

# 基于SA-CNN-LSTM的广西土壤速效氮含量预测方法研究

邓 昀<sup>1,2</sup>, 刘 畅<sup>1,2</sup>

(1. 桂林理工大学 计算机科学与工程学院; 2. 广西嵌入式技术与智能系统重点实验室, 广西 桂林 541006)

**摘要:** 速效氮是衡量土壤肥力的重要指标, 使用高光谱技术准确预测其含量对于林业生长至关重要, 但现有光谱一阶微分处理方法缺乏敏感性, 且传统的长短期记忆网络(LSTM)预测精度不高。鉴于此, 提出一种SA-CNN-LSTM混合模型, 并将其与CNN、LSTM和BiLSTM等模型进行对比分析。在广西黄冕和雅长国有林场采集了196个土壤样本, 对原始光谱数据进行了28种对数阶微分(LOG)结合小波变换(WT)的预处理, 并使用卷积神经网络(CNN)和自注意力机制(SA)以加强LSTM的长距离依赖挖掘精度问题。结果表明, 对数阶微分处理优于一阶微分, 在对数阶微分的幂为9时建模精度最高, SA-CNN-LSTM模型在验证集上的R<sup>2</sup>分别比CNN、LSTM和BiLSTM提高了6.79%、7.34%和10.37%, 均方根误差(RMSE)降低了18.60%、19.58%和24.44%。使用对数阶微分对光谱进行预处理和SA-CNN-LSTM建模效果最优, 验证集R<sup>2</sup>为0.889, RMSE为16.572 2, PRD为2.998 7, 实现了对广西林地土壤速效氮含量的精确预测。

**关键词:** 高光谱技术; 卷积神经网络; 长短期记忆网络; 自注意力机制; 深度学习

DOI: 10.11907/rjtk.251096

中图分类号: TP399

文献标识码: A

文章编号: 1672-7800(2026)004-0001-11

扫描二维码阅读全文:



## Research on Prediction Method of Soil Available Nitrogen Content in Guangxi Based on SA-CNN-LSTM

DENG Yun<sup>1,2</sup>, LIU Chang<sup>1,2</sup>

(1. School of Computer Science and Engineering, Guilin University of Technology;  
2. Guangxi Key Laboratory of Embedded Technology and Intelligent Systems, Guilin 541006, China)

**Abstract:** Available nitrogen is an important indicator of soil fertility, and the accurate prediction of its content using hyperspectral technology is crucial to forestry growth. The existing spectral first-order differential processing method lacks sensitivity and the traditional long short-term memory network (LSTM) has low prediction accuracy. Therefore, a SA-CNN-LSTM hybrid model was proposed, and compared with CNN, LSTM and BiLSTM models. In this study, 196 soil samples were collected from Huangmian and Yachang State Forest Farms in Guangxi, and the original spectral data were preprocessed with 28 logarithmic order differentials (LOG) combined with wavelet transform (WT). Convolutional neural network (CNN) and self-attention mechanism (SA) were used to enhance the long-distance dependency mining accuracy of LSTM. The results show that logarithmic order differential processing is better than first order differential, and the modeling accuracy is highest when the power of logarithmic order differential is 9. The R<sup>2</sup> of SA-CNN-LSTM model on the validation set is 6.79%, 7.34% and 10.37% higher than that of CNN, LSTM and BiLSTM, respectively, and the root mean square error (RMSE) is reduced by 18.60%, 19.58% and 24.44%. The effect of using logarithmic order differential to preprocess the spectrum and SA-CNN-LSTM modeling is the best, with a validation set R<sup>2</sup> of 0.889, RMSE of 16.572 2 and PRD of 2.998 7, which achieves accurate prediction of available nitrogen content in forest soil in Guangxi.

**Key Words:** hyperspectral; convolutional neural network; long short-term memory network; self-attention mechanism; deep learning

收稿日期: 2025-03-13

基金项目: 中央引导地方科技发展资金项目(桂科ZY22096012); 国家自然科学基金项目(32360374); 广西自然科学基金项目(桂科AB24010338)

作者简介: 邓昀(1980-), 男, 桂林理工大学计算机科学与工程学院教授、硕士生导师, 研究方向为机器学习与嵌入式、数据分析和深度学习; 刘畅(1999-), 男, 桂林理工大学计算机科学与工程学院硕士研究生, 研究方向为深度学习与数据分析。本文通讯作者: 刘畅。

## 0 引言

土壤速效氮作为衡量土壤肥力的关键指标,对作物生长、健康和品质至关重要,精准掌握其含量对农业林业发展意义重大<sup>[1]</sup>。传统化学分析法虽精确但繁琐、周期长、成本高,无法实时反映养分变化<sup>[2]</sup>。高光谱遥感技术以其多波段、窄波段特点,能够捕捉丰富的土壤光谱信息,因而利用表层土壤光谱信息间接估测土壤速效氮含量具有显著优势<sup>[3]</sup>。它不仅能够快速、实时地获取土壤养分信息,而且操作简便,不需要复杂的样品处理和实验室分析,成本相对较低。高光谱遥感技术还适用于大范围的土壤养分监测,能够提供全面的土壤养分分布信息,有助于更好地了解土壤肥力的空间变异规律,为精准农业和智能林业发展提供有力支持<sup>[4]</sup>。

为了在复杂土壤中测定氮含量,Bremner等<sup>[5]</sup>分析了26种有机土壤的Dumas和Kjeldahl方法,发现测试样品中Dumas方法给出了明显较高的N值。Marco等<sup>[6]</sup>利用可见光和近红外漫反射光谱学,在实验室中推断土壤养分含量,取得良好结果。Asa等<sup>[7]</sup>发现Savitzky-Golay平滑搭配可见近红外(Vis-NIR)反射光谱和中红外(mid-IR)反射光谱是成本效益最高的方式。钟亮等<sup>[8]</sup>通过对比不同神经网络模型建模效果发现,VGGNet-7网络具有极佳的模型估测能力。黄招娣等<sup>[9]</sup>利用LS-SVM-LVs模型对OM和N的预测精度最高,验证了其在NIR区域具有光谱响应的特性。李泽鑫等<sup>[10]</sup>构建基于MODTRAN的大气传输模型,针对黑土有机质含量进行预测,结果表明天基遥感载荷光谱分辨率参数在小于40 nm区间反演性能较好。刘忠妹等<sup>[11]</sup>采用SG平滑或导数变换进行模式优选,获取最佳光谱数据,并发现SVM模型效果更佳。殷彩云等<sup>[12]</sup>建立了土壤全氮含量估测模型,结果显示RF模型预测能力精度更高。曾佳辉等<sup>[13]</sup>结合分数阶微分和异常值识别,提高土壤有机质模型反演精度,实现土壤有机质含量的快速、准确估计。

高光谱数据中包含了从可见光到红外波段的连续光谱信息,地表中的氮在不同的光谱波段下会表现出不同的光学特性。高光谱数据能够准确识别不同类型的黏土矿物,其在光谱特征上存在微小差异,这有助于了解土壤的矿物组成和结构特征。但是,采集到的高光谱数据存在噪声、大气干扰问题,而且原始的高光谱数据共线性太高,不能直接用来建模。因此,使用高光谱土壤数据建模时,需要遵循一系列标准化流程。首先,对采集到的高光数据点进行数学变换以突出光谱的有效特征波段,变换方式有标准正态变换(SNV)、移动平滑(MA)、高斯平滑(SG)、一阶导数(D1)等;其次,使用处理后的高光谱数据进行建模,模型包括偏最小二乘(PLSR)、支持向量回归(SVR)、随机森林

(RFR)等;最后,使用 $R^2$ 、RMSE、RPD等评价指标评估模型效果。

当前研究在探索土壤速效氮的估算时,依赖于上述复杂的机器学习建模流程,这种流程操作繁琐,在处理过程中涉及的高光谱波段关系异常复杂,会导致结果的精确度和效率受到影响。而神经网络的强大特征提取能力可以极大简化光谱预处理流程,卷积神经网络(CNN)在光谱反演中的应用开始逐渐出现,它相比机器学习能够更加高效地处理海量光谱数据<sup>[14]</sup>。深度神经网络中还有一种递归神经网络,例如长短期记忆网络(LSTM)<sup>[15]</sup>。该模型以序列数据为输入,通过在序列的演进方向上进行递归操作,并以链式方式连接所有循环节点以进行计算。由于LSTM具有记忆性和参数共享的特点,在学习序列数据的非线性特征方面具有很大优势。因此,采用LSTM网络有助于提取光谱数据中的长距离依赖关系,从而更深层次地发现每类光谱之间的微小差异。

综上所述,本文提出了一种新的复合深度学习模型,将LSTM网络重新设计以适应光谱数据,与CNN结合并加入自注意力机制,构建一种SA-CNN-LSTM网络模型,实现了土壤速效氮的快速、准确预测。具体研究内容如下:

(1)确定最佳土壤光谱预处理方法。对原始光谱数据进行一阶微分,采用不同的对数阶微分结合小波变换等28组预处理方法进行处理,并且分析不同预处理的光谱数据与速效氮之间的相关性。使用VggNet和ResNet建模,从而确定最佳预处理方法。

(2)建立自注意力机制的CNN-LSTM土壤速效氮含量预测模型。针对现有模型预测精度不高等问题,采用了4种深度学习方法和3种机器学习建模方法进行实验(CNN、LSTM、BiLSTM、PLSR、SVR、RFR和SA-CNN-LSTM),对比不同建模方法的速效氮含量预测精度,证明本文提出的SA-CNN-LSTM能够对土壤速效氮含量进行快速且准确的预测。

## 1 实验方法

对原始土壤光谱数据进行预处理,采用3种数学变换方式,即原始数据(R)、不同对数阶微分变换(LOG)和小波变换(WT),共进行了28组实验。对比分析不同对数阶微分下的光谱曲线吸收特性、波段重叠、光谱波峰波谷大小等,并对不同预处理方式进行相关性分析。

采用7种深度学习方法和3种机器学习建模方法进行实验,分别是VggNet、ResNet、CNN、LSTM、BiLSTM、PLSR、SVR、RFR、CNN-LSTM和SA-CNN-LSTM。对比不同建模方法的速效氮含量预测精度,选出最佳预处理方式和最优建模方法。土壤速效氮实验方法如图1所示。

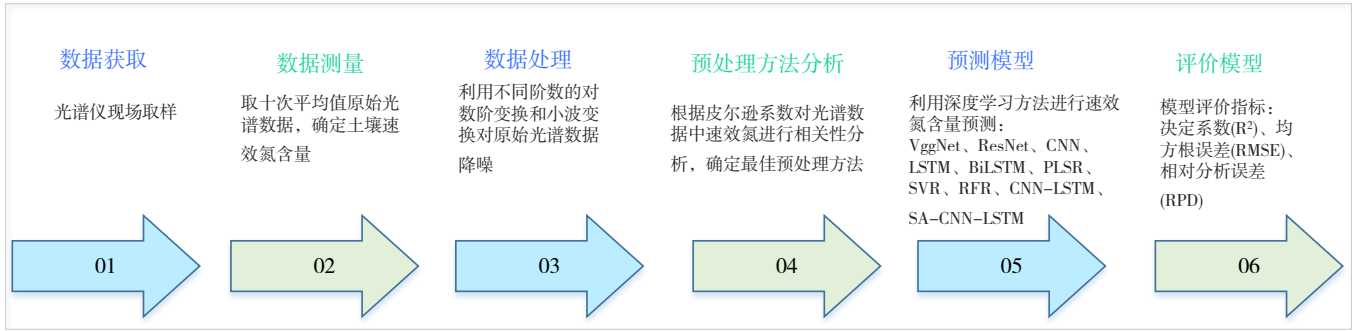


Fig. 1 Soil available nitrogen experimental method

图 1 土壤速效氮实验方法

### 2 SA-CNN-LSTM 模型

为了提高土壤速效氮预测准确性,本文提出了一种融合自注意力机制的 SA-CNN-LSTM 模型。该模型利用自注意力机制优化光谱特征选择,强调关键波段信息。光谱数据通常由多个波段的反射率值构成,不同波段之间可能存在远程依赖关系,某些特定波段的组合对土壤速效氮预测更为重要。传统 CNN-LSTM 模型往往只能依赖卷积或门控机制处理序列数据,而无法有效关注不同波段的重要性。因此,在 CNN 处理之前,首先引入自注意力机制以优化光谱特征表示。

自注意力机制的作用体现在 3 个方面<sup>[16]</sup>。①突出关键光谱波段:数据在进入 CNN-LSTM 之前,自注意力机制可以动态调整不同波段的权重,使模型优先关注对速效氮最相关的波段;②捕捉全局依赖关系:与 CNN 只能提取局部特征不同,自注意力机制可以直接建立远程依赖关系,使不同波段的信息提取更加充分;③降低信息冗余,提高计算效率:相比 LSTM 逐步传递信息的方式,自注意力机制可并行计算多个时间步的特征关系,减少计算成本。

自注意力机制基本架构如图 2 所示。其算法运行流程如下:①输入光谱数据的序列向量  $X$ ,其形状通常是(序列长度、样本数量),通过不同的可学习权重矩阵  $W_q$ 、 $W_k$ 、 $W_v$  进行线性变换,得到查询(Query)、键(Key)和值(Value)向量。通过点积计算查询向量 Query 和键向量 Key 的相似度,得到注意力权重系数矩阵  $a$ ;②使用 Softmax 对注意力权重系数矩阵  $a$  进行归一化,得到注意力权重系数矩阵  $A$ ;③使用注意力权重矩阵  $A$  对值向量 Value 进行加权求和操作,得到注意力数值。

传统的卷积神经网络模型(CNN)通常包含输入层、卷积层、激活函数、最大池化层、全连接层和输出层<sup>[17-19]</sup>。当它处理一维光谱序列数据,可以通过卷积操作捕捉到序列数据中的局部特征,同时保留原始序列的顺序。而当前的 CNN 模型中,全连接层在处理序列数据时只能考虑当前时间步的特征,无法考虑之前的历史信息,这会导致模型训练困难,对于这些问题,长短期记忆网络结构(LSTM)恰好可以解决。长短期记忆网络(LSTM)模型包含 3 个门,分别

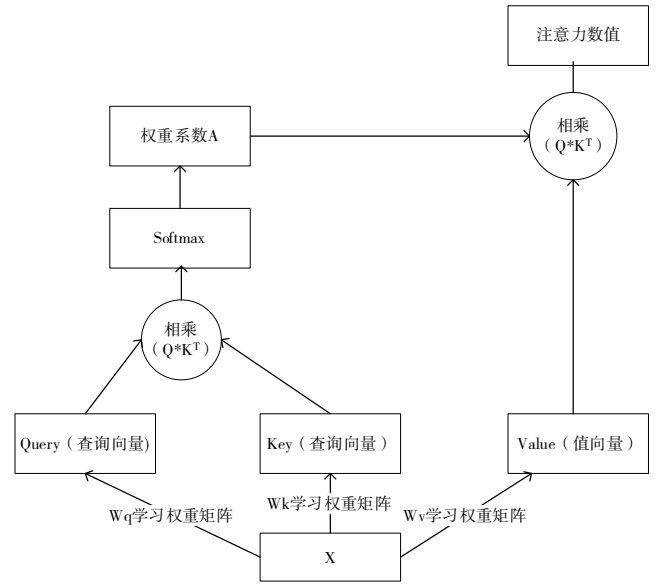


Fig. 2 Self-attention structure

图 2 自注意力结构

是输入门、遗忘门和输出门,网络结构如图 3 所示<sup>[20]</sup>。

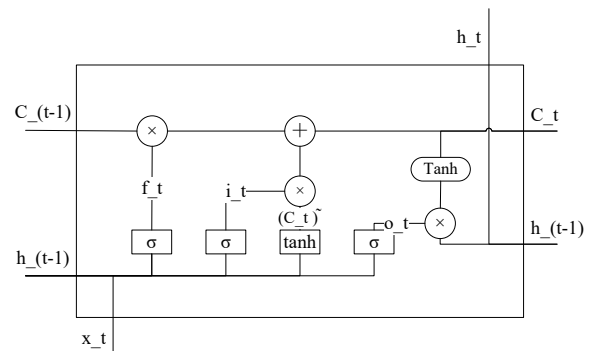


Fig. 3 Long short-term memory network structure

图 3 长短期记忆网络结构

将自注意力、卷积神经网络、长短期记忆网络进行融合,即将自注意力放在 CNN 处理输出后、LSTM 输入前,使光谱数据在输入 LSTM 模型前,CNN 和自注意力可以对原始光谱数据进行充分的特征提取,以增强 LSTM 的处理能力和预测精度。SA-CNN-LSTM 模型结构如图 4 所示,网络层参数如表 1 所示。




Fig. 4 SA-CNN-LSTM network structure

图4 SA-CNN-LSTM网络结构

Table 1 SA-CNN-LSTM network parameters

表1 SA-CNN-LSTM网络参数

层(类型)	输出形状	参数
conv1d	(32, 128)	128
max_pooling1d	(32, 64)	0
conv1d_1	(64, 64)	6 028
max_pooling1d_1	(64, 32)	0
conv1d_2	(128, 32)	24 704
max_pooling1d_2	(128, 16)	0
lstm	64	78 840
lstm_1	64	88 440
self_attention	64	23 100
flatten	1 024	0
dense	200	322 200
dropout	100	0
activation	1	0
dense_1	100	20 100
dropout_1	50	0
dense_2	1	101

### 3 数据收集与处理

#### 3.1 研究区概况

研究区位于广西国有黄冕林场(109°43′-109°58′E, 24°37′-24°52′N)和国有雅长林场(106°08′-106°26′E, 24°37′-25°00′N)<sup>[21]</sup>, 采样点如图5所示, 其地理环境复杂多样, 处于亚热带气候带, 该地受季风影响显著。在本文研究区内, 树木的生长分布状况呈现出均匀态势, 这为采样工作提供了良好条件。为了确保样本的代表性和广泛性, 采用S形取样法, 在0~20 cm的土层深度内, 精心选取了196个土壤样品<sup>[22]</sup>。这些样品的采集点遍布整个研究区, 包括边缘地带, 以确保样本能够充分反映整个区域的土壤特性。

采集到的土壤样本经过自然风干和研磨处理, 被均分为两部分。一部分样本经过0.2 mm筛子的筛选, 采用重铬酸钾氧化加热法以测定其中的速效氮含量<sup>[23]</sup>。这种方法具有高度的准确性和可靠性, 能够提供关于土壤氮素状况的精确数据。另一部分样本则经过0.149 mm筛子的筛选, 使用ASD FieldSpec 4 Hi-Res光谱仪获取高光谱数据, 这台仪器能够在350~2 500 nm的宽光谱范围内进行高精度测量。为了确保数据准确性和稳定性, 对每个样本进行了10次重复采样, 并取平均值作为最终光谱数据。在获取高光谱数据后, 导入Excel进行处理, 处理过程中去除小于

400 nm和大于2 400 nm波段的数据。因为这些波段的数据可能受到多种因素的影响, 如仪器噪声、环境干扰等, 去除这些波段的数据, 以确保后续分析工作更加准确。

本文研究在采样、处理和数据分析等方面都采取了严格的方法和措施, 以确保研究结果的准确性。

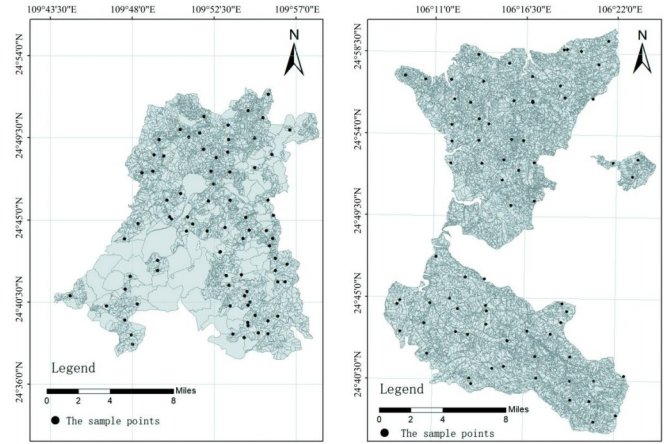


Fig. 5 Soil sampling points

图5 土壤样本采样点

#### 3.2 土壤速效氮含量统计特征

采用SPXY算法划分196个不同速效氮含量的土壤样本数据, 以4:1比例构建训练集与验证集, 确保数据分布均匀且具代表性。157个训练样本用于模型训练, 39个验证样本则用于检验模型预测性能。如表2所示, 研究区域内的196个样本, 其速效氮含量波动范围广泛, 从最低的30.9 g/kg到最高的399.7 g/kg, 平均值稳定在118.11 g/kg, 标准差达到60.37, 显示出51.11%的中等程度变异, 峰度值表示数据分布形态较为陡峭, 偏度值说明数据分布偏斜状况。

Table 2 Statistical characteristics of soil available nitrogen content

表2 土壤速效氮含量统计特征

样本类型	样本量	最小值	最大值	平均值	标准差	峰度	偏度	变异系数
总体样本	196	30.9	399.7	118.11	60.37	4.19	1.60	51.11
训练样本	157	30.9	396.1	117.80	57.70	3.82	1.52	48.98
验证样本	39	46.4	399.7	119.30	69.82	4.23	1.71	58.52

如图6所示, 样本的光谱反射率曲线展现出相似的变化趋势, 在400~1 320 nm波段内, 光谱反射率随波长增加而显著上升, 呈现出非常陡峭的上升趋势; 在1 320~2 100 nm波段内, 光谱反射率趋于稳定, 波动较小; 在2 100~2 400 nm波段内, 光谱反射率则呈现出下降趋势。在900 nm附近, 存在对氧化铁的吸收峰, 其可能是影响光谱反射率的因素。

研究还发现, 速效氮含量与光谱反射率之间存在着密切关联。速效氮含量越高, 光谱反射率往往越小; 反之速效氮含量较低时, 光谱反射率值则相对较大。

#### 3.3 光谱预处理方法

##### 3.3.1 SPXY样本划分算法

SPXY算法优化改进了Kennard-Stone算法, 在处理光




Fig. 6 Soil sample curves of available nitrogen contents

图6 速效氮含量的土壤样本曲线

谱数据中土壤速效氮含量的样板间数据时表现得更科学和实用<sup>[24]</sup>。传统的 Kennard-Stone 算法主要依据空间分布划分样本,而 SPXY 算法则兼顾光谱数据特性与土壤速效氮含量分布。其核心在于距离公式,既考虑空间距离,又融入光谱数据差异与土壤速效氮含量变化。算法通过计算距离矩阵、迭代选取最远样本等策略,选出代表性强、分布均匀的样本子集。SPXY 算法在样本划分上更科学有效,样本选取也更加合理。

### 3.3.2 对数阶微分

研究表明,对得到的原始光谱进行一阶微分变换可以增强光谱差异,减少光谱损失,但缺点是可能会错过最优解<sup>[25]</sup>。因此,为了更精细地增强光谱内部差异,实验采用对数阶微分(LOG)变换对光谱进行处理。对数阶微分计算方法如式(1)所示。

在区间 $[a, b]$ 中, $f(\theta)$ 的 $o$ 阶导数公式如式(1)所示。

$$d^o f(\theta) = \lim_{h \rightarrow 0} \left( \frac{1}{h^o} \right)^{(b-a)/h} \sum_{m=0}^{o-1} (-1)^m \frac{\Gamma(o+1)}{m! \Gamma(o-m-1)} f(\theta - mh) \quad (1)$$

本文取对数阶微分的阶数 $o$ 中对数的幂,以1的间隔从5到20变化,组成以 $\log_{10}(5)$ 到 $\log_{10}(20)$ 变化的对数阶微分。其中, $o=\log_{10}(5)$ 、 $\log_{10}(10)$ 分别表示原始未处理的反射光谱、一阶微分变换处理后的反射光谱。

### 3.4 小波变换降噪

小波变换(WT)降噪是一种利用小波函数对信号进行多尺度分解的降噪方法,它能够有效地提取各频带中的有用信息,从而降低高光谱数据中的噪声干扰<sup>[26]</sup>。本文采用了 Donoho 提出的基于小波变换的阈值降噪方法<sup>[27]</sup>。

### 3.5 评价指标

为了更好地评估 SA-CNN-LSTM 的建模能力,采用3个评价指标评估模型性能。

(1) R<sup>2</sup> (R-squared)。R<sup>2</sup> 是一种回归模型评价指标,用于衡量模型对观测数据方差的解释程度。该指标数值

的范围介于0~1区间,数值越趋近于1,表明模型对数据的拟合程度越高;而数值越趋近于0,则意味着模型拟合效果较差。R<sup>2</sup>值为1时,表示模型完美拟合数据,而值为0时,则表示模型无法解释数据的方差。公式如式(2)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

(2) RMSE (Root Mean Squared Error)。RMSE 用于度量预测模型在连续变量上的预测误差,它计算了观测值和模型预测值之间差异的均方根值。RMSE 越小表示模型对于观测值的预测越准确。公式如式(3)所示。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

(3) PRD (Percentage Relative Difference)。PRD 用于衡量预测值相对于观测值的相对误差,它表示预测值与观测值之间的差异占观测值的百分比。PRD 越小,表示模型预测越接近真实值。公式如式(4)所示。

$$RPD = \frac{SD}{RMSE} \quad (4)$$

## 3.6 实验环境

本文在 Windows 10、NVIDIA GeForce RTX 3060 GPU 和 16 GB 内存环境下,使用 Python 3.10 结合 Tensorflow 2.13.0 设计与实现 VggNet、ResNet、CNN、LSTM、BiLSTM、CNN-LSTM 和 SA-CNN-LSTM 模型,并利用 PyCharm 作为 IDE。

## 4 实验模型训练与分析

### 4.1 数据预处理

数据的变换操作即将原始数据通过合适的算法进行相关处理,使得数据能更好地适应特定模型。合适的变换方法对模型精度有着很大影响,是整个数据分析工作的核心一环,也是保证后续研究工作可靠性的重要基础。

本文采用的数学变换方式是对数阶微分(LOG)结合小波变换(WT)以增强相关光谱参数与土壤指标的相关性。图7(b)-(n)为不同LOG的幂在区间3到15阶,间隔为1的光谱反射率图。由于图7(a)原始光谱曲线具有吸收特性不明显、波段之间相关重叠、光谱信号弱和波峰波谷不明显以及反射率范围宽等特点,因而通过LOG处理光谱能够更好地捕捉丰富的光谱信息。图7(b)-(d)为LOG<sub>10</sub>(3)阶到LOG<sub>10</sub>(5)阶的光谱数据曲线图,曲线没有出现显著的吸收特征变化。从LOG<sub>10</sub>(5)阶开始,反射率首次出现了负值,且随着阶数的增加,反射率逐渐趋向于0,这均说明随着微分变换阶数的增加,光谱曲线的混合重叠峰和基线漂移问题正在逐渐被消除。从图7(i)可以看出,LOG的幂为10时,大多数光谱反射率逐渐趋向于0,而随着LOG的取得幂值越来越大(图7(j)-(n)),反射率的光谱信息也得到了增强,同时特定的吸收特征也消失了。当

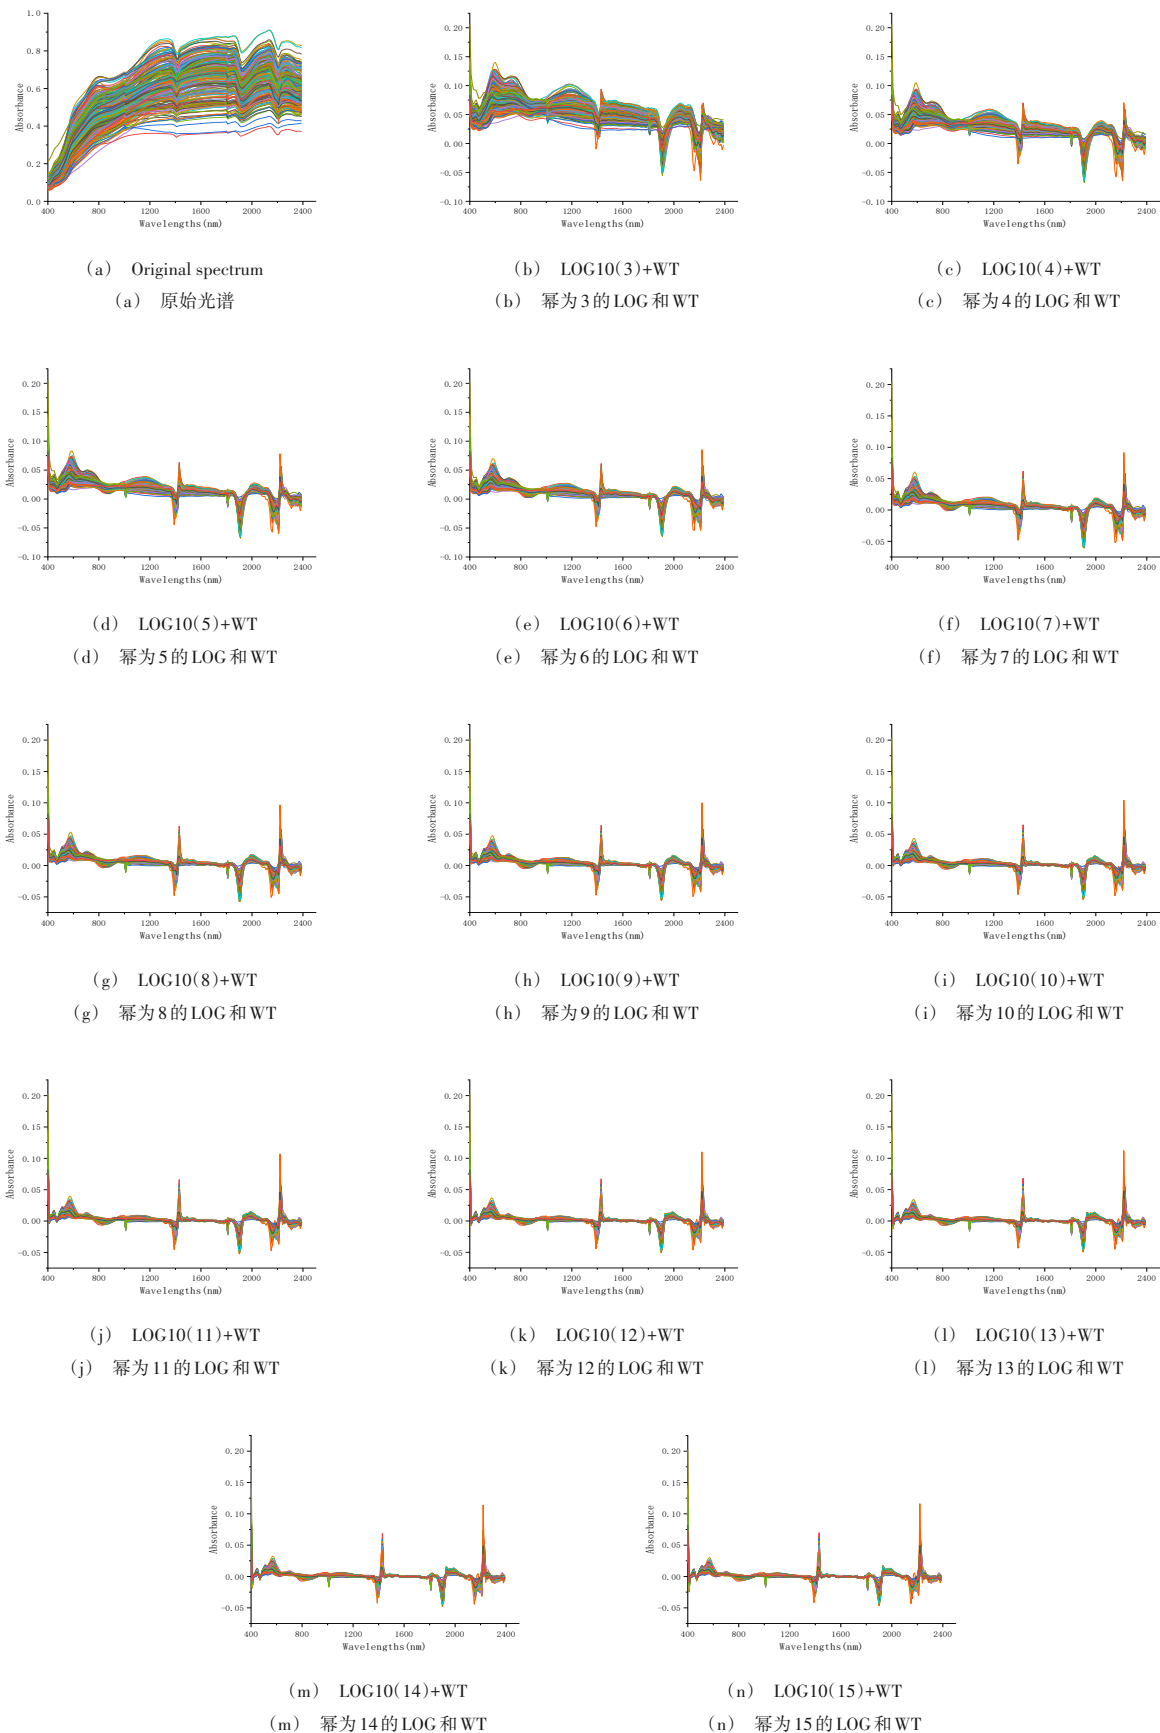


Fig. 7 Data processing results of LOG and WT with different powers

图7 不同幂的LOG和WT的数据处理结果

超过 LOG10(10) 时,光谱的反射率基本趋向于 0,图像的基本信息几乎丢失,曲线相对于 LOG 之前产生了较为明显的上下波动,局部反射率得到了不同程度的放大,出现了多个峰值波段。由此可以发现,对数阶微分变换较一阶微分变换更能捕捉到数据的潜在信息,并提高模型精度。

4.2 基于不同预处理方法的 VggNet 反演分析

基于不同幂的对数阶微分 LOG+WT 的 VggNet 回归建模结果如表 3 所示, R<sup>2</sup> 的范围是 [0.303 1, 0.781 1], RMSE 的范围是 [24.997 6, 52.848 1], RPD 的范围是 [0.808 7, 1.939 4]。从表 3 数据对比可知,基于 LOG10(9)-WT 反射率的 VggNet 模型预测精度最佳,验证集 R<sup>2</sup>、RMSE 和 PRD 分别为 0.781 1, 24.997 6 和 1.933 8。图 8(a)-(d) 为实测值和预测值的散点图, LOG10(9)-WT 的方案最接近 1:1 线,而此时基于 LOG10(10)-WT 的 VggNet 模型的验证集 R<sup>2</sup>、RMSE 和 PRD 分别为 0.689 4, 29.353 5 和 1.849 1。并且,基于 LOG+WT 的 VggNet 模型的验证集效果几乎都比一阶微分的预测精度高。综上所述,在深度学习模型 VggNet 中,对数阶 LOG+WT 算法的拟合效果优于一阶微分+WT。

Table 3 VggNet regression modeling results

表 3 VggNet 回归建模结果

预处理方法	训练结果			测试结果		
	R <sup>2</sup>	RMSE	RPD	R <sup>2</sup>	RMSE	RPD
R	0.690 6	33.128 6	1.408 1	0.303 1	52.848 1	0.808 7
LOG10(10)	0.915 9	17.803 3	3.170 0	0.649 7	32.381 2	1.400 9
LOG10(3)-WT	0.888 1	19.763 8	2.703 6	0.438 0	47.922 9	0.951 3
LOG10(4)-WT	0.906 2	19.255 7	2.921 2	0.708 2	25.356 6	1.833 6
LOG10(5)-WT	0.914 8	18.050 4	3.139 3	0.756 5	36.306 7	1.939 4
LOG10(6)-WT	0.954 5	13.295 5	4.483 6	0.673 1	28.773 9	1.700 7
LOG10(7)-WT	0.913 5	16.671 7	3.091 3	0.452 3	51.537 9	0.843 9
LOG10(8)-WT	0.946 8	14.611 9	4.090 3	0.668 3	26.088 6	1.746 6
LOG10(9)-WT	0.939 2	15.114 7	3.880 6	0.781 1	24.997 6	1.933 8
LOG10(10)-WT	0.933 3	15.690 5	3.705 9	0.689 4	29.353 5	1.849 1
LOG10(11)-WT	0.945 2	14.230 8	3.951 3	0.739 1	28.874 7	1.788 7
LOG10(12)-WT	0.947 2	13.943 6	4.099 6	0.761 6	27.863 1	1.752 8
LOG10(13)-WT	0.921 9	16.991 6	3.356 9	0.655 9	33.098 6	1.446 0
LOG10(14)-WT	0.936 5	15.171 1	3.601 1	0.708 4	30.821 3	1.503 7
LOG10(15)-WT	0.937 5	15.065 7	3.628 1	0.747 4	28.687 8	1.756 3

4.3 基于不同预处理方法的 ResNet 反演分析

基于不同幂的 LOG+WT 的组合预处理方法构建 ResNet 网络模型的建模结果如表 4 所示。可以看出,验证集的决定系数为 0.388 2~0.751 9,均方差误差为 0.247 5~0.345 3,相对分析误差为 1.220 7~2.120 9。综合比较可知,基于 LOG10(9)-WT 的 ResNet 网络模型建模结果最佳,验证集 R<sup>2</sup>、RMSE 和 PRD 分别为 0.751 9, 0.247 5 和 2.084 6,而基于 LOG10(10)-WT 的 ResNet 网络模型的验证集 R<sup>2</sup>、RMSE 和 PRD 分别为 0.522 1, 0.345 3 和 1.835 6。图 9(a)-(d) 为实测值和预测值的散点图。结果表明,在深度学习 ResNet 中,基于对数阶 LOG+WT 的 ResNet 模型精度和稳定性优于一阶微分(LOG10(10))+WT。

4.4 基于自注意力的 CNN-LSTM 网络模型建模结果分析

本文通过分析不同幂的对数阶微分 LOG+WT 预处理

Table 4 ResNet network modeling results

表 4 ResNet 网络模型建模结果

预处理方法	训练结果			测试结果		
	R <sup>2</sup>	RMSE	RPD	R <sup>2</sup>	RMSE	RPD
R	0.856 4	0.242 1	2.305 7	0.388 2	0.327 3	1.220 7
LOG10(10)	0.992 5	0.054 9	11.087 8	0.693 6	0.255 9	1.837 1
LOG10(3)-WT	0.975 4	0.098 3	6.045 7	0.565 0	0.327 5	1.644 5
LOG10(4)-WT	0.987 4	0.070 5	8.505 7	0.589 8	0.313 5	1.357 8
LOG10(5)-WT	0.982 8	0.082 1	7.661 6	0.585 7	0.319 1	1.777 3
LOG10(6)-WT	0.977 3	0.095 4	6.818 2	0.653 9	0.271 3	1.993 5
LOG10(7)-WT	0.985 5	0.076 3	7.913 1	0.712 8	0.249 9	1.945 1
LOG10(8)-WT	0.990 3	0.062 2	9.801 6	0.684 8	0.264 1	2.120 9
LOG10(9)-WT	0.984 1	0.079 0	7.468 2	0.751 9	0.247 5	2.084 6
LOG10(10)-WT	0.988 4	0.067 4	9.468 1	0.522 1	0.345 3	1.835 6
LOG10(11)-WT	0.993 2	0.051 2	12.003 9	0.678 1	0.294 4	1.945 4
LOG10(12)-WT	0.985 9	0.074 4	7.973 0	0.615 4	0.306 9	1.471 0
LOG10(13)-WT	0.985 7	0.074 9	7.920 7	0.738 7	0.253 8	2.100 9
LOG10(14)-WT	0.992 5	0.053 9	11.277 5	0.719 1	0.269 1	2.003 4
LOG10(15)-WT	0.991 2	0.059 5	10.5170	0.529 8	0.321 1	1.600 4


方法对模型精度的影响,结果证明幂为 9 的对数阶微分 LOG10(9) 结合小波变换是最佳预处理方法。以此为基础,构建了 CNN、LSTM、BiLSTM、PLSR、SVR、RFR 和 SA-CNN-LSTM 模型,并进行比较实验,结果如表 5、图 10 所示。

Table 5 Modeling results of CNN, LSTM, BiLSTM, PLSR, SVR, RFR and SA-CNN-LSTM models


表 5 CNN、LSTM、BiLSTM、PLSR、SVR、RFR 和 SA-CNN-LSTM 模型建模结果

建模方法	训练结果			测试结果		
	R <sup>2</sup>	RMSE	RPD	R <sup>2</sup>	RMSE	RPD
LOG10(9)-CNN	0.918 2	17.936 1	3.497 6	0.832 2	20.356 7	2.441 2
LOG10(9)-LSTM	0.897 5	20.076 0	3.124 7	0.828 0	20.607 3	2.411 5
LOG10(9)-BiLSTM	0.897 7	20.060 9	3.127 1	0.805 2	21.930 2	2.266 1
LOG10(9)-PLSR	0.859 4	24.218 3	2.713 6	0.801 3	25.674 2	2.352 7
LOG10(9)-SVR	0.892 1	20.784 3	3.054 1	0.822 4	22.635 4	2.498 6
LOG10(9)-RFR	0.906 8	18.932 5	3.315 9	0.841 2	20.784 9	2.679 4
LOG10(9)-SA-CNN-LSTM	0.940 3	15.322 5	4.094 1	0.888 7	16.572 2	2.998 7


从实验结果看, CNN 在训练集上的 R<sup>2</sup> 为 0.918 2, RMSE 为 17.936 1, RPD 为 3.497 6; 在验证集上的 R<sup>2</sup> 为 0.832 2, RMSE 为 20.356 7, RPD 为 2.441 2。CNN 在训练集上表现良好,但在验证集上 R<sup>2</sup> 和 RPD 有所下降。LSTM 在训练集上的 R<sup>2</sup> 为 0.897 5, RMSE 为 20.076 0, RPD 为 3.124 7; 在验证集上的 R<sup>2</sup> 为 0.828 0, RMSE 为 20.607 3, RPD 为 2.411 5。LSTM 在训练集和验证集上的表现相对稳定,但整体指标不如 CNN。BiLSTM 在训练集上的 R<sup>2</sup> 为 0.897 7, RMSE 为 20.060 9, RPD 为 3.127 1; 在验证集上的 R<sup>2</sup> 为 0.805 2, RMSE 为 21.930 2, RPD 为 2.266 1。BiLSTM 在训练集和验证集上的表现与 LSTM 相似,但在验证集上的 R<sup>2</sup> 和 RPD 略低。SVR 比 PLSR 表现更好,训练集 R<sup>2</sup> 接近 0.9, RMSE 略高。RFR 训练集 R<sup>2</sup> 较高,测试集略有下降,整体优于 SVR。SA-CNN-LSTM 在训练集上的 R<sup>2</sup> 为 0.940 3, RMSE 为 15.322 5, RPD 为 4.094 1; 在验证集上的 R<sup>2</sup> 为 0.888 7,




(a) Original spectrum  
(a) 原始光谱




(a) Original spectrum  
(a) 原始光谱




(b) LOG10(10)  
(b) 幂为10的LOG




(b) LOG10(10)  
(b) 幂为10的LOG




(c) LOG10(10)-WT  
(c) 幂为10的LOG和WT



(c) LOG10(10)-WT  
(c) 幂为10的LOG和WT



(d) LOG10(9)-WT  
(d) 幂为9的LOG和WT



(d) LOG10(9)-WT  
(d) 幂为9的LOG和WT

Fig. 8 VggNet network modeling results with different combined pre-processing methods

图8 不同组合预处理方法的VggNet网络建模结果

Fig. 9 ResNet network modeling results with different combined pre-processing methods

图9 不同组合预处理方法的ResNet网络建模结果

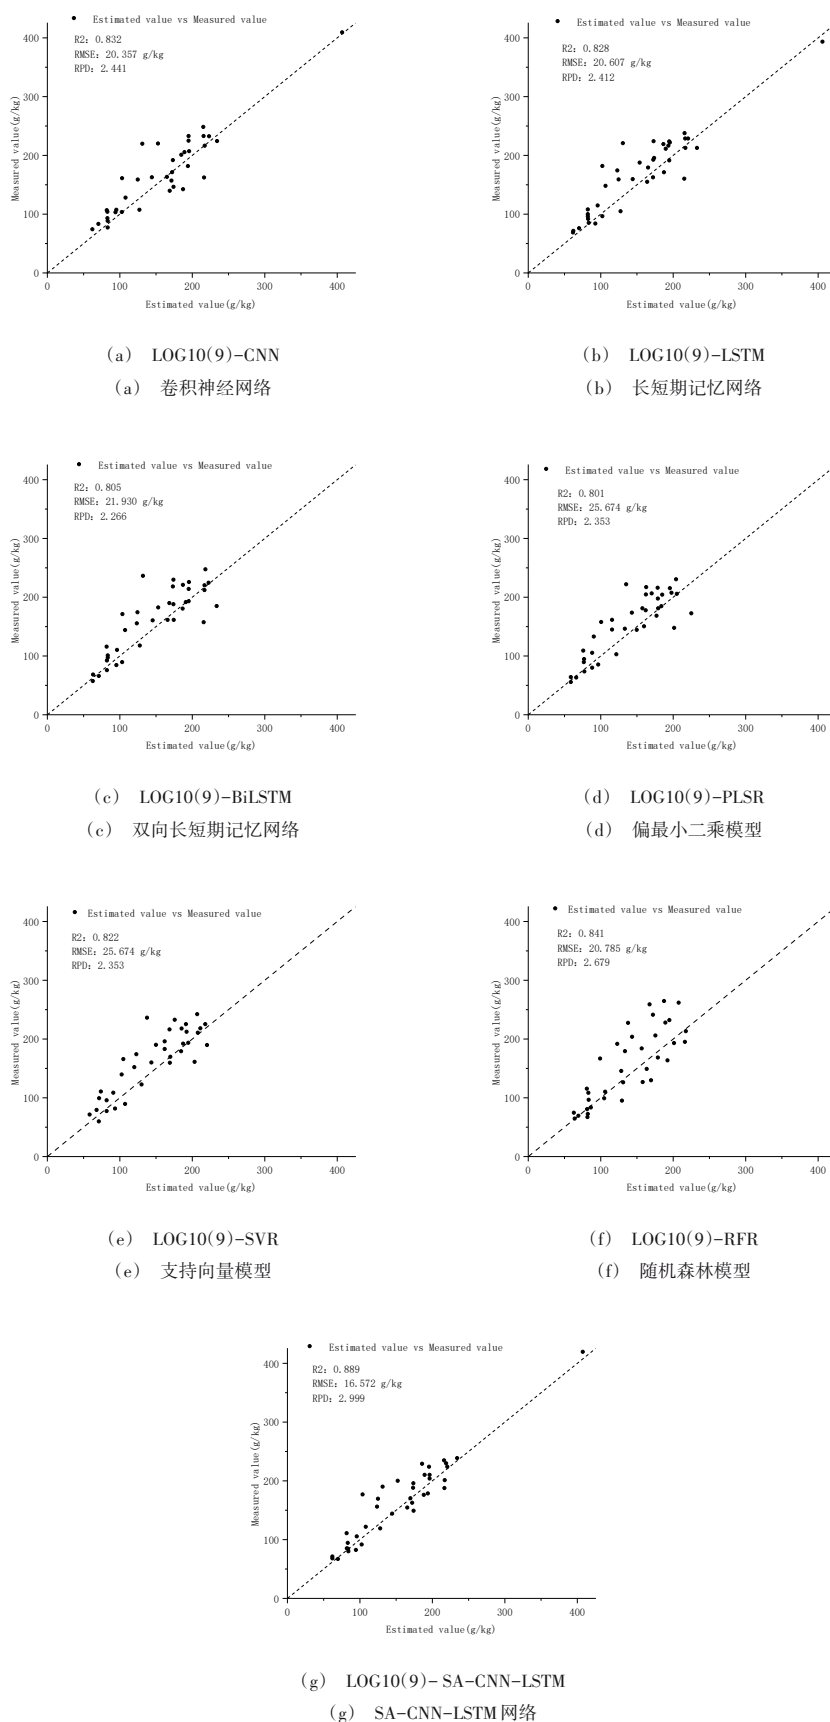


Fig. 10 Results of CNN, LSTM, BiLSTM, PLSR, SVR, RFR and SA-CNN-LSTM models

图 10 CNN、LSTM、BiLSTM、PLSR、SVR、RFR 和 SA-CNN-LSTM 模型结果

RMSE为16.572 2,RPD为2.998 7。SA-CNN-LSTM在训练集和验证集上的表现均优于其他模型。与CNN相比,其在测试集上的 $R^2$ 、RPD分别提升了6.79%、22.85%,RMSE降低了18.60%;与LSTM相比,其在测试集 $R^2$ 、RPD分别提升了7.34%、24.34%,RMSE降低了19.58%。图10(a)-(d)为实测值和预测值的散点图。综上所述,SA-CNN-LSTM模型在各项指标上表现更好,说明该模型在处理光谱数据时具有更高精度。

## 5 结语

本文在广西黄冕林场和雅长林场采集196个土壤样品,通过对土样数据进行多种预处理,深入探索不同光谱预处理对模型性能的影响,并对比分析多种深度学习模型在不同光谱预处理下的建模效果。结果表明,所构建的SA-CNN-LSTM的土壤速效氮高光谱预测模型效果更好。本文提出的光谱预处理方法中,采用对数阶微分为LOG10(9)结合小波变换的处理方法更优,与原始光谱数据相比,VggNet和ResNet模型的 $R^2$ 分别提升了0.478 0和0.363 7,与使用一阶微分相比,VggNet和ResNet模型的 $R^2$ 分别提升了0.131 4和0.058 3,这表明对数阶微分结合小波变换在提升模型预测性能方面表现优异,是更优的光谱预处理方法。在深度学习模型对比中,本文SA-CNN-LSTM相比CNN、LSTM、PLSR、SVR、RFR和BiLSTM,验证集 $R^2$ 提升显著。结果表明,CNN和SA加强了LSTM的长距离依赖挖掘精度问题,SA-CNN-LSTM的土壤速效氮高光谱预测模型效果更好。与其他模型相比,本文SA-CNN-LSTM建模效果表现更好,模型精度 $R^2$ 为0.889 0,均方根误差为16.572 2,相对分析误差为2.998 7,实现了对广西林地土壤速效氮的快速、精准预测,具有很好的实践价值。

研究发现,不同的光谱预处理方法对区域具有适应性。未来工作中,将深入研究不同处理算法对光谱特征的影响,通过使用不同区域、不同类型的光谱数据,构建泛化性和鲁棒性更强的土壤速效氮预测模型。

### 参考文献:

- [1] GUO Y J, LI H P, ZHANG Q B, et al. Response of soil available nitrogen mineralization capacity to temperature and organic fertilizer addition in alpine grasslands of the Qinghai-Tibet Plateau[J]. Grassland Science, 2024, 41(5): 1048-1056.  
郭雅婧,李辉鹏,张其斌,等.青藏高原高寒草地土壤速效氮矿化能力对温度和有机肥添加的响应[J]. 草业科学, 2024, 41(5): 1048-1056.
- [2] ZHANG Y, JIAN J. Hyperspectral estimation modeling of soil As content in the eastern part of Tianfu New District, Chengdu based on SPA-BPNN[J]. Journal of Guilin University of Technology, 2024, 44(1): 58-66.  
张宇,简季.基于SPA-BPNN的成都市天府新区东部土壤As含量高光谱估测建模[J]. 桂林理工大学学报, 2024, 44(1): 58-66.
- [3] TAN Y S, WEI Z X, XIAO Y, et al. Inversion of organic carbon content in lime soil in Karst area based on hyperspectral and multispectral fusion[J]. Chinese Journal of Applied Ecology, 2025, 36(1): 197-207.  
谭咏诗,韦真茜,肖雁,等.基于高光谱和多光谱融合的喀斯特地区石灰土有机碳含量反演[J]. 应用生态学报, 2025, 36(1): 197-207.
- [4] LIANG Z Y, CHEN S H, LI N, et al. Spectral estimation of available phosphorus in soils with the same particle size[J]. Chinese Journal of Soil and Fertilizer, 2024(12): 230-239.  
梁智永,陈署冕,李娜,等.不同粒径土壤有效磷光谱估测[J]. 中国土壤与肥料, 2024(12): 230-239.
- [5] BREMNER J, MULVANEY C. Nitrogen total [DB/OL]. <https://onlinelibrary.wiley.com>.
- [6] NOCITA M, STEVENS A, NOON C, et al. Prediction of soil organic carbon for different levels of soil moisture using Vis-NIR spectroscopy[J]. Geoderma, 2013, 199: 37-42.
- [7] GHOLIZADEH A, BORŪVKA L, SABERIOON M, et al. Visible, near-infrared, and mid-infrared spectroscopy applications for soil assessment with emphasis on soil organic matter content and quality: state-of-the-art and key issues[J]. Applied Spectroscopy, 2013, 67(12): 1349-1362.
- [8] ZHONG L, GUO X, GUO J X, et al. Hyperspectral estimation of organic matter in red soil based on different convolutional neural network models[J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(1): 203-212.  
钟亮,郭熙,国佳欣,等.基于不同卷积神经网络模型的红壤有机质高光谱估算[J]. 农业工程学报, 2021, 37(1): 203-212.
- [9] HUANG Z D, CHEN Z L, WANG C, et al. Comparison of different multivariate calibration methods for measuring soil properties using visible/short-wave near infrared spectroscopy combined with machine learning algorithms[J]. Spectroscopy and Spectral Analysis, 2023, 43(11): 3535-3540.  
黄招娣,陈再良,王琛,等.比较可见/短波近红外光谱结合机器学习算法测量土壤性质的不同多元校准方法分析[J]. 光谱学与光谱分析, 2023, 43(11): 3535-3540.
- [10] LI Z X, GAO S, HU D H, et al. Analysis on the influence of space-based payload characteristics, spectral resolution and signal-to-noise ratio on the quantitative inversion of organic matter in black soil[J]. Remote Sensing Technology and Application, 2024, 39(4): 917-926.  
李泽鑫,高爽,胡登辉,等.天基载荷特性光谱分辨率与信噪比对黑土地有机质定量反演影响分析[J]. 遥感技术与应用, 2024, 39(4): 917-926.
- [11] LIU Z M, LI X Q, CHEN G L, et al. Inversion of total nitrogen content in rubber plantation soil in Yunnan based on hyperspectral[J]. Tropical Agricultural Science & Technology, 2023, 46(1): 35-41.  
刘忠妹,黎小清,陈桂良,等.基于高光谱的云南胶园土壤全氮含量反演[J]. 热带农业科技, 2023, 46(1): 35-41.
- [12] YIN C Y, BAI Z J, LUO D F, et al. Comparative study on soil total nitrogen content estimation models based on hyperspectral data[J]. Soil and Fertilizer Sciences in China, 2022(1): 9-15.  
殷彩云,白子金,罗德芳,等.基于高光谱数据的土壤全氮含量估测模型对比研究[J]. 中国土壤与肥料, 2022(1): 9-15.
- [13] ZENG J H, DUAN S B, YAO Y M, et al. Research on hyperspectral inversion of soil organic matter by combining fractional differential and outlier identification[J]. China Agricultural Information, 2023, 35(4): 11-25.  
曾佳辉,段四波,姚艳敏,等.结合分数阶微分和异常值识别的土壤有

- 机质高光谱反演研究[J]. 中国农业信息, 2023, 35(4): 11-25.
- [14] PAN Z Y, WU R J, LIN Y F, et al. Hyperspectral remote sensing image classification based on improved residual 3D-CNN and neighbor attention [J]. Remote Sensing of Natural Resources, 2025(2): 1-12.  
潘增滢, 吴瑞姣, 林易丰, 等. 改进的残差式3D-CNN和近邻注意力的高光谱遥感图像分类[J]. 自然资源遥感, 2025(2): 1-12.
- [15] ZHANG D Y, WU T J, LUO J C, et al. Remote sensing fine mapping of agricultural planting structure based on spatiotemporal coordination [J]. National Remote Sensing Bulletin, 2024, 28(8): 2014-2029.  
张冬韵, 吴田军, 骆剑承, 等. 时空协同的农业种植结构遥感精细制图[J]. 遥感学报, 2024, 28(8): 2014-2029.
- [16] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 6000-6010.
- [17] ZHAO Y T, LI Z, LIU X L, et al. Load identification method integrating convolutional neural network and attention mechanism [J]. Power Engineering Technology, 2025, 44(1): 227-235.  
赵毅涛, 李钊, 刘兴龙, 等. 融合卷积神经网络和注意力机制的负荷识别方法[J]. 电力工程技术, 2025, 44(1): 227-235.
- [18] REN D Z, ZHANG Q H. Rolling bearing fault diagnosis method based on improved one-dimensional convolutional neural network [J]. Henan Science and Technology, 2024, 51(10): 20-26.  
任德珍, 张清华. 基于改进一维卷积神经网络的滚动轴承故障诊断方法[J]. 河南科技, 2024, 51(10): 20-26.
- [19] LIANG Y Q, BAI S C, ZHANG Z Y. Research progress of neural networks combined with Hamiltonian mechanics in deep learning [J]. Computer Engineering and Applications, 2025, 61(14): 20-36.  
梁永琦, 白双成, 张志一. 深度学习中结合哈密顿力学的神经网络研究进展[J]. 计算机工程与应用, 2025, 61(14): 20-36.
- [20] CUI S Q, GAO Y M, HUO J H, et al. Wind speed prediction method based on EMD-ARIMA-LSTM [J]. Science and Technology Innovation and Application, 2025, 15(5): 50-53.  
崔胜秋, 郝伊明, 霍家豪, 等. 基于EMD-ARIMA-LSTM的风速预测方法[J]. 科技创新与应用, 2025, 15(5): 50-53.
- [21] DENG Y, NIU Z W, FENG Q Y, et al. Improved temporal convolutional network based hyperspectral prediction model for red soil organic matter [J]. Spectroscopy and Spectral Analysis, 2023, 43(9): 2942-2951.  
邓昀, 牛照文, 冯琦尧, 等. 改进时间卷积网络的红壤有机质高光谱预测模型[J]. 光谱学与光谱分析, 2023, 43(9): 2942-2951.
- [22] WANG T G, LI H Q, KONG S, et al. Analysis of soil salinity characteristics in cotton-growing areas of Tumushuke City, southern Xinjiang [J]. Special Economic Plants and Animals, 2023, 26(12): 19-22.  
王潭刚, 李慧琴, 孔松, 等. 南疆图木舒克市植棉区土壤盐分特征分析[J]. 特种经济动植物, 2023, 26(12): 19-22.
- [23] SHEN J L, WU L H, LI L S, et al. Effects of land use types on soil organic carbon components and carbon sequestration in a typical Karst mountain small watershed [J]. Journal of Ecology and Environment, 2025, 34(3): 358-367.  
申佳龙, 吴栋宏, 李林霜, 等. 典型喀斯特山地小流域土地利用类型对土壤有机碳组分及其固碳效应的影响[J]. 生态环境学报, 2025, 34(3): 358-367.
- [24] WU Q Y, ZHU Z Y, WU J M, et al. Dataset representativeness measurement and block sampling strategy for the pan-Kennard-Stone algorithm [J]. Chemical Journal of Chinese Universities, 2022, 43(10): 150-157.  
武晴滢, 祝震予, 吴剑鸣, 等. 泛Kennard-Stone算法的数据集代表性度量与分块采样策略[J]. 高等学校化学学报, 2022, 43(10): 150-157.
- [25] ZHANG Y L, WANG H, XIAO J J, et al. Estimation of soil organic matter content in mountainous cultivated land based on hyperspectral [J]. Jiangsu Journal of Agricultural Sciences, 2024, 40(1): 112-120.  
张永亮, 汪泓, 肖政军, 等. 基于高光谱的山区耕地土壤有机质含量估测[J]. 江苏农业学报, 2024, 40(1): 112-120.
- [26] HU W, HUANG Y, WEI L, et al. Deep convolutional neural networks for hyperspectral image classification [J]. Journal of Sensors, 2015(2): 1-12.
- [27] DONOHO D L, JOHNSTONE I M. Ideal spatial adaptation by wavelet shrinkage [J]. Biometrika, 1994, 81(3): 425-455.

(责任编辑: 孙 娟)