

多层感知卷积神经网络的国产多光谱影像分类

朱瑞飞^{1,2}, 马经宇¹, 李竺强^{1*}, 王栋^{1,2}, 安源^{1,2}, 钟兴^{1,2}, 高放¹, 孟祥玉³

¹ 长光卫星技术有限公司吉林省卫星遥感应用技术重点实验室, 吉林 长春 130012;

² 中国科学院长春光学精密机械与物理研究所, 吉林 长春 130033;

³ 吉林省国土资源调查规划研究院, 吉林 长春 130061

摘要 联合像元谱段信息与空间结构特征, 提出一种适用于多光谱遥感影像像素级分类的多层感知卷积神经网络 (MPCNet), 并基于吉林 1 号光谱卫星 (Jilin-1GP) 影像, 在印度纳西克研究区对地表覆盖分类算法进行性能测试。为保证实验的高可靠性, 在相同时间段结合 Landsat8、Sentinel-2A 及 HJ-1A 影像进行同步分类来定性与定量评估。除此之外, 选取三个当前流行算法支持向量机 (SVM)、LightGBM、浅层卷积神经网络 (CNN) 进行算法性能比较。实验结果表明, 在 Jilin-1GP 影像上的总体分类精度可达 94.0%~95.8%, Kappa 系数达到 0.932~0.948。相比准确率较高的浅层 CNN, MPCNet 的总体分类精度提升 3.7 个百分点。

关键词 遥感; 光谱卫星; 空间-光谱信息; 多层感知卷积神经网络; 分类评估

中图分类号 TP751.1

文献标志码 A

doi: 10.3788/AOS202040.1528003

Domestic Multispectral Image Classification Based on Multilayer Perception Convolutional Neural Network

Zhu Ruifei^{1,2}, Ma Jingyu¹, Li Zhuqiang^{1*}, Wang Dong^{1,2}, An Yuan^{1,2}, Zhong Xing^{1,2},
Gao Fang¹, Meng Xiangyu³

¹ Jilin Key Laboratory of Satellite Remote Sensing Application Technology, Chang Guang Satellite Technology Co., Ltd., Changchun, Jilin 130012, China;

² Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun, Jilin 130033, China;

³ Jilin Institute of Land Survey & Planning, Changchun, Jilin 130061, China

Abstract In this study, a multilayer perception convolutional neural network (MPCNet) was proposed for the pixel-level classification of multispectral remote sensing images, which combines the spectral information and spatial structure features of pixels. The performance of a land-cover-classification algorithm was tested based on the Jilin-1 spectral satellite (Jilin-1GP) images in the Nashik research area, India. To ensure high reliability of the experiment, the Landsat8, Sentinel-2A, and HJ-1A images were used within the same time interval for synchronized classification to perform qualitative and quantitative evaluations. Moreover, three current popular algorithms, namely, support vector machine (SVM), LightGBM, and shallow convolutional neural network (CNN), were selected to compare the algorithm performance. The experimental results indicate that the overall classification accuracy on the Jilin-1GP images can reach 94.0%–95.8%, and the Kappa coefficient can reach 0.932–0.948. The overall classification accuracy of the MPCNet increase by 3.7 percentage compared with that of the shallow CNN, which exhibits high accuracy.

Key words remote sensing; spectral satellite; spatial-spectral information; multilayer perception convolution neural network; classification evaluation

OCIS codes 280.4991; 110.4234; 100.2960; 100.4996

收稿日期: 2020-04-01; 修回日期: 2020-04-23; 录用日期: 2020-05-06

基金项目: 国家重点研发计划重点专项(2018YFB1004605)

* E-mail: skybelongtous@foxmail.com

1 引 言

遥感技术作为一门新兴的交叉科学技术得到了迅猛发展。研究发现光谱在很大程度上表征地物的本征特性^[1],光谱分辨率的提高有助于对地物进行精确识别和分类^[2]。徐冠华等^[3]针对目前国内遥感面临的机遇与挑战,通过总结国内外遥感应应用技术的发展态势,提出了以建立地球综合观测服务系统为基础的多源卫星观测系统商业化、市场化的建议。随着商业航天崛起,卫星数据应用服务更加灵活,高分辨率卫星遥感系统商业化,这极大增强了遥感数据服务保障能力,可广泛应用于农业^[4]、林业、环境^[5]、矿产、能源等领域。为尽快将光谱卫星数据应用到地理国情监测业务中,本文研究了一种适用于多光谱遥感影像像素级分类的深度卷积神经网络(CNN)算法,以满足较高精度的地表覆盖分类需求。

传统的多光谱影像分类算法通常基于光谱信息,利用距离度量或者特征学习分类器,如 K 邻近算法^[6]或支持向量机(SVM)^[7]对遥感影像进行监督分类。对于具有大幅宽、多波段及高分辨率的多光谱数据来说,这些方法需要依赖大量样本去训练,时间成本很大。谢登峰等^[8]利用遥感数据时空融合方法,以 Landsat8 和 MODIS 为数据源构建具有高时间、高空间分辨率的遥感影像数据,利用 SVM 对秋粮作物进行分类识别,水稻和玉米的总体识别精度仅为 86.90%。林文鹏等^[9]利用 MODIS 数据,采用波谱分析的方法建立一种基于遥感影像全覆盖的秋季作物类型自动提取方法,实现了主要秋季作物的遥感自动识别;但该方法依赖先验的波谱信息,需要消除不同传感器影像的辐射差异,自动化应用不高。为解决时序化监测地表覆盖变化时需要多期影像的问题,胡勇等^[10]采用相对辐射归一化方法和自动大气校正方法对 Landsat 数据进行定量化处理,然后利用光谱特征扩展的方法对时间序列数据进行分类。Yang 等^[11]利用多种机器学习分类器进行组合投票,得到投票结果后再利用层次分析方式得到最终像素的类别,这提升了部分分类精度,但会影响分类效率。

随着深度学习算法开源崛起,“人工智能+数据创造”模式给遥感应应用快速发展带来机遇。从一开始的卷积神经网络 LeNet,到后来的 AlexNet、GoogleNet 深度神经网络模型,深度强化学习成为人工智能的热点之一。基于遥感影像的深度学习算法通过多层次卷积神经网络自动学习遥感影像特

征,并对特征进行逐层抽象提取,进而构建隐藏感知器模型。于佩鑫等^[12]利用卷积神经网络来识别坡耕地的侵蚀沟,达到土壤侵蚀检测的目的。李竺强等^[13-14]提出一种适合于高光谱像素级分类的深度学习三维卷积神经网络模型,该模型在公开高光谱数据集中得到很好的验证。Zhou 等^[15]构建评估遥感影像检索数据集“PatternNet”,该数据集解决了深度学习时缺少海量标准遥感数据集的困境。阚希等^[16]构建并训练基于层叠去噪自编码器的特征融合与分类网络,该网络能有效辨识青藏高原遥感图像中的云、积雪及无雪地表。Pan 等^[17]提出一种适用于小尺度高光谱影像分类的网络 MugNet,该网络可在有限训练样本情况下得到不错的分类结果。

遥感数据与土地资源在时空特性方面具有高度的一致性^[18]。为提升多光谱遥感影像分类精度,本文基于吉林一号光谱卫星遥感影像数据,提出一种适用于多光谱像素级分类的多层感知卷积神经网络(MPCNet)算法,联合像元谱段信息与空间结构特征,得到像素分类标签在空间上的局部连续全局最优。为体现 MPCNet 算法分类性能的优越性,将国产光谱卫星 Jilin-1GP01 在印度纳西克拍摄的多光谱(19 谱段)数据作为研究区,对当前主流算法 SVM、LightGBM^[19]、浅层 CNN 进行分类性能的对比测试。同时为保证实验的高可靠性,对在该区域、同一时间区间下的 Landsat8、Sentinel-2A 及 HJ-1A 卫星进行横向对比分类验证。

2 本文方法

2.1 地表覆盖分类架构

图 1 为所提遥感影像分类算法 MPCNet 流程图,其中 FC 为全连接层,BN 为批归一化层,Conv 为卷积层,ReLU 为修正线性单元,MaxPool 为最大池化层。在分类模型训练阶段,首先对待分类的多光谱影像构建地物空间-光谱数据集;随后利用少量规模的样本数据集对改进的深度卷积神经网络进行训练;待分类网络模型收敛后,对待检测影像进行未知像素预测,并结合条件随机场(CRF)对分类结果进行优化;最终通过验证点集对分类结果进行精度分析和评价。

2.2 多层感知卷积神经网络构建

根据多光谱遥感影像有较高空间分辨率且光谱信息较丰富的特点,结合典型卷积神经网络特征逐层融合优势^[20-21],提出了 MPCNet,结构如图 2 所示。

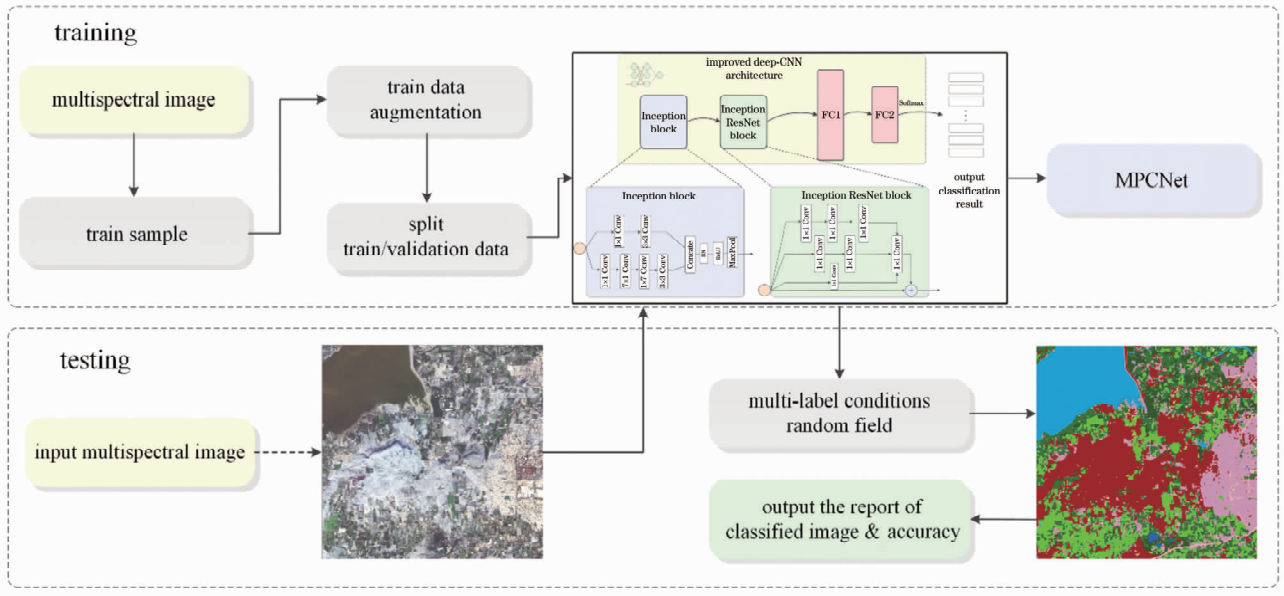


图 1 MPCNet 分类算法流程图

Fig. 1 Flow chart of MPCNet classification algorithm

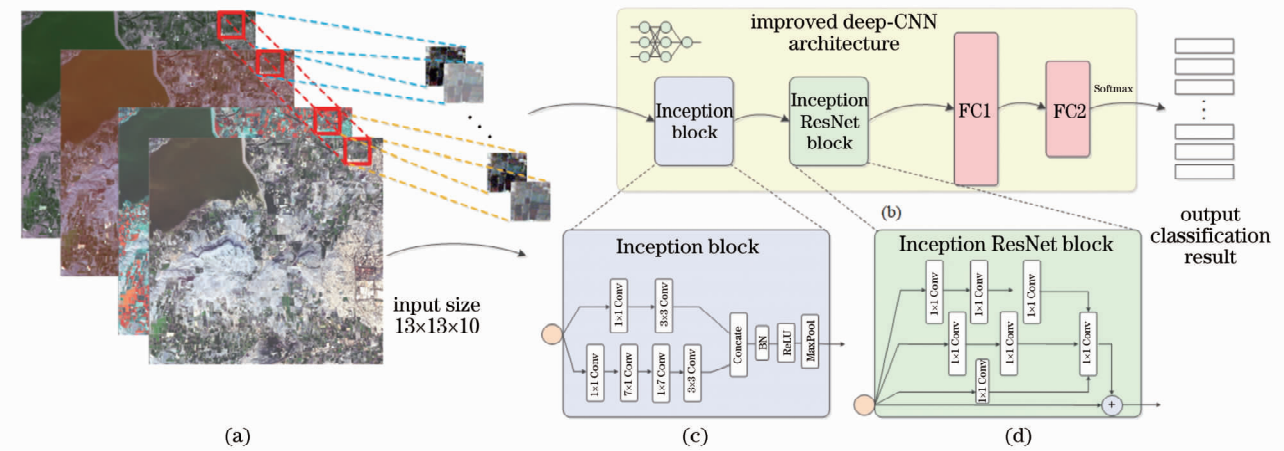


图 2 基于 MPCNet 的多光谱遥感影像分类模型

Fig. 2 Multispectral remote sensing image classification model based on MPCNet

利用多光谱遥感影像的光谱-空间特征连续性优势对网络模块进行优化,网络整体架构如图 2(b)所示。MPCNet 的卷积结构可以分为 Inception 模块和 Inception ResNet 模块,分别如图 2(c)、(d)所示,其中 Inception 模块受不规则卷积影响,相比普通的浅层 CNN,结构灵活、特征区别性更加显著,同时计算量小、收敛速度快。Inception ResNet 模块能够有效抑制过拟合且利于层次堆叠。两种结构块的组合可以充分学习到不同地物特征的差异性,最大程度减少“同物异谱”和“同谱异物”问题。

空间-光谱立方体(尺寸为 $13 \times 13 \times 10$)包含影像中每个像元邻域空间纹理与谱段光谱信息。每个

空间-光谱立方体首先经过 Inception 模块,经卷积层叠加、合并及激活后得到 192 个 11×11 的特征图,经过最大池化后得到 192 个 6×6 的特征图;随后经过 Inception ResNet 模块,经卷积层叠加、残差融合及激活后得到 192 个 6×6 的特征图,并通过最大池化得到 192 个 3×3 的特征图;然后经过两个全连接层(FC1、FC2)得到尺寸为 256×1 的特征向量;最后通过 Softmax 分类器得到每类地物的分类概率,表达式为

$$P(y_i = l | \mathbf{F}_i; \boldsymbol{\theta}) = \frac{\exp(\boldsymbol{\theta}_l^T \mathbf{F}_i)}{\sum_{j=1}^k \exp(\boldsymbol{\theta}_j^T \mathbf{F}_i)}, \quad (1)$$

式中: \mathbf{F}_i 为多光谱影像上第 i 个像元对应的空间-光谱立方体经过网络映射至 FC2 层得到的特征向量;

θ 为一个大小为 $k \times (n+1)$ 的参数矩阵, n 为 FC2 层对应特征向量的维度; y_i 为第 i 个像元的类别标签; k 为类别个数; θ_l 为类别 l 对应的一个大小为 $1 \times (n+1)$ 的参数矩阵; j 为类别序号。

2.3 多光谱遥感影像训练及优化策略

多光谱遥感影像训练及优化策略为空间-光谱样本集构建、MPCNet 训练、待分类多光谱影像预测、分类结果联合 CRF 优化。

空间-光谱样本集构建: 针对待分类的多光谱影像, 依据影像所覆盖区域的地物类别, 利用高分辨率卫星影像结合“全球 30 m 土地覆盖数据集(FROM-GLC-2017)”成果影像^[22]进行样本标记。随后利用各类别标记区域, 将每个像素周围邻近区域 $M \times M \times B$ 作为训练样本单元, 其中 M 为空间邻域尺寸, B 为多光谱影像波段个数。在完成标记区域样本提取后, 通过数据增强方法对样本集进行扩充, 并对样本数据进行归一化操作, 同时对样本标签进行独热编码。在完成数据增强后, 将数据集划分为训练集和验证集, 其中训练集用于分类网络的迭代优化, 验证集用于网络性能的实时评定。

MPCNet 训练: 在网络训练过程中, 根据 Softmax 分类器对应的交叉熵损失构建目标函数, 表达式为

$$J = -\frac{1}{N} \left\{ \sum_{i=1}^N \sum_{j=1}^k \text{sign}(y_i = l) \log[P(y_i = l | \mathbf{F}_i; \theta)] \right\}, \quad (2)$$

式中: N 为训练样本个数。

通过 Adagrad 算法^[23]对网络参数进行优化, 其梯度更新公式为

$$\Theta_{t+1,s} = \Theta_{t,s} - \frac{\alpha}{\sqrt{G_{t,ss}} + \epsilon} \cdot \mathbf{g}_{t,s}, \quad (3)$$

式中: $\mathbf{g}_{t,s}$ 为第 t 轮第 s 个参数的梯度; 对角阵 $\mathbf{G}_t \in \mathbb{R}^{d \times d}$, $G_{t,ss}$ 为对角阵 \mathbf{G}_t 在对角线位置 ss 处的元素;

ϵ 为平滑项, 用于避免分母为 0; α 为学习率。相比于基于固定学习率的随机梯度下降法 (SGD), Adagrad 算法可以自适应地为每个参数分配不同的学习率, 并随训练过程推进不断对学习率进行调整, 进而有助于加速优化。

待分类多光谱影像预测: 待分类网络模型收敛后, 即可对待分类多光谱影像进行自动解译。同训练集构建规则一致, 取影像上每个像素周围大小为 $M \times M \times B$ 的空间-光谱矩阵作为该像素的特征, 将数据块输入网络后, 取最大概率值对应的类别作为该像素的标签, 利用多 GPU 并行处理技术可快速完成整幅影像分类工作。

分类结果联合 CRF 优化: CRF 模型作为一种判别式模型, 可以在给定观测场的条件下对标记场的后验概率直接建模, 被广泛应用于图像分类和标记任务中^[24-26]。将 MPCNet 与 CRF 两种模型融合, 不仅可以充分利用 MPCNet 提取深层图像特征的能力, 同时由于 CRF 模型的二阶势函数考虑了空间上下文信息, 可以在分类结果上有效抑制噪声。利用全连接 CRF 算法^[27]可以对分类结果进行进一步优化, 以提高分类精度。

全连接 CRF 能量函数构造: 定义 y_p 为像元点 x_p 的类别标签, 其取值范围为语义标签集 $Y = \{y_1, y_2, \dots, y_n\}$, c_p 为像元点 x_p 的颜色值。通过已获取的 MPCNet 的分类概率 P 及像元颜色特征 C 推理对应的类别标签, 构建的目标函数为

$$E(Y | X) = \sum_p \varphi_u(y_p) + \sum_{p < q} \varphi_c(x_p, x_q), \quad (4)$$

$$\varphi_u(y_p) = -\ln P(y_p | x_p), \quad (5)$$

式中: $\varphi_u(y_p)$ 为一元概率项; $P(y_p | x_p)$ 为标签 y_p 的类别概率; $\varphi_c(x_p, x_q)$ 为二元平滑项, 可以表示为被分配到不同标签的邻近像素的惩罚 $u(x_p, y_p)$ 与高斯核 ϕ 的乘积。高斯核 ϕ 的表达式为

$$\phi(\omega_p, \omega_q) = \lambda \cdot \exp\left(-\frac{\|\mathbf{x}_p - \mathbf{x}_q\|^2}{2\theta_\alpha^2} - \frac{\|\mathbf{c}_p - \mathbf{c}_q\|^2}{2\theta_\beta^2}\right) + (1 - \lambda) \cdot \exp\left(-\frac{\|\mathbf{x}_p - \mathbf{x}_q\|^2}{2\theta_\alpha^2}\right), \quad (6)$$

式中: 接近度参数 θ_α 为邻域像元的距离标准差; 相似度参数 θ_β 为邻近像元的颜色标准差; ω_p 和 ω_q 分别为像元 p, q 在任意特征空间下的向量。在真彩色遥感影像中, 邻近像元若颜色纹理比较相近, 则为同一标签的可能性更高, 二元平滑项给相似像素分配相同的标签, 而给相差较大的像素分配不同标签, 从而最大限度地去除小的孤立区域。优化后的类别

图即为最终多光谱遥感影像分类结果。

3 实验与分析

3.1 国外实验区介绍

实验研究区 (73.607°E ~ 73.860°E, 19.949°N ~ 20.160°N) 位于印度孟买东北处约 132 km 处, 纳西克城市附近。

图 3 为所用的多源遥感数据。其中图 3(a)~(d)为实验测试数据。图 3(a)为 Jilin-1GP01 真彩色显示影像。Jilin-1GP01 携带 2 台多光谱成像仪、1 台短波红外相机、1 台中波红外相机及 2 台长波红外相机,能够提供 450~13500 nm 波段具有不同分

辨率的标准产品。图 3(e)、(f)为实验评估数据,其中图 3(e)为谷歌地球高分辨率影像,分辨率为 0.3 m,图 3(f)为 GLC-2017 全球土地覆盖数据,分辨率为 30 m。具体的多光谱卫星数据波段选择、空间分辨率及拍摄时间情况细节如表 1 所示。

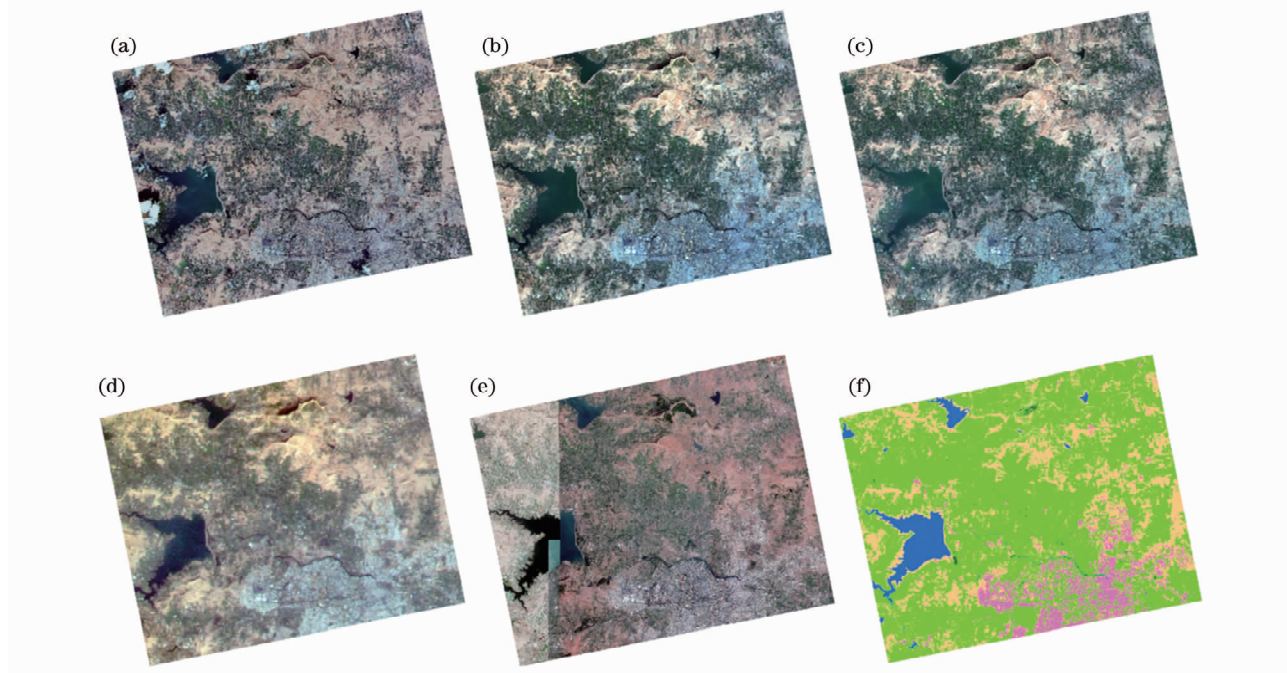


图 3 实验数据介绍。(a) Jilin-1GP01 真彩色影像; (b) Landsat8 真彩色影像; (c) Sentinel-2A 真彩色影像; (d) HJ-1A 真彩色影像; (e)谷歌地球高分辨率影像; (f) FROM-GLC-2017 地表覆盖产品

Fig. 3 Introduction of experimental data. (a) True color image of Jilin-1GP01; (b) true color image of Landsat8; (c) true color image of Sentinel-2A; (d) true color image of HJ-1A; (e) high resolution image of Google Earth; (f) land cover product of FROM-GLC-2017

表 1 多光谱卫星的波段选择、空间分辨率及拍摄时间

Table 1 Band selection, spatial resolution, and shooting time of multispectral satellite

Satellite type	Available/selective band number	Wavelength range /nm	Spatial resolution /m	Shooting time
Jilin-1GP01	26/10	400-13500	5	2019-01-22
Landsat8	11/11	430-12510	30	2019-01-13
Sentinel-2A	13/13	443-2190	10	2019-01-20
HJ-1A	4/4	430-900	30	2019-01-14

将 Gong 等^[22]发布的全球 30 m 土地覆盖数据集 FROM-GLC-2017 作为参考影像,结合地物光谱反射率特征对不同地表覆盖类型样本进行选取,如图 4 所示。同时利用谷歌地球高分辨率影像进行目视解译,提高样本选择准确性。主要类别包括未种植耕地、耕地、建筑、草地、裸地、道路、林地、水域,若有云覆盖,则包括云和阴影,共 10 类。研究区面积为 437.12 km²,选取的样本影像面积为 3.495 km²,样本数量约为影像像元总数的 0.79%。将样本点集划

分成训练集、验证集及测试集,其中训练点集像元数为 105247,验证点集像元数为 45107,测试点集像元数为 13234。对选取的样本影像绘制反射率曲线,如图 4 所示。其中细实线为每一个类地物中单个像元的反射率曲线,粗实线为样本点集的平均反射率曲线 m_s ,阴影区域为同类地物样本点集的反射率值在区间 $[m_s - \sigma_s, m_s + \sigma_s]$ 的波动情况,其中 σ_s 为反射率标准差。在阴影样本反射率中,不同种地物被遮挡后,由于地物反射光谱透过云时具有

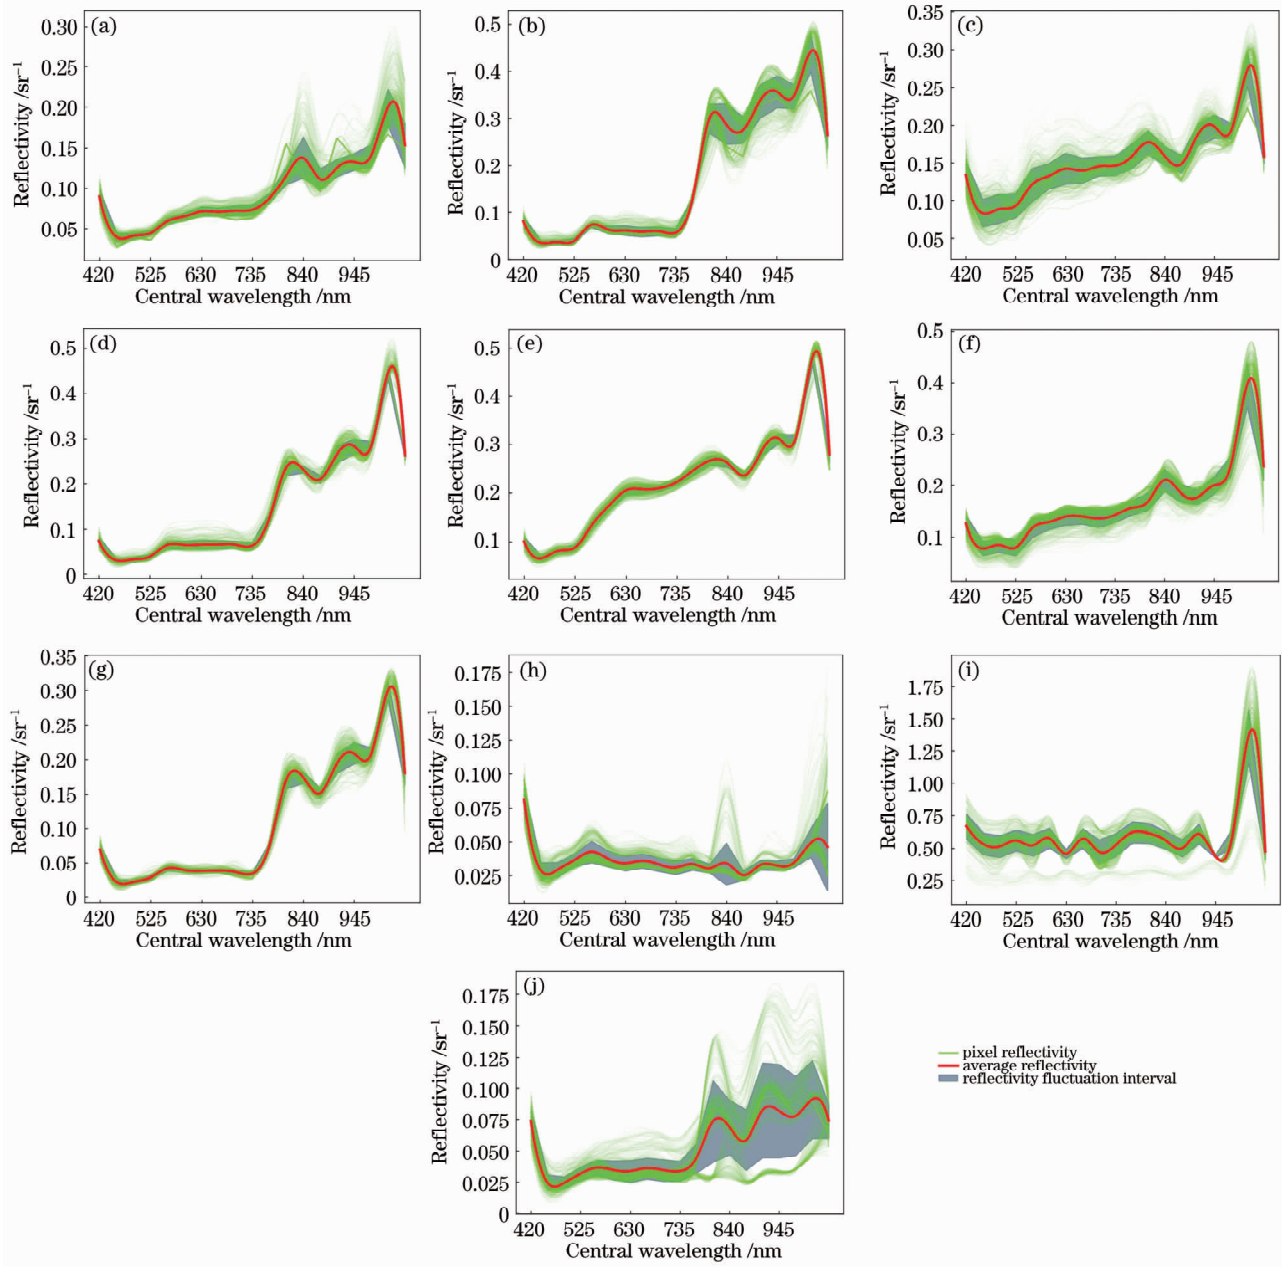


图4 Jilin-1GP01 纳斯克研究区样本反射率曲线图。(a)未种植耕地;(b)耕地;(c)建筑;(d)草地;(e)裸土;
(f)道路;(g)林地;(h)水域;(i)云;(j)阴影

Fig. 4 Reflectivity curves of samples in Nashik research area of Jilin-1GP01. (a) Uncultivated land ; (b) cultivated land ; (c) building ; (d) grassland ; (e) bare land ; (f) road ; (g) forest land ; (h) water ; (i) cloud ; (j) shadow

差异性,在 680~1020 nm 之间的波谱反射率波动较大。在水体样本反射率中,740~760 nm 及 945~1020 nm 处有两处波峰值,这是由水体悬浮物质反射引起的。综上所述,样本地物反射率曲线与理论上的分布规律基本一致。由于同物异谱与同谱异物现象,传统的机器学习分类算法会产生分类混淆,造成影像总体分类精度下降。所提算法可以有效地利用光谱信息和空间纹理特征,使得特征在高维空间

可分。

3.2 国内实验区介绍

选择国内山东省新泰市作为实验区对所提算法进行普适性验证。影像总面积约为 1933.28 km²。地处 35.617° N ~ 36.117° N 与 117.239° E ~ 117.997° E,地形以丘陵为主。农作物与植被层次比较丰富。表 2 为 Jilin-1GP02 波段选择、空间分辨率及拍摄时间的具体情况。

表 2 Jilin-1GP02 波段选择、空间分辨率及拍摄时间
Table 2 Band selection, spatial resolution, and shooting time of Jilin-1GP02

Satellite type	Sensor	Scene ID	Available/selective band number	Wavelength range / nm	Spatial resolution /m	Shooting time
Jilin-1GP02	PMS1	0001	26/10	400-13500	5	2019-03-15
	PMS1	0002				
	PMS2	0001				
	PMS2	0002				

3.3 实验参数设置

算法在基于深度学习的框架 Tensorflow1.4.0 上开发,支持跨平台 Ubuntu 18.04/Window 7/Window 10 运行。本次实验系统为 Ubuntu18.04,处理器为 Intel © Core™ i7-6850K,图形处理器(GPU)为 Nvidia GeForce Titan X GPU,显存 12 GB。在实验过程中,MPCNet 所涉及到的参数有,每个样本对应的空间邻域尺寸为 13×13 ,初始学习率为 0.01,batch size 为 500,训练次数为 10×10^4 ,多标签 CRF 中邻近像元的个数为 24,全连接 CRF 的空间平滑项系数为 0.607。

在其他算法中,SVM 使用线性核,惩罚系数为 100,分类概率阈值为 0;LightGBM 提升树类型为 GBDT,学习率为 0.01,拟合树的棵数为 1500,基学习器叶子节点个数为 35,叶子节点最小记录数为 200,L1 正则化系数为 0.6;浅层 CNN 为一个 6 层网络,包含 2 个卷积层、2 个池化层、2 个全连接层,其中卷积层中卷积核大小为 3×3 ,池化层中卷积核大小为 2×2 ,初始学习率为 0.01,batch size 为 500,训练次数为 15×10^4 。

3.4 分类精度评价

为验证 Jilin-1GP01 分类性能,采用所提 MPCNet 分类算法对拍摄影像进行分类精度评估,同时获取同一时间区间下 Landsat8、Sentinel-2A 及 HJ-1A 卫星数据进行横向验证。采用类别精度(P)、召回率(R)、 F_1 score(F_1)、Kappa 系数(K)及总体分类精度(P_{OA})作为分类精度评价指标。

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (7)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (8)$$

$$F_1 = \frac{2(R \times P)}{R + P}, \quad (9)$$

$$p_0 = \frac{\sum_{j=1}^k x_{jj}}{N_t}, \quad (10)$$

$$p_c = \frac{\sum_{j=1}^k (x_{j+} \times x_{+j})}{N_t^2}, \quad (11)$$

$$K = \frac{p_0 - p_c}{1 - p_c}, \quad (12)$$

$$P_{OA} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}}, \quad (13)$$

式中: N_{TP} 为被正确划分为正例的个数; N_{FP} 为被错误划分为正例的个数; N_{FN} 为被错误划分为负例的个数; N_{TN} 为被正确划分为负例的个数; N_t 为验证点集的总像元数; x_{j+} 与 x_{+j} 为分类混淆矩阵各行、各列之和; x_{jj} 为混淆矩阵对角线元素。

3.4.1 多源遥感影像分类结果评价

图 5(a)~(d)为 MPCNet 算法对 Jilin-1GP01、Landsat8、Sentinel-2A 及 HJ-1A 采集的可视化影像进行分类的效果图。表 3 为 MPCNet 算法对不同卫星数据的分类精度评价指标。可以看出,Jilin-1GP01 影像中道路细节比较清晰,不同垂直结构的植被可以得到有效分辨,总体分类精度高达 95.8%;Sentinel-2A 影像中分类的地物细节比较良好,总体分类精度达 93.5%;但 Sentinel-2A 影像对于不同类型的耕地,MPCNet 算法会产生分类混淆,在 Landsat8 与 HJ-1A 影像中,由于影像分辨率为 30 m,MPCNet 算法不适用于提取道路这类宽度较细的线状地物。HJ-1A 影像中关于道路的 F1 score 为 18%,并且对于范围较小的林地,类别精度不高,为 27%。

图 6 为 MPCNet 算法在局部纳西克区域的地物分类细节效果,其中图 6(e)为 OpenStreetMap 地图矢量数据集提供的建筑道路矢量数据与遥感影像叠加的结果,其中透明度设置为 65%。相比图 6(d),图 6(c)中道路轮廓较为清晰;与图 6(e)相比,图 6(c)中城市边界识别较为准确。

3.4.2 不同分类算法的分类结果评价

为验证所提算法的分类性能,基于国产光谱卫

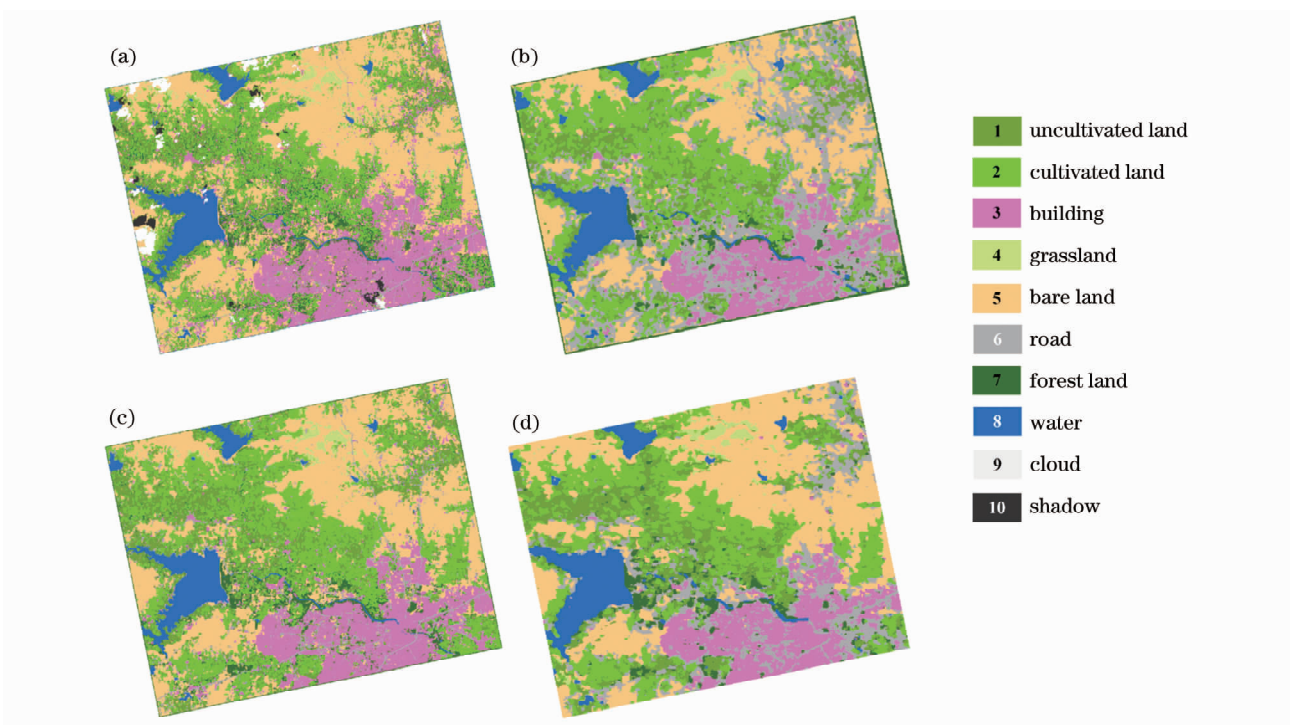


图 5 MPCNet 算法的分类效果。(a) Jilin-1GP01 影像；(b) Landsat8 影像；(c) Sentinel-2A 影像；(d) HJ-1A 影像
 Fig. 5 Classification results using MPCNet algorithm. (a) Jilin-1GP01 image ; (b) Landsat8 image ;
 (c) Sentinel-2A image ; (d) HJ-1A image

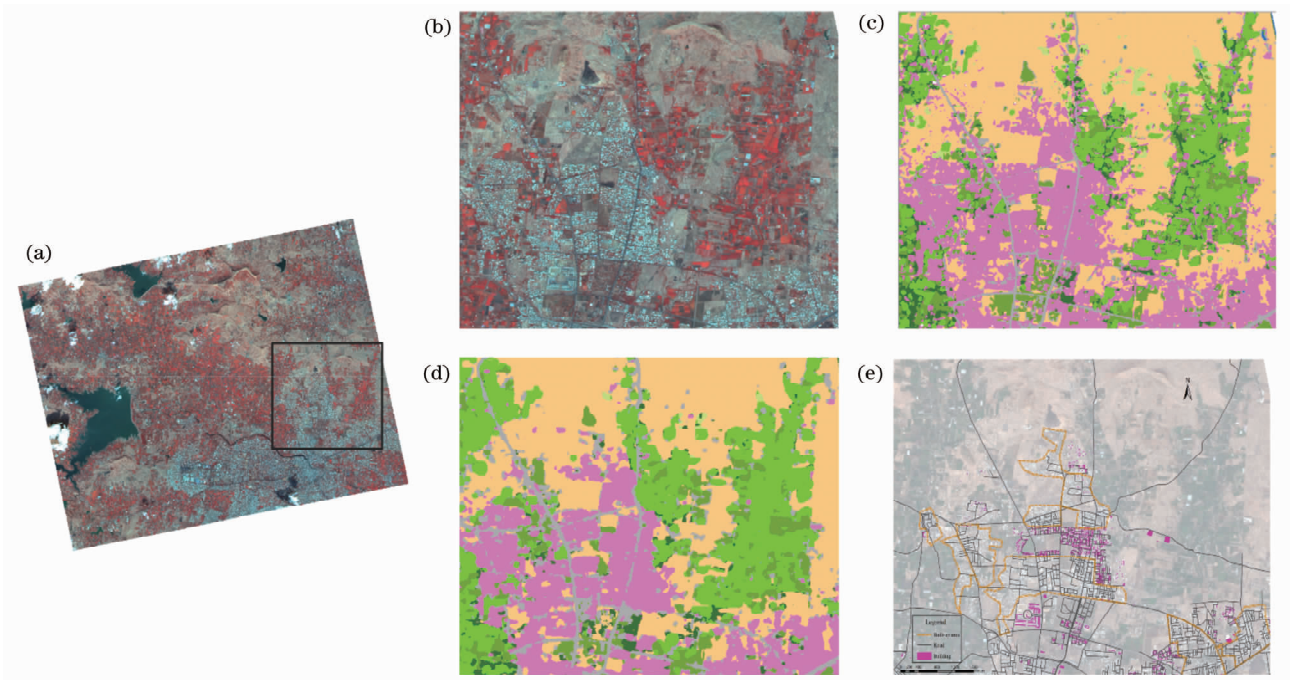


图 6 在局部纳西克区域的地物特征分类细节效果。(a)假彩色合成影像；(b)局部放大影像；(c) Jilin-1GP01 分类效果；
 (d) Sentinel-2A 分类效果；(e)矢量数据叠加的遥感影像

Fig. 6 Classification detail results of surface features at local Nashik area. (a) Pseudo-color composite image ; (b) local
 enlargement image ; (c) classification result by Jilin-1GP01 ; (d) classification result by Sentinel-2A ; (e) remote
 sensing image superimposed vector data

表 3 MPCNet 算法对不同卫星数据的分类精度评价指标

Table 3 Classification accuracy evaluation index of different satellite data based on MPCNet algorithm

Area type	Jilin-1GP01		Landsat8		Sentinel-2A		HJ-1A	
	<i>P/R</i>	<i>F</i> ₁	<i>P/R</i>	<i>F</i> ₁	<i>P/R</i>	<i>F</i> ₁	<i>P/R</i>	<i>F</i> ₁
Uncultivated land	1.00/0.93	0.96	0.91/0.83	0.87	0.96/0.89	0.92	0.76/0.74	0.75
Cultivated land	0.94/0.89	0.91	0.81/0.88	0.84	0.83/0.98	0.90	0.52/0.70	0.60
Building	0.96/0.99	0.97	0.94/0.79	0.86	0.97/0.94	0.96	0.85/0.61	0.71
Grassland	1.00/0.88	0.94	1.00/0.73	0.85	1.00/0.82	0.90	0.92/0.69	0.79
Bare land	0.96/1.00	0.98	0.96/0.93	0.94	0.94/0.99	0.96	0.75/0.86	0.80
Road	0.95/0.80	0.87	0.43/0.80	0.56	0.85/0.83	0.84	0.14/0.23	0.18
Forest land	0.71/1.00	0.83	0.62/1.00	0.76	0.69/1.00	0.82	0.27/0.68	0.38
Water	1.00/1.00	1.00	1.00/0.97	0.98	1.00/0.93	0.96	0.91/0.60	0.72
<i>K</i>	0.948		0.828		0.920		0.595	
<i>P</i> _{OA}	0.958		0.859		0.935		0.667	

星 Jilin-1GP01/02 数据,选取国外与国内研究区作为测试数据,分别采用 SVM、LightGBM(LGBM-GBDT)、浅层 CNN 及 MPCNet 算法进行分类精度评价。图 7 为不同算法对 Jilin-1GP01 影像的分类效果,分类精度评价指标如表 4 所示。从图 7(b)、(c)与(e)可以看出,MPCNet 在传统方法分类过程中,类似椒盐的混淆噪声得到很好的优化,且对于云与阴影的识别效果也很优异。图 8 展示国内研

究区的分类结果,Jilin-1GP02 影像的分类精度评价指标如表 5 所示。相比纳西克单景影像,新泰市采用镶嵌影像,覆盖范围更大。从表 5 可以看出,MPCNet 总体分类精度保持在 0.950 左右。实验结果表明,基于深度学习的浅层 CNN 及 MPCNet 算法在性能指标上有全面提升,且 MPCNet 在多数分类指标上优于浅层 CNN,总体分类精度提升 3.7 个百分点。

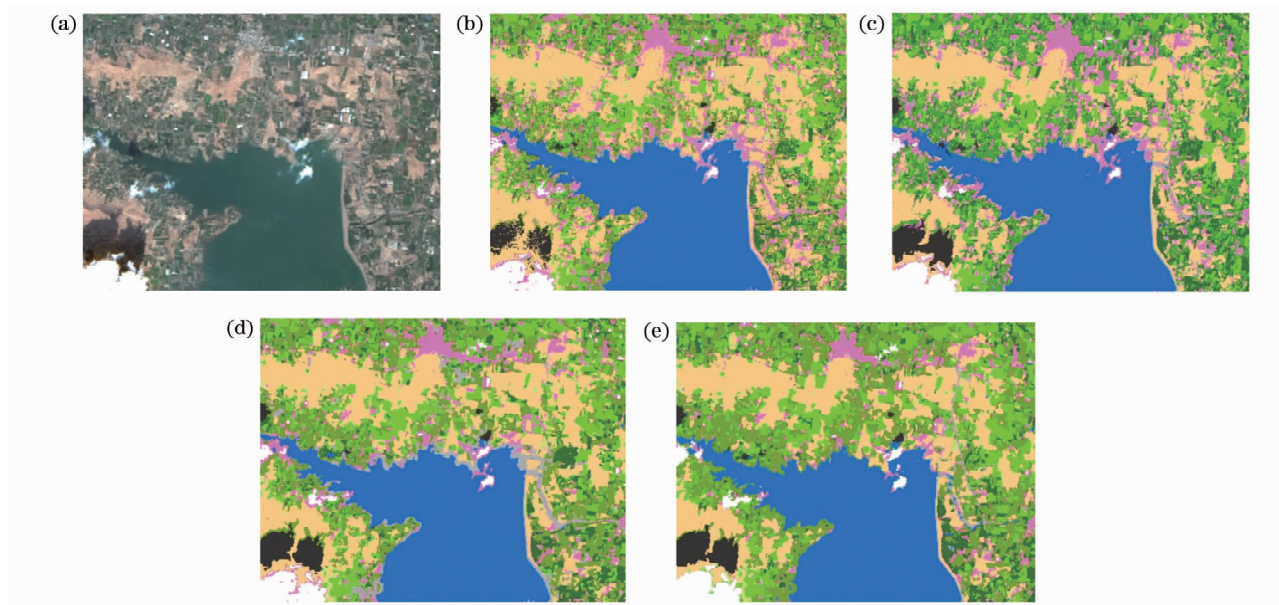


图 7 不同算法对 Jilin-1GP01 纳西克影像的分类效果。(a)局部影像;(b) SVM;(c) LGBM-GBDT; (d)浅层 CNN;(e) MPCNet

Fig. 7 Classification results of different algorithms on Jilin-1GP01 images in Nashik.

(a) Local image ; (b) SVM ; (c) LGBM-GBDT ; (d) shallow CNN ; (e) MPCNet

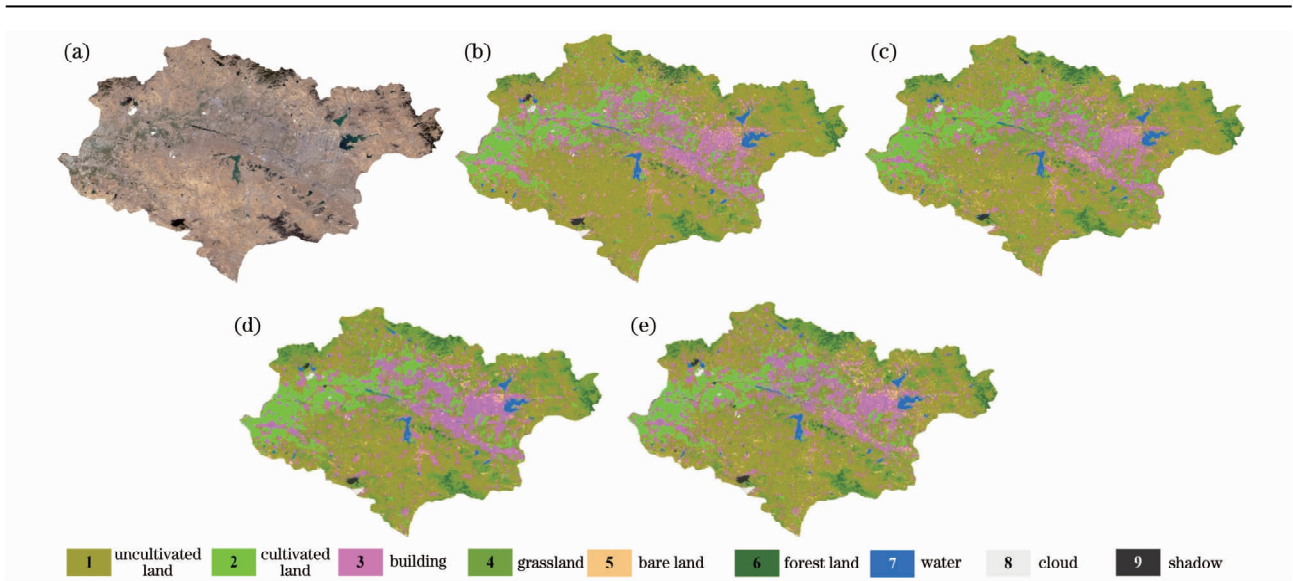


图 8 不同算法对 Jilin-1GP02 新泰市影像的分类效果。(a)局部影像;(b) SVM;(c) LGBM-GBDT;
(d)浅层 CNN;(e) MPCNet

Fig. 8 Classification results of different algorithms on Jilin-1GP02 images in Xintai city.

(a) Local image ; (b) SVM ; (c) LGBM-GBDT ; (d) shallow CNN ; (e) MPCNet

表 4 不同算法对 Jilin-1GP01 影像的分类精度评价指标

Table 4 Classification accuracy evaluation index of different algorithms on Jilin-1GP01 images

Area type	SVM		LGBM-GBDT		Shallow CNN		MPCNet	
	<i>P/R</i>	<i>F</i> ₁	<i>P/R</i>	<i>F</i> ₁	<i>P/R</i>	<i>F</i> ₁	<i>P/R</i>	<i>F</i> ₁
Uncultivated land	0.91/0.70	0.78	0.90/0.83	0.86	0.91/0.85	0.88	1.00/0.93	0.96
Cultivated land	0.90/0.89	0.89	0.91/0.90	0.91	0.98/0.90	0.94	0.94/0.89	0.91
Building	0.86/1.00	0.92	0.93/0.99	0.96	0.91/1.00	0.95	0.96/0.99	0.97
Grassland	0.99/0.79	0.88	1.00/0.69	0.82	1.00/0.89	0.94	1.00/0.88	0.94
Bare land	0.91/0.99	0.95	0.90/0.99	0.94	0.92/1.00	0.96	0.96/1.00	0.98
Road	0.64/0.28	0.39	0.88/0.62	0.73	0.76/0.40	0.53	0.95/0.80	0.87
Forest land	0.60/0.85	0.71	0.65/1.00	0.79	0.67/1.00	0.80	0.71/1.00	0.83
Water	1.00/0.96	0.98	1.00/0.97	0.99	1.00/0.96	0.98	1.00/1.00	1.00
<i>K</i>	0.857		0.899		0.901		0.948	
<i>P</i> _{OA}	0.886		0.919		0.921		0.958	

表 5 不同算法对 Jilin-1GP02 影像的分类精度评价指标

Table 5 Classification accuracy evaluation index of different algorithms on Jilin-1GP02 images

Area type	SVM		LGBM-GBDT		Shallow CNN		MPCNet	
	<i>P/R</i>	<i>F</i> ₁	<i>P/R</i>	<i>F</i> ₁	<i>P/R</i>	<i>F</i> ₁	<i>P/R</i>	<i>F</i> ₁
Uncultivated land	0.56/0.66	0.61	0.99/0.92	0.95	0.96/0.99	0.98	0.99/0.98	0.99
Cultivated land	0.97/0.98	0.97	0.71/0.67	0.69	0.88/0.85	0.86	0.96/0.94	0.95
Forest land	0.95/0.87	0.90	0.85/0.85	0.85	0.97/0.97	0.97	0.97/0.98	0.97
Shrub	0.56/0.85	0.67	0.44/0.87	0.59	0.75/0.98	0.85	0.88/0.97	0.92
Water	1.00/0.78	0.88	0.75/0.68	0.71	0.92/0.78	0.84	0.95/0.93	0.94
Building	0.62/0.69	0.65	0.80/0.76	0.78	0.83/0.97	0.90	0.92/0.94	0.93
Bare land	0.57/0.49	0.53	0.70/0.70	0.70	0.85/0.78	0.81	0.83/0.89	0.86
<i>K</i>	0.731		0.724		0.877		0.932	
<i>P</i> _{OA}	0.763		0.756		0.891		0.940	

表 6 不同算法对 Jilin-1GP01 影像的处理效率

Table 6 Processing efficiency of different algorithms on Jilin-1GP01 images

Algorithm	Image size	Image storage / Mbit	Feature extraction time /s	Model training time /min	Inference time / min	Total process time /min
SVM			713.4	47.45	63.42	122.76
LGBM-GBDT	5368×4565	888.04	24.3	1.34	7.42	9.17
Shallow CNN			38.0	14.92	2.96	18.51
MPCNet			37.5	10.80	3.56	14.98

表 6 计算了四种分类算法对 Jilin-1GP01 影像的处理效率,可以看出,相比 SVM, MPCNet 处理效率优势明显;由于浅层 CNN 模型收敛速度慢,与浅层 CNN 相比, MPCNet 在训练时间上提升 27% 左右。基于决策树的 LGBM-GBDT 算法采用最优的叶明智(leaf-wise)策略分裂叶子节点,分类效率较高,但总体分类精度比 MPCNet 低 3.9 个百分点。结合表 4、5,与准确率较高的浅层 CNN 相比, MPCNet 的总体分类精度提升 3.7 个百分点~4.9 个百分点。在未来工作中,将考虑多 GPU 异步处理技术来实现并行训练,提高算法效率。

4 结 论

为解决对国产多光谱遥感影像进行分类后地物分类混淆,有椒盐噪声,造成总体分类精度低等问题,提出适用于多光谱像素级分类的 MPCNet 算法。MPCNet 在谱段特征的基础上发挥了像元空间邻域的信息优势,进而有效提升了地物的总体分类精度。相比其他分类算法, MPCNet 在性能指标上有明显提升。同时为保证实验结果的可靠性,对不同卫星在同一时间段拍摄的影像数据进行横向对比评价。参考谷歌地球高分辨率影像及全球地表覆盖产品,对地物分类结果进行综合定性评估。在 Jilin-1GP01 影像上的总体分类精度比在 Sentinel-2A 影像上的高约 2 个百分点,比在 Landast8 影像高约 9 个百分点,比 HJ-1A 影像高约 29 个百分点。尤其是针对不同垂直结构的植被,在 Jilin-1GP01 影像上的分类效果比较明显,植被的 F1 score 比在 Sentinel-2A、Landast8 上的高约 2 个百分点~7 个百分点。

未来研究中,将考虑在改进的深度卷积网络中融合多个尺度卷积核对空间特征进行叠加学习,来进一步提升对多光谱遥感影像的分类性能。另一方面,考虑多 GPU 异步处理技术来实现大规模多光谱遥感影像的并行分类测试,提高自动化地表覆盖产品的生产效率,进而提升地表覆盖产品的时间分

辨率。

致谢 此次部分实验验证数据获得了国家对地观测科学数据分中心的帮助,在此表示衷心感谢!

参 考 文 献

- [1] Tong Q X, Zhang B, Zhang L F. Current progress of hyperspectral remote sensing in China[J]. Journal of Remote Sensing, 2016, 20(5): 689-707.
童庆禧, 张兵, 张立福. 中国高光谱遥感的前沿进展[J]. 遥感学报, 2016, 20(5): 689-707.
- [2] Goetz A F H. Three decades of hyperspectral remote sensing of the earth: a personal view[J]. Remote Sensing of Environment, 2009, 113: S5-S16.
- [3] Xu G H, Liu Q H, Chen L F, et al. Remote sensing for China's sustainable development: opportunities and challenges[J]. Journal of Remote Sensing, 2016, 20(5): 679-688.
徐冠华, 柳钦火, 陈良富, 等. 遥感与中国可持续发展: 机遇和挑战[J]. 遥感学报, 2016, 20(5): 679-688.
- [4] Zheng Y, Wu B F, Zhang M. Estimating the above ground biomass of winter wheat using the Sentinel-2 data[J]. Journal of Remote Sensing, 2017, 21(2): 318-328.
郑阳, 吴炳方, 张森. Sentinel-2 数据的冬小麦地上干生物量估算及评价[J]. 遥感学报, 2017, 21(2): 318-328.
- [5] Li X W, Shi H, Zhang Y, et al. Cyanobacteria blooms monitoring in Taihu lake based on the Sentinel-2A satellite of European space agency[J]. Environmental Monitoring in China, 2018, 34(4): 169-176.
李旭文, 侍昊, 张悦, 等. 基于欧洲航天局“哨兵-2A”卫星的太湖蓝藻遥感监测[J]. 中国环境监测, 2018, 34(4): 169-176.
- [6] Samaniego L, Bardossy A, Schulz K. Supervised classification of remotely sensed imagery using a modified k -NN technique[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(7): 2112-2125.

- [7] Cui B D. Remote sensing image classification based on SVM classifier [J]. Computer Engineering and Applications, 2011, 47(27): 189-191.
崔炳德. 支持向量机分类器遥感图像分类研究[J]. 计算机工程与应用, 2011, 47(27): 189-191.
- [8] Xie D F, Zhang J S, Pan Y Z, et al. Fusion of MODIS and Landsat 8 images to generate high spatial-temporal resolution data for mapping autumn crop distribution [J]. Journal of Remote Sensing, 2015, 19(5): 791-805.
谢登峰, 张锦水, 潘耀忠, 等. Landsat 8 和 MODIS 融合构建高时空分辨率数据识别秋粮作物[J]. 遥感学报, 2015, 19(5): 791-805.
- [9] Lin W P, Wang C Y, Chu D P, et al. Extraction of fall crop types based on spectral analysis [J]. Transactions of the Chinese Society of Agricultural Engineering, 2006, 22(9): 128-132.
林文鹏, 王长耀, 储德平, 等. 基于光谱特征分析的主要秋季作物类型提取研究[J]. 农业工程学报, 2006, 22(9): 128-132.
- [10] Hu Y, Liu L Y, Peter C, et al. Landsat time-series land cover mapping with spectral signature extension method[J]. Journal of Remote Sensing, 2015, 19(4): 648-656.
胡勇, 刘良云, Peter C, 等. 光谱特征扩展的时间序列 Landsat 数据地表覆盖分类[J]. 遥感学报, 2015, 19(4): 648-656.
- [11] Yang B, Cao C X, Xing Y, et al. Automatic classification of remote sensing images using multiple classifier systems [J]. Mathematical Problems in Engineering, 2015: 1-10.
- [12] Yu P X, Zhou X, Liu S H, et al. Feature extraction and recognition of erosion gully based on remote sensing image in the black soil region in Northeast China[J]. Journal of Remote Sensing, 2018, 22(4): 611-620.
于佩鑫, 周询, 刘素红, 等. 东北黑土区侵蚀沟遥感影像特征提取与识别[J]. 遥感学报, 2018, 22(4): 611-620.
- [13] Li Z Q, Zhu R F, Gao F, et al. Hyperspectral remote Sensing Image classification based on three-dimensional convolution neural network combined with conditional random field optimization[J]. Acta Optica Sinica, 2018, 38(8): 0828001.
李竺强, 朱瑞飞, 高放, 等. 三维卷积神经网络模型联合条件随机场优化的高光谱遥感影像分类[J]. 光学学报, 2018, 38(8): 0828001.
- [14] Paoletti M E, Haut J M, Plaza J, et al. A new deep convolutional neural network for fast hyperspectral image classification [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 145: 120-147.
- [15] Zhou W X, Newsam S, Li C M, et al. PatternNet: a benchmark dataset for performance evaluation of remote sensing image retrieval[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 145: 197-209.
- [16] Kan X, Zhang Y H, Cao T, et al. Snow cover recognition for Qinghai-Tibetan Plateau using deep learning and multispectral remote sensing[J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(10): 1210-1221.
阚希, 张永宏, 曹庭, 等. 利用多光谱卫星遥感和深度学习方法进行青藏高原积雪判识[J]. 测绘学报, 2016, 45(10): 1210-1221.
- [17] Pan B, Shi Z W, Xu X. MugNet: deep learning for hyperspectral image classification using limited samples[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 145: 108-119.
- [18] Zhang Z X, Wang X, Wen Q K, et al. Research progress of remote sensing application in land resources[J]. Journal of Remote Sensing, 2016, 20(5): 1243-1258.
张增祥, 汪潇, 温庆可, 等. 土地资源遥感应用研究进展[J]. 遥感学报, 2016, 20(5): 1243-1258.
- [19] Ke G L, Meng Q, Finley T, et al. LightGBM: a highly efficient gradient boosting decision tree[C]// Advances in Neural Information Processing Systems 30, December 4-9, 2017, Long Beach, CA, USA. New York: Curran Associate, 2017.
- [20] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, inception-ResNet and the impact of residual connections on learning [EB/OL]. (2016-08-23) [2020-03-28]. <https://arxiv.org/abs/1602.07261>.
- [21] 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.
- [22] Gong P, Wang J, Yu L, et al. Finer resolution observation and monitoring of global land cover: first mapping results with Landsat TM and ETM+ data [J]. International Journal of Remote Sensing, 2013, 34(7): 2607-2654.
- [23] Duchi J, Hazan E, Singer Y. Adaptive subgradient methods for online learning and Stochastic optimization[J]. The Journal of Machine Learning Research, 2011, 12(7): 257-269.
- [24] Zhong P, Wang R S. Learning conditional random fields for classification of hyperspectral images[J]. IEEE Transactions on Image Processing, 2010, 19(7): 1890-1907.

- [25] Zhao J, Zhong Y F, Zhang L P. Detail-preserving smoothing classifier based on conditional random fields for high spatial resolution remote sensing imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(5): 2440-2452.
- [26] Xia M, Cao G, Wang G Y, et al. Remote sensing image classification based on deep learning and conditional random fields[J]. Journal of Image and Graphics, 2017, 22(9): 1289-1301.
- 夏梦, 曹国, 汪光亚, 等. 结合深度学习与条件随机场的遥感图像分类[J]. 中国图象图形学报, 2017, 22(9): 1289-1301.
- [27] Krähenbühl P, Koltun V. Efficient inference in fully connected CRFs with Gaussian edge potentials[C]// Advances in Neural Information Processing Systems 24, December 3-6, 2011, Granada, Spain. New York: Curran Associate, 2011.