



基于循环神经网络的城市级土地利用变化分析

——以湖北省武汉市为例

王惠¹, 李忠涵^{1*}, 卫石印¹, 邵帅¹, 王欣瑶¹, 杨吉祥²

(1. 山东省煤田地质局第一勘探队, 山东 青岛 266000; 2. 山东睿航产业投资有限公司, 山东 日照 276800)

摘要: 土地利用变化体现了城市空间结构的演变, 反应了城市发展状态。为探究武汉市土地利用变化的规律, 利用优化后的循环神经网络模型对其 2018 年、2020 年和 2023 年 3 个时间点的遥感影像进行分类, 并结合地类转移矩阵分析了其面积变化和空间变化特征。结果表明, 优化后的循环神经网络在处理城市级大范围的遥感影像数据方面表现出色, 3 个时期的测试精度分别为 93.13%、93.22% 和 91.78%, Kappa 系数均超过 0.85, 分类精度较好; 另外在研究期内, 武汉市水域及水利设施用地主要转出为耕地, 而耕地的主要转出则是城镇及工矿用地, 林地与耕地之间存在面积相似的转入转出关系, 未利用地的转入和转出都是耕地和城镇及工矿用地。研究结果揭示了武汉市 2018—2023 年土地利用变化情况, 也可以为城市的土地管理和规划提供有价值的参考。

关键词: 土地利用; 循环神经网络; 转移矩阵; 湖北省武汉市

中图分类号:F301; P208

文献标识码:A

doi:10.12128/j.issn.1672-6979.2025.11.010

0 引言

土地利用与人类的生产和生活息息相关, 在城市发展巾, 土地利用数据为了解城市化的发展提供了数据基础^[1-2], 进而支撑土地资源管理、资源环境监测、国土空间规划和可持续发展等领域的研究工作。

遥感技术经过几十年的发展已经成为获取土地利用类型的重要手段之一, 通过不同传感器的不同空间、时间和光谱分辨率的遥感影像, 利用科学化的分类方法可以有效的提取影像范围内的土地利用类型^[3-4]。近些年, 随着深度学习技术的不断发展, 基于神经网络模型的遥感影像分类方法得到了更多新的探索, Mou 等提出一种新颖的循环神经网络(Recurrent Neural Network, RNN)模型, 首次将 RNN 用于高光谱图像的土地利用分类中, 将高光谱像素作为顺序数据进行分析, 然后通过深度神经网络的学习来确定像素的类别^[5]; 在农业遥感图像分类领域, CAI 等利用 Landsat 系列影像, 将深度神经网络

(Deep Neural Networks, DNN) 应用到时间序列遥感图像建立了作物分类模型, 将时间序列图像按时间步长进行巧妙划分, 然后将不同时间点的光谱值作为 DNN 模型的输入信息, 使其可以充分利用时间序列信息和 DNN 模型的特征^[6]; 此外, 国内学者在该领域也同样做出了研究贡献, 如向煜等提出基于空洞卷积、FRN 数据归一化和 ELU 激活函数的改进 Unet 网络进行建筑物分割, 实现提高预测模块的准确率^[7]。

本文研究是基于前人的研究成果, 以湖北省武汉市为研究区, 将改进后的循环神经网络算法应用到土地利用分类中, 对中分辨率遥感影像对象进行深度特征提取, 丰富其特征表达, 最终实现城市级遥感影像的高精度土地利用分类。同时, 选取 2018 年、2020 年和 2023 年三期影像作为信息数据源, 计算研究区地类转移变化情况, 以期反应武汉市土地资源利用变化的客观现实, 为土地的利用和管理提供参考依据(表 1)。

收稿日期: 2025-04-27; 修订日期: 2025-06-04; 编辑: 陶卫卫

作者简介: 王惠(1987—), 女, 山东青岛人, 工程师, 主要从事地质工程、工程测量、地理信息应用相关工作; E-mail: 345230694@qq.com

*通信作者: 李忠涵(1994—), 女, 山东青岛人, 工程师, 主要从事地质工程、工程测量、地理信息应用相关工作; E-mail: 87981435@qq.com

表 1 研究区三期影像数据信息表

年份	数据标识	条带号	行编号	日期	云量
2018 年	LC81220392018107LGN00	122	39	2018-04-17	0.72%
	LC81230382018098LGN00	123	38	2018-04-08	1.88%
	LC81230392018098LGN00	123	39	2018-04-08	8.94%
2020 年	LC08_L2SP_122039_20200828_20200906_02_T1	122	39	2020-08-28	1.78%
	LC08_L2SP_123038_20201022_20201105_02_T1	123	38	2020-10-22	0.17%
	LC08_L2SP_123039_20200803_20200914_02_T1	123	39	2020-08-03	1.98%
2023 年	LC09_L2SP_122039_20230407_20230409_02_T1	122	39	2023-04-07	2.19%
	LC09_L2SP_123038_20230430_20230502_02_T1	123	38	2023-04-30	0.95%
	LC09_L2SP_123039_20230313_20230315_02_T1	123	39	2023-03-13	0.03%

1 研究区概况

武汉市是湖北省省会,地貌属于鄂东南丘陵经江汉平原东缘向大别山南麓低山丘过渡地区,中间低平,南北丘陵、岗垄环抱,北部低山林立,行政区位具体如图 1 所示。另外,武汉市在水文特征方面具有江河纵横、湖港交织的特点,长江、汉水交汇于市境中央,且接纳南北支流入汇,众多大小湖泊镶嵌在大江两侧,形成湖沼水网。

2 数据来源及方法

2.1 遥感影像数据

本研究采用 2018 年、2020 年、2023 年的三期 Landsat - 8/Landsat - 9 影像作为基础源数据(图 1),其来源于中国科学院计算机网络信息中心的地理空间数据云平台。另外,由于研究区武汉市跨越多景影像,故选用日期相近的三幅数据进行拼合,再依据研究区范围进行裁剪。

2.2 改进后的循环神经网络分类方法

为建立影像像元与实际地类之间的对应关系,需对像元的光谱特征进行对比、训练和测试处理,建立起影像像元与地类类型的一对一关系,进而实现影像分类的目的^[8-9]。因此,如何对像元光谱特征进行处理实现像元与地类的转化是遥感影像土地利用分类研究中的一个非常关键的问题。

神经网络作为一个能拟合任意函数的黑盒子,只要输入足够的训练数据,设定原始标签,便能根据标签与原数据之间的特征关系得到其他待预测数据的分析结果,故其在遥感影像分类中应用广泛^[10-12]。但是,常见的神经网络只能逐个对输入进

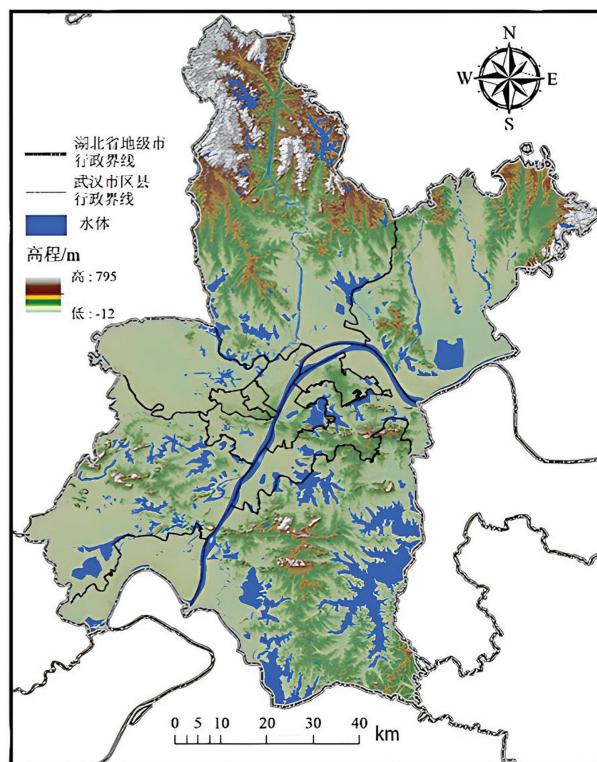


图 1 武汉市地势分布示意图

行处理,前一个输入和后一个输入完全没有关系,为解决这类问题,循环神经网络(Recurrent Neural Network, RNN)被提出。循环神经网络作为一类以序列数据为输入,在序列的演进方向进行递归并且所有节点(循环的单元)按链式连接的递归神经网络,在处理序列数据有效挖掘数据中的有用信息上引起了极大的关注^[13],其网络结构如图 2 所示。根据图 2 结构,可以看出其由一个输入层、一个隐藏层、一个输出层和一个延迟器组成,循环神经网络利用循环过程来获取特征因子之间的相关性和顺序的可变性,其中的网络参数可以通过训练已知的样本来确定,因此循环神经网络也可以被用来处理简单

的图像分类问题^[14-16]。

然而在常见的循环神经网络中,输入层只考虑了待预测数据前面的数据,即只考虑了上下文关系中的“上文”,而没有考虑作为“下文”的内容,只是一个单通道的过程。因此,本文引入双向循环神经网络(Bidirectional Recurrent Neural Network, Bi-RNN),其假设最终的输出不仅仅与正向的序列有关,并且还与反向的序列有关^[17]。通过 2 个循环神经网络上下叠加在一起组成,最终输出是由这 2 个神经隐藏层的状态共同决定,可以有效的解决影像

特征因子之间的顺序先后问题。图 3 所示为双向循环神经网络的基础结构图,由一个输入层 A、一个输出层 B 和 2 个隐藏层 h 组成,在同一节点中有正序和逆序 2 个隐藏层状态,最终的输出由 2 个方向上的权重参数共同决定。通过顺序透视图来表示和处理对象的特征因子,而不是将它们作为特征向量来捕获基于固有序列的数据结构,充分利用特征因子的顺序属性,例如特征因子之间的相关性和顺序的可变性。

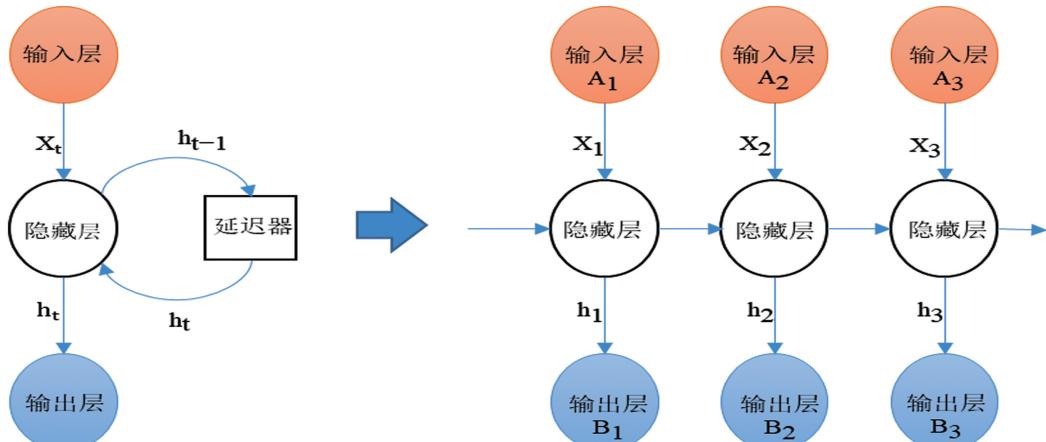


图 2 循环神经网络基础结构示意图

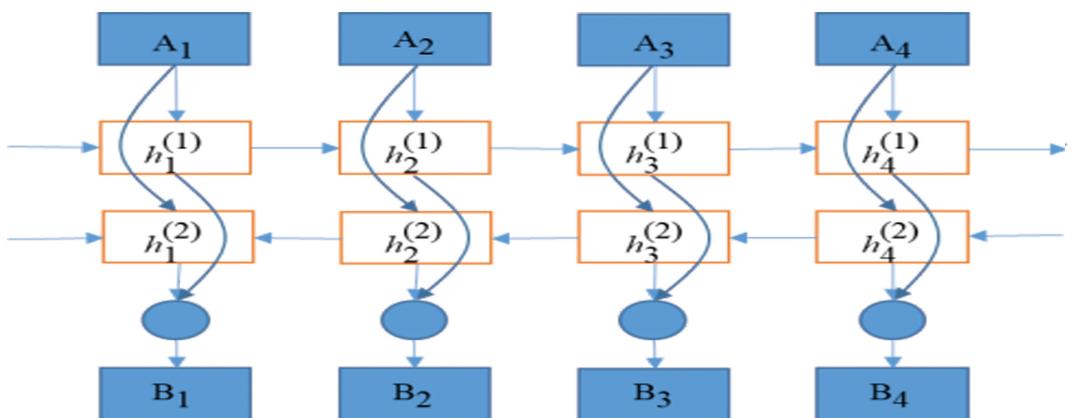


图 3 双向循环神经网络基础结构图

实际上对于标准的循环网络体系结构,可以用到的上下文范围非常有限。主要原因在于循环神经网络的误差梯度在经过多个步骤的反向传播后容易产生极端的非线性行为,包括梯度消失和爆炸增长。为了解决这种问题,长短期记忆网络(Long Short-Term Memory, LSTM)被提出以用来处理长序列

以解决梯度消失问题^[18-20],LSTM 引入了门的概念和存储单元,可以允许循环网络学习更多的步骤,从而可以利用大范围的特征因子上下文。

因此,本研究采用了双向循环神经网络与长短时记忆网络相结合的深度神经网络来实现中分辨率遥感影像的多类型分类问题,充分利用特征因子的

顺序属性，并解决循环神经网络的误差梯度在经过多个步骤反向传播后产生极端的非线性行为。

3 结果与分析

研究区土地利用类型体系的构建，一方面是考虑影像训练样本可获取性，使其具备对比性和代表性；另一方面是结合地类实际情况和国家相关的分类标准，保证分类后的土地利用类型与调查数据具有较好的兼容性和延续性。根据武汉市土地利用状况，并参考资源环境数据云平台的分类方法，按照一级分类标准，将研究区土地划分为城镇及工矿用地、耕地、林地、水域及水利设施用地和未利用地共五大类。

3.1 遥感影像数据信息

为了保证循环神经网络中的梯度具有较快的下降收敛，针对模型输入的特征因子采用标准化的方式进行处理以提高模型的运算效率。在保持各数据量纲统一的前提下，对网络模型的输入数据进行标准化处理，然后再构建分类模型进行后续的训练与测试步骤。

数据标准化的主要思想是将数据按一定的比例进行缩放，使之落入到一个更小的特定区间，标准化处理方法中最典型的是数据归一化处理，通常是将数据统一映射到 $[0, 1]$ 或者 $[-1, 1]$ 的区间上，本研究采用目前最常用的 Z-score 标准化方法对数据进行归一化处理，计算公式如式 1 所示。

$$Y_i = \frac{X_i - \bar{X}}{s}, \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \\ s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2} \quad (1)$$

式中： Y_i 表示归一化处理后的数据； X_i 表示原始数据； \bar{X} 为原始数据平均值； n 为原始数据总数。

3.2 多时相土地利用信息提取

本研究通过对提取的影像特征因子进行标准化处理，并结合随机选择和手动筛选过程明确分类的样本库，每期影像均选取了 3 000 个样本总量，其中测试样本占总体样本的 30%。随后根据循环神经网络的模型架构，构建了本研究的训练模型，通过测试样本的结果精度反馈不断调整训练参数（如：隐藏层单元数量、批次大小、训练轮数等），最终实现 2018 年、2020 年和 2023 年的遥感影像的土地利用

信息提取，具体结果如图 4 所示。与武汉大学的杨杰和黄昕教授发布的土地覆盖数据基本一致^①。

本文采用混淆矩阵对分类结果的精度进行分析，计算三期影像分类的混淆矩阵，结果如图 5 所示。

从混淆矩阵可以获得主要的评价指标包括：生产者精度、用户精度、总体精度以及 Kappa 系数。各个指标具体的含义及计算公式如下：

生产者精度指的是将整个图像正确分类为 M_{ii} 类的对象总数与该地类真实参考的总数的比值，计算公式如式 2 所示。

$$PA = (M_{ii}/M_i) \times 100\% \quad (2)$$

式中： M_{ii} 为正确分类为 M_{ii} 的对象总数； M_i 为该类真实参考的对象总数。用户精度指的是正确分类为 M_{ii} 类的对象总数与被划分为 M_j 类的对象总数的比值，计算公式如式 3 所示。

$$UA = (M_{ii}/M_j) \times 100\% \quad (3)$$

式中： M_{ii} 为正确分类为 M_{ii} 的对象总数； M_j 为被划分为 M_j 类的对象总数。

总体精度指的是被正确分类的对象总数与总参考地类对象总数的比值，计算公式如式 4 所示。

$$OA = (\sum_{i=1}^n M_{ii}/Z) \times 100\% \quad (4)$$

式中： M_{ii} 为被正确分类的对象总数； Z 为总参考地类对象的总数。

Kappa 系数相比上述的评价指标，更能够更加客观的评价分类结果的质量。其计算公式如式 5 所示。

$$Kappa = \frac{\frac{1}{Z} \sum_{i=1}^n M_{ii} - \sum_{i=1}^n \frac{M_i}{Z} \frac{M_j}{Z}}{1 - \sum_{i=1}^n \frac{M_i}{Z} \frac{M_j}{Z}} \quad (5)$$

式中： M_{ii} 为被正确分类的对象总数； M_i 为该类真实参考的对象总数； M_j 为被划分为 M_j 类的对象总数； Z 为总参考地类对象的总数。

^① 本研究使用的土地覆盖对比数据来源于武汉大学的杨杰和黄昕教授发布的 1990—2021 年的年度土地覆盖数据，数据格式为栅格数据。杨杰和黄昕教授使用 335 709 张 Landsat 图像，在谷歌地球引擎(GEE)平台上制作了源自 Landsat 的中国年度土地覆盖数据集 annual land cover(CLDC)。其撰写的《30 m annual land cover and its dynamics in China from 1990 to 2019》的研究论文发表于 Earth System Science Data。该数据包括 9 种用地类型，分别为：耕地、森林、灌木、草原、水域、冰雪、裸地、不透水面、湿地。

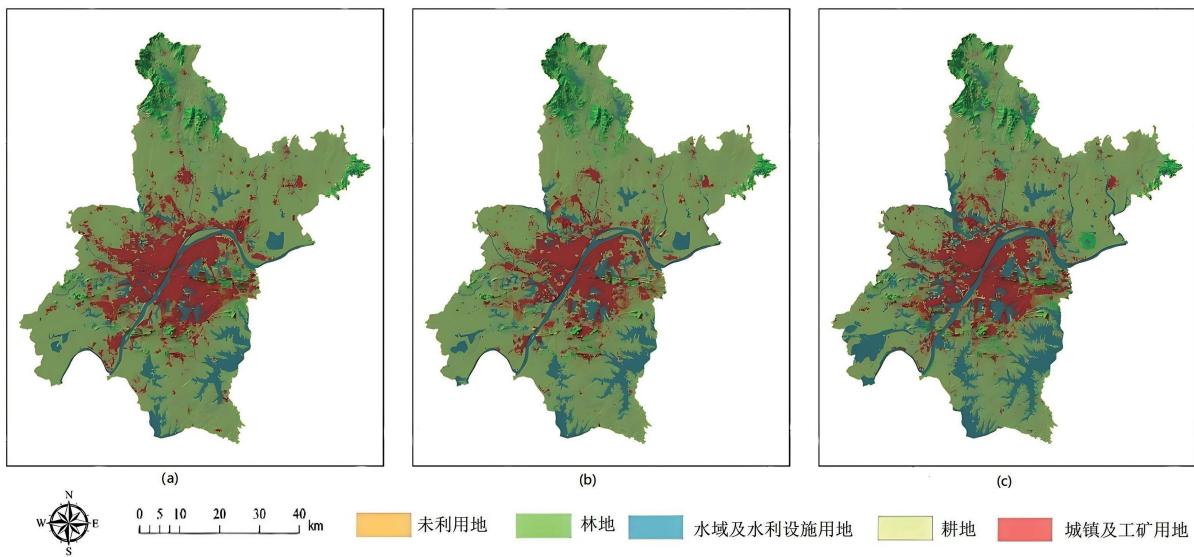


图 4 武汉市三期土地利用类型分布图

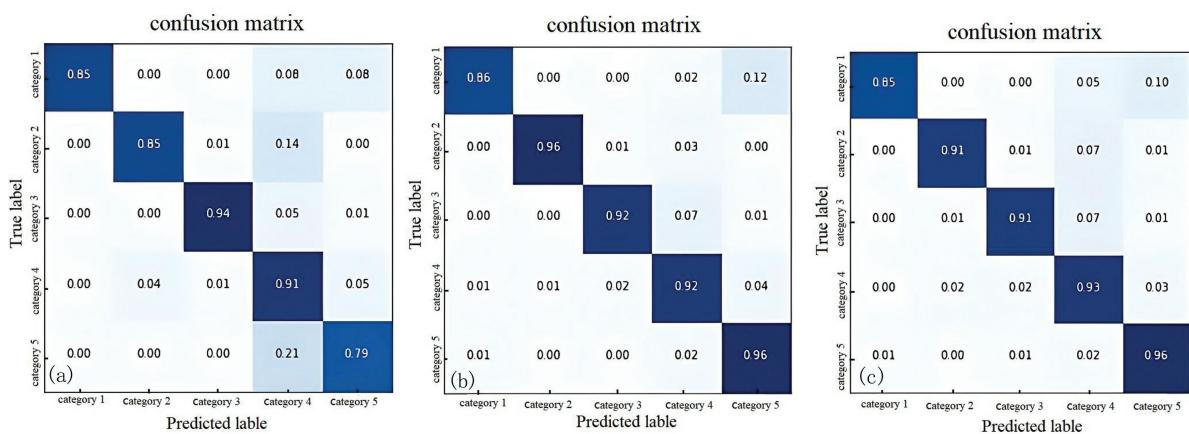


图 5 三期数据的混淆矩阵可视化图

根据生产者精度、用户精度、总体精度以及 $Kappa$ 系数的计算公式, 计算研究区三期的分类精度, 具体如表 2 所示。

表 2 分类精度统计表

年份	训练精度	测试总体精度	$Kappa$ 系数
2018 年	96.76%	93.13%	0.90
2020 年	96.47%	93.22%	0.90
2023 年	93.47%	91.78%	0.85

由表 2 可见, 测试样本的总体精度都达到了 91% 以上, 分类结果可以适用于后续的空间动态变化分析。

3.3 土地利用面积变化特征分析

根据研究区三期的土地利用分类结果, 利用 GIS 的空间分析法将不同时期的分类结果进行空间叠加, 分别计算 2018—2020 年(表 3)以及 2020—2023 年(表 4)的转移矩阵, 分析 2 个变化时间段各地类的变化情况, 从而识别研究区地物的结构特征和各类型之间的转移方向。

其中, 表 3、表 4 首列中, 类别 1 代表未利用地, 类别 2 代表林地, 类别 3 代表水域及水利设施, 类别 4 代表耕地, 类别 5 代表城镇及工矿用地。

表 3 2018—2020 年土地利用类型转移矩阵 单位:km²

	类别 1	类别 2	类别 3	类别 4	类别 5	2018 年
类别 1	32.56	0.97	2.29	41.23	56.63	132.82
类别 2	0.56	398.42	10.19	140.54	5.12	555.05
类别 3	0.54	27.70	966.91	47.30	5.49	1048.07
类别 4	36.93	117.39	467.27	4847.36	298.52	5766.96
类别 5	21.65	7.09	29.91	197.44	825.60	1081.11
2020 年	92.24	550.88	1475.97	5272.94	1191.32	8584.01

表 4 2020—2023 年土地利用类型转移矩阵 单位:km²

	类别 1	类别 2	类别 3	类别 4	类别 5	2020 年
类别 1	26.64	1.07	0.23	20.71	43.58	92.24
类别 2	0.82	405.22	27.67	102.56	15.13	550.88
类别 3	3.27	11.32	814.43	607.10	39.74	1475.97
类别 4	30.34	108.41	22.18	4719.96	392.13	5272.94
类别 5	39.59	5.38	2.87	187.50	956.01	1191.32
2023 年	100.65	531.31	867.52	5637.91	1446.62	8584.01

(1) 2018—2020 年期间武汉市土地利用类型转移。表 3 所示为 2018—2020 年期间武汉市土地利用类型转移矩阵。通过分析转移情况,研究区的土地利用类型变化特点有以下 5 点表现:

① 2018—2020 期间,城镇及工矿用地的主要转出为耕地,转出面积为 197.44 km²,其次为水体和未利用地;主要转入也是耕地,转入面积为 298.52 km²,其次是未利用地,转入面积 56.63 km²。

② 2018—2020 期间,水域及水利设施用地的主要转出为耕地,转出面积为 47.30 km²;主要转入也是耕地,转入面积达到 467.27 km²。

③ 2018—2020 期间,林地主要转出为耕地,转出面积达到 140.54 km²;主要转入也是耕地,转入面积达到 117.39 km²。

④ 2018—2020 期间,耕地的主要转出为水域及水利设施用地、城镇及工矿用地和林地,转出面积分别达到了 467.27 km²、298.52 km² 以及 117.39 km²;主要的转入为城镇及工矿用地和林地,分别为 197.44 km² 和 140.54 km²。

⑤ 2018—2020 期间,未利用地的主要转出为城镇及工矿用地和耕地,转出面积达到了 56.63 km² 和 41.23 km²;主要转入为耕地和城镇及工矿用地,转入面积为 36.93 km² 和 21.65 km²。

(2) 2020—2023 年期间武汉市土地利用类型转移。表 4 所示为 2020—2023 年期间土地利用类型

转移矩阵。通过分析转移情况,研究区的土地利用类型变化特点有以下 5 点表现:

① 2020—2023 期间,城镇及工矿用地的主要转出为耕地,转出面积为 187.50 km²;主要转入也是耕地,转入面积达到了 392.13 km²。

② 2020—2023 期间,水域及水利设施用地的主要转出是耕地,转出面积达到了 607.10 km²。

③ 2020—2023 期间,林地主要转出为耕地,转出面积为 102.56 km²;主要的转入也是耕地,面积达到了 108.41 km²。

④ 2020—2023 期间,耕地的主要转出是城镇及工矿用地和林地,转出面积分别为 392.13 km² 和 108.41 km²;主要转人为水域及水利设施用地、城镇及工矿用地和林地,转入面积从大到小分别是 607.10 km²、187.50 km² 和 102.56 km²。

⑤ 2020—2023 期间,未利用地的主要转出为城镇及工矿用地和耕地,转出面积分别为 43.58 km² 和 20.71 km²;主要的转入也是城镇及工矿用地和耕地,转入面积为 39.59 km² 和 30.34 km²。

3.4 土地利用空间变化特征分析

武汉市作为长江干流上重要港口城市,水域对其工业、商业和物流等各方面都具有重大意义,且为水产养殖、旅游业等提供了丰富的资源。本文在对研究区 2018—2023 年间的土地利用空间变化特征分析时,将着重分析水域和水利设施空间,研究其空间变化以期给区域可持续发展提供参考。通过叠加分析可以得到如图 6 所示的 2018—2020 年、2020—2023 年和 2018—2023 年武汉市水域及水利设施用地变化图。

由图 6 可知,2018—2020 年期间水域及水利设施用地的占地面积呈增加趋势,其空间变化的主要特点是在原有的水体往四周扩散,并且在武汉市的西南部出现大范围的增加,在中部偏东北部有一大块规则的减少区域。2020—2023 年期间水域及水利设施用地的占地面积呈减少趋势,并且集中在武汉市的西南部,在中部偏东北部有一大块规则的增长区域,形状大小与 2018—2020 年减少的规则区域相同。2018—2023 年期间,武汉市的水域及水利设施用地没有出现大范围的增加或者减少,仅在西部及西南部出现了面积减少的区域。

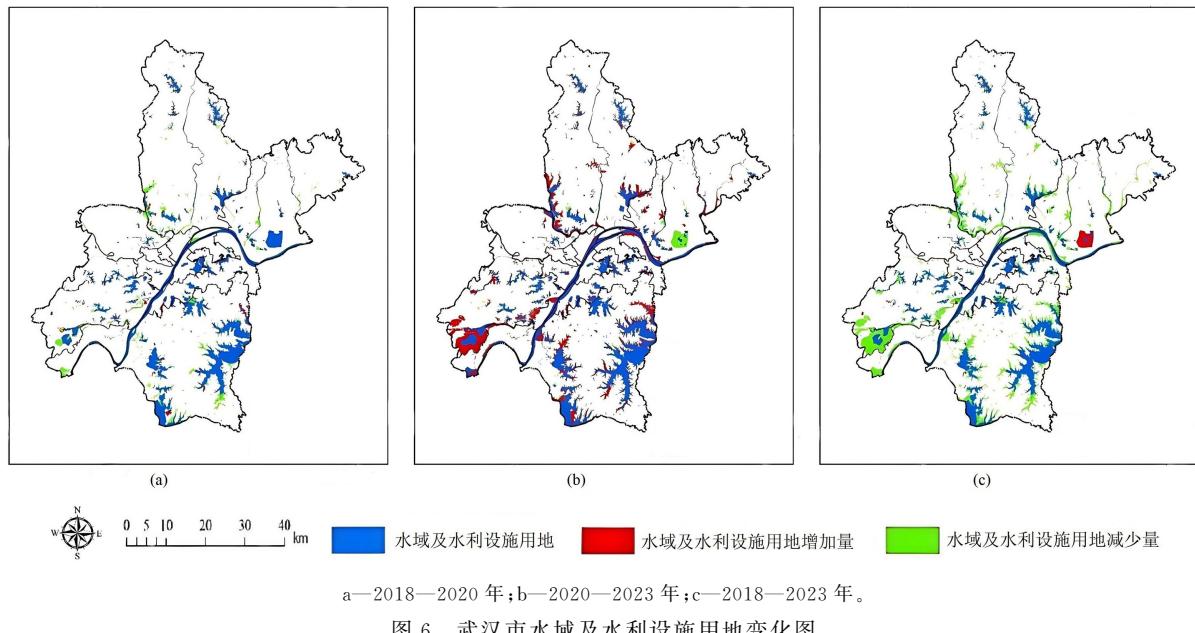


图 6 武汉市水域及水利设施用地变化图

4 结论

本文选取湖北省武汉市作为研究区域,以 2018 年、2020 年、2023 年三期的 Landsat 系列遥感数据作为主要数据来源,应用循环神经网络构建土地利用分类模型,并结合研究区的相关政策资料,对武汉市土地利用演变特征进行深入的研究分析。结果表明:

(1) 基于循环神经网络的遥感影像分类在提取武汉市的土地利用类型时测试精度分别为 93.13%、93.22% 和 91.78%,Kappa 系数分别为 0.90、0.90 和 0.85,精度较高,表明该方法在提取土地利用信息时具有很好的效果,可以为同类遥感影像分类提供思路。但是,在城市边缘区域,由于存在多种土地利用类型的交错分布,如耕地与城镇及工矿用地的过渡地带,以及山区林地与其他地类的边界区域,受到地形复杂、地物光谱特征相似等因素影响,循环神经网络模型在区分这些土地利用类型时可能出现精度下降的情况。

(2) 在研究期间,区域水域及水利设施用地没有出现大范围的增加或者减少,变化范围集中在西部及西南部,如严家山湖附近区域,有面积减少的情况。同时,需注意土地利用变化是一个复杂的动态过程,受到政策、经济、社会等多种因素综合影响,本研究对于经济发展、人口流动等社会经济因素未进行考虑。

(3) 针对本研究的局限性,在分类精度提升上,未来可以进一步优化循环神经网络模型结构,如注意力机制、生成对抗网络等,提高模型对特殊区域和小面积地物的特征识别能力。同时,可以结合多源数据,如高分辨率遥感影像、地形数据等,丰富地物特征信息,从而更精准地进行土地利用分类。

参考文献:

- [1] 彭程,王靖伟,高涛,等.基于迁移学习和 ResNet50 的遥感图像土地覆盖分类[J].山东国土资源,2023,39(10):62-66.
- [2] 刘冰,王靖伟,吴福荣,等.黄河三角洲景观格局变化及生态风险评价[J].山东国土资源,2023,39(5):39-45.
- [3] 陈波,胡玉福,喻攀,等.基于纹理和地形辅助的山区土地利用信息提取研究[J].地理与地理信息科学,2017,33(1):1-7.
- [4] 裴欢,孙天娇,王晓妍.基于 Landsat 8 OLI 影像纹理特征的面向对象土地利用/覆盖分类[J].农业工程学报,2018,34(2):248-255.
- [5] MOU L, GHAMISI P, ZHU X. Deep recurrent neural networks for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7): 3639-3655.
- [6] CAI Y, GUAN K, PENG J, et al. A high-performance and in-season classification system of field-level crop types using time-series Landsat data and a machine learning approach[J]. Remote Sensing of Environment, 2018(210): 35-47.
- [7] 向煜,黄志.一种基于改进的 Unet 网络的遥感影像建筑物分割方法[J].城市勘测,2024(1):109-113.
- [8] 徐楠,解军,冯中萍,等.基于循环神经网络的土地利用变化与驱动力分析:以山东日照为例[J].山东国土资源,2025,41(1):63-70.

- [9] 李军.改进灰色 BP 神经网络模型在建筑物沉降监测中的应用[J].城市勘测,2020(2):173-176.
- [10] 梁勇,赵贺伟,王志强,等.基于遗传算法的空空导弹消耗规律神经网络预测方法[J].海军航空工程学院学报,2019,34(1):151-162.
- [11] 周光海.基于模糊神经网络的输电杆塔变形预测方法[J].城市勘测,2023(2):157-160.
- [12] 张珂,冯晓晗,郭玉荣,等.图像分类的深度卷积神经网络模型综述[J].中国图象图形学报,2021,26(10):2305-2325.
- [13] LU Q, ZHU Z, XU F, et al. Chinese Sentiment Classification Method with Bi-LSTM and Grammar Rules[J]. Data Analysis and Knowledge Discovery, 2019, 3(11): 99-107.
- [14] 刘建伟,宋志妍.循环神经网络研究综述[J].控制与决策,2022,37(11):2753-2768.
- [15] 孔繁锵,余圣杰,王坤,等.卷积循环神经网络的高光谱图像解混方法[J].西安电子科技大学学报,2025,52(1):142-151.
- [16] 程文涛,任冬伟,王旗龙.基于循环神经网络的散焦图像去模糊算法[J].计算机应用研究,2022,39(7):2203-2209.
- [17] 王焜焜,徐行健,孟繁军,等.基于多特征注意力双向循环神经网络的客观题难度预测模型[J].计算机工程,1-10(2025-06-23). <https://doi.org/10.19678/j.issn.1000-0069581>.
- [18] 李明晓,张恒才,仇培元,等.一种基于模糊长短期神经网络的移动对象轨迹预测算法[J].测绘学报,2018,47(12):1660-1669.
- [19] 陈媛媛,赵秉琨,王慧,等.基于 LSTM 模型的时序 InSAR 地表形变预测[J].人民长江,2024,55(3):146-152.
- [20] 徐海龙,乔书波,林家乐.利用长短时记忆网络的日长变化预报[J].测绘科学技术学报,2020,37(5):474-478.

Analysis of Urban Land Use Change Based on Cyclic Neural Network

——Taking Wuhan City in Hubei Province as an Example

WANG Hui¹, LI Zhonghan¹, WEI Shiyin¹, SHAO Shuai¹, WANG Xinyao¹, YANG Jixiang²

(1.No.1 Exploration Brigade of Shandong Coalfield Geologic Bureau, Shandong Qingdao 266000, China; 2. Shandong Ruihang Industrial Investment Limited Corporation, Shandong Rizhao 276800, China)

Abstract: Land use and land cover change reflects the evolution of urban spatial structure and reflects the state of urban development. In order to study the law of land use change in Wuhan city, the optimized recurrent neural network model is used to classify the remote sensing images in 2018, 2020 and 2023. Characteristics of its area change and spatial change have been analyzed in combination with land type transfer matrix. It is showed that the optimized recurrent neural network performs well in processing remote sensing image data. The test accuracy in three periods is 93.13%, 93.22% and 91.78% respectively, and the Kappa coefficients are all over 0.85, so the classification accuracy is good. In addition, during the study period, the water areas and water conservancy facilities in Wuhan city are mainly transferred to cultivated land, while the cultivated land is mainly transferred to towns and industrial and mining land. There is a similar transfer—in relationship between forest land and cultivated land, and the unused land is transferred to cultivated land, towns and industrial and mining land. The research results reveal land use changes in Wuhan city from 2018 to 2023. It can provide valuable references for urban land management and planning.

Key words: Land use; circulating neural network; transfer matrix; Wuhan city in Hubei province