORD M M. An active learning approach to hyperspectral data classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008,46(4): 1231-1242.
- [9] CRAWFORD M M, TUIA D, YANG H L. Active learning: Any value for classification of remotely sensed data?[C]. *Proceedings of the IEEE*, 2013, 101(3): 593-608.
- [10] CHI M, BRUZZONE L. Semisupervised classification of hyperspectral images by SVMs optimized in the primal[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(6): 1870-1880.
- [11] CAMPS-VALLS G, MARSHEVA T V B, ZHOU D. Semi-supervised graph-based hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(10): 3044-3054.
- [12] KIM W, CRAWFORD M M. Adaptive classification for hyperspectral image data using manifold regularization kernel machines[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(11): 4110-4121.
- [13] YE M, QIAN Y, ZHOU J, TANG Y Y. Dictionary learning-based feature-level domain adaptation for cross-scene hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(3): 1544-1562.
- [14] ZHOU X, PRASAD S. Domain adaptation for robust classification of disparate hyperspectral images [J]. *IEEE Transactions on Geoscience and Remote Sensing*,2017, 3(4): 822-836.
- [15] TUIA D, PERSELLO C, BRUZZONE L. Domain adaptation for the classification of remote sensing data: An overview of recent advances[J]. *IEEE Transactions on Geoscience and Remote Sensing Magazine*, 2016, 4(2): 41-57.
- [16] BRUZZONE L, CHI M, MARCONCINI M. A novel transductive SVM for semisupervised classification of remote-sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(11): 3363-3373.
- [17] LI Ying, ZHANG Lifu, YAN Wei, et al. Weed identification using imaging spectrometer data[J]. *Journal of Remote Sensing*, 2013, 8(4):855-871.
李颖, 张立福, 严薇, 等. 地面成像光谱数据的田间杂草识别[J]. *遥感学报*, 2013, 8(4):855-871.
- [18] DENG Bin, JIA Sen, SHI Daming. Deep metric learning-based feature embedding for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(2):1422-1435.
- [19] HUANG G, LIU Z, et al. Densely connected convolutional networks[C]. *30th IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, HI, 2017: 2261-2269.
- [20] 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.
- [21] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]. *IEEE Conference on Computer Vision and Pattern Recognition*, Boston, MA, 2015: 1-9.
- [22] HE K, ZHANG X, REN S, SUN J. Deep residual learning for image recognition [C]. *2016 IEEE Conference on Computer Vision and Pattern Recognition*, Seattle, WA, 2016: 770-778.