引文格式：骆思莹,颜怀成,宋奇芮,等. 基于全连接神经网络的多源土地利用数据融合方法研究[J]. 地理空间信息, 2026, 24(2):101-104. doi:10.3969/j.issn. 1672-4623.2026.02.021

基于全连接神经网络的多源土地利用数据融合方法研究

骆思莹[1]，颜怀成[2]，宋奇芮[3]，江忆恒[3]，杨　静[3,4]，孙毅中[4]
（1. 江苏省金威测绘服务中心，江苏 南京 210013；2. 江苏省测绘工程院，江苏 南京 210013；
3. 南京邮电大学物联网学院，江苏 南京 210023；4. 南京师范大学地理科学学院，江苏 南京 210023）

摘　要：土地利用数据是信息地理学的基础，对研究人地交互、城市可持续发展等至关重要。尽管现有研究通过遥感影像、解译算法等提升了土地利用类型识别精度，并生成了多种用地数据产品，但这些产品间存在显著空间差异。为此，提出利用全连接神经网络，结合地理环境因子，构建多源用地数据融合整合方法，以提高数据精度。以南京市为研究样区进行验证，结果显示该方法显著提升了分类精度，overall accuracy（OA）和 Kappa 系数分别达到 0.784 和 0.728。该方法及产品可为城市建设规划、资源统筹管理、环境监查保护等提供有力支持，具有重要的研究价值与现实意义。

关键词：全连接神经网络；土地利用数据；地理环境因子；多源数据融合
中图分类号：P237　　**文献标志码：**B　　**文章编号：**1672-4623（2026）02-0101-04

Research on Multi-source Land-use Data Fusion Method Based on Fully Connected Neural Network

LUO Siying[1], YAN Huaicheng[2], SONG Qirui[3], JIANG Yiheng[3], YANG Jing[3,4], SUN Yizhong[4]
(1. Jiangsu Jinwei Surveying and Mapping Service Center, Nanjing 210013, China;
2. Jiangsu Provincial Institute of Surveying and Mapping Engineering, Nanjing 210013, China;
3. School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210023, China;
4. School of Geography Science, Nanjing Normal University, Nanjing 210023, China)

Abstract: Land-use data serve as a fundamental element of geographical information science and are crucial for studying human-environment interactions and urban sustainable development. Although current research has improved the accuracy of land-use classification through remote sensing images and interpretation algorithms, significant spatial discrepancies still exist among the resulting land-use data products. To address this issue, we proposed a multi-source land-use data fusion method based on fully connected neural network (FCNN), incorporating geographical environmental factors to enhance data accuracy. Taking Nanjing City as a case study, the results show that the proposed method significantly improves classification accuracy, achieving an overall accuracy of 0.784 and a Kappa coefficient of 0.728. This method and its derived data products can provide strong support for urban planning, resource management, and environmental monitoring and protection, demonstrating significant research value and practical relevance.

Key words: FCNN, land-use data, geographical environmental factor, multi-source data fusion

目前，基于遥感影像已衍生出多种 LULC 数据产品[1-6]，但由于数据源与解译算法的差异性，导致同一区域不同产品间存在显著的空间一致性差异[7-10]。

针对以上问题[11-14]，本文旨在从地理空间相关性视角出发，结合地理环境因子，构建基于全连接神经网络（fully connected neural network，FCNN）的多源数据融合方法。以南京市为例，训练模型并评价模型的精度。本研究期望进一步提高土地利用数据精度，为地球系统演化研究、土地资源管理和城市规划等领域提供数据支持。

1　研究数据

南京市位于长江下游地区，是沿海经济带的重要交通枢纽。作为江苏省省会及长三角核心城市之一，南京市城市化进程迅速，形成了多样化的自然地理环境和丰富的生态系统。其土地利用模式既体现了大城市发展的共性特征，又保留了独特的自然与人文景观，这为 LULC 分类和融合提供了复杂的场景，可以

项目来源：江苏省科技计划青年基金资助项目（BK20230372、2023-09.BK20230372、2023-09）。
第一作者简介：骆思莹（1991—），本科，工程师，现从事地图学与地理信息系统应用与开发方面的工作，E-mail：1518288361@qq.com。
通信作者：杨静（1992—），博士研究生，副教授，现从事规划 GIS、地理建模、时空大数据等方面研究，E-mail：yangjing92@njupt.edu.cn。

充分体现多源数据融合的优势。

本研究使用了2015年多源土地利用和地理环境因子两类基础数据。多源土地利用数据包括中国土地覆盖数据集（china land cover dataset，CLCD）、全球30 m高分辨率土地覆盖动态监测数据集（global land cover，GLC）和多期土地利用/覆盖变化遥感监测数据集（land use and cover change，LUCC）3个数据。地理环境因子数据主要包括数字高程模型（DEM）、坡度、坡向、距城市距离、距区县中心点距离、距国道距离、距高速公路距离、距铁路距离、夜间灯光强度、地表反射率、平均降水量、归一化植被指数（NDVI）和平均温度等（表1）。

表1 研究数据

数据类型	影响因素	分辨率	数据来源	数据年份
土地利用数据集	CLCD	30 m	https://open.geovisearth.com/service/resource/31	2015
	GLC	30 m	https://data.casearth.cn/sdo/detail/6523adf6819aec0c3a438252	2015
	LUCC	30 m	https://www.resdc.cn/	2015
地理环境因子	DEM	1 km	https://zhuanlan.zhihu.com/p/30702123	2017
	坡度	1 km	作者制作	2017
	坡向	1 km	作者制作	2017
	距城市距离	20 km	作者制作	2017
	距区县中心点距离	20 km	作者制作	2017
	距国道距离	20 km	作者制作	2017
	距高速公路距离	20 km	作者制作	2017
	距铁路距离	20 km	作者制作	2017
	夜间灯光强度	1 km	https://eogdata.mines.edu/products/vnl/	2015
	地表反射率	30 m	https://data.casearth.cn/thematic/RTU_Data/303	2018
	平均降水量	1 km	https://blog.csdn.net/m0_63269495/article/details/135645183	2015
	归一化植被指数（NDVI）	1 km	http://www.gisrs.cn/infofordata?id=05b59e69-ba30-4454-a9c0-67ca038fb9f3	2015
	平均温度	1 km	http://www.gisrs.cn/infofordata?id=3f816a8e-ebea-4484-b9e6-c27761fdb85f	2015

2 研究方法

2.1 研究框架

如图1所示，本研究的实验流程可以分为以下3个部分：①数据获取和预处理。选择CLCD、GLC和LUCC三类LULC数据作为被融合数据，进行用地类型重分类，并分析各类用地的空间相关地理环境因子。为满足深度学习模型对训练样本数量与质量的要求，本文共构建了6 000个以上的目视解译样本点。在样本选取过程中，综合考虑了CLCD、GLC与LUCC三类数据产品在长三角区域内的空间分布特征与类别数量比例，采用比例分层抽样方式进行控制，确保样本在三类数据下均具备较高的匹配度与可比性，从而增强了样本的代表性与泛化能力。每个解译点结合高分辨率遥感影像进行人工判读，确保其标签的准确性，并按照70%训练和30%验证比例构建模型数据集。②多源LULC数据融合方法构建。以训练数据集作为模型输入数据，根据全连接神经网络原理，设定输入层神经元结构，确定隐藏层参数，设计输出层网络结构[15]。通过优化和迭代，确定模型参数最优解，实现数据融合方法的构建。③利用验证数据集，结合*OA*和Kappa系数，分析模型的有效性，并利用提出的模型实现多源LULC数据的融合。

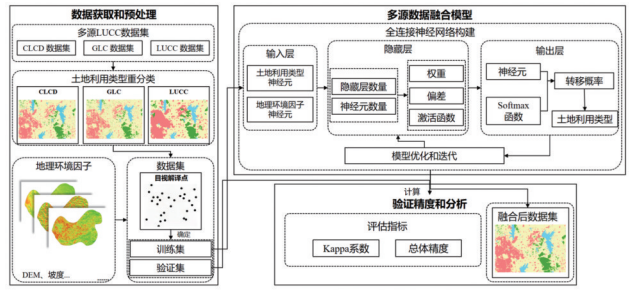


图1 多源LULC数据融合流程图

2.2 地理环境因子确定

本研究选择CLCD、GLC _FCS30D和LUCC这3个常用的LULC数据集进行融合。基于这3个LULC数据集的用地分类标准，确定融合后的新的LULC数据包括耕地、林地、草地、水域、建设用地、裸地、冰川7类用地。

地理环境因子的合理选定是确保多源LULC数据融合精度的关键。研究表明，耕地、林地、草地等自然覆被类型与地形因子（如DEM、坡度、坡向）及气候因子（如平均降水量、平均气温）存在显著的空间耦合关系。归一化植被指数（NDVI）作为表征地表植被覆盖状况的光谱特征指标，是区分上述地类的重要依据。地表反射率已成为学者们监测水域分布状况及其变化的一个核心指标。建设用地的空间分布与人类活动强度密切相关，其布局受到城市、区县中心点距离、国道、高速公路及铁路等交

通网络的影响，其中夜间灯光强度更是直观地反映人类活动密集程度的重要依据。因此，本研究最终确定了13个地理环境因子作为多源LULC数据融合的关键变量，具体包括DEM、坡度、坡向、距城市距离、距区县中心点距离、距国道距离、距高速公路距离、距铁路距离、夜间灯光强度、平均降水量 、平均气温、NDVI以及地表反射率。

2.3　全连接神经网络模型构建

本研究选择全连接神经网络（FCNN）作为数据融合模型，主要基于其良好的非线性拟合能力、高维输入处理能力及结构的可扩展性。

2.3.1　数据预处理

对13个地理环境因子数据进行归一化处理，以减少数据源差异，确保融合标准的一致性，从而优化和提高土地利用数据精度优化的目的。在本研究中，将80%和20%的数据集分别作为模型的训练集和验证集。

2.3.2　输入层

在输入层中，将3个LULC数据源的7类用地和13个地理环境因子分别作为一个神经元，即输入层共包含34个神经元。其中，土地利用类型的输入采用独热编码（One-Hot Encoding）方法，通过为每个用地类别分配一个独立的位，避免了由于顺序产生的误差。

输入层中各个神经元以向量 $\boldsymbol{X}$ 的形式输入：

$$\boldsymbol{X}=\left(x_1,x_2,x_3,\cdots,x_{34}\right) \tag{1}$$

式中，x_1 到 x_7 为采用独热编码后栅格单元内CLCD数据集的用地类型，分别表示耕地、林地、草地、水域、建设用地、裸地、冰川，其数值为二值分布，当栅格单元内CLCD数据集属于某一类用地，其对应的元素值为1，其余元素值为0；x_8 到 x_{14} 、x_{15} 到 x_{21} 则分别为GLC和LUCC数据集中的土地利用类型，元素数值确定与CLCD数据集相似；x_{22} 到 x_{34} 为归一化后的地理环境因子值，代表各因子的影响强度。

2.3.3　隐藏层

在建立全连接神经网络时，隐藏层层数和神经元数量的决定会对网络的精度产生显著影响。对于多分类问题，过深的层数可能会引发过拟合问题，使模型难以收敛。而单一的层数则会增加模型的训练难度。所以，本文选用两层隐藏层。此外，神经元数量的设置则同样也会影响训练的最终精度。本文参考现有研究中提出的检验公式，确定两层隐藏层的神经元数量 N_i 、N_o。

$$N_h=\frac{N_s}{\left(\alpha\times\left(N_i+N_o\right)\right)} \tag{2}$$

式中，N_h 为隐藏层神经元个数；N_s 为训练集的样本数量；α 为可以自取的变量值；N_i 为输入层神经元个数；N_o 为输出层神经元个数。基于以上方法，确定本文2个隐藏层的神经元数量分别为64和32个。

权重和偏置共同决定了隐藏层每个神经元的线性变换，而激活函数则通过引入非线性因素，使得网络能够表达更为复杂的非线性关系，从而有效地学习不同土地利用类型中潜在模式和特征。例如，第 k 层的第 j 个神经元的输出为 y_j^k，则它与前一层的 n 个神经元之间的对应关系为：

$$y_j^k=f\left(\sum_{i=1}^{n}y_i^{k-1}\times w_{ij}^k+b_j^k\right) \tag{3}$$

式中，w_{ij}^k 为第 $k-1$ 层的第 i 个神经元的输出传到第 k 层的第 j 个神经元时所占的权重；b_j^k 为第 k 层第 j 个神经元所代表的偏值；f 为激活函数。

$$\mathrm{ReLU}(y)=\max(0,y) \tag{4}$$

式中，采用ReLU作为激活函数，可以提升梯度下降和反向传播的效率，有效避免梯度爆炸和梯度消失的问题。

2.3.4　输出层

在神经网络中，输出层由7个神经元组成，本研究选择适用于多分类任务的Softmax方法，计算每个神经元的输出值，结果以向量 $\boldsymbol{Y}$ 的形式输出：

$$\boldsymbol{Y}=\left(y_1,y_2,y_3,\cdots,y_7\right) \tag{5}$$

式中，y_1 到 y_7 为7类用地类型的预测概率值，最终选取概率值最大的用地类型定义为模型的预测结果。

2.3.5　模型优化与迭代

在深度学习中，损失函数和优化器是关键组件。交叉熵损失函数是一种常用的损失函数，能够评估模型预测结果与真实标签之间的差异。在多分类任务中，交叉熵损失函数能够有效地评估分类任务中模型的准确性，从而常常被用于优化模型参数。Adam（自适应矩估计）优化器通过结合一阶矩估计（梯度的均值）和二阶矩估计（梯度的方差）来动态调整每个参数的学习率，为不同的梯度赋予不同的权重，使神经网络在学习率稳定的情况下能够快速且稳定地收敛到最优解。因此，本文选择这两者作为全连接神经网络的组成部分。

2.4　精度评估

本文选取kappa系数和总体精度 OA 作为评判模型精度的指标。Kappa系数常用于衡量分类的效果，能

有效展示检验的一致性：

$$\text{Kappa}=\frac{p_o-p_e}{1-p_e} \tag{6}$$

式中，p_o 为预测结果与真实结果一致的像元所占比例，即实际精度；p_e 为在随机分类情况下，预测结果与真实结果一致的理论概率，通常由各类别的真实值比例与预测值比例相乘再求和得出。两者均以研究区内像元总数为标准化基数。总体精度 *OA* 指分类正确的样本个数占所有样本个数的比例，是表示精度的重要参数：

$$OA=\frac{\text{True}}{\text{All}} \tag{7}$$

式中，True 为预测结果和真实结果一致的像元数量；All 为研究区内经过目视解译的总样本量。

3 研究结果

3.1 多源LULC数据的融合

基于全连接神经网络的多源数据融合方法，本文生成了 2015 年南京市的土地利用类型产品（图 2）。融合的数据产品表明，2015 年南京市土地利用类型以建设用地、水体、耕地、林地为主，其中耕地占比最高；从空间上来看，中部沿江地区主要为建设用地类型，南北地区则多由耕地和林地构成，呈现出特殊的土地利用空间分布格局。

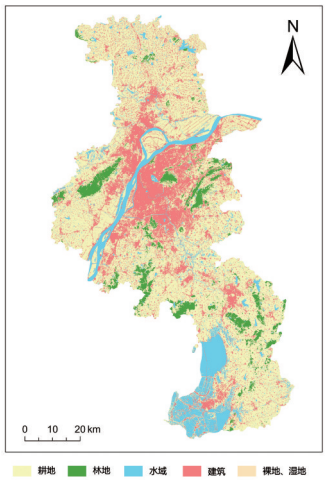


图2 多源用地数据的融合结果

审图号：GS(2024)0650

3.2 产品精度的对比与分析

由于草地、裸地和冰川地物类型在南京地区分布极少，所以暂不计入考虑范围中。基于 6 250 个南京市目视解译样本点验证结果显示，本文产品的总体精度 *OA* 系数约达 78.4%，Kappa 系数为 0.7。其中耕地土地利用类型的 *OA* 系数最高，达到 84%；林地、水体次之，约达 69%；建设用地略低，精度约为 63%。与此同时，耕地的 Kappa 系数同样最高，能够达到 84.7%，说明本模型对于耕地的评估准确率较高；林地、水体略次之，Kappa 值达到 65%左右；建设用地略低，约为 59%。

为了更好地反映本文产品的质量，将其与 CLCD、GLC、LUCC 的分类结果分别进行比较。就总体 *OA* 系数而言，本产品的精度能够达到 78.4%，相较于 CLDC（72.6%）、GLC（60.2%）、LUCC（64.9%）有明显的提高。从各土地利用类型来看，仅有耕地的 *OA* 略低于 CLCD 数据源和林地 *OA* 略低于 CLCD、LUCC 数据源，水域、建设用地的 *OA* 则显著高于其他三套产品。就 Kappa 系数而言，本文产品均最高。

4 结 语

本研究提出结合空间相关性的多源数据融合策略，在有效吸收各类遥感数据优点的同时，提升了模型对不同地类的区分能力，分类精度在多数地物类型上实现了不同程度的提升。结果表明，通过引入地理环境因子与多源遥感信息的协同建模，可在一定程度上弥补单一数据产品的局限性。考虑到建设用地的动态变化对国土监测具有重要意义，未来研究可进一步聚焦该类地物的时序演变规律与模型误差来源机制的分析。

参考文献

[1] 闾国年,袁林旺,陈旻,等. 信息地理学学科发展的思考[J]. 地球信息科学学报,2024,26(4):767-778

[2] 杨冰. 基于不同分类方法土地利用/覆盖分类精度分析[D]. 呼和浩特:内蒙古农业大学,2008

[3] 张雁. 基于机器学习的遥感图像分类研究[D]. 北京:北京林业大学,2015

[4] 简剑锋,李新涛,王任享,周利华,尹忠海. 一种遥感影像云层遮挡消除方法[J]. 光子学报,2009,(11):3044-3048

[5] Mukai S. Atmospheric Correction of Remote Sensing Images of the Ocean Based on Multiple Scattering Calculations[J]. IEEE Transactions on Geoscience and Remote Sensing,1990,28(4):696-702

[6] 罗娇. 遥感图像产品元数据质量检查软件研制[J]. 城市勘测,2013(4):116-118

[7] 黄伦春,肖玉环,张红英. 基于PCA变换的多元遥感影像融合方法研究[J]. 工程地球物理学报,2014,11(2):266-270

[8] Jaber M M,Ali M H,Abd S,et al. A Machine Learning-based Semantic Pattern Matching Model for Remote Sensing Data Registration[J]. Journal of the Indian Society of Remote

（下转第 140 页）