

# 利用残差密集网络的高光谱图像分类

魏祥坡\*, 余旭初, 谭熊, 刘冰  
信息工程大学, 河南 郑州 450001

**摘要** 卷积神经网络模型能够提取图像不同层次的分层特征, 提取图像包含有大量的细节信息, 然而, 现有方法没有充分利用网络模型提取的所有分层特征。为了充分利用所有分层特征, 增强特征重利用和信息连续传递, 设计了适用于高光谱图像分类的残差密集网络模型。残差密集网络结合了残差网络和密集网络, 包括浅层特征提取、残差密集单元和密集特征融合三部分。利用卷积操作提取原始图像的浅层特征, 将浅层特征作为残差密集单元的输入, 残差密集单元的输出与下一个单元中每个卷积层的输出建立短连接, 实现了信息连续传递; 将两个单元提取的密集特征与浅层特征相加形成全局残差学习, 实现了所有分层特征的融合, 最终的融合特征用于高光谱图像分类。实验表明, 本文方法用于 Indian Pines 数据、University of Pavia 数据及 Salinas 数据能够分别取得 98.71%、99.31% 及 97.91% 的分类精度, 有效提高了高光谱图像的分类精度, 增强了分类方法的稳定性。

**关键词** 图像处理; 高光谱图像; 残差学习; 密集网络; 残差密集网络

中图分类号 TP751

文献标识码 A

doi: 10.3788/LOP56.151006

## Hyperspectral Image Classification Based on Residual Dense Network

Wei Xiangpo\*, Yu Xuchu, Tan Xiong, Liu Bing

Information Engineering University, Zhengzhou, Henan 450001, China

**Abstract** A convolutional neural network (CNN) can extract hierarchical features in an image, and the extracted images include a large amount of detailed information contained in the image. However, CNN-based methods do not take full advantage of all hierarchical features extracted by the network. To make full use of all hierarchical features and enhance feature reuse and information flow, we design a residual dense network suitable for hyperspectral image classification. The residual dense network combines residual and dense networks, including shallow feature extraction, residual dense units, and dense feature fusion. Firstly, shallow features of the original image are extracted using a convolution operation, which is input to the residual dense unit. Secondly, the output of the residual dense unit establishes a shortcut connection with each convolution layer and output layer in the next unit, thereby realizing continuous information transmission. Subsequently, dense features extracted from the two units are added to the shallow features to form global residual learning, which realizes the fusion of all hierarchical features. The fused features are then used for hyperspectral image classification. Experimental results demonstrate that the proposed method can obtain 98.71%, 99.31%, and 97.91% classification accuracies on the Indian Pines, University of Pavia, and Salinas data, respectively, which effectively improves the classification accuracy of hyperspectral images and enhances the stability of classification methods.

**Key words** image proceedings; hyperspectral image; residual learning; dense network; residual dense network

**OCIS codes** 100.2960; 100.4996; 280.4991; 110.4234

## 1 引言

高光谱图像能够获取地面目标近似连续的波段信息, 极大提高了地物的区分能力, 在矿物勘探、精

细农业、国防建设等领域发挥了重要作用<sup>[1]</sup>。高光谱图像分类是利用高光谱图像中包含的丰富信息, 为每个像素赋以唯一的类别标识, 是高光谱图像应用的重要方面。然而, 高光谱图像中存在同物异谱

收稿日期: 2019-01-03; 修回日期: 2019-01-24; 录用日期: 2019-03-06

基金项目: 国家自然科学基金(41801388)、河南省科技攻关计划项目(152102210014)

\* E-mail: 13526635671@163.com

及同谱异物现象,导致图像数据结构呈高度非线性,相邻波段及相邻像元之间具有较强的相关性;同时高光谱图像中训练样本往往数量有限,容易发生维数灾难。因此,如何提取具有较强可分性的判别性特征是高光谱图像分类的关键。

机器学习中的支持向量机(SVM)方法,能够有效处理高维数据,解决维数灾难问题,一直是高光谱图像分类的经典方法。该方法能够有效处理非线性数据,极大提高了高光谱图像的分类精度。然而,SVM方法没有考虑邻域像元之间的相关性,并且需要复杂的调参过程。

近年来,凭借强大的自动学习特征的能力,深度学习被广泛应用于图像识别、目标检测等领域,在高光谱图像分类方面也取得了优异的效果。自编码器(SAE)和深度置信网络(DBN)是最早用于高光谱图像分类的深度学习模型<sup>[2-4]</sup>,然而,这两种模型都要求将三维数据变换为一维输入向量,损失了空间信息,而且需要大量的模型参数。卷积神经网络(CNN)<sup>[5-6]</sup>能够通过处理像元的邻域,提取空间-光谱特征,进一步提高了高光谱图像分类的精度。

然而随着模型层数的增加,CNN训练过程中会出现梯度消失的现象,导致分类精度下降。残差网络(ResNet)<sup>[7-8]</sup>在CNN结构中加入恒等映射,在残差单元的输入和输出之间添加短连接,能够在增加模型层数的同时有效解决梯度消失问题,防止过拟合。ResNet已经被广泛应用于图像处理领域,如超分辨率重建<sup>[9]</sup>、目标检测<sup>[10]</sup>、图像识别等,近年来,其在高光谱图像分类应用中也取得了良好的效果。钟健等<sup>[11]</sup>提出了一种半监督残差梯型网络(Semi-RLNet),将传统梯型网络中的全连接网络结构改为ResNet结构,实现了ResNet与SAE的有效结合。Song等<sup>[12]</sup>以多个含有不同卷积核数量的ResNet为基本单元,对各个残差单元进行池化操作,连接不同单元的池化层,能够实现高光谱图像不同层次特征的融合。Zhong等<sup>[13]</sup>构建了包含三维卷积层的残差网络单元,为充分利用残差单元的特征提取能力,利用包含不同尺寸卷积核的残差单元分别提取图像中的光谱特征和空间特征,不仅有效保留了图像中的光谱信息和空间信息,还解决了由深层网络结构导致的精度下降问题。然而,ResNet没有充分利用残差单元中每一个卷积层输出的信息,也忽略了任意两个卷积层之间的联系,同时层层相加的模式也不利于网络中信息的传递。

Huang等<sup>[14]</sup>提出了密集网络(DenseNet)模

型,DenseNet能够以连接模式连接密集单元中的任意两个卷积层,实现了特征重利用及信息传递。Wang等<sup>[15]</sup>将DenseNet用于高光谱图像分类,不仅提高了分类精度,还缩短了训练时间。然而,DenseNet只考虑了密集单元内部不同层之间的联系,没有充分利用不同单元提取的所有分层特征。Zhang等<sup>[16]</sup>提出了用于图像超分辨率重建的残差密集网络(ResDenNet),将ResNet与DenseNet结合,再将网络模型中不同单元提取的浅层特征与深层特征结合,取得了更好的效果。ResDenNet包括浅层特征提取、残差密集单元(RDB)、密集特征融合三部分,首先对原始图像进行卷积操作提取浅层特征,将浅层特征作为残差密集单元的输入;残差密集单元包含密集连接和局部特征融合,其输出与下一个单元内的各个卷积层直接相关,实现了单元之间的信息连续传递;随后,密集特征融合实现了浅层特征和各个单元提取的不同分层特征之间的全局特征融合,局部特征融合及全局特征融合均以短连接的方式实现,最终的融合特征用于图像重建。而考虑到高光谱图像复杂的光谱-空间结构,充分利用不同单元提取的分层特征,将浅层特征与深层特征结合能够提供丰富的图像细节信息,有利于图像分类。根据高光谱图像数据的特点,本文设计了适用于高光谱图像分类的残差密集网络模型。与SVM、CNN、ResNet及DenseNet等方法在三组高光谱数据上进行对比实验,结果表明,本文方法能够有效提高高光谱图像分类的精度,增强分类方法的稳定性。

## 2 基本原理

### 2.1 残差网络

设残差单元的输入为 $x$ ,对于没有短连接的网络单元输出为 $F(x)$ ,添加了短连接的残差单元,其输出为 $H(x)$ ,则存在 $H(x)=F(x)+x$ 。实验证明,在残差单元中,优化残差映射 $F(x)$ 比优化原始函数映射 $H(x)$ 要容易得多, $H(x)$ 在网络结构中可以理解为残差映射 $F(x)$ 与恒等映射 $x$ 的加和。恒等映射既没有增加参数数量,也不会影响原始网络模型的复杂度。图1为ResNet的结构图,其中,Conv表示卷积操作,BN表示批归一化,ReLU表示网络采用ReLU激活函数。

### 2.2 密集网络

图2为密集单元的结构图。DenseNet以密集单元为基础,密集单元由卷积层、激活层、批归一化层组成,第 $l$ 层的输入为从输入层到第 $l-1$ 层所有




图1 残差单元结构图

Fig. 1 Structure of residual block

输出特征图的叠加,可以表示为

$$X_l = H_l([X_0, X_1, \dots, X_{l-1}]), l = 1, 2, \dots, N, \quad (1)$$

式中: $X_l$ 为第 $l$ 层的输出; $H_l(\cdot)$ 为第 $l$ 层的非线性变换操作; $[\cdot]$ 表示不同特征图之间的连接操作。DenseNet将不同卷积层输出的特征图连接起来,并保留了不同特征图的原始值。DenseNet的密集连接结构缓解了训练过程中的梯度消失问题,有助于




图2 密集单元结构图( $l=3$ )

Fig. 2 Structure of dense block ( $l=3$ )

构建更深层的网络模型,能够有效防止过拟合。

### 2.3 残差密集网络

图3为残差密集单元的示意图。ResDenNet以残差密集单元为基础,残差密集单元由多个卷积层和激活层构成,起到特征提取的作用,每个单元的输出都会与下一个单元的每个卷积层的输出建立短连接,实现了信息连续传递。




图3 残差密集单元示意图

Fig. 3 Illustration of residual dense block

设第 $d$ 个单元的输入和输出分别为 $F_{d-1}$ 和 $F_d$ ,其特征图数量均为 $G_0$ ,单元中第 $c$ 个卷积层的输出可以表示为

$$F_{d,c} = H\{[F_{d-1}, F_{d,1}, \dots, F_{d,c-1}]\}, \quad (2)$$

式中: $H(\cdot)$ 为该卷积层的非线性操作,包括卷积及ReLU函数。设 $F_{d,c}$ 输出 $G$ 个特征图,表示上一单元输出的特征图与本单元前 $c-1$ 个卷积层输出的特征图之间的连接,共含有 $G_0 + (c-1) \times G$ 个特征图。

由于单元的输入与卷积层之间采用连接模式,有必要在单元的最后对特征图进行压缩,因此采用 $1 \times 1$ 卷积控制特征图的数量,可以表示为

$$F_{d,LF} = H_{LF}^d\{[F_{d-1}, F_{d,1}, \dots, F_{d,c}]\}, \quad (3)$$

式中: $H_{LF}^d$ 表示 $1 \times 1$ 卷积操作。单元最后的输出可以表示为

$$F_d = F_{d-1} + F_{d,LF}. \quad (4)$$

通过将单元的输出与输入相加实现了局部残差学习,进一步保留了大量图像细节信息,提高了残差密集单元的特征提取能力。

### 2.4 高光图像残差密集网络分类方法

图4为适用于高光图像分类的ResDenNet模型。将高光图像数据中某个像素的邻域作为网络模型的输入,经过二维卷积层及非线性激活层提取图像的浅层特征,同时作为残差密集单元的输入。网络

模型包含两个残差密集单元。与Zhang等<sup>[16]</sup>不同的是,由于高光图像数据结构复杂,需要在特征提取过程中加入对特征进行抽象简化的操作,因此在残差密集单元之后添加池化层,池化层能够进一步对提取的特征进行抽象,只需要保留对分类有用的抽象特征,适用于高光图像复杂数据结构。两个残差密集单元提取的密集特征经过连接操作及卷积操作后,与提取的浅层特征相加形成全局残差学习,实现了浅层特征和深层特征结合,充分保留了图像中含有的丰富信息,有利于提高网络模型的特征提取能力。针对高光图像的复杂数据结构,进一步增强特征的抽象程度,网络模型对全局残差学习输出的结果进行批归一化、dropout、全连接(FC)操作,能够提高特征的可分性,减少模型参数数量,降低模型训练难度,最后以softmax函数作为分类函数,生成类别标签。

除残差密集单元内部的 $1 \times 1$ 卷积层之外,其余卷积层中卷积核尺寸均设置为 $3 \times 3$ ,而且卷积层之后均伴随着非线性激活层,能够提高模型提取非线性特征的能力。模型的优化函数采用适合非凸优化问题的Adam函数<sup>[17]</sup>。对于原始数据的邻域大小,实验证明,较大的邻域能够取得较好的效果,但是相应的训练时间会增加,因此综合考虑设置邻域大小为 $9 \times 9$ <sup>[18]</sup>。




图4 高光谱图像分类残差密集网络模型示意图

Fig. 4 Illustration of residual dense network model for hyperspectral image classification

### 3 实验结果与分析

#### 3.1 实验数据

为了验证本文方法的合理性和有效性,采用高光谱图像数据 Indian Pines 数据(IN)、University of Pavia 数据(UP)及 Salinas 数据(SA)进行验证实验。实验在计算机上基于 Ubuntu 系统,利用 Python 编程语言自主编程实现,配置为 Intel Core i7-4720HQ @ 2.6 GHz、Nvidia GeForce GTX 965 M和 16 GB 内存。Indian Pines 数据是由美国 AVIRIS 成像光谱仪获取的印第安纳州西北部某林区的图像,图像大小为 145 pixel×145 pixel,去除水汽吸收波段后共 200 个波段,波长范围为 0.4~2.45  $\mu\text{m}$ ,空间分辨率为 20 m。图像中共有 16 类地物,在实验中剔除真实样本数量较少的类别,仅

保留 9 类地物<sup>[19]</sup>,实验中训练样本和测试样本的数量如表 1 所示。University of Pavia 数据是由德国宇航中心 ROSIS 成像光谱仪获取的意大利帕维亚大学图像,图像大小为 610 pixel×340 pixel,去除水汽吸收波段后共 103 波段,波长范围为 0.43~0.86  $\mu\text{m}$ ,空间分辨率为 1.3 m。图像共有 9 类地物 42776 个标签样本,每类地物取 200 个训练样本,其余作为测试样本,如表 2 所示。Salinas 数据是由 AVIRIS 传感器获取的美国加州 Salinas 山谷地区的高光谱图像,图像大小为 512 pixel×217 pixel,去除水汽吸收波段后共 204 波段,图像中共包含 16 类地物,其训练样本和测试样本数量如表 3 所示。3 组数据来自不同的传感器,具有不同的空间分辨率,能够有效验证本文方法的有效性和稳定性。

表 1 Indian Pines 数据样本数量

Table 1 Numbers of Indian Pines data samples

Number	1	2	3	4	5	6	7	8	9	10
Category	Corn-notill	Corn-mintill	Grass-pasture	Grass-trees	Hay-windowed	Soybean-notill	Soybean-mintill	Soybean-clean	Woods	Total
Number of training sample	200	200	200	200	200	200	200	200	200	1800
Number of testing sample	1228	630	283	530	278	772	2255	393	1065	7434

表 2 University of Pavia 数据样本数量

Table 2 Numbers of University of Pavia data samples

Number	1	2	3	4	5	6	7	8	9	
Category	Asphalt	Meadows	Gravel	Trees	Sheets	Bare Soil	Bitumen	Bricks	Shadows	Total
Number of training sample	200	200	200	200	200	200	200	200	200	1800
Number of testing sample	6431	18449	1899	2864	1145	4829	1130	3482	747	40976

#### 3.2 参数选择

ResDenNet 主要由卷积层、池化层等组成,多个参数对网络模型的性能有着很大的影响,包括学习率、卷积核数量、批尺寸等,需要对网络参数进行选择 and 确定。先分别设置学习率为 0.001、0.01 和 0.1,实验发现最优学习率为 0.001。然后分别采用

卷积核数量为 8、16、24、32、40 的网络模型进行分类实验。图 5 对比了三组数据利用不同模型的分精度,可以看出,Indian Pines 数据及 University of Pavia 数据的分类精度均在卷积核数量为 32 时达到最高,而 Salinas 数据在卷积核数量为 24 时取得最佳的分类精度。

表3 Salinas 数据样本数量  
Table 3 Numbers of Salinas data samples

Number	Category	Number of training sample	Number of testing sample
1	Baocoli_weeds_1	200	1809
2	Baocoli_weeds_2	200	3526
3	Fallow	200	1776
4	Fallow_rough_plow	200	1194
5	Fallow_smooth	200	2478
6	Stubble	200	3759
7	Celery	200	3379
8	Grapes_untrained	200	11071
9	Soil_vinyard_develop	200	6003
10	Corn_senesced_weeds	200	3078
11	Lettuce_romaine_4 weeks	200	868
12	Lettuce_romaine_5 weeks	200	1727
13	Lettuce_romaine_6 weeks	200	716
14	Lettuce_romaine_7 weeks	200	870
15	Vinyard_untrained	200	7068
16	Vinyard_vertical_trellis	200	1607
	Total	3200	50929




图5 不同卷积核数量的模型分类精度

Fig. 5 Classification accuracies of models with different kernel numbers




图6 不同批尺寸的模型分类精度

Fig. 6 Classification accuracies of models with different batch sizes

其次设置训练过程中批尺寸为 16、24、32、50、64,图 6 列出了不同批尺寸的模型分类精度。可以看出,在 Indian Pines 数据中,批尺寸为 32 时模型表现最好;而在 University of Pavia 数据及 Salinas 数据中,批尺寸为 64 时分类精度最高。

### 3.3 实验结果与分析

为了评价本文方法的合理性和有效性,将本文方法与典型分类方法进行对比,如 SVM、CNN、ResNet 和 DenseNet。其中,SVM 核函数采用径向基函数(RBF)函数,并采用交叉验证的方法确定核参数  $\lambda$  和惩罚系数  $c$ 。CNN、ResNet、DenseNet 按照 ResDenNet 的模型结构设计,经过参数选择实验,在 Indian 数据中,CNN、ResNet、DenseNet 的最优卷积核数量和批尺寸分别为 32 和 24、40 和 24、24 和 50;在 University of Pavia 数据中,CNN、

ResNet、DenseNet 的最优卷积核数量和批尺寸分别为 32 和 50、40 和 50、32 和 64;在 Salinas 数据中,CNN、ResNet、DenseNet 的最优卷积核数量和批尺寸分别为 32 和 32、32 和 24、40 和 64。在分类过程中,每个分类器的训练样本数量都是相同的(每类 200 个样本)。评价指标采用总体精度(OA)、平均精度(AA)及 Kappa 系数等,每种分类方法独立运行 10 次分类实验,给出了评价指标的平均值及方差。

表 4 列出了 3 组实验数据的分类结果评价指标,表中加粗数字为同一行中的最优值。从表 4 可以看出:SVM 在 3 组数据中分类精度较差,而深度网络模型凭借其强大的特征提取能力取得了较高的分类精度;ResNet 和 DenseNet 要比普通 CNN 模型分类精度更高,证实了在网络模型中添加短连接和密集连

接对模型性能的提高作用。本文方法 ResDenNet 取得了最高的分类精度,在 3 组数据上分别达到 98.71%、99.31% 和 97.91%, 相比 DenseNet 提高了 0.8%、0.7% 和 1.4%, 相比 ResNet 提高了 0.9%、0.8% 和 1.5%。正是由于 ResDenNet 结合了 ResNet 和 DenseNet,在 DenseNet 的基础上实现了局部残差学习及全局残差学习,同时结合了高光谱图像中不同尺度层次的特征,提高了模型的特征提取能力,促进了模型中信息流通,增强了模型的稳定性,因此 ResDenNet 结果的方差最小,稳定性最强。高光谱影

像的空间分辨率普遍不高,导致影像中存在混合像元;而由于 University of Pavia 数据的空间分辨率最高,地物实际大小与像元对应尺度的匹配性最好,能够取得最高的分类精度。

利用 Indian Pines 数据和 University of Pavia 数据训练的模型对 Salinas 数据直接进行分类处理,进行 10 次独立实验,其结果如表 5 所示。可以看出,Salinas 数据利用其他数据训练好的模型仍能得到较好的分类精度,但相比直接利用本数据内的样本训练得到的分类精度有所降低。

表 4 实验数据分类精度(平均值±方差)

Table 4 Classification accuracies (mean value±variance) of experimental datasets

Dataset	Criteria /%	SVM	CNN	ResNet	DenseNet	ResDenNet
IN	OA	86.82±1.12	96.09±0.46	97.79±0.47	97.92±0.11	98.71±0.01
	AA	87.60±0.43	96.28±0.31	97.90±0.45	98.09±0.13	98.94±0.01
	Kappa	84.70±1.34	95.44±0.63	97.42±0.63	97.56±0.15	98.48±0.02
UP	OA	89.87±1.25	97.33±0.03	98.49±0.19	98.58±0.09	99.31±0.01
	AA	89.91±0.51	96.55±0.04	98.26±0.16	98.43±0.07	99.08±0.02
	Kappa	87.32±1.46	96.48±0.06	98.01±0.34	98.13±0.16	99.08±0.01
SA	OA	89.66±1.18	92.84±0.52	96.39±0.54	96.52±0.15	97.91±0.02
	AA	93.62±0.47	96.44±0.24	98.16±0.31	98.13±0.09	98.90±0.01
	Kappa	88.56±1.26	92.05±0.35	95.99±0.42	96.13±0.17	97.68±0.03

表 5 Salinas 数据分类精度(平均值±方差)

Table 5 Classification accuracies (mean value±variance) of Salinas dataset

Dataset	Criteria/%	Model based on IN	Model based on UP	Model self-trained
SA	OA	96.75±0.13	97.21±0.10	97.91±0.02
	AA	98.52±0.01	98.67±0.01	98.90±0.01
	Kappa	96.38±0.16	96.90±0.12	97.68±0.03

图 7~9 分别为 3 组数据采用不同方法获取的分类结果图,可以看出,ResDenNet 的分类结果图

更平滑,同质区域的整体性更好,孤立噪声点也最少。




图 7 Indian Pines 数据分类结果图

Fig. 7 Classification maps for Indian Pines dataset

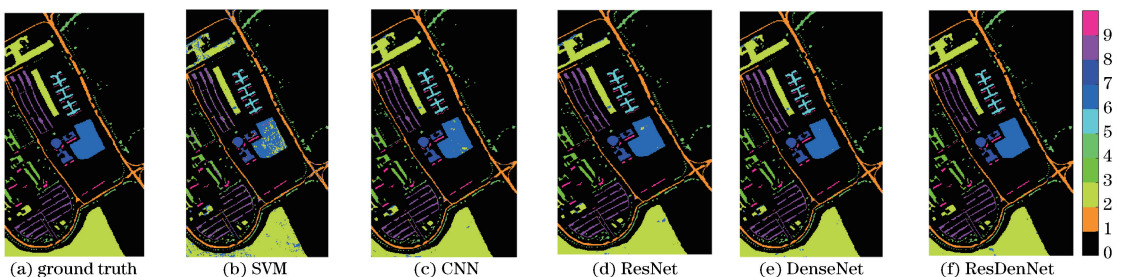


图 8 University of Pavia 数据分类结果图

Fig. 8 Classification maps of University of Pavia dataset

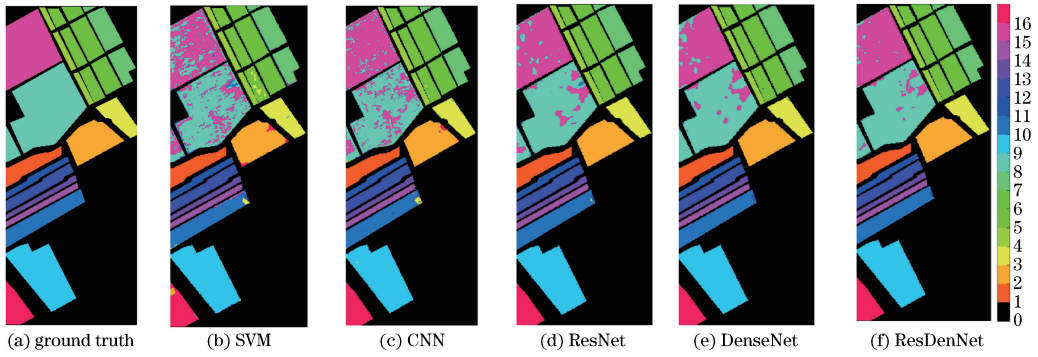


图 9 Salinas 数据分类结果图

Fig. 9 Classification maps of Salinas dataset

表 6 列出了 CNN、ResNet、DenseNet 及 ResDenNet 分类方法各自的平均训练测试时间,由于添加了短连接及密集连接,ResNet 和 DenseNet 的训练测试时间要比 CNN 训练测试时间更长。在 Indian Pines 数据的 DenseNet 分类实验中,经过多次对比,发现去除密集单元中的批归一化层时,分类精度更高,因此 DenseNet 分类实验训练测试时间较 ResNet 和 ResDenNet 方法的训练测试时间更短。在 University of Pavia 数据中,DenseNet 方法包含了批归一化层,因此训练测试时间比 ResNet 方法要长;而 ResDenNet 在残差密集单元中去除了批归一化层,降低了模型复杂度,相比于 DenseNet 缩短了训练测试时间。

最后利用不同数量的训练样本参与模型训练,检验模型在小样本情况下的分类精度。分别设置3组数

表 6 不同方法训练测试时间

Table 6 Training and testing time for different methods

Dataset	Type	CNN	ResNet	DenseNet	ResDenNet
IN	Train	132.32	231.49	136.07	249.43
	Test	1.98	6.56	3.91	4.82
UP	Train	94.87	156.80	192.23	187.68
	Test	12.29	14.44	17.08	16.89
SA	Train	173.84	300.37	354.32	272.12
	Test	7.26	9.23	14.27	15.09

据的训练样本数量为 50、100、150 和 200,图 10 给出了 3 组数据的分类精度对比。从图 10 可以看出,随着训练样本数量的变化,ResNet 和 DenseNet 的分类精度比较接近,而 ResDenNet 的分类精度始终保持最优,呈现逐步提高的趋势。正是由于 ResDenNet 充分利用了网络模型中不同单元提取的所有的分层特征,实现了信息连续传递,增强了网络模型的稳定性。




图 10 不同训练样本数量的模型分类精度

Fig. 10 Classification accuracies for different training sample numbers

## 4 结 论

为了充分利用网络模型不同单元提取的分层特征,设计了适用于高光谱图像分类的 ResDenNet 模型。ResDenNet 结合了残差网络和密集网络,能够充分利用模型中不同单元提取的所有分层特征,不仅通过短连接和密集连接克服了梯度消失问题,还

充分提取了图像中的细节信息,增强了特征重利用和信息连续传递。

分析了不同网络参数对分类精度的影响,选出适合不同网络模型的较好参数,对比了不同网络模型的训练测试时间,以及本文方法在不同数量的训练样本条件下的分类精度。实验表明,本文方法能够有效提高分类精度,增强分类方法的稳定性。

ResNet 和 DenseNet 充分利用 CNN 的特征提取能力,为高光谱图像分类提供了有力的工具,后续研究可以考虑将 ResNet 和 DenseNet 与半监督方法结合,利用少量的训练样本取得较高的分类精度。

## 参 考 文 献

- [1] Bioucas-Dias J M, Plaza A, Camps-Valls G, *et al.* Hyperspectral remote sensing data analysis and future challenges[J]. IEEE Geoscience and Remote Sensing Magazine, 2013, 1(2): 6-36.
- [2] Chen Y S, Lin Z H, Zhao X, *et al.* Deep learning-based classification of hyperspectral data[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2094-2107.
- [3] Chen Y S, Zhao X, Jia X P. 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.
- [4] Huang H, He K, Zheng X L, *et al.* Spatial-spectral feature extraction of hyperspectral image based on deep learning[J]. Laser & Optoelectronics Progress, 2017, 54(10): 101001.  
黄鸿, 何凯, 郑新磊, 等. 基于深度学习的高光谱图像空-谱联合特征提取[J]. 激光与光电子学进展, 2017, 54(10): 101001.
- [5] Hu W, Huang Y Y, Wei L, *et al.* Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015: 258619.
- [6] Yan M, Zhao H D, Li Y H, *et al.* Multi-classification and recognition of hyperspectral remote sensing objects based on convolutional neural network[J]. Laser & Optoelectronics Progress, 2019, 56(2): 021702.  
闫苗, 赵红东, 李宇海, 等. 基于卷积神经网络的高光谱遥感地物多分类识别[J]. 激光与光电子学进展, 2019, 56(2): 021702.
- [7] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [8] Lu Y S, Li Y X, Liu B, *et al.* Hyperspectral data haze monitoring based on deep residual network[J]. Acta Optica Sinica, 2017, 37(11): 1128001.  
陆永帅, 李元祥, 刘波, 等. 基于深度残差网络的高光谱遥感数据霾监测[J]. 光学学报, 2017, 37(11): 1128001.
- [9] Wang C, Liu Y, Bai X, *et al.* Deep residual convolutional neural network for hyperspectral image super-resolution[M] // Zhao Y, Kong X, Taubman D. Image and graphics. ICIG 2017. Lecture notes in computer science. Cham: Springer, 2017, 10668: 370-380.
- [10] Zhang C, Chen Y. Object detection based on hard examples mining using residual network[J]. Laser & Optoelectronics Progress, 2018, 55(10): 101003.  
张超, 陈莹. 残差网络下基于困难样本挖掘的目标检测[J]. 激光与光电子学进展, 2018, 55(10): 101003.
- [11] Zhong J. Research on semi-supervised learning method of remote sensing image based on deep neural network [D]. Shenyang: Shenyang Aerospace University, 2018: 38-47.  
钟健. 基于深度神经网络的遥感图像半监督学习方法研究[D]. 沈阳: 沈阳航空航天大学, 2018: 38-47.
- [12] Song W W, Li S T, Fang L Y, *et al.* Hyperspectral image classification with deep feature fusion network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(6): 3173-3184.
- [13] Zhong Z L, Li J, Luo Z M, *et al.* Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(2): 847-858.
- [14] Huang G, Liu Z, van der Maaten L, *et al.* Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 2261-2269.
- [15] Wang W J, Dou S G, Jiang Z M, *et al.* A fast dense spectral-spatial convolution network framework for hyperspectral images classification [J]. Remote Sensing, 2018, 10(7): 1068.
- [16] Zhang Y L, Tian Y P, Kong Y, *et al.* Residual dense network for image super-resolution[C] // 2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 2472-2481.
- [17] Kingma D P, Ba J. Adam: a method for stochastic optimization [J/OL]. (2017-01-30) [2019-01-05]. <https://arxiv.org/abs/1412.6980>.
- [18] Liu B, Yu X C, Zhang P Q, *et al.* A semi-supervised convolutional neural network for



- hyperspectral image classification [J]. Remote Sensing Letters, 2017, 8(9): 839-848.
- [19] Li W, Wu G D, Zhang F, *et al.* Hyperspectral image classification using deep pixel-pair features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(2): 844-853.