

基于卷积神经网络的高光谱遥感地物多分类识别

闫苗^{1,2}, 赵红东^{1*}, 李宇海², 张洁^{1,2}, 赵泽通^{1,2}

¹河北工业大学电子信息工程学院, 天津 300401;

²中国电子科技集团公司第五十三研究所光电信息控制和安全技术重点实验室, 天津 300308

摘要 在进行遥感图像多分类识别时, 针对使用传统方法遇到的分类模型特征提取困难、分类精度不理想、分类种类少等问题, 研究了卷积神经网络(CNN)模型在高光谱遥感地物多分类识别中的可行性及不同 CNN 模型对高光谱遥感地物多分类的识别效果。从 ISPRS(International Society for Photogrammetry and Remote Sensing)提供的 Vaihingen 及 Google Earth 中采集数据, 制作了包含 6 类地物的数据集一。在此基础上增加 10 类地物制作数据集二, 再增 14 类地物制作数据集三。在预处理图像数据之后, 通过设置神经网络结构、调整模型参数、对比神经网络模型等, 上述 3 类数据集的地物分类识别率均达到 95% 以上。通过分析不同 CNN 模型对高光谱遥感地物多分类识别效果的影响, 证实了 CNN 模型在高光谱遥感地物多分类识别应用的可行性且具有较高的识别率。实验结果为 CNN 模型在高光谱遥感地物多分类识别中的应用提供了一定的参考。

关键词 遥感; 高光谱图像; 图像分类; 卷积神经网络; 特征提取

中图分类号 TP751

文献标识码 A

doi: 10.3788/LOP56.021702

Multi-Classification and Recognition of Hyperspectral Remote Sensing Objects Based on Convolutional Neural Network

Yan Miao^{1,2}, Zhao Hongdong^{1*}, Li Yuhai², Zhang Jie^{1,2}, Zhao Zetong^{1,2}

¹School of Electronics and Information Engineering, Hebei University of Technology, Tianjin 300401, China;

²Electronics Technology Group Corporation No.53 Research Institute, Key Laboratory of Electro-Optical Information Control and Security Technology, Tianjin 300308, China

Abstract Aiming at the problems of difficult feature extraction, poor classification accuracy, and less classification types in the remote sensing image multi-classification by the conventional methods, the feasibility of the convolutional neural network (CNN) model and the recognition effects of different CNN models are studied in the multi-classification recognition of hyperspectral remote sensing objects. The datasets are collected from Vaihingen provided by the international society for photogrammetry and remote sensing (ISPRS) and Google Earth. After the dataset-I containing six categories of ground objects is made, the dataset-II and dataset-III are made by adding ten and fourteen categories of ground objects, respectively. Through pre-processing image data, setting up network structures, adjusting model parameters, comparing network models, and so on, the classification accuracies of the above three datasets are all above 95%. By analyzing the influences of different CNN models on the multi-classification recognition of hyperspectral remote sensing objects, the feasibility and high recognition ability of CNN model in the multi-classification recognition of hyperspectral remote sensing are confirmed. The experimental results provide a certain reference for the application of CNN model in the multi-classification recognition of hyperspectral remote sensing objects.

Key words remote sensing; hyperspectral image; image classification; convolutional neural network; feature extraction

OCIS codes 280.4750; 110.4234; 100.4145; 100.3008; 100.2960

收稿日期: 2018-07-17; 修回日期: 2018-07-19; 录用日期: 2018-08-02

基金项目: 光电信息控制和安全技术重点实验室基金项目资助(614210701041705)

* E-mail: zhaohd@hebut.edu.cn

1 引言

随着“数字地球”的提出,高光谱遥感图像的分类识别在农业、工业、交通等领域得到了广泛的应用^[1-4]。由于不同的应用领域对高光谱遥感图像处理的要求不同,因此高光谱遥感图像的分类^[5-7]在图像处理中就显得尤为重要。

近年来,机器学习在图像处理方面得到了广泛应用^[8-9]。2009年 Yang 等^[10]提出采用稀疏表征图像结合支持向量机的方法进行图像分类,并在2010年、2011年的 ImageNet 大规模视觉识别挑战赛 (ILSVRC) 中获得最佳成绩,但该方法也存在缺点:稀疏编码和分类模型是在不同目标函数的监督下分开训练得到的,两者无法有效地联合训练。直到2012年, Hinton 等^[11]在竞赛中使用卷积神经网络 (CNN),将 TOP5 错误率降低到 15.3%,而使用传统方法的参赛者(第2名)的识别错误率高达 26.2%。随后,以 CNN 为代表的各种机器学习的方法被广泛应用于图像分类中^[12-13]。

目前,采用 CNN 的方法分类 4 类地物的识别率达到 94.5732%^[14],采用模糊径向基函数 (RBF) 神经网络的方法识别率达到 96.56%^[15]。采用 ELM-SVM 的方法对 5 类地物进行分类的识别率达到 90.6%^[16]。采用 Log-Gabor 和 Krawtchouk 矩的方法对 5 类地物进行分类的识别率达到了 89.92%,同时对 6 类地物进行分类的识别率达到 85.54%^[17]。采用融合空间关系的方法对 6 类地物进行分类的识别率达到 91.8%^[18]。

由于目前应用在高光谱遥感图像分类识别方面的分类识别方法,大多数分类类别较少且分类识别率也有待提高,因此本文采用 CNN 对高光谱遥感

图像进行多分类识别。通过实验验证了 CNN 算法在高光谱遥感地物多分类识别应用中的可行性。通过设置 4 种神经网络模型,分析了不同的 CNN 模型对高光谱遥感地物多分类识别效果的影响。通过设置神经网络结构、调整神经网络参数,选择最佳神经网络模型,对 3 个数据集进行分类识别实验,证实了卷积神经网络在高光谱遥感地物多分类识别方面具有较高的识别能力。实验结果在高光谱遥感图像多分类识别的研究方面具有一定的参考价值。

2 分类识别模型

遥感图像分类识别处理流程如图 1 所示。首先将采集的数据集图像调整为统一尺寸,按不同的类别命名,以方便标签的制作。因为采集的地物种类较多,背景复杂,颜色多样,尤其是类别中的房屋、汽车等具有非常复杂的颜色,除此之外,植物在不同季节、不同成长阶段会呈现不同的颜色,所以为了避免神经网络对颜色特征的提取和对颜色的分类,将彩色图像转为灰度图像。这种做法虽然失去了部分光谱信息,但避免了神经网络因复杂的颜色特征而造成较大的失误。最后将数据以 uint8 的格式保存至 .mat 文件。

在软件中读取数据集,并将数据转为 28 pixel × 28 pixel 图片并进行归一化处理。将训练集样本输入到神经网络模型并进行神经网络训练,使用反向传播算法对每个样本进行一次权值更新,达到一定的迭代次数或者误差达到给定阈值时停止训练。将测试数据输入已经训练好的 CNN 模型中,通过前向传播最终得到分类的结果^[19-20]。

2.1 前向传播

前向传播主要包括卷积和池化过程。其中,每

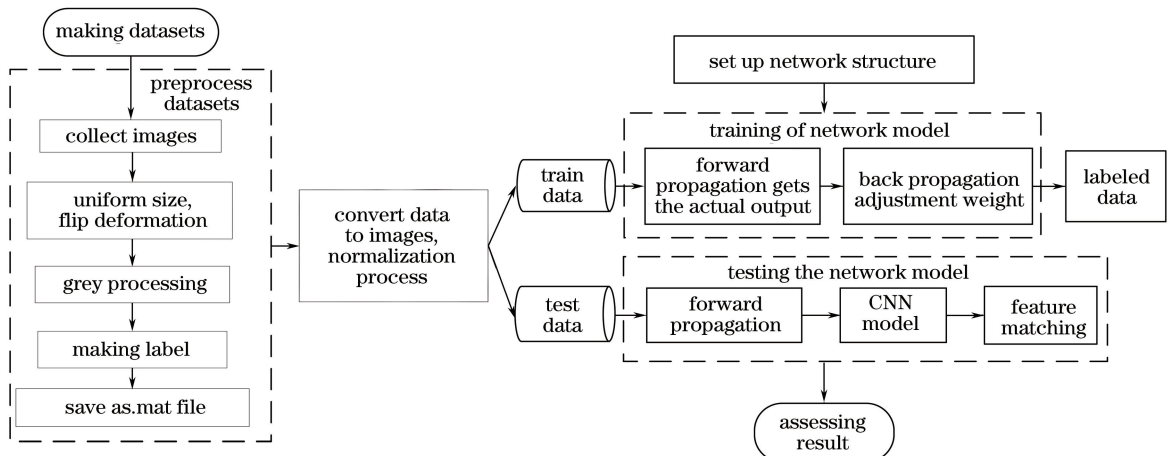


图 1 遥感图像分类处理流程

Fig. 1 Flow chart of proposed remote sensing image classification

个卷积核可以提取的特征不同,所以在每个卷积层选取多个不同的卷积核,并对同一个图片进行特征提取。卷积层的输出为

$$x_j^{(l)} = f \left[\sum_{i \in M_j} x_i^{(l-1)} \cdot k_{ij}^{(l)} + b_j^{(l)} \right], \quad (1)$$

式中: M_j 为选择的输入特征图的集合; l 表示层数; j 表示第 j 个特征图; $k_{ij}^{(l)}$ 表示第 $(l-1)$ 层的第 i 个特征图与第 l 层的第 j 个特征图的卷积核; k 为卷积核; b 为偏置。

$f(\cdot)$ 为 ReLU 激活函数,即

$$f(x) = \begin{cases} 0, & \text{if } X \leq 0 \\ X, & \text{if } X > 0 \end{cases} \quad (2)$$

池化层夹在两个卷积层之间,通过对图像特征的二次提取,舍去一些不明显的特征,从而达到压缩数据和参数的量、缩短训练时间、尽量避免过拟合的目的。池化层输出为

$$x_j^{(l)} = f [W_j^{(l)} d(x_j^{(l-1)}) + b_j^{(l)}], \quad (3)$$

式中: W 为每个输出特征图相应的权值; d 为下采样函数。

2.2 Softmax 分类器

在本文的 Softmax 分类器模型中,有 q 个不同的类别标签 ($q=6, 10, 14$, 分别对应 6 类地物、10 类地物、14 类地物),对于训练集由 m 个已标注的样本构成,即 $\{(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(m)}, y^{(m)})\}$ 有标签 $y^{(u)} \in \{1, 2, \dots, q\}$ 。对于给定的输入值 $x^{(u)}$,使用假设函数对每一个类别 v 估计出概率值 $p_v = (y^{(u)} = v | x^{(u)}; \theta)$,因此假设函数要输入一个 q 维的向量来表示这 q 个估计值的概率。假设函数 $h_\theta(x)$ 表示为

$$h_\theta(x) = \begin{bmatrix} p_1 = [y^{(u)} = 1 | x^{(u)}; \theta] \\ p_2 = [y^{(u)} = 2 | x^{(u)}; \theta] \\ \vdots \\ p_q = [y^{(u)} = q | x^{(u)}; \theta] \end{bmatrix} = \frac{1}{\sum_{v=1}^q \exp[\theta_v^T x^{(u)}]} \begin{bmatrix} \exp[\theta_1^T x^{(u)}] \\ \exp[\theta_2^T x^{(u)}] \\ \vdots \\ \exp[\theta_q^T x^{(u)}] \end{bmatrix}, \quad (4)$$

式中: $\theta_1, \theta_2, \dots, \theta_q \in \mathbf{R}^{n+1}$ 是模型的参数。在 Softmax 分类模型进行回归计算时,使用 θ 符号来表示全部的模型参数, θ 为一个 $q \times (n+1)$ 的矩阵; $1/\sum_{v=1}^q \exp[\theta_v^T x^{(u)}]$ 是对概率分布进行归一化,所有概率之和为 1。

Softmax 分类器代价函数是 Logistic 回归代价函数的一般形式,对类别标记的 q 个可能值进行了累加。

$$L(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^q F\{y^{(u)} = v\} \right] \times \log \frac{\exp[\theta_v^T x^{(u)}]}{\sum_{v=1}^q \exp[\theta_v^T x^{(u)}]}, \quad (5)$$

式中, $F\{\cdot\}$ 是示性函数,

$$F\{X\} = \begin{cases} 1, & X \text{ is true} \\ 0, & X \text{ is false} \end{cases} \quad (6)$$

3 实验与结果分析

3.1 实验数据与识别率评定

虽然目前关于高光谱遥感地物分类识别的数据集有很多,但是大多数遥感分类识别数据集的识别类别数在 5~10 之间,现成的、类别达到 10 类以上且可直接应用的数据集较少。为验证卷积神经网络在高光谱遥感地物多分类识别中的可行性及其在多分类识别方面识别多种类的能力,本文采用采样距离为 8 cm 的德国 Vaihingen 数据集的全部地物类别(已公开),包含牧草(Pasture)、油菜(Rape)、甜菜(Sugar beet)、黑麦(Triticale)、大豆(Soybeans)、裸地(Bare area)、树林(Woods)、河流(River)、道路(Road)、房屋(Building)、汽车(Car)共计 11 类。为扩充数据集类别,又从 Google Earth 中采集的 800 VHR (very-high-resolution) 的 NWPU VHR-10 数据集中增加了飞机(Airplane)、船只(Ship)、油桶(Oil drum)3 类地物,共计 14 类,如图 2 所示。其中,牧草、油菜、甜菜、黑麦、大豆、树林、裸地采集为统一尺寸 100 pixel×100 pixel,汽车尺寸为 64 pixel×64 pixel,河流尺寸根据河面的宽度截取为 600 pixel×600 pixel,道路尺寸根据道路的宽窄不同分别截取为 160 pixel×160 pixel、124 pixel×124 pixel、100 pixel×100 pixel,房屋尺寸根据房屋的大小不同选择合适的尺寸截取,船只尺寸截取为 64 pixel×64 pixel,油桶尺寸为 72 pixel×72 pixel,飞机的尺寸根据飞机的大小不同选择合适的尺寸截取。最后通过尺寸变换将所有图像都调整为 28 pixel×28 pixel 的统一尺寸。数据集中的房屋、道路、汽车、飞机、船只、油桶分别具有不同的形状、大小和拍摄角度,且背景复杂。

实验数据分为 3 个数据集,数据集一包含 6 类地物:牧草、油菜、甜菜、黑麦、大豆、裸地。在此基础上增加树林、河流、房屋、道路 4 类地物,制作包含 10 类地物的数据集二。在数据集二的基础上又增加了汽车、飞机、船只、油桶 4 类地物,制作包含 14 类地物的数据集三。

分类识别率为

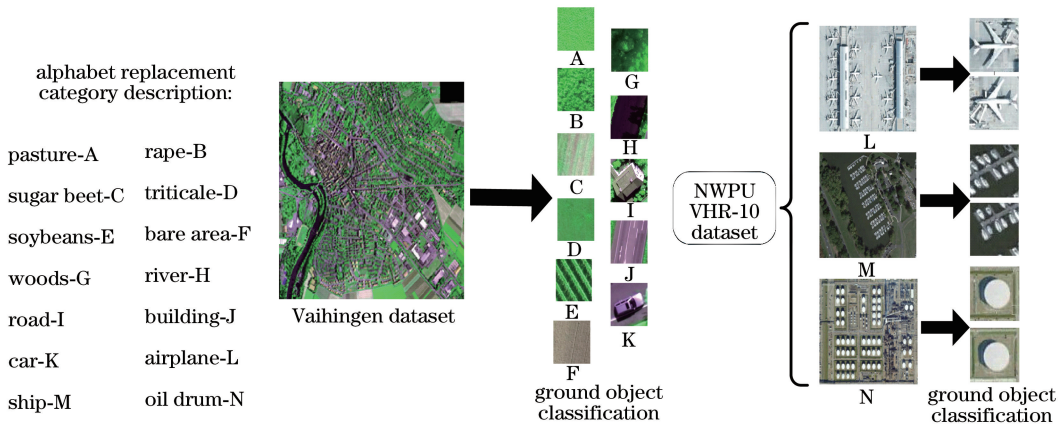


图 2 遥感地物类别示例图像

Fig. 2 Image examples of remote sensing ground objects

$$P_A = \left(1 - \frac{T_e}{T}\right) \times 100\%, \quad (7)$$

式中： P_A 为识别率； T_e 为测试集所有未识别图片数量； T 为测试集图片总数。

3.2 模型参数选择

分类识别率是对所有测试图像进行分类得到的，本节依据识别率高下来评价 CNN 模型。CNN 模型不同结构和参数将直接影响分类识别效果，故设计不同的卷积神经网络模型对地物进行分类识别，实验数据采用数据集二。

图 3 为不同池化层、不同分类器的神经网络模型学习率的对比。当池化层为 Max 池化时，不同学习率下分类器依次为 Softmax、Sigmoid 时随着迭代次数的增加，神经网络识别率的变化情况如图 3(a) 和(b) 所示。可以看出，图 3(a) 的学习率为 0.03、图 3(b) 的学习率为 0.3。当池化层为 Mean 池化时，不同学习率下分类器分别为 Softmax、Sigmoid 时随着迭代增加，神经网络识别率的变化情况如图 3(c) 和(d) 所示。可以看出，图 3(c) 最佳学习率为 0.6，图 3(d) 最佳学习率为 0.9。

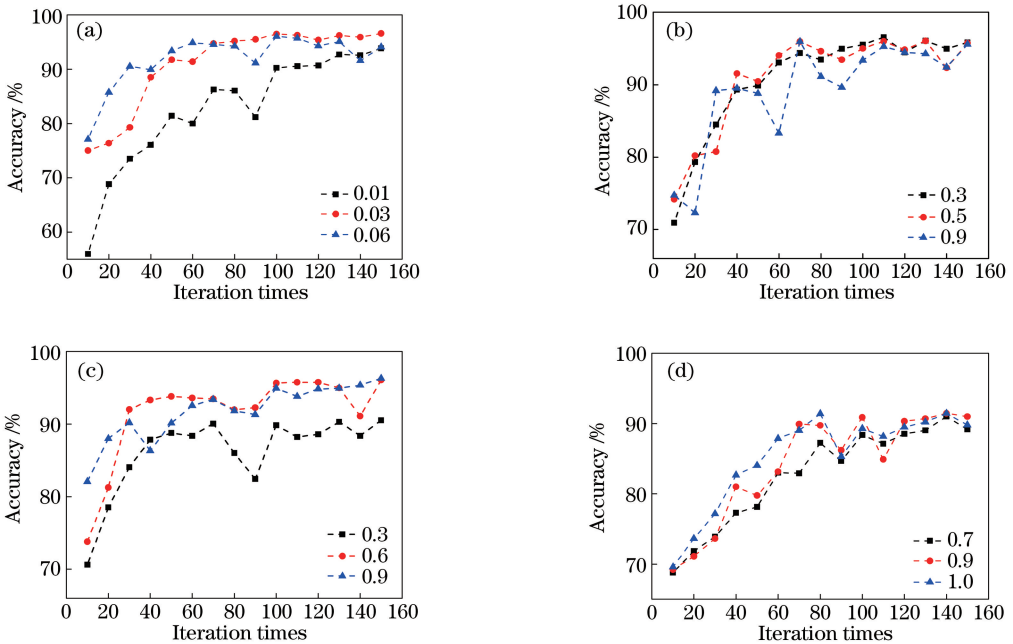


图 3 不同池化层、不同分类器的神经网络模型的学习率的对比。(a) Max 池化、Softmax 分类器；(b) Max 池化、Sigmoid 分类器；(c) Mean 池化、Softmax 分类器；(d) Mean 池化、Sigmoid 分类器

Fig. 3 Learning rate comparison of neural network models with different pooling layers and classifiers. (a) Max pooling, Softmax classifier; (b) Max pooling, Sigmoid classifier; (c) Mean pooling, Softmax classifier; (d) Mean pooling, Sigmoid classifier

表 1 为最佳学习率下迭代次数为 150 次时的不同神经网络模型对比。对比表 1 中模型 I 和模型 II 可知,池化层同为 Max 池化时,在最佳学习率下,使用 Softmax 分类器的模型分类识别率高于 Sigmoid 分类器的;池化层同为 Mean 池化时,对比表 1 中的模型 III 和模型 IV 可知,使用 Softmax 分类器的模型分类识别率明显高于 Sigmoid 分类器的,实验证明使用 Softmax 分类器的识别率最高,

故最终选择梯度计算更简洁、训练速度更快、代价函数更易收敛的 Softmax 分类器对高分遥感的地物进行分类识别。对比表 1 中模型 I 和模型 III 可知,分类器同为 Softmax 分类器时,Max 池化层的模型识别略高于 Mean 池化层的。分类器同为 Sigmoid 分类器时,对比表 1 中模型 II 和模型 IV 可知,使用 Max 池化层的模型分类识别率明显高于 Mean 池化层的,故最终选择 Max 池化为模型池化层。

表 1 神经网络模型对比图

Table 1 Comparison of neural network models

Model	Model I	Model II	Model III	Model IV
Network model	Conv1 (6@5×5)	Conv1 (6@5×5)	Conv1 (6@5×5)	Conv1 (6@5×5)
	Max pooling (2×2)	Max pooling (2×2)	Mean pooling (2×2)	Mean pooling (2×2)
	Conv1 (12@5×5)	Conv1 (12@5×5)	Conv1 (12@5×5)	Conv1 (12@5×5)
	Max pooling (2×2)	Max pooling (2×2)	Mean pooling (2×2)	Mean pooling (2×2)
	Softmax classifier	Sigmoid classifier	Softmax classifier	Sigmoid classifier
Optimal learn rate	0.03	0.3	0.6	0.9
Accuracy	0.9658	0.9583	0.9604	0.91

图 4 为不同迭代次数下的 4 种模型的识别率对比图。由图 4 可知,模型 I 的识别效果最佳,模型 IV 的识别效果最差。对比图 4 中模型 I 和模型 II、模型 III 和模型 IV 可知,模型 I 的分类识别率明显高于模型 II 的,模型 III 的分类识别率明显高于模型 IV 的,说明分类器影响模型分类识别率,并且 Softmax 分类器的模型分类识别率高于 Sigmoid 分类器的。对比图 4 中的模型 I 和模型 III、模型 II 和模型 IV 可知,模型 I 和模型 II 的分类识别率的变化相对平稳,模型 III 和模型 IV 分类识别率的变化幅度较大,说明池化层影响着模型分类器识别效果的稳定性,并且相较于具有 Mean 池化层的模型,Max 池化层模型更具有稳定性。

模型选择确定后使用数据集一(共 6 类地物)进行分类实验。数据集分为训练集和测试集,其中训练集每类 1000 幅图像,共计 6000 幅图像;测试集每类 240 幅图像,共计 1440 幅图像。使用训练集训练神经网络,使用测试集进行模型验证。数据集一的测试集中未识别图像的数量统计如表 2 所示。

由表 2 可知,随着迭代次数的增加,每类地物被错分的数量逐渐减少,分类错误图像总数逐渐降低,神经网络分类识别准确率不断提高。当迭代次数为 160 次时,1440 幅测试集图像只有 29 幅被错误分类,分类识别准确率达到 97.9861%,充分证明本文方法在高分遥感地物多分类识别中的可行性。

为验证该方法在高光谱遥感地物多分类识别中

表 2 数据集一测试集中未识别图像的数量

Table 2 Number of unclassified images in test set for dataset-I

Iteration times	A	B	C	D	E	F	Total
20	0	180	0	54	4	0	238
40	0	98	0	50	0	0	148
60	0	1	0	55	0	0	56
80	0	0	0	68	0	0	68
100	0	0	0	63	0	4	67
120	0	0	0	36	0	0	36
140	0	0	0	33	0	0	33
160	0	1	0	28	0	0	29
180	0	0	0	36	0	0	36
200	0	0	0	35	0	0	35
220	0	0	0	36	0	0	36




图 4 不同迭代次数下的 4 种模型识别率对比图

Fig. 4 Recognition rate comparison of four models for different iteration times

3.3 3 个数据集的测试验证

为验证本文神经网络对于地物分类的可行性,

的识别能力,使用数据集二和数据集三进行实验验证。数据集二包含 10 类地物,分为训练集和测试集,其中训练集每类 1000 幅图像,共计 10000 幅;测

试集每类 240 幅图像,共计 2400 幅。数据集二的测试集中未识别图像的数量统计如表 3。由表 3 可知,10 类地物最佳分类识别率为 97%。

表 3 数据集二测试集中未识别图像的数量

Table 3 Number of unclassified images in test set for dataset-II

Iteration times	A	B	C	D	E	F	G	H	I	J	Total
20	0	191	0	41	2	0	54	0	111	168	567
40	0	17	0	63	1	0	22	0	85	88	276
60	0	15	0	36	1	0	10	0	11	62	135
80	0	14	0	56	2	0	8	0	5	31	116
100	0	5	0	39	2	0	4	0	1	33	84
120	0	1	0	63	1	0	4	0	8	34	111
140	0	0	0	61	1	0	6	0	10	20	98
160	0	0	0	50	2	0	2	0	6	26	86
180	0	4	0	58	1	0	1	0	1	29	94
200	0	0	0	49	1	0	1	0	11	25	87
220	0	2	0	45	1	0	1	0	2	21	72

数据集三包含 14 类地物,共计 17360 幅图像,其中 14000 幅图像用于模型训练,3360 幅图像用于测试集以验证神经网络模型。数据集三的测试集中

未识别图像的数量统计如表 4。由表 4 可知,14 类地物最佳分类识别率为 96.3393%。

表 4 数据集三测试集中未识别图像的数量

Table 4 Number of unclassified images in test set for dataset-III

Iteration times	A	B	C	D	E	F	G	H	I	J	K	L	M	N	Total
20	0	160	0	29	4	40	78	0	168	183	116	67	54	24	923
40	0	25	0	25	5	0	27	0	16	90	63	18	14	10	293
60	0	0	0	91	4	9	34	0	75	38	45	1	13	8	318
80	0	25	0	33	4	0	8	0	7	63	30	10	8	6	194
100	0	0	0	44	0	0	16	0	19	40	37	3	7	6	172
120	0	72	0	8	3	38	7	0	0	47	34	19	7	3	238
140	0	0	0	56	2	0	16	0	11	32	31	4	7	5	164
160	0	0	0	58	1	0	5	0	12	36	30	5	5	5	157
180	0	0	0	106	0	0	12	0	68	28	31	3	5	5	258
200	0	3	0	30	0	0	9	0	0	34	32	4	6	5	123
220	0	0	0	57	0	0	15	0	16	24	30	4	5	5	156

通常情况下,当分类类别较少时,分类识别准确率高,当分类种类大幅度增加时,分类识别精度通常很低。对比表 3 和表 4 可知,使用卷积神经网络进行高光谱遥感地物多分类识别时,在遥感地物分类类别由 6 类增加至 14 类的情况下,地物分类识别率仅由 97.9861%降低到 96.3393%,分类识别率仅下降了 1.6%左右。实验结果充分证明了本文方法在高分遥感地物多分类识别中具有较强的识别能力。图 5 为数据集一、二和三在最佳参数下的识别率对比图。由图 5 可知,随着迭代次数增加,各数据集分类识别率逐渐趋于稳定,在分类种类大幅度增加的情况下,识别率仍都高于 95%。

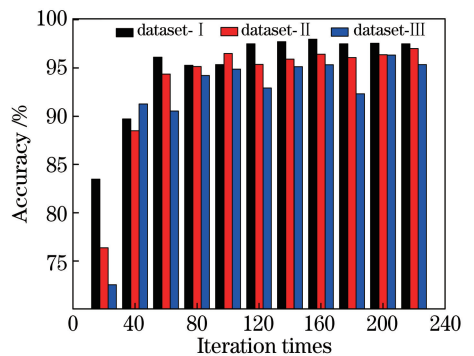


图 5 3 个数据集在最佳参数下的识别率对比
Fig. 5 Accuracy comparison of three datasets under optimal parameters

4 结 论

采用卷积神经网络进行高光谱遥感图像多分类识别,并通过识别率来评价卷积神经网络模型在高光谱遥感地物多分类识别中的可行性。通过不同的 CNN 模型对高光谱遥感地物多分类识别的影响,研究最佳选择后的卷积神经网络在高光谱遥感地物多分类识别方面的识别能力。采集 ISPRS 提供的 Vaihingen 数据集的全部地物类别制作数据集一、数据集二,又从 Google Earth 中扩充了部分地物类别制作成数据集三。将采集的图像进行预处理,增加数据的复杂度,提高神经网络训练的泛化能力,从而提高分类识别正确率。

对比 4 种卷积神经网络模型对 10 类地物分类识别的实验结果发现:分类器影响模型分类识别能力,并且使用 Softmax 分类器的模型分类识别率高于 Sigmoid 分类器的;池化层也影响模型分类识别效果的稳定性,并且相较于具有 Mean 池化层的 CNN 模型,Max 池化层模型分类识别效果更稳定。通过设置神经网络结构、调整模型参数、对比神经网络模型等,最终使得 6 类地物的分类识别率达到 97.9861%,验证了卷积神经网络模型在高光谱遥感地物多分类目标识别中的可行性。通过分别对具有 10 类地物的数据集二和具有 14 类地物的数据集三进行分类识别,最终 10 类地物的分类识别率达到 97%,14 类地物的分类识别率达到 96.3393%。实验结果证实了卷积神经网络在高光谱遥感地物多分类识别方面具有较高的识别能力,对之后研究高光谱遥感图像多分类识别具有一定的参考价值。如何在更多分类的情况下,仍保持神经网络较高的识别率及进一步缩短神经网络训练时间是下一步的研究方向。

参 考 文 献

- [1] He S L, Xu J H, Zhang S Y. Land use classification of object-oriented multi-scale by UAV image [J]. Remote Sensing for Land & Resources, 2013, 25(2): 107-112.
何少林,徐京华,张帅毅.面向对象的多尺度无人机影像土地利用信息提取[J].国土资源遥感,2013,25(2):107-112.
- [2] Mekhalfi M L, Melgani F, Bazi Y, *et al.* Land-use classification with compressive sensing multifeature fusion[J]. IEEE Geoscience Remote Sensing Letters, 2015, 12(10): 2155-2159.
- [3] Cheriyyadat A M. Unsupervised feature learning for aerial scene classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(2): 439-451.
- [4] Cheng G, Han J W, Lu X Q. Remote sensing image scene classification: benchmark and state of the art [J]. Proceedings of the IEEE, 2017, 105(10): 1865-1883.
- [5] Deng X Q, Zhu Q B, Huang M. Variety discrimination for single rice seed by integrating spectral, texture and morphological features based on hyperspectral image [J]. Laser & Optoelectronics Progress, 2015, 52(2): 021001.
邓小琴,朱启兵,黄敏.融合光谱、纹理及形态特征的水稻种子品种高光谱图像单粒鉴别[J].激光与光电子学进展,2015,52(2):021001.
- [6] Ye Z, Bai L, Nian Y J. Hyperspectral image classification algorithm based on Gabor feature and locality-preserving dimensionality reduction [J]. Acta Optica Sinica, 2016, 36(10): 1028003.
叶珍,白璘,粘永健.基于 Gabor 特征与局部保护降维的高光谱图像分类算法[J].光学学报,2016,36(10):1028003.
- [7] Wang J N. Hyperspectral image classification based on joint sparse representation and morphological feature extraction [J]. Laser & Optoelectronics Progress, 2016, 53(8): 082801.
王佳宁.基于联合稀疏表示与形态特征提取的高光谱图像分类[J].激光与光电子学进展,2016,53(8):082801.
- [8] Chen Y, Fan R S, Wang J X, *et al.* Cloud detection of ZY-3 satellite remote sensing images based on deep learning [J]. Acta Optica Sinica, 2018, 38(1): 0128005.
陈洋,范荣双,王竞雪,等.基于深度学习的资源三号卫星遥感影像云检测方法[J].光学学报,2018,38(1):0128005.
- [9] Liu D W, Han L, Han X Y. High spatial resolution remote sensing image classification based on deep learning [J]. Acta Optica Sinica, 2016, 36(4): 0428001.
刘大伟,韩玲,韩晓勇.基于深度学习的高分辨率遥感影像分类研究[J].光学学报,2016,36(4):0428001.
- [10] Yang J C, Yu K, Gong Y H, *et al.* Linear spatial pyramid matching using sparse coding for image classification [C]. 2009 IEEE Conference on Computer Vision and Pattern Recognition, June 20-

- 25, 2009, Miami, FL, USA. New York: IEEE, 2009, 8: 20-25.
- [11] Hinton G E, Salakhutdinov R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507.
- [12] Liu N, Wan L H, Zhang Y, *et al.* Exploiting convolutional neural networks with deeply local description for remote sensing image classification [J]. IEEE Access, 2018, 6: 11215-11228.
- [13] Yu S Q, Jia S, Xu C Y. Convolutional neural networks for hyperspectral image classification [J]. Neurocomputing, 2017, 219: 88-98.
- [14] Fu X L, Li L P, Mao K B, *et al.* Remote sensing image classification based on CNN model [J]. Chinese High Technology Letters, 2017, 27(3): 203-212.
付秀丽, 黎玲萍, 毛克彪, 等. 基于卷积神经网络模型的遥感图像分类 [J]. 高技术通讯, 2017, 27(3): 203-212.
- [15] Yang J, Song C F, Song W A, *et al.* Remote sensing image classification based on fuzzy RBF neural network based on genetic algorithm [J]. Journal of Chinese Computer Systems, 2018, 39(3): 621-624.
杨剑, 宋超峰, 宋文爱, 等. 基于遗传算法的模糊 RBF 神经网络对遥感图像分类 [J]. 小型微型计算机系统, 2018, 39(3): 621-624.
- [16] Gulnaz A, Hurxida J, Sun T L, *et al.* An approach based on ELM-SVM for remote sensing image classification [J]. Journal of Northeast Normal University (Natural Science Edition), 2017, 49(1): 53-61.
古丽娜孜·艾力木江, 乎西旦·居马洪, 孙铁利, 等. 一种基于 ELM-SVM 的遥感图像分类方法 [J]. 东北师大学报(自然科学版), 2017, 49(1): 53-61.
- [17] Wu Y Q, Tao F X, Cao Z Q. Remote sensing image classification based on Log-Gabor wavelet and Krawtchouk moments [J]. Geomatics and Information Science of Wuhan University, 2016, 41(7): 861-867.
吴一全, 陶飞翔, 曹照清. 基于 Log-Gabor 小波和 Krawtchouk 矩的遥感图像分类 [J]. 武汉大学学报(信息科学版), 2016, 41(7): 861-867.
- [18] Li L, Zhang Y, Li S, *et al.* Classification of remote sensing images based on the fusion of spatial relationship [J]. Remote Sensing for Land & Resources, 2017, 29(3): 10-16.
李亮, 张云, 李胜, 等. 融合空间关系的遥感图像分类 [J]. 国土资源遥感, 2017, 29(3): 10-16.
- [19] Nogueira K, Penatti O A B, dos Santos J A. Towards better exploiting convolutional neural networks for remote sensing scene classification [J]. Pattern Recognition, 2017, 61: 539-556.
- [20] Zhang P Z, Gong M G, Su L Z, *et al.* Change detection based on deep feature representation and mapping transformation for multi-spatial-resolution remote sensing images [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 116: 24-41.