



孔杰,杨红云,黄淑梅,吴正,孙爱珍. 基于残差神经网络的水稻氮磷钾元素营养诊断[J]. 中国农业大学学报,2025,30(02):163-175.

KONG Jie, YANG Hongyun, HUANG Shumei, WU Zheng, SUN Aizhen. Nutritional diagnosis of nitrogen, phosphorus and potassium in rice based on the residual neural network[J]. *Journal of China Agricultural University*, 2025, 30(02): 163-175.

DOI: 10.11841/j.issn.1007-4333.2025.02.15

基于残差神经网络的水稻氮磷钾元素营养诊断

孔杰¹ 杨红云^{1*} 黄淑梅² 吴正² 孙爱珍²

(1. 江西农业大学 软件学院, 南昌 330045;

2. 江西农业大学 计算机与信息工程学院, 南昌 330045)

摘要 为实现水稻氮磷钾3种主要营养元素缺失种类的快速、准确诊断识别,以晚稻“黄华占”为研究对象,进行水稻大田栽培试验。分别设置:4个施氮水平,施肥总量分别为:N0(0 kg/hm²)、N1(130 kg/hm²)、N2(260 kg/hm²)以及N3(390 kg/hm²);4个施磷水平,P0(0 kg/hm²)、P1(300 kg/hm²)、P2(600 kg/hm²)和P3(780 kg/hm²);4个施钾水平,K0(0 kg/hm²)、K1(90 kg/hm²)、K2(180 kg/hm²)和K3(270 kg/hm²)。在水稻分蘖期和拔节期,首先扫描获得水稻各分蘖茎完全展开的顶三叶叶片图像数据,生成对抗网络(Generative Adversarial Network, GAN)对水稻图片进行超分辨率重构后,并通过图像预处理对数据进行归一化和扩充;此外,在保留残差神经网络Resnet34的主干结构的情况下,在残差块中引入注意力机制和软阈值化函数,并将在ImageNet图像数据集上得到的预训练权重迁移至改进了残差结构的模型中,从而对水稻分蘖期、拔节期叶片图像数据进行氮磷钾营养元素缺乏胁迫诊断识别。结果表明:改进后的Resnet34网络在重度缺肥梯度的2个时期测试准确率分别达到98.98%和98.10%,在中度缺肥梯度的准确率达到了97.99%和95.90%。在过量肥梯度的准确率为91.87%和88.49%;与改进前的网络相比,在分蘖期和拔节期的水稻图像测试集上,三元素胁迫分类准确率最大提升了29.58%和29.75%;分析混淆矩阵发现对氮胁迫的识别准确率最佳,在训练曲线上表现出更快的收敛速度。综上,本研究建立的水稻氮磷钾营养元素诊断模型能很好地在水稻分蘖期、拔节期完成水稻氮磷钾3类营养元素缺乏胁迫诊断,预测水稻生长营养状态,可为水稻氮磷钾元素营养诊断提供科学参考。

关键词 水稻; 氮磷钾营养诊断; Resnet34; 注意力机制; 软阈值化

中图分类号 TP183

文章编号 1007-4333(2025)02-0163-13

文献标志码 A

Nutritional diagnosis of nitrogen, phosphorus and potassium in rice based on the residual neural network

KONG Jie¹, YANG Hongyun^{1*}, HUANG Shumei², WU Zheng², SUN Aizhen²

(1. School of Software, Jiangxi Agricultural University, Nanchang 330045, China;

2. School of Computer and Information Engineering, Jiangxi Agricultural University, Nanchang 330045, China)

Abstract To achieve rapid and accurate diagnosis and recognition of three major nutrient element deficiency types in rice, one late rice variety “Huanghuazan” was selected as the research object for field cultivation trials. Different treatments are set as follows: Four nitrogen application levels are N0 (0 kg/hm²), N1 (130 kg/hm²), N2 (260 kg/hm²) and N3 (390 kg/hm²); Four phosphorus application levels are P0 (0 kg/hm²), P1 (300 kg/hm²), P2 (600 kg/hm²), P3 (780 kg/hm²); Four potassium application levels are K0

收稿日期: 2024-07-01

基金项目: 国家自然科学基金项目(62162030, 61562039)。

第一作者: 孔杰(ORCID:0009-0005-8189-3254), 硕士研究生, E-mail: fyukou@qq.com

通讯作者: 杨红云(ORCID:0000-0001-5356-7586), 教授, 主要从事农业信息技术研究, E-mail: nc_yhy@163.com

(0 kg/hm²), K1 (90 kg/hm²), K2 (180 kg/hm²) and K3 (270 kg/hm²). During the tillering and jointing stages of rice growth, the high-resolution image data of the top three fully expanded leaves from each tiller were scanned, and after generative adversarial network (GAN) reconstruction of rice image with super-resolution, the data underwent normalization and expansion through image preprocessing; Additionally, attention mechanisms and soft thresholding functions were integrated into the residual block while preserving the backbone structure of residual neural network Resnet34; Furthermore, pre-trained weights obtained from the ImageNet dataset were transferred to the model with an improved residual structure. The results indicate that: The improvement of Resnet34 network yielded extraordinary results, exhibiting a remarkable accuracy of 98.98% and 98.10% within the severe fertilizer deficiency gradients during these pivotal growth phases. Resnet34 network demonstrated robustness in moderate deficiency scenarios, and achieved the accuracies of 97.99% and 95.90%, respectively. Regarding excessive fertilizer application, the Resnet34 model maintained a commendable performance and achieved accuracies of 91.87% and 88.49% across the respective gradients. Compared with the pre-improvement network, the three-element stress classification accuracy of the rice image test set at the tillering stage and jointing stage increased by 29.58% and 29.75%; The analysis of the confusion matrix indicated that the identification accuracy of nitrogen stress was superior, and the training curve demonstrated faster convergence speed. In conclusion, the model established in this study exhibits exceptional proficiency in diagnosing nutrient deficiency stress during the pivotal tillering and jointing stages of rice growth, and can accurately predict the rice nutritional status. This study provides a scientific reference for the nutritional diagnosis of nitrogen, phosphorus and potassium in rice.

Keywords rice; nitrogen, phosphorus and potassium nutritional diagnosis; Resnet34; attention mechanism; soft thresholding

水稻作为全球关键粮食作物之一,其生长依赖氮磷钾元素的协同作用,3种元素在幼苗期促进根系扩张和叶片的光合效率,进而增强CO₂同化速率和养分再吸收,共同推动有效穗数增长和结实率提升,最终促进水稻增产^[1-3]。反之,施肥量的不足则会引起植株生长不良^[4]、影响光合作用效率^[5-6]进而影响产量。因此在水稻种植与施肥管理中,科学准确地诊断植株是否遭到了缺素胁迫及具体摄入失衡的元素种类很重要。

目前,氮磷钾缺素胁迫诊断主要有传统大田试验^[7-8]、化学定量分析^[9]、光谱和形态学特征建模^[10-11]等,虽然上述诊断技术在一定条件下可以进行氮磷钾3种元素营养诊断和缺素分析,然而,大田试验耗时较长且植株自身所受的外界因素影响较大^[12],化学分析过程需要在实验室进行处理且对专业要求度高^[13],光谱扫描设备价格昂贵,特征提取分析需要人为设计,且信息的提取和优化特征需要数学算法的支撑。

近年来,随着计算机技术的蓬勃发展,使用深度学习等技术应用于农业领域的植株营养诊断,病虫害识别,田间杂草分割等方面越来越广泛^[14]。周琼等^[15]应用BP神经网络提取水稻特征进行水稻氮

素营养诊断识别,整体识别准确率最高达90%。张林朋等^[16]通过采用改进的VGG16网络和迁移学习相结合的方式,训练网络模型对水稻叶片图像数据进行氮元素营养诊断识别,改进的组合网络模型在水稻氮元素营养诊断方面达到了最高95%的识别准确率;钱政等^[17]通过在传统深度残差网络Resnet34中引入注意力机制模块(Squeeze-and-Excitation block, SE block)并通过迁移学习的方式改进残差网络,使用改进后的网络模型在水稻幼穗分化期对叶片进行氮胁迫识别,准确率达到98.13%;杨红云等^[18]通过对水稻叶片图片的特征分布情况分析,选取特征较为集中的水稻叶片叶尖部分,并通过Stacking集成DenseNet、ResNet50、InceptionResNet V2卷积神经网络建立的水稻营养元素诊断模型,其分类准确率高达98.10%;Sethy等^[19]采用了卷积神经网络来提取特征,并结合支持向量机(SVM)作为鉴别器,性能最优的模型实现了高达99.80%的识别准确率;叶春等^[20]通过将水稻冠层图像提取图像纹理色彩特征并和ResNet50网络融合来估测作物氮素含量,其R²提升了16.36%。

上述研究多以氮素营养胁迫程度识别为主,然而针对不同营养元素缺素胁迫诊断研究较少。因

此,本研究拟选取晚稻“黄华占”为研究对象,通过设置不同氮磷钾营养施肥梯度栽培大田试验,采集水稻分蘖期和拔节期叶片图像;使用图像预处理和图像超分辨率重构方法对叶片图像进行增强,通过引入注意力机制和软阈值化函数对 Resnet34 网络进行改进,并导入迁移学习的方式构建水稻氮磷钾元素缺素和过量摄入元素胁迫识别模型,以期水稻栽培及生产管理过程中科学诊断水稻生长提供理论依据。

1 材料与方法

1.1 试验设计

为了获取水稻叶片完全展开的高清图像,于2022年6月25日在江西省吉安市新干县(115°15′~115°44′ E, 27°30′~27°58′ N)进行水稻大田试验。土壤基本理化性质如下:全氮 1.02 g/kg、全磷 0.48 g/kg、全钾 14.22 g/kg、有机质 19.46 g/kg、碱解氮 111.31 mg/kg、速效磷 10.65 mg/kg、速效钾 122 mg/kg。选择优质常规晚稻“黄华占”品种为研究对象,氮磷钾分别设4个不同梯度施肥水平,共12块1.5 m²的稻田,每块稻田移栽50株水稻,重复1次。稻田间筑高土夯实田埂分隔,并用薄膜覆盖埂体,单灌单排。氮肥供试肥料为尿素(N 46%),以双季稻在高产田下的高施氮总量(260 kg/hm²)为基础^[21],划分严重缺肥 N0(0 kg/hm²)、中度缺肥 N1(130 kg/hm²)、正常施肥 N2(260 kg/hm²)、过量施肥 N3(390 kg/hm²)4个施氮梯度。并按基肥:分蘖肥:拔节肥=5:2:3的比例施肥。磷肥使用钙镁磷肥(P₂O₅ 12%),施肥梯度为 P0(0

kg/hm²)、P1(300 kg/hm²)、P2(600 kg/hm²)、P3(780 g/hm²),一次性做基肥施用。由于过量磷肥会抑制植株生长^[22],故而将过量肥施肥量置为1.3倍于正常施肥量。钾肥使用氯化钾(含 K₂O 60%),以高施钾量(施肥总量为 180 kg/hm²)为正常施钾量^[23],划分 K0(0 kg/hm²)、K1(90 kg/hm²)、K2(180 kg/hm²)、K3(270 kg/hm²)4个施肥梯度。基肥量:拔节肥量=7:3。所有田块于2022-06-25进行播种,2022-07-18进行移栽,其他正常进行水、农药管理。

1.2 水稻叶片图像获取

水稻数字图像获取的设备选用 MICROTEK 平板扫描仪(型号 MRS9600TFU2L,上海中晶科技有限公司生产,分辨率为 600 PPI)。分别在水稻分蘖期(2022-08-06)和拔节期(2022-08-26)扫描获取水稻图像。取水稻分蘖茎完全展开顶三叶,为加快扫描效率,一次扫描2根分蘖茎的6片叶图像。分蘖期和拔节期分别得到了780张分辨率为8401 DPI×14401 DPI的叶片图像,2次扫描共计1560张。通过扫描仪得到的水稻叶片完全展开图像如图1(a)所示。在本研究中将单片叶水稻图像视为单个样本,因此在扫描得到的基础图像后需分离出单叶水稻图像并将背景统一为黑色如图1(b),最终为了方便后续的进一步处理将长宽比固定为1:1(图1(c))。初步处理后得到了分蘖期氮磷钾3种不同元素摄入比例失衡图像,每种元素4个施肥梯度各390张单叶图像。拔节期12个类别各梯度也为390张。遭受各元素的缺素,过量素胁迫的2个时期部分叶片图像详见图2。




图1 水稻图像数据获得和处理过程示例

Fig. 1 Example of rice image data acquisition and processing process




图2 典型的遭受施肥异常胁迫的部分水稻叶片图像

Fig. 2 Typical images of rice leaves subjected to abnormal fertilization stress

1.3 数据预处理

为了将样本裁剪至符合深度学习网络的输入尺寸,需要将图像分辨率缩放至224 DPI×224 DPI大小。但在试验过程中发现,由原样本的8 401 DPI×144 01 DPI大小的图像直接缩放为224 DPI×224

DPI,会带来图像分辨率降低幅度过大,而导致的分类效果不理想的问题。因而在样本缩放过程之间引入生成对抗网络^[24](Super-Resolution Generative Adversarial Network, SR-GAN)对图像进行超分辨率重构^[25],数据处理方法如图3所示。




图3 数据预处理方法

Fig.3 Data preprocessing methods

分离后水稻图像中存在着部分叶片产生卷曲,重叠且排序错乱等问题。将问题样本剔除后在分蘖期得到氮元素4个梯度1 547张图片,磷元素4个梯度1

560张,钾元素4个梯度1 556张共计4 663张。在拔节期得到氮元素4个梯度1 560张,磷元素4个梯度1 560张,钾元素4个梯度1 560张共计4 680张。为了

提高分类准确率需要对水稻图像进行扩充,采用图3所示中诸如亮度、饱和度、锐度增强、几何变换及添加噪声等9种方式进行数据集的10倍(包含原样本图片)扩大化,扩充后的数据分布具体情况如表1所示。

表1 数据集数量及分布

Table 1 Number of datasets and distribution

营养元素 Nutrient element	施肥梯度 Fertilization gradient	分蘖期 Tillering stage		拔节期 Jointing stage	
		原始图像数量 No. of original images	扩充后图像数量 No. of images after expansion	原始图像数量 No. of original images	扩充后图像数量 No. of images after expansion
氮 Nitrogen	N0	377	3 770	390	3 900
	N1	390	3 900	390	3 900
	N2	390	3 900	390	3 900
	N3	390	3 900	390	3 900
磷 Phosphorus	P0	390	3 900	390	3 900
	P1	390	3 900	390	3 900
	P2	390	3 900	390	3 900
	P3	390	3 900	390	3 900
钾 Potassium	K0	390	3 900	390	3 900
	K1	390	3 900	390	3 900
	K2	390	3 900	390	3 900
	K3	386	3 860	390	3 900

为了在各时期各梯度上准确识别水稻叶片受到了哪种元素的胁迫。将N2P2K2视为正常施肥梯度,分别在2个时期内选取施肥梯度为N0P0K0制作重度缺肥梯度数据集、选取N1P1K1制作中度缺肥梯度数据集、选取N3P3K3制作过量施肥梯度数据集。每个数据集按照训练集、验证集、测试集比为8:1:1进行划分。由于本研究重点在于识别水稻在元素摄入失衡状态下具体是哪类元素摄入异常,故正常施肥数据集不进行试验分类。

1.4 数据处理环境及参数设置

本试验模型的训练和测试均在Windows 10 64 bit操作系统下完成,CPU型号为13th Gen Intel(R) Core(TM)i5-13400F 2.50 Ghz,内存16 GB,GPU型号NVIDIA RTX 4070,显存容量12 GB。图像标准化使用Adobe Photoshop 2020 21.0.1版,超分辨率重构采用开源模型Upscale2.5.5。构建及测试模型的软件环境为Python 3.9.17、Tensorflow 2.14.0、Pytorch2.0.1、CUDA 11.8、CUDNN 8.8并使用Anconda 4.7.1搭建上述虚拟环境。

综合考虑硬件设备性能及训练效果后,将单次传递给程序用以训练的样本个数(Batch size)初始

值设置为24,后续根据试验需求进行更改。迭代次数(Epochs)设置为100,采用在大型数据集上表现较优的自适应梯度下降算法(Adam)^[26],损失函数选取交叉熵损失函数,初始学习率置为0.001。

1.5 模型构建

1.5.1 使用软阈值化替换注意力机制中特征加权算法

软阈值化是很多信号降噪算法的核心步骤,通过将原始信号转换到一个范围内并设置阈值,将大于阈值绝对值的特征通过减去该阈值进行保留,反之绝对值小于阈值的特征朝着零方向进行收缩以达到消除信号中的非必要特征的目的^[27]。具体公式如下:

$$\text{soft}(x, t) = \begin{cases} x - t & x > t \\ 0 & -t \leq x \leq t \\ x + t & x < -t \end{cases} \quad (1)$$

式中: x 为输入特征; t 为阈值。以阈值 t 的绝对值为界,分别对输入的负值特征和正值特征进行加减阈值的计算方式。使得特征向0的方向进行收缩,这种方式可以保留更多的信号特性,避免特征被过度压缩和损失。

挤压和激励网络(Squeeze-and-Excitation Network, SENet)是注意力机制在通道维度上的一种实现^[28]。其具体结构如图4(a)所示,SENet通过全局平均池化层将每个通道上尺寸大小为($C \times H \times W$)的特征图压缩为大小为($C \times 1 \times 1$)的一维实数,随后给予每个通道一个特征权重,最后将归一化后的权重通过相乘加权算法(Scale)相加在每个通道上。



SENet与软阈值化的结合最早由赵明航等^[29]提出,通过替换SENet中的特征加权算法为式(1)的软阈值化算法以达到特征筛选和去噪的目的。在图

4(b)中,通过阈值获取子网络得到一个0和1之间的数字 $\times$ 特征图绝对值的平均,其具体算法如下:

$$a = \frac{1}{1 + e^{-z}} \quad (2)$$

$$t = a \times \text{average} |x_{i,j,c}| \quad (3)$$

式中: z 为图4(b)阈值获取子网络中2层FC网络的输出; a 为相应的缩放参数;阈值 t 为缩放系数乘以输入特征图宽度 i 、高度 j 、通道数 c 绝对值的平均。相较于特征加权算法,软阈值化能保留更多的负类特征,具有更高的灵活性。



C , 通道数; H , 特征图的高度; W , 特征图的宽度; S , 步长。

C , number of channels; H , height of the feature map; W , width of the feature map; S , step size.

图4 使用软阈值化算法及注意力机制对网络进行改进

Fig. 4 Improvement of the network using soft thresholding algorithm and attention mechanism

1.5.2 构建水稻氮磷钾营养诊断模型

在残差块中引入替换算法后的注意力机制形成的新残差块被称为残差收缩单元,本试验保留conv1层的核大小为 7×7 ,步长为2的卷积层和

conv2_x层最顶部的 3×3 ,步长为2最大池化层,并从该层开始替换原本的残差块为步长为1的残差收缩单元。为了不改变特征图经过每层输出后的尺寸和通道数,在conv3_x层分别加入不同步长的残

差收缩单元,剩余 2 层采取相同的操作。在替换完 Resnet34 网络结构中的 16 个残差模块后,保留底部 的全局均匀池化层和 FC 全连接层后进行输出,输出 中包含了整体分类准确率在内的各项评价指标 及反映 3 元素分类的预测分类数和实际分类数的 混淆矩阵。同时使用迁移学习的方式加快模型的 收敛速度,最终构建的模型完整结构如图 4(c) 所示。

- 试验主要流程如下：
- 步骤 1:分离后的叶片不进行重构,仅将大小缩 放至 224 DPI×224 DPI,将样本输入未经修改的 Resnet34 基础网络并训练模型。将此方式记为 方案 1。
- 步骤 2:基于步骤 1,在 Resnet34 原有的网络结 构上替换基础网络的残差块结构为残差收缩单元, 数据集的处理方式与步骤 1 一致。记为方案 2。
- 步骤 3:基于步骤 2,使用迁移学习将 ImageNet 大型数据集上预训练的 Resnet34 网络模型权重参 数迁移到步骤 2 构建的网络模型中,记为方案 3。
- 步骤 4:在步骤 3 的基础上,数据预处理阶段使 用 SR-GAN 网络对图像进行 1 倍放大因子的超分 辨率重构,记为方案 4。
- 步骤 5:记录不同模型训练方式在验证集上输 出的诸如准确率、损失函数、训练曲线等评价 指标。

步骤 6:使用测试集对上述 3 种方案得到的模型 进行分类测试,记录准确率、精确率、召回率、F1 分 值及交叉熵损失。

2 结果与分析

2.1 不同方案在 2 个时期的各梯度评价指标对比 分析

4 种方案得到的模型在水稻分蘖期、拔节期 的不同施肥梯度测试集上的试验结果分别如表 2 和表 3 所示。可见:对比方案 1 和方案 2 发现,使 用残差收缩单元替换了 Resnet34 原有的残差块 后,对水稻元素的缺素及过量素胁迫的分类效果 有显著提升,在分蘖期中度缺肥梯度 N1P1K1 上 达到了最大为 27.37% 的分类准确率的提升;对 比方案 2 和方案 3 发现,迁移学习的加入能够一 定程度上提高模型的各项评价指标增强模型性 能;从 2 个时期不同施肥梯度中方案 3 和方案 4 对 比发现,对水稻叶片图像使用生成对抗网络进行 1 倍放大因子的超分辨率重构,能够在一定程度 上丰富图像的特征信息,从而提升识别准确率。 在拔节期过量施肥梯度 N3P3K3 达到了最大为 2.41% 的提升。综合 2 个时期不同施肥梯度来 看,方案 4 在各时期各梯度测试集上的表现显著 优于前 3 种方案,具有更高的识别准确率和更低 的交叉熵损失,具有更强的泛化能力。

表 2 分蘖期不同方案的试验结果
Table 2 Experimental results of different protocols at tillering stage

施肥梯度 Fertilization gradient	方案 Method	训练方式 Training method	准确率/% Accuracy	损失函数 Loss	精确率/% Precision	召回率/% Recall	F1 值/% F1-score
重度缺肥胁迫 N0P0K0	方案 1	全新学习	84.64	0.412 4	84.61	84.66	84.61
	方案 2	全新学习	97.38	0.060 1	97.43	97.36	97.27
	方案 3	迁移学习	98.29	0.050 3	98.18	98.28	98.27
	方案 4	迁移学习	98.99	0.051 0	98.89	98.97	98.98
中度缺肥胁迫 N1P1K1	方案 1	全新学习	68.38	0.631 3	68.76	67.42	68.29
	方案 2	全新学习	95.75	0.100 0	95.81	95.77	95.73
	方案 3	迁移学习	96.89	0.080 0	96.88	96.90	96.86
	方案 4	迁移学习	97.96	0.075 1	97.96	97.95	97.96
过量施肥胁迫 N3P3K3	方案 1	全新学习	78.02	0.500 4	78.01	78.08	78.04
	方案 2	全新学习	85.95	0.301 1	85.95	85.93	85.98
	方案 3	迁移学习	88.48	0.280 8	88.43	88.46	88.47
	方案 4	迁移学习	91.87	0.210 1	91.88	91.86	91.87

表3 拔节期不同方案的试验结果

Table 3 Experimental results of different protocols at jointing stage

施肥梯度 Fertilization gradient	方案 Method	训练方式 Training method	准确率/% Accuracy	损失函数 Loss	精确率/% Precision	召回率/% Recall	F1值/% F1-score
重度缺肥胁迫 N0P0K0	方案1	全新学习	71.98	0.499 8	71.97	71.98	71.96
	方案2	全新学习	96.96	0.106 7	94.35	97.18	96.97
	方案3	迁移学习	97.59	0.080 1	97.57	97.58	97.58
	方案4	迁移学习	98.10	0.070 1	98.09	98.10	98.10
中度缺肥胁迫 N1P1K1	方案1	全新学习	66.15	0.536 4	66.17	66.12	66.16
	方案2	全新学习	92.76	0.170 4	92.78	92.77	92.76
	方案3	迁移学习	94.09	0.090 3	94.07	94.08	94.09
	方案4	迁移学习	95.90	0.082 9	95.89	95.90	95.88
过量施肥胁迫 N3P3K3	方案1	全新学习	73.99	0.499 8	73.98	73.96	73.00
	方案2	全新学习	82.80	0.410 4	82.79	82.82	82.81
	方案3	迁移学习	86.08	0.340 0	86.07	86.09	86.08
	方案4	迁移学习	88.49	0.288 1	88.48	88.48	88.49

2.2 训练曲线结果分析

不同方案在2个时期不同施肥梯度上得到的训练曲线如图5和图6所示。由图5中方案1在各个施肥梯度上的训练曲线对比可见,方案1的准确率和交叉熵损失值并未随着迭代次数的增加而收敛,表明方案1中Resnet34原始网络在高相似度的

图像分类任务中效果不佳,存在着欠拟合现象。由图5和图6中方案2的训练曲线可见,使用残差收缩单元替换残差块后消除了欠拟合现象使训练曲线随着迭代次数的增加而逐渐收敛,可见软阈值化算法和注意力机制的加入能够提升模型的抗噪性。




图5 分蘖期各施肥梯度训练曲线

Fig. 5 Training curve for each fertilizer gradient at tillering stage

由图5和图6中方案2和方案3的 (a_1) 、 (b_1) 、 (c_1) 的准确率曲线对比可见:方案3达到最大分类准确率和最低的交叉熵损失值所需的迭代次数更少,表明迁移学习的加入缩短了模型的训练耗时,提升了收敛速度。

由图5和图6中方案4的各施肥梯度训练曲线可见,方案4较方案3有着更高的分类准确率和更低的交叉熵损失,表明SR-GAN即使在不改变图像大小的情况下依旧能丰富图像细节特征,提升模型的分类性能。




图6 拔节期各施肥梯度训练曲线

Fig. 6 Training curves for each fertilizer gradient at jointing stage

2.3 混淆矩阵的分析

为了进一步评估方案4得到的模型分类性能,使用混淆矩阵对2个时期各施肥梯度的分类结果进一步分析,结果见图7。由图7 (a_1) 和图7 (a_2) 可见:无论是在分蘖期还是拔节期,严重缺肥梯度得到的识别准确率最佳,这是因为在该施肥梯度下叶片的病理表现诸如叶片发黄、卷曲、叶面积不足等较为明显,提升了样本之间的区分度。对比图7(a)和图7(b)可见:拔节期的3梯度分类准确率低于分蘖期3梯度,这反映了随着施肥量的增加,叶片发育逐渐趋于正常,样本噪声提升导致错误分类率逐渐上升,磷元素胁迫有概率被错误分类成氮钾元素胁迫,氮钾胁迫也存在一定的错误分类率,表明随着施肥梯度越趋于正常施肥量,模型在3元素的胁迫种类识别上所受影响越大。从图7 (b_3) 来看,磷元素胁迫的识别准确率最佳,反之在其他梯度得到的氮胁迫识别最佳,磷元素所属的4片田块在分蘖期和拔节期的追肥中仅添加了正常含量的氮钾肥,放大了基肥中磷肥的影响,进而影响了矩阵中磷胁迫识别的准确率。

2.4 不同网络模型的性能对比

为了进一步验证本试验构建模型的有效性,选取同为残差神经网络的Resnet18、Resnet50及典型神经网络VGG16。采用准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1值(F1-score)、模型参数量(Parameters)和训练耗时(Trainig time)6类评价指标对模型进行分析,选取2个时期叶片相似度最高的过量施肥梯度测试集进行试验,得到的结果如表4。可见:残差神经网络较传统VGG16结构具有更佳的表现,且随着网络层次的加深能够一定程度上提升分类性能,但在图像相似度较大的高噪声数据集上的表现不尽如人意,而本研究所构建的模型较VGG16网络在各项评价指标上具有较大优势。相较于Resnet18网络,方案4构建的模型由于额外进行了一次特征筛选的过程,增加了部分参数量和训练耗时,但通过少量性能上的损耗带来了较为显著的分类准确率的提升。改进后的模型在分类性能和资源占用率上优于具有更深网络层次结构的Resnet50,具有较好的抗噪性和泛用性。




图7 方案4在不同时期不同施肥梯度的混淆矩阵

Fig. 7 Confusion matrix for different fertilizer gradients at varioustime for method 4

表4 不同网络模型试验数据							
Table 4 Experimental data of different network models							
模型 Model	时期 Stage	准确率/% Accuracy	精确率/% Precision	召回率/% Recall	F1值/% F1-score	参数量/M Parameters	训练耗时/s Training time
VGG16	分蘖期 Tillering stage	68.63	68.74	68.64	68.76	138.36	27 823.88
	拔节期 Jointing stage	66.94	69.93	69.92	69.94	138.36	28 821.40
Resnet18	分蘖期 Tillering stage	73.24	72.23	73.26	73.24	11.71	16 702.54
	拔节期 Jointing stage	71.88	71.87	71.87	71.88	11.71	16 754.66
Resnet50	分蘖期 Tillering stage	85.69	85.68	85.68	85.69	25.58	31 648.25
	拔节期 Jointing stage	82.36	82.35	82.38	82.36	25.58	31 678.74
Method 4	分蘖期 Tillering stage	92.87	92.88	92.88	92.85	22.81	24 276.46
	拔节期 Jointing stage	91.89	91.86	91.87	91.89	22.81	25 375.31

3 讨论

在本研究早期使用各类深度学习模型对水稻样本进行营养诊断过程中,发现了随着施肥梯度越

趋于正常区间,模型的诊断能力不断下降,推测随着植株的肥料摄入增加,叶片样本之间的相似度会越来越大,图像的噪声给传统的网络模型带来的负面影响扩大,进而导致分类性能的降低,这与郭紫

微等^[17]研究中得出的水稻叶片特征集中于叶尖部分, 剩余部位的特征有效性较低的结论是一致的。区别之处在于本研究并未手动裁剪特征分布较低的图像区域, 而是在模型中引入降噪算法和注意力机制自动筛选特征。试验结果也表明即使在不改变图像原始信息的情况下对网络结构上的正确改进也能提高模型在高相似度样本下的分类性能。在预处理阶段引入SR-GAN对样本进行重构提升了Resnet34网络的分类准确率, 这与何朝霞等^[30]研究结论是一致的, 论证了SR-GAN作为一种图像增强方式的有效性。改进后的模型在不同施肥梯度上的氮、磷、钾缺素胁迫区分效果由大到小依次为严重缺肥梯度、过量肥梯度、中度施肥梯度, 这一结果与孙棋^[30]的研究结果吻合。证明了本试验所探讨的数据预处理手段及模型构建方式是合理有效的, 改进后的氮磷钾营养诊断模型在各评价指标上的表现优于传统模型, 能够准确地在不同施肥梯度正确识别出水稻所遭受的胁迫种类。

本研究所构建的水稻氮、磷、钾3元素营养诊断模型虽能较好地判定植株当前是遭受了哪一类元素的摄入异常胁迫, 但依然存在着模型本身的分类性能随着施肥梯度的增加而降低的问题, 这导致了后续进一步细分水稻单一元素的胁迫程度上依旧有着不小的挑战。因此, 为了发挥扫描得到的高清图像的优势, 后续可以通过使用等效的卷积层替换全连接层来解除残差网络的输入图像大小限制, 进一步优化模型在多分类任务上的性能。此外后续还需要增加不同品种, 多个生长时期及不同作物类型的样本进行泛用性和推广性上的讨论。水稻氮磷钾3元素营养诊断的核心及目的是建立田间无损、快速的营养诊断体系, 并在此基础上科学指导施肥、追肥, 因此如何将模型摆脱实验室的专业设备并将其部署到常见的生产终端, 如何在诊断完成后进一步设计最优施肥、追肥方案上仍需要进一步的研究探索。

4 结 论

本研究通过构建氮磷钾3种营养元素的营养诊断模型, 对采集的图像数据进行识别, 在预处理阶段对样本图片进行超分辨率重构, 在模型构建过程中使用软阈值化算法和注意力机制对模型进行改进, 且在训练过程中迁移预训练的权重最终进行水

稻的缺素, 过剩素胁迫进行识别。主要结论如下:

1) 在注意力机制中, 软阈值化算法相较于通道特征加权算法在高噪声样本的分类任务中表现更为优异, 能提升模型分类性能;

2) 通过迁移学习方式, 模型能在新任务上快速得到良好的初步性能, 从而减少了从零开始的海量训练输入和高昂的训练成本, 进而提高了模型的工作效能;

3) 在数据预处理阶段使用超分辨重构的方式可以小幅度地提升分类准确率。

4) 改进后的Resnet34网络模型在各项评价指标上表现优异, 作为一种田间快速、无损的作物营养识别手段是有效可行的。

参考文献 References

- [1] 李亦斌. 氮、磷、钾对水稻秧苗根系生长的影响[J]. 湖南农业科学, 2006(3): 29-30
Li Y B. Effects of N, P, K fertilizations on root growing during rice seedling[J]. *Hunan Agricultural Sciences*, 2006(3): 29-30(in Chinese)
- [2] 彭建伟, 刘强, 荣湘民, 朱红梅, 谢桂先, 汤桂容. 氮磷钾配比及氮用量对水稻光合特性及产量的影响[J]. 湖南农业大学学报(自然科学版), 2004, 30(2): 123-127
Peng J W, Liu Q, Rong X M, Zhu H M, Xie G X, Tang G R. Effects of different rational ratio of N, P, K fertilizer and amount of N fertilizer on photosynthesis character and yield of rice [J]. *Journal of Hunan Agricultural University*, 2004, 30(2): 123-127(in Chinese)
- [3] 李卫国, 任永玲. 氮、磷、钾、硅肥施对水稻产量及其构成因素的影响[J]. 山西农业科学, 2001, 29(1): 53-58
Li W G, Ren Y L. The effects of combined N P K Si fertilization on rice yield and component factors [J]. *Journal of Shanxi Agricultural Sciences*, 2001, 29(1): 53-58(in Chinese)
- [4] 何小亮, 祁秀平. 水稻缺肥或施肥过量各元素表现症状分析[J]. 吉林农业, 2013(8): 8
He X L, Qi X P. Analysis on the symptoms of various elements in rice with fertilizer deficiency or excessive fertilization [J]. *Jilin Agriculture*, 2013(8): 8(in Chinese)
- [5] 朱永波, 韩展誉, 程方民. 氮肥对水稻营养品质、外观品质和加工品质的影响[J]. 基层农技推广, 2019, 7(12): 26-29
Zhu Y B, Han Z Y, Cheng F M. Effects of nitrogen fertilizer on nutritional quality, appearance quality and processing quality of rice [J]. *Primary Agricultural Technology Extension*, 2019, 7(12): 26-29(in Chinese)
- [6] 侯赛赛, 薛占军, 张益兴, 李青云, 王鑫鑫. 不同供磷水平下大白菜的光合作用及叶绿素荧光参数变化[J]. 北方园艺, 2023(19): 8-15
Hou S S, Xue Z J, Zhang Y X, Li Q Y, Wang X X. Changes of photosynthesis and chlorophyll fluorescence parameters of Chinese cabbage under different phosphorus supply levels [J]. *Northern Horticulture*, 2023(19): 8-15(in Chinese)
- [7] 敖和军, 王淑红, 邹应斌, 彭少兵, 程兆伟, 刘武, 唐启源. 不同施肥水平


- 下超级杂交稻对氮、磷、钾的吸收累积[J]. 中国农业科学, 2008, 41(10): 3123-3132
- Ao H J, Wang S H, Zou Y B, Peng S B, Cheng Z W, Liu W, Tang Q Y. Characteristics of nutrient uptake and utilization of super hybrid rice under different fertilizer application rates [J]. *Scientia Agricultura Sinica*, 2008, 41(10): 3123-3132(in Chinese)
- [8] 尹春芹, 王宏燕, 王旭梅. 氮、磷、钾、有机肥配施对水稻产量及其构成因子关系的研究[J]. 东北农业大学学报, 2005, 36(3): 263-267
- Yin C Q, Wang H Y, Wang X M. Study on combined N, P, K, organic fertilization on rice yield and component factors[J]. *Journal of Northeast Agricultural University*, 2005, 36(3): 263-267(in Chinese)
- [9] 侯云鹏, 韩立国, 孔丽丽, 尹彩侠, 秦裕波, 李前, 谢佳贵. 不同施氮水平下水稻的养分吸收、转运及土壤氮素平衡[J]. 植物营养与肥料学报, 2015, 21(4): 836-845
- Hou Y P, Han L G, Kong L L, Yin C X, Qin Y B, Li Q, Xie J G. Nutrient absorption, translocation in rice and soil nitrogen equilibrium under different nitrogen application doses[J]. *Journal of Plant Nutrition and Fertilizer*, 2015, 21(4): 836-845(in Chinese)
- [10] Duan G L, Liu W J, Chen X P, Hu Y, Zhu Y G. Association of arsenic with nutrient elements in rice plants [J]. *Metallomics*, 2013, 5(7): 784-792
- [11] Chen L S, Lin L, Cai G Z, Sun Y Y, Huang T, Wang K, Deng J S. Identification of nitrogen, phosphorus, and potassium deficiencies in rice based on static scanning technology and hierarchical identification method [J]. *PLoS One*, 2014, 9(11): e113200
- [12] 韩上, 武际, 胡现荣, 桑亚松, 胡润, 胡鹏, 郭熙盛. 安徽省不同区域油菜对氮肥一次性施用方式的响应[J]. 中国土壤与肥料, 2018(2): 82-88
- Han S, Wu J, Hu X R, Sang Y S, Hu R, Hu P, Guo X S. Responses of different nitrogen fertilizer single basal application methods on rapeseed (*Brassica napus* L) in different regions of Anhui Province[J]. *Soil and Fertilizer Sciences in China*, 2018(2): 82-88(in Chinese)
- [13] 杨红云, 周琼, 杨璐, 孙玉婷, 路艳. 水稻氮素营养诊断方法研究进展[J]. 中国稻米, 2020, 26(2): 5-8, 13
- Yang H Y, Zhou Q, Yang J, Sun Y T, Lu Y. Research progress on nitrogen nutrition diagnosis methods of rice [J]. *China Rice*, 2020, 26(2): 5-8, 13(in Chinese)
- [14] 吕盛坪, 李灯辉, 冼荣亨. 深度学习在我国农业中的应用研究现状[J]. 计算机工程与应用, 2019, 55(20): 24-33, 51
- Lv S P, Li D H, Xian R H. Research status of deep learning in agriculture of China[J]. *Computer Engineering and Applications*, 2019, 55(20): 24-33, 51(in Chinese)
- [15] 周琼, 杨红云, 杨璐, 孙玉婷, 孙爱珍, 杨文姬. 基于BP神经网络和概率神经网络的水稻图像氮素营养诊断[J]. 植物营养与肥料学报, 2019, 25(1): 134-141
- Zhou Q, Yang H Y, Yang J, Sun Y T, Sun A Z, Yang W J. Feasibility study of BP neural network and probabilistic neural network for nitrogen nutrition diagnosis of rice images [J]. *Journal of Plant Nutrition and Fertilizers*, 2019, 25(1): 134-141(in Chinese)
- [16] 张林朋, 杨红云, 钱政, 郭紫微. 基于改进的VGG16网络和迁移学习的水稻氮素营养诊断[J]. 中国农业大学学报, 2023, 28(6): 219-229
- Zhang L P, Yang H Y, Qian Z, Guo Z W. Nitrogen nutrition diagnosis in rice based on improved VGG16 network and transfer learning [J]. *Journal of China Agricultural University*, 2023, 28(6): 219-229 (in Chinese)
- [17] 钱政, 杨孙哲, 张国卿, 郭紫微, 张林朋, 万家兴, 杨红云. 基于卷积神经网络的水稻氮素营养诊断[J]. 中国农业科技导报, 2023, 25(9): 113-121
- Qian Z, Yang S Z, Zhang G Q, Guo Z W, Zhang L P, Wan J X, Yang H Y. Rice nitrogen nutrition diagnosis based on convolutional neural network[J]. *Journal of Agricultural Science and Technology*, 2023, 25(9): 113-121(in Chinese)
- [18] 杨红云, 郭紫微, 郭高飞, 黄进龙, 钱政, 张林朋, 刘娇娇. 基于Stacking集成卷积神经网络的水稻氮素营养诊断[J]. 植物营养与肥料学报, 2023, 29(3): 573-581
- Yang H Y, Guo Z W, Guo G F, Huang J L, Qian Z, Zhang L P, Liu J J. Rice nitrogen nutrition diagnosis based on stacking integrated convolutional neural network [J]. *Journal of Plant Nutrition and Fertilizer*, 2023, 29(3): 573-581(in Chinese)
- [19] Sethy P K, Barpanda N K, Rath A K, Behera S K. Nitrogen deficiency prediction of rice crop based on convolutional neural network[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2020, 11(11): 5703-5711
- [20] 叶春, 刘莹, 刘继忠, 舒时富, 李艳大, 吴罗发. 基于LBPHSV+ResNet50融合的水稻冠层氮素营养监测方法[J]. 中国农业大学学报, 2023, 28(1): 39-47
- Ye C, Liu Y, Liu J Z, Shu S F, Li Y D, Wu L F. A method for monitoring nitrogen nutrition in rice canopy based on LBPHSV+ResNet50 fusion[J]. *Journal of China Agricultural University*, 2023, 28(1): 39-47(in Chinese)
- [21] 徐新朋, 周卫, 梁国庆, 孙静文, 王秀斌, 何萍, 徐芳森, 余喜初. 氮肥用量和密度对双季稻产量及氮肥利用率的影响[J]. 植物营养与肥料学报, 2015, 21(3): 763-772
- Xu X P, Zhou W, Liang G Q, Sun J W, Wang X B, He P, Xu F S, Yu X C. Effects of nitrogen and density interactions on grain yield and nitrogen use efficiency of double-rice systems[J]. *Journal of Plant Nutrition and Fertilizers*, 2015, 21(3): 763-772
- [22] 康云艳, 冯新富, 杨暹. 过量磷对菜心植株生长和产量及品质的影响[J]. 北方园艺, 2011(15): 70-72
- Kang Y Y, Feng X F, Yang X. Effect of excess phosphorus on growth, yield and quality of Chinese flowering cabbage [J]. *Northern Horticulture*, 2011(15): 70-72(in Chinese)
- [23] 王强盛. 水稻钾素营养的积累特征及生理效应[D]. 南京: 南京农业大学, 2009
- Wang Q S. Accumulation characteristics and physiological effects of rice potassium nutrition [D]. Nanjing: Nanjing Agricultural University, 2009 (in Chinese)
- [24] Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, Courville A, Bengio Y. Generative adversarial networks [J]. *Communications of the ACM*, 2020, 63(11): 139-144
- [25] Ledig C, Theis L, Huszár F, Caballero J, Cunningham A, Acosta A, Aitken A, Tejani A, Totz J, Wang Z H, Shi W Z. Photo-realistic single image super-resolution using a generative adversarial network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). July 21-26, 2017, Honolulu, : IEEE, 2017: 105-114
- [26] Kingma D, Ba J. ADAM: A method for stochastic optimization [J]. *Computer Science*, 2014: 6980
- [27] Donoho D L. De-noising by soft-thresholding[J]. *IEEE Transactions on Information Theory*, 1995, 41(3): 613-627
- [28] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018, Salt Lake City: IEEE, 2018: 7132-7141

[29] Zhao M H, Zhong S S, Fu X Y, Tang B P, Pecht M. Deep residual shrinkage networks for fault diagnosis [J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(7): 4681-4690

[30] 孙棋. 基于数字图像处理技术的水稻氮素营养诊断研究[D]. 杭州: 浙江大学, 2008

Sun Q. Study on nitrogen nutrition diagnosis of rice based on digital image processing technology [D]. Hangzhou: Zhejiang University, 2008 (in Chinese)

责任编辑: 杨爱东



通讯作者简介: 孔杰, 硕士研究生, 就读于江西农业大学软件学院农业工程与信息技术专业。参与国家自然科学基金项目(61562039和62162030)。在校学习期间, 获得江西省计算机创新大赛三等奖一次, 校研究生奖学金多次。



通讯作者简介: 杨红云, 教授, 硕士生导师。中国人工智能学会智能农业专委会、中国自动化学会和中国计算机学会成员。主要从事计算机图形、图像以及机器学习等技术在农业领域的应用研究, 主持国家自然科学基金项目2项, 主持省厅级项目3项, 作为主要成员参与科技部重点研发项目1项、参与国家自然科学基金项目3项和参与其他省厅级项目10余项, 近5年以第一作者或通讯作者发表CSCD核心以上期刊学术论文20余篇; 出版专著1部, 主编教材1部, 作为主要成员荣获江西省教学成果奖一等奖1项以及江西省一流本科课程建设项目1项。