

基于机器学习的多源遥感影像 融合土地利用分类研究^①

陈磊士, 赵俊三, 李易, 朱祺夫, 许可

昆明理工大学 国土资源工程学院, 昆明 650093

摘要: 为了快速获取准确的城市土地利用信息, 提高西南地区遥感影像城市土地利用分类信息提取的精度, 探讨了当前快速发展的机器学习技术在该领域中的分类实验. 选用昆明市主城区作为研究区域, 以 Landsat8 与 Sentinel-1A 影像为原始数据, 使用 GS 变换法对影像进行融合, 使用卷积神经网络(Convolutional Neural Network, CNN)和 BP 神经网络(Back Propagation Network)2 种分类算法对融合前后的遥感影像进行土地利用分类信息提取, 对分类结果进行分析. 研究表明: 基于 Landsat8 和 Sentinel-1A 的融合影像数据的卷积神经网络分类算法具有最好的分类效果, 其总体分类精度和 $Kappa$ 系数分别为 85.8091%, 0.8124, 认为基于多源遥感影像融合的卷积神经网络分类方法是获取准确的城市土地利用分类信息的一种可行的方法, 可以为高原地区城市的土地利用分类提取研究参考.

关键词: 机器学习; 城市土地利用分类; 影像融合; 卷积神经网络; Landsat8; Sentinel-1A

中图分类号: TP79

文献标志码: A

文章编号: 1000-5471(2018)10-0103-09

土地利用变化(Land-Use and Land-Cover Change)研究是全球城市开发利用和环境变化研究的一项重要内容^[1], 可以为多层次、多尺度的土地资源评价及规划研究提供基本的数据来源, 为城市的各项规划管理工作提供科学依据^[2]. 近年来随着城市的快速发展, 城市土地利用方式的变化呈现出范围广和速度快两大特点, 而遥感具有的基于空间连续和持续观测的影像数据的快速获取能力, 使其成为土地利用分类研究的重要方法^[3], 在国内外相关研究中取得了较好的效果^[4]. 目前应用于城市区域土地分类研究的遥感数据源大多为多光谱光学影像数据, 如 MODIS, Landsat8, SPOT, TM/ETM+ 数据等, 基于不同地物在遥感影像上的图形学差别进行土地利用分类, 分类精度较高^[5]. 而中国部分城市复杂的云层覆盖制约了光学遥感数据源的应用, 单一的光学遥感数据源很难满足这些城市土地利用现状信息的采集与研究需要. 对多源遥感影像数据进行融合, 可以获得更丰富的土地利用现状信息并且具有更高的精度^[6]. SAR(Synthetic Aperture Radar, 合成孔径雷达)遥感相比光学遥感, 获取地形数据时基本不受天气影响, 其缺点是细节的表征不如光学遥感影像^[7], 对 2 种遥感影像进行融合操作有利于提取城市土地利用现状信息并进行土地利用分类研究^[8], 目前已有关于多源融合影像的土地利用分类研究的实证研究^[9].

Sentinel-1A 是 2014 年欧洲空间局哥白尼计划(GMES)发射的环境监测卫星, 携带有一个 C 波段合成孔径雷达, 可在任何天气条件下提供遥感图像, 其观测数据为电磁波射入地表的后向散射雷达脉冲强度及相位信息, 覆盖广、周期短且观测模式多, 具有广阔的应用前景^[10]. 在光学遥感数据源方面, 美国国家航空局于 2013 年发射 Landsat8 美国对地观测卫星, Landsat8 作为 Landsat 计划的第八颗卫星, 包含 OLI(Operational Land Imager 陆地成像仪)和 TIRS(Thermal Infrared Sensor 热红外传感器)2 种传感器, 其多

① 收稿日期: 2018-02-06

基金项目: 国家自然科学基金项目(41761081).

作者简介: 陈磊士(1993-), 男, 硕士研究生, 主要从事 3S 集成与应用开发研究.

光谱影像相比 TM/ETM+ 在波段的数量、光谱范围和影像的辐射分辨率方面有了较大改进。霍天林等人^[9]对 Landsat8 和 Sentinel-1A 影像进行融合处理后,在以武汉市主城区为代表的城市复杂的水网复杂的特大城市中应用几种常用分类方法提取信息,提取结果明显优于单一遥感图像,是获取高精度土地利用信息有效方法。

机器学习是人工智能的核心,随着当前机器学习技术的发展,其中的深度学习模型凭借着多隐层结构的优势,被广泛应用于各个领域^[11]。卷积神经网络(Convolutional Neural Network, CNN)是前馈神经网络的一种,其特点包括局部感知域、权值共享域和池化,对于影像的模式分类有很大的优势,其层次多、容量大的优点满足了影像分类中对大量数据处理的需要,近年来在遥感影像分类处理领域中取得了很好的成果^[12],但在复杂气候高原山地城市应用深度学习进行多源遥感影像融合的土地利用信息提取的分类效果仍有待研究^[13]。本研究将分别对单一 Landsat8 遥感影像以及对 Landsat8 与 Sentinel-1A 影像融合的多源影像数据使用 BP 神经网络和卷积神经网络进行分类处理,并对其分类结果进行评价分析。

1 研究区概况

昆明市是云南省唯一的特大城市及我国西部的第四大城市,地处云贵高原中部。其主城区位于滇池以北,三面环山,海拔 1 500~2 000 m 左右,昆明市下辖五华区、盘龙区、官渡区、呈贡区以及西山区的一部分(图 1)。云南省第二次土地调查结果显示,昆明市下辖主城区总面积为 1 760.78 km²(含滇池草海水域 10.7 km²),2010 年第六次全国人口普查结果显示,昆明常住人口约 358 万人。作为云南省的城市化重心,昆明近年来城区范围扩张较快,对土地利用信息的快速提取有长期需求。全市范围内的土壤类型为高原红壤,属于低纬度地区高原山地季风性气候,1951 年至 2015 年期间的年平均气温为 15.7 °C,年平均降水 965.8 mm,平均相对湿度 69.5%。2011 年 1 月至 2017 年 10 月,共出现降雨 1 058 天,多云 654 天,晴 649 天,阴 25 天,雪 20 天,由于地处高原其气候存在着明显的垂直差异和水平差异,其云雨天气过多不适宜进行单一的光学遥感影像分类信息提取^[14],因此本研究对 Landsat8 和 Sentinel-1A 的遥感影像进行融合处理,使用卷积神经网络和 BP 神经网络算法对影像分类进行城市土地的利用现状信息提取。

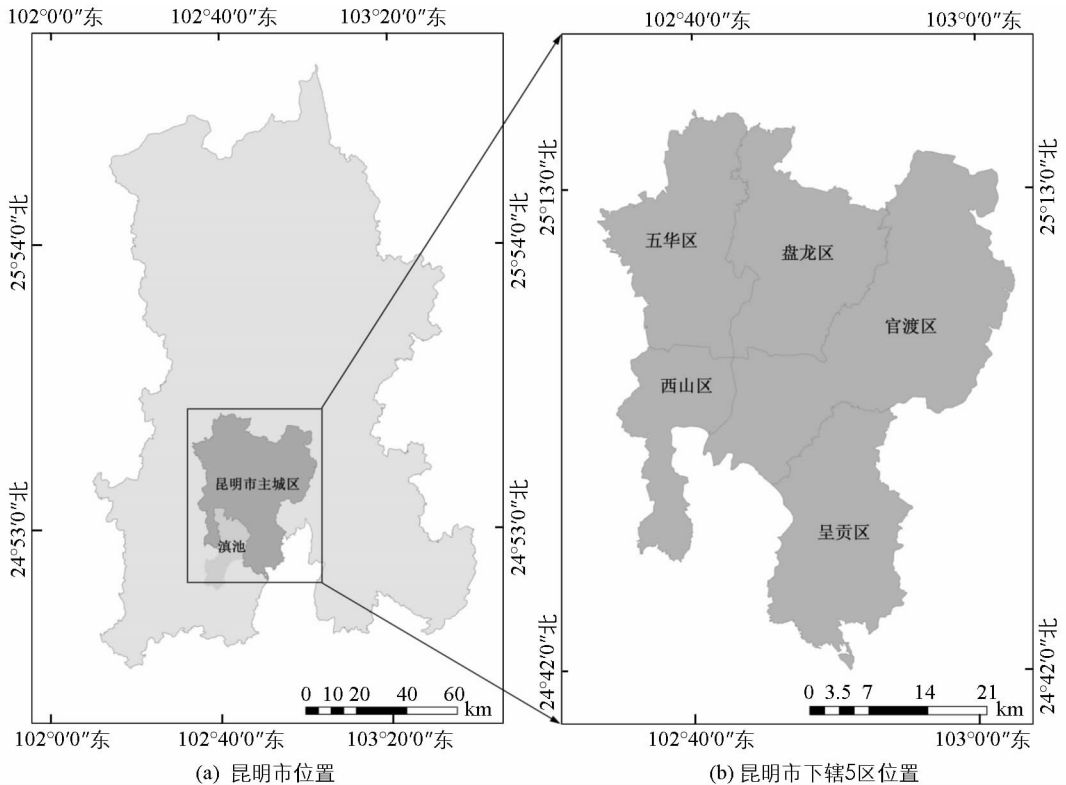


图 1 研究区概况

2 数据来源与分类类型

本研究采用的数据源包括: 2016 年 4 月 1 日成像的欧洲空间局 Sentinel-1A(IW)宽幅合成孔径雷达干涉模式影像(SENTINEL-1 Interferometric Wide Swath Level 1 Product), 产品级别 GRDH, C 波段, 极化方式为 VV, 分辨率为 $5\text{ m} \times 20\text{ m}$; 与 Sentinel-1A 影像对应的精密轨道数据, 包括 POD 精密轨道数据(POD Precise Orbit Ephemerides)和 POD 回归轨道数据(POD Restituted Orbit); 2016 年 4 月 28 日的 Landsat8 OLI_TIRS 影像, 分辨率为 30 m , 太阳高度角 66.33° , 轨道号 129/43. 辅助数据包括: 昆明市主城区矢量范围线, 用于研究区范围划定; 昆明市土地利用现状图(2015 年)及野外调研资料, 用于分类样本选取; 云南省第二次全国土地调查昆明市主城区范围矢量数据, 作为分类器分类结果的判读对比标准; SRTM.V4 昆明市 30 m 精度 DEM 数据, 用于影像的地形校正。

以《土地利用现状分类》(GB/T21010—2007)为依据, 结合昆明市主城区的土地利用现状和已有的研究成果^[10], 将该区域的土地利用现状分类为建设用地、水域、裸地、林地、园地 5 类. 其中建设用地、水域和林地常用的城市土地利用分类类型; 由于主城区内土壤类型为高原红壤, 大片的裸露土地有明显的影像特征, 使用裸地表征这一类型; 由于研究区内耕地面积小、分布零散, 且区分度较低, 牧草地和其他农用地影像特征不显著, 故与分布较广的园地归为一类。

由于 Landsat8 与 Sentinel-1A 传感器的成像方式、光谱的范围和所表征的地物特性等不能直接对应, 直接按照像元的灰度值进行融合操作会产生误差, 因此需要基于传感器特征的对应辐射传输方程及物理模型, 通过辐射定标计算 Landsat8 与 Sentinel-1A 影像各自所表征的后向散射值以及真实地物的反射率, 再以此为依据进行影像融合操作和土地利用信息的提取^[13]。

3 实验方法

3.1 Sentinel-1A 数据预处理

使用的 SARscape 软件将 Sentinel-1A 数据以及相匹配的精密轨道数据导入 ENVI 软件中, 数据的处理将在 ENVI 软件中完成, 实验流程如图 2 所示. 使用 Frost 滤波器对 SAR 数据进行滤波处理, 其目的在于最大限度地消除数据的斑点噪声与相干斑噪声, 保留影像数据边缘并且加强其细节; 然后运用 Geocoding and Radiometric Calibration 模块对 SAR 数据进行辐射定标和地理编码, 将不同传感器和不同接受模式下的 SAR 数据的后向散射值(即发射脉冲与接收信号的强度比)进行归一化. 归一化计算使用 Semi-empirical correction 法, 该方法下后向散射系数的变异系数既考虑了距离补偿也考虑了地形条件, 参考地形为 SRTM.V4 昆明市 30 m 精度 DEM. 散射面积的计算使用真实距离法, 与常规的区域相比, 云南省这类地形起伏较大的地区采用入射角法计算精度更高^[15]. 辐射定标的公式如式(1):

$$P_d = \frac{P_t \cdot G_r^A(\theta_d, \theta_{az}) \cdot G_r^A(\theta_d, \theta_{az}) \cdot \lambda^3 \cdot G_r^E \cdot G_p \cdot A \cdot \sigma^o + P_n}{(4\pi)^3 \cdot R^3 \cdot L_s \cdot L_a} \quad (1)$$

式中: P_d 为后向散射强度; P_t 为传输功率; P_n 为附加功率; G_r^A 代表投射天线增益; G_r^A 代表接收天线增

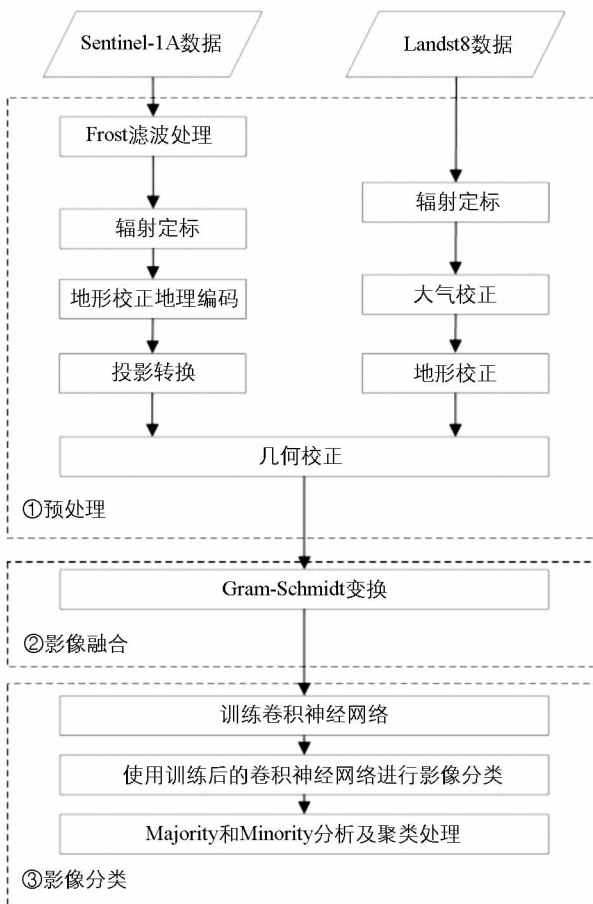


图 2 实验流程图

益; G^E 代表接收器的电流增益; G_p 为处理器常数; R^3 代表距离传递损耗; θ_d 代表天线仰角; θ_{az} 代表天线方位角; L_a 为大气损耗; L_s 为系统损耗; A 为散射面积.

由于 SAR 图像存在阴影、叠掩、透视收缩等几何畸变和辐射畸变等问题, 需要对影像进行地形校正, 减小由地形的高低起伏带来的影像畸变问题, 对数据进行地形校正地理编码(GTC). 采用 SRTM.V4 昆明市 30 m 精度 DEM 建立斜距坐标系和地理坐标系的映射关系, 将地理信息写入经过地形校正的影像, 之后进行投影转换, 最终将 SAR 影像从斜距投影转换为地理坐标系.

3.2 Landsat8 数据预处理

将 Landsat8 影像数据导入 ENVI, 使用 Radiometric Calibration 模块进行辐射定标, 输入波段, 选择热红外波段中心波长 10.900 的波段, 辐射亮度值设定为 Radiance, 以得到精度较高的真实地物反射率. FLAASH 模块能够精确补偿大气的影像, 使用 FLAASH 大气校正工具, 导入 MLT 文件中的相关参数, 辐射率单位调整系数设定为 0.1, 大气模型参数则按照气候模型设定.

常用的遥感影像地形校正模型有 C 校正模型、Shepherd 模型、SCS+C 校正模型等, 已有的研究表明, 在我国适用最为广泛的 Landsat 影像地形校正方法为 C 模型法, C 模型适合用在以实验区为代表的地形起伏不算太大的地区. C 模型是一种应用了半经验系数 C 的基于余弦校正模型的模型, 其公式^[16]为:

$$L_H = L_T \cdot \frac{\cos\theta_s + C}{\cos i + C} \quad (2)$$

式中: L_H 代表校正后的像素辐射量度; L_T 代表校正前的像素辐射量度; θ_s 为太阳天顶角; i 为太阳的有效入射角; C 为半经验系数, 无明确的物理含义.

在经过校正的 Sentinel-1A 和 Landsat8 图像上选取较为均匀的控制点, 对 2 幅影像进行几何校正, 校正方法选择二次多项式法, 将误差控制在 0.5 个像元之内.

3.3 影像融合

进行光学影像与 SAR 影像融合的目的是为了提高影像信息的可用性, 充分利用遥感影像的互补信息和冗余信息, 从而提高数据的分类精度. 常用的影像融合方法有 GS(Gram-Schmidt)变换法、SVR 融合法、小波变换法、HIS 变换法等. GS 变换法的优点是信息失真较小, 并且能够较好地保持多光谱影像的几何特征与光谱信息^[17], 因此本研究选用 GS 变换法对 Sentinel-1A 和 Landsat8 影像进行融合.

GS 变换法是一种多维正交线性变换法, 通过正交化消除冗余信息, 并通过子空间上的一个基得到子空间的一个正交基, 再得到对应的标准正交基. 设 $\{u_1, u_2, \dots, u_n\}$ 为相互独立的一组向量, 通过 GS 变换构造的正交向量为 $\{v_1, v_2, \dots, v_n\}$, 其计算公式如下:

$$v_1 = u_1 \quad (3)$$

$$v_{i+1} = u_{i+1} - p_{w_i} u_{i+1} \quad (4)$$

$$p_{w_i} u_{i+1} = \frac{(u_{i+1}, v_i)}{\|v_i\|^2} \cdot u_i, \quad (i = 1, 2, \dots, n) \quad (5)$$

式中: w_i 代表前 i 个已计算的正交向量张成的空间; $p_{w_i} u_{i+1}$ 是 u_{i+1} 在 w_i 上的正交投影.

其主要步骤为: 先用 Landsat8 影像对 Sentinel-1A 影像进行模拟, 用多光谱重采样的方法模拟 Sentinel-1A 影像作为 GS 变换的第一分量, 用 GS 变换将 Landsat8 影像转换到正交空间, 将经过修改的 Sentinel-1A 影像替换成变换后的第一分量, 从而产生新的数据集, 最后通过反 GS 变换得到融合后的多光谱影像.

3.4 影像分类

卷积神经网络相对 BP 神经网络减少了需要学习的参数数目, 可以直接进行多维图像输入, 免去了图像特征的提取以及复杂的数据重建过程, 有效降低了网络模型的复杂度^[18].

卷积神经网络分类模型的框架如图 3 所示, C 层是一个特征提取层, 用于提取影像的局部特征, 每个特征矩阵对应一个卷积核. 前一层输入的特征矩阵与可学习的卷积核进行二位卷积, 其计算公式如(6)所示. S 层将前一层的数据进行缩放映射, 用于减少数据的维度, 经过缩放其提取的特征具有不变性, 采用均值池化法用于防止过度拟合^[19], 最终起到了二次特征提取的作用. 其计算公式如(7)所示.

$$X_o^l = f(\sum_{i \in m} X_i^{l-1} \times K_o^l + B^{kl}) \tag{6}$$

$$X_o^l = f\left(\frac{1}{k} \sum_{i \in m} X_i^{l-1} + B^l\right) \tag{7}$$

式中: l 表示网络层数序列; K 表示卷积核; B 表示偏置; m 表示输出特征矩阵的阶数; X_o^l 表示第 l 的输出, X_i^{l-1} 表示第 l 层的输入。




图 3 卷积神经网络分类模型框架

作为对照实验的 BP 神经网络, 其分类器模型包括一个输入层、一个输出层和若干隐藏层, 各节点间作用函数如下:

$$y_j = f\left(\sum_{i=1}^n w_{ij} x_i - \theta_j\right) \tag{8}$$

$$f(x) = \frac{1}{1 + e^{-x}} \tag{9}$$

式中: y_j 为神经元 j 的输入值; x_i 为上一层第 i 神经元值; w_{ij} 代表权系数; θ_j 为阈值; f 代表非线性激励函数。

对研究区范围内各地物对应的卷积神经网络和 BP 神经网络进行训练, 当误差函数收敛为一个较小的数值并且停止震荡时, 则表明神经网络训练成功, 可以使用对应的神经网络对遥感影像进行分类。然后使用 ENVI 中的 Majority 和 Minority 分析模块对分类后的结果进行小斑块去除处理, 再进行 Clump 聚类处理, 将临近的、相似的分类区域聚类进行合并, 以增加分类图像的空间连续性^[20], 得到最终的分类效果图。

4 实验结果与评价

Landsat8 影像和基于 Sentinel-1A 和 Landsat8 的融合影像的分类结果如图 4,5 所示, 参照昆明市土地利用现状图(2015 年)、SRTM.V4 昆明市 30 m 精度 DEM 数据和野外调研资料, 以经过修正的云南省第二次全国土地调查昆明市主城区范围矢量数据作为标准分类结果, 以标准分类区域内随机生成的方式产生判别点, 使用人工判别的方式得到对应的分类类别结果, 对 Landsat8 影像和基于 Sentinel-1A 和 Landsat8 的融合影像分别使用 BP 神经网络和卷积神经网络作为分类器的土地利用分类结果生成分类混淆矩阵, 得到各分类类别的用户精度和各实际类别对应的制图精度, 如表 1 至表 4 所示, 通过生成的混淆矩阵进行精度评价。

表 1 基于 Landsat8 影像的 BP 神经网络分类混淆矩阵

分类类别	实际类别						总和	用户精度/%
	建设用地	水域	林地	园地	裸地			
建设用地	632	0	57	31	27	747	84.61	
水域	7	196	8	19	5	235	83.40	
林地	73	2	489	61	9	634	77.13	
园地	122	5	54	412	25	618	66.67	
裸地	16	7	12	7	134	176	76.14	
合计	850	210	620	530	200			
制图精度/%	74.35	93.33	78.87	77.74	67.00			
		总体分类精度=77.302 9%		Kappa 系数=0.698 2				

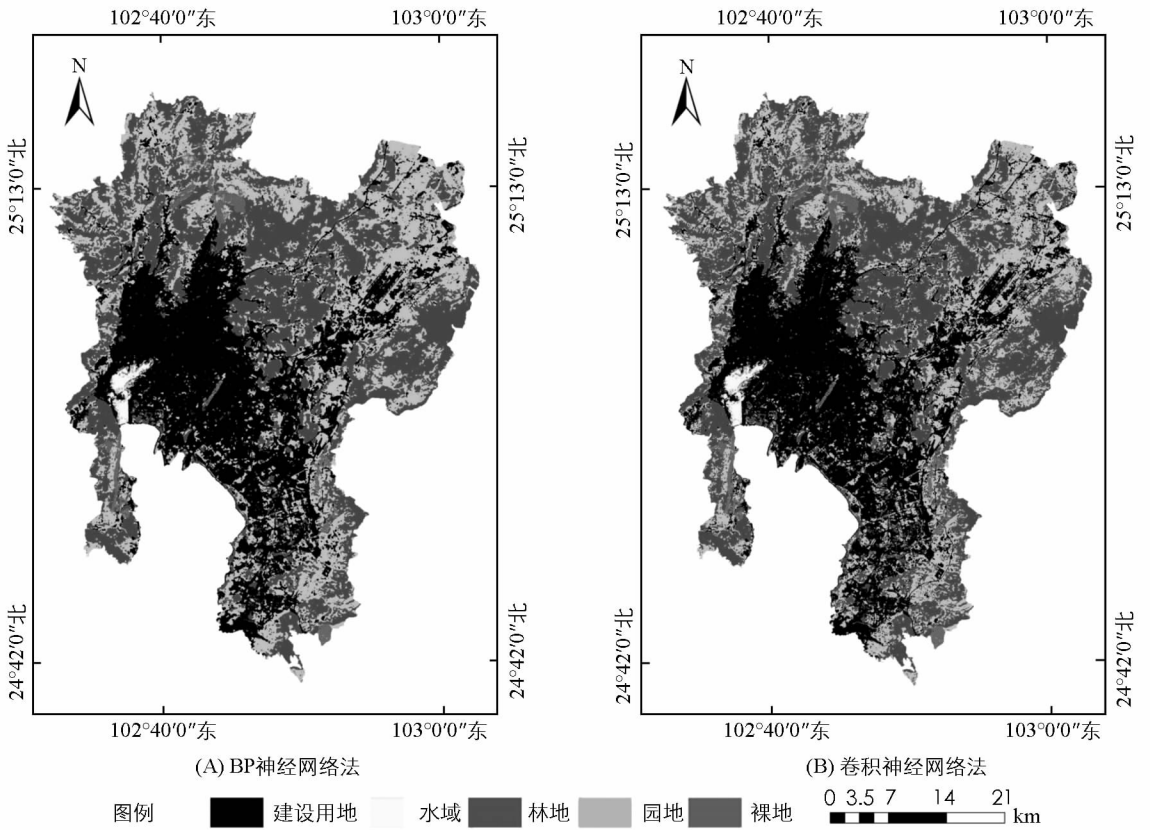


图 4 Landsat8 影像的分类结果

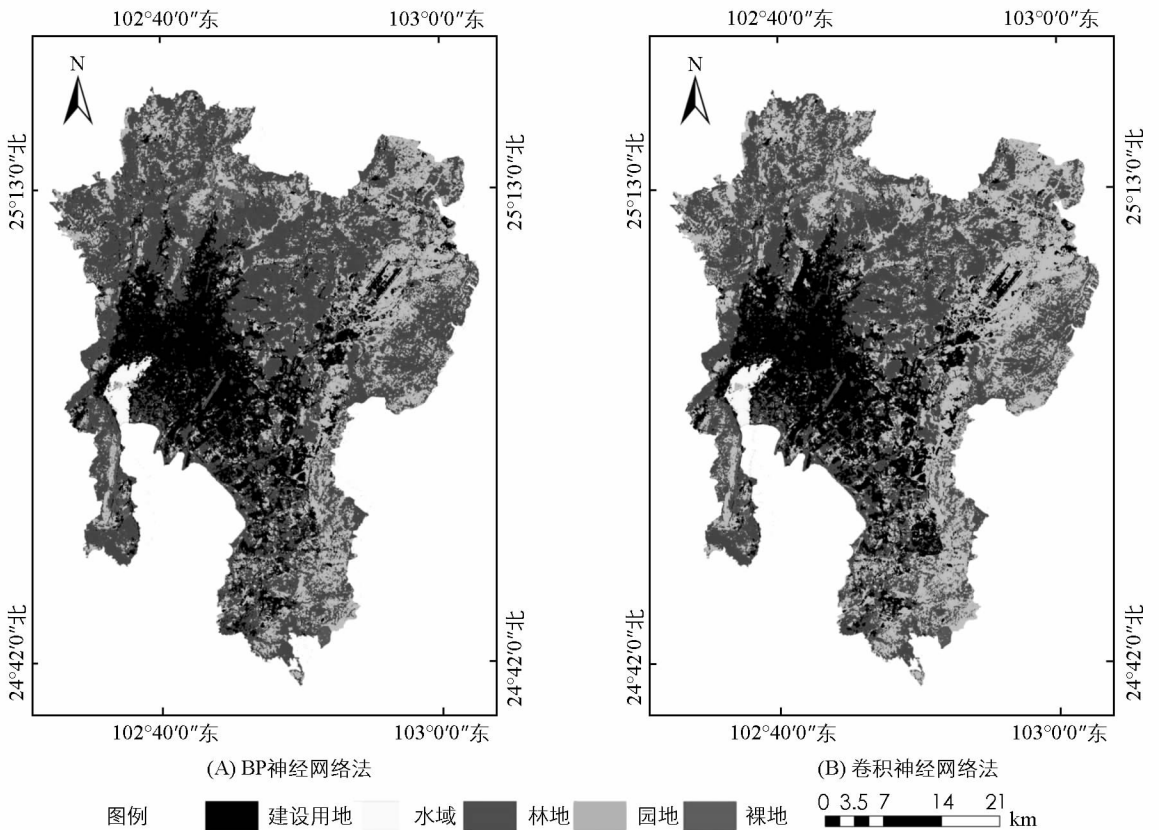


图 5 融合影像的分类结果

表 2 基于 Landsat8 影像的卷积神经网络分类混淆矩阵

分类类别	实际类别					总和	用户精度/%
	建设用地	水域	林地	园地	裸地		
建设用地	702	0	34	72	22	830	84.58
水域	0	196	12	13	3	224	87.50
林地	53	6	512	46	10	627	81.66
园地	79	3	40	398	12	532	74.81
裸地	16	5	22	1	153	197	77.66
合计	850	210	620	530	200		
制图精度/%	82.59	93.33	82.58	75.09	76.50		
总体分类精度=81.369 3% $Kappa$ 系数=0.751 0							

由分类混淆矩阵可知, 对比基于 Sentinel-1A 和 Landsat8 的融合影像和 Landsat8 影像的分类结果, 融合影像采用 BP 神经网络和卷积神经网络作为分类器的总体分类精度分别为 84.315 4% 和 85.809 1%, 其总体分类精度明显高于 Landsat8 影像的 77.302 9% 和 81.369 3%。相对于传统的 BP 神经网络, 卷积神经网络作为分类器的结果在研究区的分类精度有了明显的提高, 实验效果显著。总体分类精度最高的是融合影像应用卷积神经网络的分类结果, 达到了 85.809 1%, $Kappa$ 系数为 0.812 4, $Kappa$ 系数大于 0.8, 一致性检验的结果为完全一致, 分类可信度较高。

表 3 基于融合影像的 BP 神经网络分类混淆矩阵

分类类别	实际类别					总和	用户精度/%
	建设用地	水域	林地	园地	裸地		
建设用地	653	0	14	24	7	698	93.55
水域	0	204	2	6	4	216	94.44
林地	52	2	581	46	3	684	84.94
园地	71	0	12	411	3	497	82.70
裸地	74	4	11	43	183	315	58.10
合计	850	210	620	530	200		
制图精度/%	76.82	97.14	93.71	77.55	91.50		
总体分类精度=84.315 4% $Kappa$ 系数=0.793 8							

表 4 基于融合影像的卷积神经网络分类混淆矩阵

分类类别	实际类别					总和	用户精度/%
	建设用地	水域	林地	园地	裸地		
建设用地	682	0	21	19	14	736	92.66
水域	0	203	9	3	2	217	93.55
林地	63	1	573	46	6	689	83.16
园地	49	1	9	432	0	491	87.98
裸地	56	5	8	30	178	277	64.26
合计	850	210	620	530	200		
制图精度/%	80.24	96.67	92.42	81.51	89.00		
总体分类精度=85.809 1% $Kappa$ 系数=0.812 4							

对比分类混淆矩阵可以得到实验中各个地类的提取效果。建设用地的提取方面, 使用卷积神经网络的结果要优于使用 BP 神经网络的结果, 融合影像的提取效果最好; 水体提取的几个案例普遍较好, 效果最好的是 BP 神经网络提取的融合影像; 林地提取方面, 融合影像的精度大大高于 Landsat8 影像, 精度最高的是应用 BP 神经网络的融合影像; 而在园地的提取方面, 卷积神经网络提取的融合影像精度最高, 剩余的 3 个样本结果相近; 最后在裸地的提取上, Landsat8 影像的精度较差, 使用 2 种分类器的融合影像均有较好的提取效果。

5 结 语

本研究以昆明市主城区为例, 对该区域的影像数据使用机器学习方法进行城市土地利用分类提取。研

究对比了 BP 神经网络和卷积神经网络 2 种机器学习算法的分类精度,以 Landsat8 和 Sentinel-1A 影像数据作为数据源,使用 GS 变化法进行影像融合,探究了 Landsat8 和 Sentinel-1A 融合影像下使用不同的深度学习算法的土地利用分类效果。

研究表明,基于 Landsat8 和 Sentinel-1A 的融合影像的卷积神经网络分类算法具有最好的分类效果,其总体分类精度和 $Kappa$ 系数分别为 85.809 1% 及 0.812 4,一致性检验的结果为完全一致,获取的土地利用分类信息精度最高;其次为基于 Landsat8 和 Sentinel-1A 的融合影像的 BP 神经网络分类算法;然后是基于 Landsat8 影像的卷积神经网络分类算法,而分类精度最低的是基于 Landsat8 影像的 BP 神经网络分类算法。因此在研究区范围内,相较于 Landsat8 的多光谱影像数据,基于 Landsat8 和 Sentinel-1A 的融合影像在城市土地利用分类上更具有优势;卷积神经网络比 BP 神经网络算法具有更好的提取效果。本研究为以昆明市主城区为例的中国西南高原地区城市的土地利用分类提取研究提供了参考。但本研究存在以下不足:

1) 建设用地和园地的提取精度不高的原因可能是,在引入了 SAR 影像数据后,对 SAR 影像的极化特征未深入考虑,融合后的图像存在混合像元异物同谱现象,未来仍需要对影像融合和分类方法做进一步的改进。

2) 本研究使用的深度卷积神经网络和 BP 神经网络 2 种分类器进行的监督分类,在样本选取的过程中采取的是结合已有的资料和野外调研数据的人工选取办法,虽然精度高但较为繁琐。未来可以在样本的自动选取上展开研究,提高提取工作的简便性、适用性,尤其是在结合现有的机器学习方法方面,仍有广阔的研究空间。

参考文献:

- [1] TOWNSHEND J, MASEK J, HUANG C Q, et al. Global Characterization and Monitoring of Forest Cover Using Landsat Data: Opportunities and Challenges [J]. International Journal of Digital Earth, 2012, 5(5): 373-397.
- [2] 杜国明, 匡文慧, 孟凡浩, 等. 巴西土地利用/覆盖变化时空格局及驱动因素 [J]. 地理科学进展, 2015, 34(1): 73-82.
- [3] 彭立, 杨武年, 黄瑾. 川西高原多时相干涉雷达土地覆盖分类研究 [J]. 西南大学学报(自然科学版), 2016, 38(5): 125-132.
- [4] CHEN Y, SU W, LI J, et al. Hierarchical Object Oriented Classification Using Very High Resolution Imagery and LiDAR Data over Urban Areas [J]. Advances in Space Research, 2009, 43(7): 1101-1110.
- [5] 杨朝斌, 张树文, 卜坤, 等. 高分辨率遥感影像在城市 LUCC 中的应用 [J]. 中国科学院大学学报, 2016, 33(3): 289-297.
- [6] 蒋楠, 李卫国, 杜培军. 不同遥感数据融合方法在南方水稻面积监测中的应用研究 [J]. 西南大学学报(自然科学版), 2012, 34(6): 18-24.
- [7] 李章成, 李源洪, 周华茂. 基于 ALOS_PALSAR 双极化雷达影像遥感监测水稻的研究: 以德阳地区为例 [J]. 西南师范大学学报(自然科学版), 2012, 37(6): 62-67.
- [8] 赵有松, 李京伟, 陈军. 基于 ETM+ 制作土地利用覆盖图——以制作北京 1:5 万土地利用覆盖图为例 [J]. 测绘科学, 2001, 26(3): 3, 39-42.
- [9] 翟天林, 金贵, 邓祥征, 等. 基于多源遥感影像融合的武汉市土地利用分类方法研究 [J]. 长江流域资源与环境, 2016, 25(10): 1594-1602.
- [10] 吴健生, 潘况一, 彭建, 等. 基于 QUEST 决策树的遥感影像土地利用分类——以云南省丽江市为例 [J]. 地理研究, 2012, 31(11): 1973-1980.
- [11] 冯丽英. 基于深度学习技术的高分辨率遥感影像建设用地信息提取研究 [D]: 杭州: 浙江大学, 2017.
- [12] 秦高峰. 基于机器学习的多光谱遥感影像分类及城市扩展研究 [D]: 重庆: 重庆大学, 2012.
- [13] 曹兆伟, 林宁, 徐文斌, 等. 基于 BP 神经网络的东屿岛遥感影像分类 [J]. 海洋通报, 2016, 35(5): 587-593.
- [14] POWELL R L, ROBERTS D A, DENNISON P E, et al. Sub-pixel Mapping of Urban Land Cover Using Multiple End-member Spectral Mixture Analysis: Manaus, Brazil [J]. Remote Sensing of Environment, 2007, 106(2): 253-267.
- [15] MAAD R, HJERTAKER B T, JOHANSEN G A. Semi-empirical Scatter Correction Model for High-speed Gamma-ray

- Tomography [J]. *Measurement Science and Technology*, 2008, 19(9): 094016.
- [16] DU Q, FOWLER J E, ZHU W. On the Impact of Atmospheric Correction on Lossy Compression of Multispectral and Hyperspectral Imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(1): 130–132.
- [17] 张治清, 何宗. GEOEYE-1 多光谱与全色影像融合的适应性及质量评价研究 [J]. *西南师范大学学报(自然科学版)*, 2011, 36(1): 203–208.
- [18] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络 [J]. *自动化学报*, 2016, 42(9): 1300–1312.
- [19] KARIMI D, AKBARIZADEH G, KANGZAN K, et al. Effective Supervised Multiple-feature Learning for Fused Radar and Optical Data Classification [J]. *Iet Radar Sonar and Navigation*, 2017, 11(5): 768–777.
- [20] 王巍, 郑新奇, 原智远, 等. 邻域规则下的遥感图像分类后处理方法研究 [J]. *测绘通报*, 2015(S2): 17–21.

On Land Use Classification by Means of Machine Learning Based on Multi-source Remote Sensing Image Fusion

CHEN Lei-shi, ZHAO Jun-san, LI Yi, ZHU Qi-fu, XU Ke

Faculty of Land and Resource Engineering, Kunming University of Science and Technology, Kunming 650093, China

Abstract: In order to obtain accurate urban land use information quickly and improve the precision of land use classification information in high altitude areas by remote sensing image, the study deals with the exploration of the application of a rapidly developing technology, machine learning, in such fields. The main urban area of Kunming City was chosen as the case area in the research, taking Landsat8 and Sentinel-1A remote sensing image as the original data. Then the convolution neural network and BP neural network was used to extract the land use classification information of the remote sensing images before and after the fusion. After that the classification results were analyzed. Finally the results show that the classification method of convolutional neural network classification based on fused image data of Land sat 8 and Sentinel-1A had the best classification results, those overall classification accuracy and the Kappa coefficient reached 85.8091% and 0.8124. Therefore the classification method of convolutional neural network based on multi-source remote sensing image fusion is feasible to obtain accurate urban land use classification information, which provides a reference for the research of land use classification in urban areas of high altitude.

Key words: machine learning; urban land use classification; image fusion; convolution neural network; Landsat8; Sentinel-1A

责任编辑 胡 杨 崔玉洁