

基于多模态融合的水稻生育期智能识别方法

许永炜¹ 刘淑华² 冯泽霖^{1,3} 罗举² 倪兆新¹ 杨保军² 姚青^{1,*} 李阿根^{4,*}

(¹ 浙江理工大学 计算机科学与技术学院, 杭州 310018; ² 中国水稻研究所, 杭州 311401; ³ 浙江理工大学 信息与控制学院, 杭州 312369; ⁴ 余杭区农业生态与植物保护服务站, 杭州 311100; *通信联系人, email: q-yao@zstu.edu.cn; dbmoth@qq.com)

Intelligent Recognition Method of Rice Growth Stage Based on Multimodal Fusion

XU Yongwei¹, LIU Shuhua², FENG Zelin^{1,3}, LUO Ju², NI Zhaoxin¹, YANG Baojun², YAO Qing^{1,*}, LI Agen^{4,*}

(¹College of Computer Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China; ²China National Rice Research Institute, Hangzhou 311401, China; ³School of Information and Control, Zhejiang Sci-Tech University, Hangzhou 312369, China; ⁴Yuhang Agro-ecological Environment & Crop Protection Service Station, Hangzhou 311100, China; *Corresponding author, email: q-yao@zstu.edu.cn; dbmoth@qq.com)

Abstract: 【Objective】 The growth period of rice is an important reference indicator for irrigation, fertilization, and pest control measures in rice planting management. Researching an intelligent recognition method for rice growth period based on multimodal fusion, improving the accuracy of rice growth period recognition, is of great significance for optimizing rice planting management measures and increasing rice yield. **【Method】** To address the vulnerability of RGB images to lighting, an H-color channel image is extracted, and a dual-branch rice growth stage image recognition model based on residual network and attention mechanism is established; Due to the influence of meteorological factors on the length of rice growth period, a rice growth period meteorological identification model based on three meteorological factors and a bidirectional long-short period network is established; Using decision trees for decision-level multimodal feature fusion, multiple models were trained and tested on a self-built rice growth period dataset. **【Result】** The improved rice growth period image recognition model achieved an accuracy of 84.25%, which is superior to traditional image recognition models such as ResNet50 and ConvNeXt. The multi-modality model based on images and meteorological achieved an accuracy of 87.66% in identifying 9 rice growth stages, which is superior to the single modality recognition model based on images and meteorology. **【Conclusion】** The multimodal recognition model based on image and meteorological fusion compensates for the shortcomings of single modal recognition methods. Compared with single modal recognition models, it has significantly improved the accuracy of identifying 9 rice growth stages.

Keywords: rice growth period; multimodal; image modality; meteorological modality; decision tree

摘要: 【目的】 水稻生育期是水稻种植管理过程中灌溉、施肥和病虫害防控措施的重要参考指标。研究基于多模态融合的水稻生育期智能识别方法, 提高水稻生育期识别准确率, 对优化水稻种植管理措施, 提升水稻产量具有重要意义。 **【方法】** 针对 RGB 图像易受光照影响, 提取 H 颜色通道图像, 建立基于残差网络与注意力机制的双分支水稻生育期图像识别模型; 由于气象因子影响水稻生育期长短, 建立基于 3 个气象因子和双向长短期记忆网络的水稻生育期气象识别模型; 利用决策树进行决策级多模态特征融合, 在自建数据集上进行多种模型的训练和测试。 **【结果】** 改进的水稻生育期图像识别模型准确率达到 84.25%, 优于 ResNet50、ConvNeXt 等传统图像识别模型。基于图像和气象的多模态模型对 9 个水稻生育期识别准确率达到 87.66%, 优于单一图像和气象的单模态识别模型。 **【结论】** 基于图像与气象融合的多模态识别模型弥补了单模态识别方法的不足, 相较于单模态识别模型, 显著提升了对 9 个水稻生育期的识别准确率。

关键词: 水稻生育期; 多模态融合; 图像模态; 气象模态; 决策树

水稻生育期是根据水稻植株在生长过程中发生的形态、生理和器官形成的阶段性变化来定义的, 反映了水稻生命周期的关键转折点^[1]。根据划

分目的、精细程度和研究领域的差异, 水稻生育期一般可粗分为 5 期(苗期、分蘖期、拔节孕穗期、抽穗开花期和成熟期)或细分为苗期、分蘖期、穗分化

收稿日期: 2025-07-10; 修改稿收到日期: 2025-09-09。

基金项目: 浙江省“三农九方”科技协作计划项目(2024SNJF010); 浙江省农业重大技术协同推广计划项目(2023ZDXT01-5)。

期(包含从拔节到孕穗)、抽穗期、开花期(包含从开花到齐穗)、乳熟期、蜡熟期/黄熟期和完熟期等8个或9个生育期^[2-4]。在水稻种植管理中,不同的生育期,水管理、肥料施用和病虫害防控措施有着显著差异。例如,在水管理方面,苗期宜采用间歇性灌溉以促进根系发育;分蘖期需灵活调控灌溉量以促进有效分蘖并抑制无效分蘖;穗分化期应维持5~8 cm的较深水层以缓解干旱胁迫;抽穗期至开花期需维持3~5 cm浅水层,乳熟期则需要进行间歇性灌溉以保持土壤湿润,蜡熟期至完熟期需逐步排水至彻底断水^[5]。在施肥策略方面,苗期应施用磷肥以促进根系发育,同时控制氮肥用量,避免因氮素过量导致植株徒长;分蘖期宜施用高氮复合肥以促进分蘖,并辅以钾肥以增强植株抗性;孕穗期主要通过根部追施方式进行施肥,而穗期则以叶面喷施为主^[6]。病虫害防控方面,苗期易感立枯病、绵腐病,常见害虫包括稻飞虱与稻象甲;分蘖期与穗分化期易感纹枯病,易发稻纵卷叶螟,抽穗期至乳熟期易感稻曲病,蜡熟期易发粘虫,黄熟期至完熟期则应当注意倒伏引发的霉变^[7]。稻曲病的防控关键期为破口抽穗前7 d至齐穗期,其中以破口抽穗前2 d至抽穗期施药效果最佳,防效可达90%以上^[8]。因此,准确识别水稻不同生育期是科学灌溉施肥,高效防控病虫害,提高水稻产量的前提。

传统水稻生育期识别方法主要依赖农业技术人员实地观测,其过程专业依赖性强,主观性大,效率低。随着图像处理技术与人工智能的迅速发展,研究者逐渐采用遥感、无人机、固定摄像头、便携式相机等智能设备采集水稻不同生育阶段的光谱或可见光图像,并结合机器学习或深度学习方法进行不同生育期的自动识别。冯健昭等^[9]利用无人机搭载多光谱相机采集水稻分蘖期、拔节期、抽穗期、乳熟期、完熟期的光谱数据,并通过最小特征冗余算法与极度梯度提升算法构建识别模型,实现了5个关键生育期的识别,平均识别准确率均达到98%以上。张梦茹^[10]使用遥感卫星采集水稻的多波段、多光谱特征数据,通过结合时间卷积网络的局部感知能力与长短期记忆网络的全局记忆优势,设计了TCN-LSTM融合模型,对苗期、拔节孕穗期、乳熟期和黄熟期等4个生育期的识别准确率达到90%以上。杨振忠等^[11]使用无人机搭载多光谱相机采集水稻冠层多光谱影像,结合K近邻(KNN)算法与可见光大气修正指数构建识别模型,对分蘖期、拔节孕穗期、抽穗扬花期和灌浆成熟期等4个生育期识别准确率为86%。上述研究大多采用单一

数据采集设备(无人机或卫星)获取单模态数据(多光谱影像或遥感),识别4~5个生育期。考虑到可见光图像采集设备成本低廉、操作简便,徐建鹏等^[12]利用固定摄像机采集水稻返青期、分蘖期、拔节期、抽穗期和乳熟期的RGB图像,提出了一种基于Rectified Adam优化器的ResNet50卷积神经网络识别模型,5个水稻生育期平均识别准确率达到97.33%。Qin等^[13]通过固定摄像头采集秧苗期、分蘖期、拔节孕穗期、抽穗开花期、灌浆期和成熟期的RGB图像,构建以ResNet-50为主干网络的识别模型,6个生育期的平均准确率为87.33%。Yang等^[14]使用无人机采集水稻返青期、分蘖期、拔节期、抽穗期、灌浆期、成熟期等6个生育期的RGB图像,设计了结合空间金字塔池化(SPP)、迁移学习和辅助分支结构的卷积神经网络(Convolutional Neural Network, CNN)模型,识别准确率达到了83.9%。

随着生育期划分细化,基于单一RGB图像的水稻生育期识别准确率呈下降趋势。研究表明,水稻不同生育期长短受温度、积温、光照等多种气象因子的影响^[15-17]。Shimono等^[18]通过对照实验发现,低温在水稻幼穗分化(panicle initiation)之前的营养生长期即可诱导育性下降,影响水稻正常生长发育。Yano等^[19]研究揭示了水稻抽穗期基因*Hd1*通过感知日照长短调控下游成花素基因*Hd3a*的表达,影响开花时间;在短日照条件下,*Hd1*促进开花,而在长日照下转为抑制,表明太阳辐射对水稻生育期的双向调控作用。Katsura等^[20]通过对比实验发现,高太阳辐射地区(如云南高原)水稻生育期显著缩短,而低辐射地区(如四川盆地)则生育期延长,进一步佐证了光照强度对生育进程的影响。鉴于上述气象因子对水稻生育期的显著调控作用,单一RGB图像模态在识别多阶段生育期时存在一定的误检,本研究利用多种可见光图像采集设备采集RGB图像,结合影响水稻生育期长短的多个气象因子,建立了基于多模态融合的水稻生育期智能识别模型MultiMRiceGS,对水稻苗期、分蘖期、穗分化期、抽穗期、开花期、乳熟期、蜡熟期、黄熟期、完熟期等9个生育期进行识别。

1 材料与方法

1.1 研究技术路线

为实现水稻生育期的智能识别,本研究利用AR眼镜、手机、固定摄像机等图像采集设备采集




图 1 基于多模态的水稻生育期智能识别研究技术路线
Fig. 1. Research technology roadmap for intelligent recognition of rice growth period based on multimodal data

了 4 个水稻品种 9 个生育期的 RGB 图像；同时收集了水稻种植区域覆盖整个生育期的 3 类关键气象数据(每日平均温度、每日太阳辐射值和累积生长度日)。针对 RGB 图像易受光照影响，相邻生育期区分难度大的问题，本研究基于不同生育期图像与多个气象因子的数据建立了多模态融合的水稻生育期识别模型 MultiMRiceGS。针对 RGB 图像易受光照影响和相邻生育期难区分的问题，本研究引入 HSV 色彩空间中的 H 通道特征，构建基于 RGB 与 H 通道特征的水稻生育期图像识别模型。鉴于气象因子对水稻生育期长短具有显著调控作用，本研究以双向长短期记忆网络为主干架构，构建基于气象因子的水稻生育期识别模型，以捕捉气象因子对生育期演化的动态影响。最后采用决策树算法对基于图像与气象两种模态建立的两个模型的识别结果进行决策级融合，以提升水稻生育期整体识别精度与模型鲁棒性(图 1)。

1.2 水稻全生育期图像

2024 年 6 月–11 月，利用头戴式 AR 眼镜(蜂巢世纪 Superhex_Vision-SV1G)、手机(Redmi Note13 pro)、固定摄像机(海康威视，800W 像素)3 种图像采集设备，在浙江省杭州市富阳区的中国水稻研究


所水稻试验田(北纬 30°04'40.0"，东经 119°56'04.3")采集 4 种水稻(黄华占、C 两优华占、甬优 7872 和春优 927)9 个生育期(苗期、分蘖期、穗分化期、抽穗期、开花期、乳熟期、蜡熟期、黄熟期和完熟期)共 8894 幅 RGB 图像。

图像中水稻生育期由中国水稻研究所栽培专家根据田间同期人工检查结果来确定，并以 7:2:1 的比例划分为训练集、验证集和测试集。9 种水稻生育期如图 2 所示。

由于田间环境复杂多变，图像采集过程中常受到光照强度变化、设备抖动及拍摄角度偏差等因素干扰，导致图像质量不稳定，进而影响模型的泛化能力。为提高模型鲁棒性并缓解模型的过拟合问题，本研究对部分训练集和验证集数据进行了数据增强。增强方法包括添加高斯噪声(噪声标准差为 5 至 30)、旋转(旋转角度为-45°至 45°)、亮度变化(变化系数为-30 至 30)、对比度变化(对比度系数为 0.7 至 1.3)。图 3 给出了一幅乳熟期水稻图像在 4 种数据增强处理后的效果图。


1.3 气象数据集

收集了水稻种植区域(北纬 30° 04' 40.0"，东经 119° 56' 04.3")内影响水稻生育期长短的 3 种重要气



A: 苗期; B: 分蘖期; C: 穗分化期; D: 抽穗期; E: 开花期; F: 乳熟期; G: 蜡熟期; H: 黄熟期; I: 完熟期。
A, Seedling stage; B, Tillering stage; C, Panicle initiation stage; D, Heading stage; E, Flowering stage; F, Milk stage; G, Dough period; H, Yellow ripening stage; I, Full-ripening stage.

图 2 水稻 9 个生育期图像
Fig. 2. Images of nine growth stages in rice




A: 原图; B: 添加高斯噪声; C: 旋转; D: 亮度增强; E: 对比度增强。
A, Original image; B, Add Gaussian noise; C, Rotate; D, Brightness enhancement; E, Contrast enhancement.

图 3 乳熟期水稻图像数据增强
Fig. 3. Enhancement of image data of rice during milk ripening period

象因子数据：每日平均温度、每日太阳辐射值 (W/m²)和累积生长度日 (Growing Degree Days, GDD)。
累积生长度日计算公式如下：

$$\text{累积GDD}=\sum_{i=1}^n\left(\frac{T_{\max,i}+T_{\min,i}}{2}-T_{base}\right) \quad 1)$$

其中, n 为水稻移栽日至水稻图像拍摄日的间隔天数, $T_{\max,i}$ 表示第 i 天的最高温度, $T_{\min,i}$ 表示第



A: 每日太阳能辐射值; B: 每日平均温度值; C: 累积生长度日值。

A, Daily solar radiation value; B, Daily average temperature value; C, Accumulated growing degree day value.

图4 2024年水稻全生育期3种气象数据曲线

Fig. 4. Curve charts of three meteorological data during rice entire growth duration in 2024

i 天的最低温度, T_{base} 表示基础温度。由于本研究中的水稻均为晚稻, T_{base} 设置为 12^[21]。

其中, 每日平均温度、最高温度、最低温度和每日太阳能辐射值数据来自 <http://www.visualcrossing.com>。

1.4 基于图像的水稻生育期识别方法

鉴于部分相邻生育期在表型特征上差异较小, 且可见光图像易受光照条件影响, 本研究提出了一种基于残差网络(ResNet)与注意力机制的双分支水稻生育期识别模型 BiIRiceGS。其中, 分支 1 利用多尺度卷积与颜色注意力机制获得增强图像, 然后

输入多层残差网络进行特征提取与映射, 得到中间特征 F_1 ; 分支 2 对原始图像进行多尺度卷积, 提取不同尺度下的特征, 再通过多层残差网络进行特征升维映射, 得到中间特征 F_2 。接着通过残差注意力模块对 F_1 和 F_2 进行融合与映射, 最后使用线性层完成特征映射和降维得到各水稻生育期的置信度。该模型的网络结构如图 5 所示。

1.4.1 颜色注意力增强模块

从水稻生育期 RGB 图像(图 2)可以看出, 苗期、分蘖期和穗分化期的图像差异主要体现在叶色、覆




图 5 BiLRiceGS 模型结构

Fig. 5. Structure diagram of BiLRiceGS model

盖程度和水稻分蘖数量；乳熟期、蜡熟期、黄熟期和完熟期的图像差异主要体现在稻穗的颜色、籽粒的饱满度和稻穗的整体形态等。尽管水稻在不同生育期的颜色特征具有一定的区分度，然而 RGB 图像在实际采集过程中易受光照条件影响，导致即使处于相同生育期，不同图像之间仍可能出现一定的色差。为系统评估不同光照条件对水稻生育期 RGB 图像的影响，本研究从构建的数据集中随机抽取 50 张图像，并对其亮度参数进行调整，以模拟多种光照环境。然后分别统计在不同亮度水平下 RGB 三个通道中像素的平均值变化，绘制响应曲线，以量化光照变化对图像颜色分布的影响(图 6)。


由图 6 可知，随着亮度提高，RGB 三个通道的像素分布整体呈现出明显的右移趋势，表明 RGB 图像在生育期识别任务中对光照变化存在敏感性，可能对模型的识别能力造成干扰。

基于图像的水稻生育期识别主要依赖不同生育阶段在颜色与形态特征上的差异性，特别是水稻后面生育期，稻穗是重要的判别依据。然而，由于相邻生育期之间的时间间隔较短，尤其是在前一生育期末期与当前生育期初期阶段，稻穗颜色变化较为缓慢，色彩差异不显著(图 7)。此外，光照的变化也会显著影响同一生育期图像中稻穗颜色的呈现。上述因素可能导致相邻生育期水稻图像之间的误

判。

为了降低光照对不同生育期图像识别的影响，将 RGB 图像转换到 HSV、LAB 颜色空间，观察不同生育期在不同颜色通道下分布。首先从每个水稻生育期类别中随机抽取 50 幅图像，分别统计图像在 9 个颜色通道上的像素值分布情况。对所有像素数量数据采用归一化处理，绘制不同生育期在不同颜色通道下像素数量分布的脊状图(图 8)。

图 8 中横坐标表示各颜色通道的像素值，纵坐标对应水稻生育期编号，脊状图的高度与该通道中对应像素值的像素点数量成正比。所有通道的像素值均采用 8 位编码方式，其中 HSV 格式中的 H(Hue)通道像素值映射范围为 0~180，其余通道的像素值理论范围均为 0~255，以避免数值溢出。生育期编号 1 至 9 分别对应苗期、分蘖期、穗分化期、抽穗期，开花期、乳熟期、蜡熟期，黄熟期和完熟期。从图 8 可以看出，RGB 三个通道中第 5~9 生育期的颜色分布范围较大，呈现宽峰特征，缺乏明显的区分性。这主要是因为 RGB 通道像素值对光照强度(阴影和高光)敏感，易偏移^[22]。而 HSV 颜色空间的色调(Hue)分量在光照变化时更具稳定性^[23-24]。从图 8 可以看出，不同生育期图像在 H 通道上呈现出多尖峰分布，且颜色分离度显著高于其他通道，有利于不同生育期图像的特征提取。而在 LAB 空间的 L



A: 不同亮度下 R 通道像素平均分布; B: 不同亮度下 G 通道像素平均分布; C: 不同亮度下 B 通道像素平均分布。

A, Average distribution of R channel pixels under different brightness levels; B, Average distribution of G channel pixels under different brightness levels; C, Average distribution of B channel pixels under different brightness levels.


图 6 不同亮度下不同生育期水稻图像在 RGB 通道的分布情况

Fig. 6. Distribution of rice plant images during various growth stages in RGB channels under different brightness levels

通道，各生育期表现出与 RGB 通道类似的特性，虽然在 A 通道和 B 通道表现出尖峰特性，但其像素值分布范围相对集中，在生育期识别任务中的特征分离度较低。基于上述的分析，本研究设计了一种基于多尺度卷积和注意力机制结合的颜色注意力模块。该模块首先将 RGB 图像转换为 HSV 色彩空间，并通过多尺度卷积核提取 H 通道的多尺度颜色特征。RGB 图像转变为 HSV 格式中 H 通道图像的转换公式：

$$\begin{cases} R' = \frac{R}{255}, G' = \frac{G}{255}, B' = \frac{B}{255}, R, G, B \in [0, 255] \\ M = \max(R', G', B'), m = \min(R', G', B'), \Delta = M - m \\ H = \begin{cases} 0^\circ, \Delta = 0 \\ 60^\circ \times \left(\frac{G' - B'}{\Delta} \bmod 6 \right), M = R' \\ 60^\circ \times \left(\frac{B' - R'}{\Delta} + 2 \right), M = G' \\ 60^\circ \times \left(\frac{R' - G'}{\Delta} + 4 \right), M = B' \end{cases} \end{cases} \quad (2)$$


式中， R' 、 G' 、 B' 为原始图像 R 、 G 、 B 归一化后的值。



A: 开花期末期; B: 乳熟期初期; C: 乳熟期末期; D: 蜡熟期初期; E: 蜡熟期末期; F: 黄熟期初期; G: 黄熟期末期; H: 完熟期初期。
A, Late flowering stage; B, Early milky-ripening stage; C, Late milky-ripening stage; D, Early dough-ripening stage; E, Late dough-ripening stage; F, Early yellow-ripening stage; G, Late yellow-ripening stage; H, Early full-ripening stage.

图 7 水稻相邻生育期末期与初期图像

Fig. 7. Photographs of rice plants at successive late and early growth stages



A: RGB 格式 R 通道; B: RGB 格式 G 通道; C: RGB 格式 B 通道; D: HSV 格式 H 通道; E: HSV 格式 S 通道; F: HSV 格式 V 通道; G: LAB 格式 L 通道; H: LAB 格式 A 通道; I: LAB 格式 B 通道。

A, RGB format R channel; B, RGB format G channel; C, RGB format B channel; D, HSV format H channel; E, HSV format S channel; F, HSV format V channel; G, LAB format L channel; H, LAB format A channel; I, LAB format B channel.

图 8 九个水稻生育期图像在不同通道像素分布的脊状图

Fig. 8. Ridge plots of pixel distribution in different color channels for random images at nine growth stages

在获得 H 通道图像后,通过多尺度卷积,捕捉图像的颜色分布特征,再将平均池化结果归一化后作为原始图像的颜色注意力权重,最后通过将权重注意力作用于 RGB 图像得到颜色注意力增强图像。颜色注意力机制增强前后的水稻 9 个生育期图像如图 9 所示。

1.4.2 残差注意力模块

从图 9 可以看出,经过颜色注意力机制增强后

的图像虽然突出了不同生育期关键特征区域,但也导致图像细节模糊,影响模型对精细特征的识别。为了提高模型的识别准确率,对水稻 RGB 图像使用多尺度卷积核进行不同尺度的图像特征提取。同时,为了提高模型的鲁棒性并保留浅层特征信息,引入残差网络对多尺度特征进行处理。残差网络不仅有助于提取深层特征,还能通过跳跃连接机制缓解浅层特征在深层网络中逐渐消失的问题,从而提




图 9 原始图像和颜色注意力增强图像

Fig. 9. Original image and color attention enhanced image




图 10 基于气象数据的水稻生育期识别模型 MDRiceGS 网络结构

Fig. 10. MDRiceGS network structure diagram of rice growth period recognition model based on meteorological data

升整体特征表达能力。原始图像特征和经过颜色注意力机制增强的图像特征在经过残差注意力网络处理后得到了两组不同的深层特征。

针对传统 CNN 架构在处理特征时无法高效建立不同位置特征间关联性的问题，本研究将两个分支输出的特征张量进行拼接，并在每个张量上添加可学习的位置编码，通过结合注意力机制实现长距离特征的融合。相较于传统的注意力机制，残差注意力机制通过跳跃连接的方式将残差注意力模块的输入特征直接加到输出特征上，可以有效缓解注意力机制深层网络的退化，增强了特征选择能力，同时提升了模型的鲁棒性。注意力机制的核心公式^[25]如下：

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3)$$

其中 Q , K , V 分别表示注意力机制中的查询向量、键向量、值向量，由输入特征经过线性化操作后得到。 K^T 为向量 K 的转置，缩放因子 d_k 为输入特征矩阵的维度，用以确保梯度在反向传播时保持稳定。

1.5 基于气象数据的水稻生育期识别方法

气象因子中每日和多日的平均温度、太阳辐射值和累积生长度日对水稻生育期长短具有显著影响。考虑到双向长短期记忆网络在建立时序数据的全局依赖关系方面相较于传统卷积神经网络更具有优势^[26-27]，本研究设计了一种融合双向长短期记忆网络 (BiLSTM) 与多层感知机 (Multilayer Perceptron) 的水稻生育期识别模型 MDRiceGS，以探讨气象数据在生育期判别任务中的应用潜力。MDRiceGS 网络结构如图 10 所示。




图 11 LSTM 单元结构

Fig. 11. LSTM unit structure diagram

MDRiceGS 以基于时序排列的气象数据, 即每日平均温度、每日太阳辐射值(W/m^2)和累积生长度日作为输入。数据长度为自水稻移栽日至图像拍摄结束日期的天数, 本研究中为 135。MDRiceGS 首先通过双向长短期记忆网络提取基于时序的气象特征 F_1 至 F_n , 然后通过多层感知机 (Multilayer Perceptron) 对气象特征进行重映射和降维, 输出结果为 9 个生育期类别的置信度值。单个的 LSTM 通过三个门控机制和一个记忆单元实现数据信息的流动控制, LSTM 单元结构^[28]如图 11 所示。其中, f_n 表示遗忘门, i_n 为输入门, o_n 为输出门, h_n 表示当前单元的隐藏状态, C_n 表示当前细胞状态, $\tilde{C}_n$ 表示候选细胞状态, x_n 表示单元的当前输入特征, σ 表示激活函数, W 表示各门对应的可学习参数矩阵, b 表示各门对应的偏置系数, 各参数计算公式如下:

$$\begin{cases} C_n = f_n \odot C_{n-1} + i_n \odot \tilde{C}_n \\ h_n = o_n \odot \tanh(C_n) \\ f_n = \sigma(W_f * [h_{n-1}, x_n] + b_f) \\ i_n = \sigma(W_i * [h_{n-1}, x_n] + b_i) \\ o_n = \sigma(W_o * [h_{n-1}, x_n] + b_o) \\ \tilde{C}_n = \tanh(W_c * [h_{n-1}, x_n] + b_c) \end{cases} \quad (4)$$

1.6 多模态融合算法

多模态特征融合是多模态模型运行过程中的关键环节, 直接影响到模型的最终性能。特征级融合虽然保留了不同模态间的底层关联, 但对各模态的噪声有较高敏感性, 且部分模态特征的缺失会导致模型整体的失效^[29]。为了提高水稻生育期识别准确率, 本研究将基于图像的 BiIRiceGS 和基于气象的 MDRiceGS 的两个模型进行决策级特征融合, 构建了多模态水稻生育期识别模型 MultiMRiceGS, 以增强模型对模态缺失与噪声干扰的鲁棒性。

决策树^[30]是一种经典的监督学习算法, 广泛应用于分类和回归任务。其核心思想是通过递归地划分特征空间, 构建树形结构以实现数据的高效分类或预测。相较于基于全连接层的拟合方法, 决策树具有较强的可解释性, 无需对输入数据进行归一化操作, 计算量大大减小。在本研究使用 Gini impurity(基尼不纯度)作为引导决策树优化分类的主要指标, 其计算公式如式 5) 所示。

$$\text{Gini}(D) = 1 - \sum_{k=1}^K p_k^2 \quad (5)$$

其中, k 表示生育期总数($k=9$), p_k 表示在以输入数据的某一特征作为分类阈值比较对象的情况下被分类到生育期 k 的样本在整个数据集中的占比。

该算法通过持续优化特征选择与阈值划分, 降低节点的基尼不纯度, 从而实现整体分类性能的优化。MDRiceGS 模型和 BiIRiceGS 模型通过独立训练得到权重值, 独立输出 9 个生育期的置信度值。然后将两个模型的置信度向量进行拼接, 形成联合特征表示, 并输入至决策树分类器。决策树算法依据训练阶段获得的最优阈值, 对输入特征进行逐层判别, 从而输出多模态融合模型的最终识别结果。决策树结构如图 12 所示。

1.7 实验环境

模型训练和测试的硬件环境为内存为 128G, CPU 为 AMD EPYC 7543 32-Core Processor, GPU 为 NVIDIA GeForce RTX 4090, 操作系统为 Ubuntu 24.04.2 LTS, 选用的深度学习开源架构为 pytorch。

1.8 评估指标

为验证本研究提出的水稻生育期识别算法的有效性, 采用准确率(Accuracy)、精确率(Precision)、召回率(Recall)、 F_1 值作为不同分类模型的性能评价指标。它们的计算方法如公式 6) 所示。




图 12 水稻生育期识别决策树模型结构
Fig. 12. Structure diagram of decision tree model for rice growth period recognition

$$\left\{ \begin{array}{l} Accuracy = \frac{\sum_{i=1}^9 TP_i}{\sum_{i=1}^9 (TP_i + FP_i)} \\ Precision_i = \frac{TP_i}{TP_i + FP_i}, Precision = \frac{1}{9} \sum_{i=1}^9 Precision_i \\ Recall_i = \frac{TP_i}{TP_i + FN_i}, Recall = \frac{1}{9} \sum_{i=1}^9 Recall_i \\ F_1 = \frac{1}{9} \sum_{i=1}^9 2 \times \frac{Precision_i \times Recall_i}{Precision_i + Recall_i} \end{array} \right. \quad (6)$$

其中, TP_i 表示实际属于第 i 生育期且被正确预测为第 i 生育期的样本数, FP_i 表示实际不属于第 i 生育期但被错误预测为第 i 生育期的样本数, FN_i 表示属于第 i 生育期但被错误预测为其他生育期的样本数。

2 结果与分析

2.1 基于图像的水稻生育期识别模型 BiIRiceGS 结果与分析

2.1.1 不同改进策略对 BiIRiceGS 识别结果的影响

基于图像的双分支水稻生育期模型 BiIRiceGS 在残差网络基础上添加颜色注意力模块和残差注意力模块。为了验证这两个模块对水稻生育期识别的影响, 在水稻生育期图像数据集上进行了消融实验。

由表 1 可知, 加入颜色注意力模块带来了模型性能的显著提升, 其中准确率提升 5.16 个百分点,

召回率提升 5.17 个百分点。加入残差注意力模块后, 准确率提升 1.92 个百分点, 召回率提升 1.94 个百分点。最终, BiIRiceGS 对于水稻 9 个生育期识别准确率和精确率分别提高了 7.08 个百分点和 7.04 个百分点, 召回率提高了 7.12 个百分点, F_1 值提高了 7.07 个百分点。

2.1.2 基于图像的不同网络模型识别结果的比较

为客观评价本研究中提出的基于图像的双分支水稻生育期模型 BiIRiceGS 性能, 本研究选取了 AlexNet^[31]、GoogleNet^[32]、ResNet50^[33]、ConvNeXt^[34]、Vit-B-16^[35] 模型在相同的图像数据集上进行训练与测试。

由表 2 可知, ConvNeXt 模型和 Vit-B-16 模型的性能弱于传统的残差卷积网络模型 ResNet50, 本研究基于残差网络和注意力机制设计改进的 BiIRiceGS 模型各项评价指标均优于 ResNet50 模型。

2.1.3 BiIRiceGS 对不同品种水稻生育期的识别结果与分析

为客观评价 BiIRiceGS 模型对不同品种水稻生育期识别效果, 分别对黄华占、C 两优华占、甬优 7872、春优 927 四个品种的水稻生育期图像进行识

表 1 基于残差网络的 BiIRiceGS 模型消融实验

Table 1. Ablation experiment of BiIRiceGS model based on Resnet						%
颜色注意力模块	残差注意力模块	准确率	精确率	召回率	F ₁ 值	
Color attention module	Residual attention module	Accuracy	Precision	Recall	F ₁ value	
×	×	77.17	77.42	77.08	77.13	
√	×	82.33	82.55	82.25	82.26	
×	√	79.09	79.15	79.02	78.99	
√	√	84.25	84.46	84.20	84.20	

表 2 不同模型对水稻生育期识别性能对比

Table 2. Comparison of recognition performance of different models for rice growth period				%
模型 Model	准确率 Accuracy	精确率 Precision	召回率 Recall	F_1 值 F_1 value
AlexNet	72.76	73.44	73.06	72.80
GoogleNet	76.60	77.29	77.15	76.67
ResNet50	80.80	80.93	81.13	80.71
ConvNeXt	76.08	76.82	76.61	69.92
Vit-B-16	74.54	75.31	74.92	74.64
BiRiceGS	84.25	84.46	84.20	84.20

表 3 BiRiceGS 模型针对不同品种水稻的识别结果

Table 3. Recognition results of BiRiceGS model for different varieties of rice				%
水稻品种 Rice variety	准确率 Accuracy	精确率 Precision	召回率 Recall	F_1 值 F_1 value
黄华占 Huanghuazhan	84.38	84.58	84.27	83.87
C 两优华占 C Liangyouhuazhan	83.21	83.56	82.97	82.71
甬优 7872 Yongyou 7872	86.91	87.31	87.03	87.10
春优 927 Chunyou 927	82.31	82.84	81.96	82.09

表 4 不同 BiLSTM 层数的 MDRiceGS 对水稻生育期的识别结果

Table 4. Recognition results of rice growth period using MDRiceGS with different BiLSTM layers					
BiLSTM 层数 BiLSTM layer	准确率 Accuracy(%)	精确率 Precision(%)	召回率 Recall(%)	F_1 值 F_1 value (%)	参数量 Parameter quantity
1	76.80	76.87	76.76	76.85	9.35M
2	77.51	77.49	77.44	77.43	9.74M
3	77.87	77.82	77.75	77.74	10.14M
4	77.34	77.31	77.25	77.24	10.53M

别测试。

从表 3 可以看出，BiRiceGS 模型能够较好的识别出这四种水稻品种的生育期，表明该模型具有较好的鲁棒性。

2.2 基于气象数据的水稻生育期识别模型 MDRiceGS 结果与分析

2.2.1 不同 BiLSTM 层数对 MDRiceGS 识别结果的影响

为评估双向长短期记忆网络层数对 MDRiceGS 模型性能的影响，本研究设置了 1 至 4 层进行模型的训练与测试。

由表 4 可知，当 BiLSTM 层数为 3 的时候，MDRiceGS 拥有最佳的性能，且参数量相较于 1 层和 2 层 BiLSTM 网络并未显著增加，因此 MDRiceGS 模型使用 3 层 BiLSTM 网络。

2.2.2 MDRiceGS 对不同品种水稻生育期识别结果

基于 3 种气象数据的 MDRiceGS 对 4 种水稻品种 9 个水稻生育期的识别结果见表 5。

从表 5 可以看出，MDRiceGS 模型对四种水稻生育期识别效果相差不大。从表 3 和表 5 可以看

出，基于气象的 MDRiceGS 模型的整体识别准确率和召回率逊色于基于图像的 BiRiceGS 模型。

2.3 基于多模态的水稻生育期识别模型的结果与分析

2.3.1 不同深度的决策树算法对水稻生育期识别的影响

为评估决策树深度对多模态特征融合算法参数量和融合性能的影响，设置决策树深度为 4~7，并在相同数据集上进行训练与测试，结果如表 6 所示。

由表 6 可知，在决策树算法的深度达到 6 后准确率不再提升，但是参数量显著提升，因此，选择决策树算法深度为 6。

2.3.2 不同融合算法对水稻生育期识别结果的影响

为选择最优特征融合算法，评估不同特征融合算法对模型的最终识别效果和参数量的影响，本研究在相同数据集上使用经典的决策级融合算法(决策树，随机森林)和特征级融合算法(多层感知机)进行对比实验，实验结果如表 7 所示。

表 5 MDRiceGS 模型针对不同品种水稻生育期的识别结果

Table 5. Recognition results of MDRiceGS model for growth period of different rice varieties				%
水稻品种 Rice variety	准确率 Accuracy	精确率 Precision	召回率 Recall	F_1 值 F_1 value
黄华占 Huanghuazhan	77.78	78.36	77.50	77.78
C 两优华占 C Liangyouhuazhan	77.86	77.84	77.67	77.51
甬优 7872 Yongyou 7872	78.19	78.00	78.05	77.91
春优 927 Chunyou 927	77.62	77.64	77.47	77.21
平均值 Mean	77.87	77.82	77.75	77.74

表 6 不同决策树深度对水稻生育期的识别结果

Table 6. Recognition results of rice growth period based on different decision tree depths					
决策树深度 Decision tree depth	准确率 Accuracy(%)	精确率 Precision(%)	召回率 Recall(%)	F_1 值 F_1 value(%)	参数量 Parameter quantity
4	71.24	71.27	71.24	71.05	4.86 kb
5	86.53	86.43	86.42	86.49	7.25 kb
6	87.66	87.54	87.56	87.53	9.64 kb
7	87.66	87.54	87.56	87.53	12.8 kb

表 7 不同融合算法对水稻生育期的识别结果

Table 7. Recognition results of rice growth period using different fusion algorithms					
融合算法 Fusion algorithm	准确率 Accuracy (%)	精确率 Precision(%)	召回率 Recall(%)	F_1 值 F_1 value(%)	融合模块参数量 Fusion module parameter quantity
多层感知机 Multilayer perceptrons	81.45	81.33	81.32	81.30	1.25 Mb
随机森林 Random forest	87.75	87.61	87.65	87.61	87.60 kb
决策树(深度为 6) Decision tree (depth of 6)	87.66	87.54	87.56	87.53	9.64 kb

表 8 MultiMRiceGS 模型对四种水稻生育期的识别结果

Table 8. Recognition results of growth stages of four types of rice using MultiMRiceGS model					%
水稻品种 Rice variety	准确率 Accuracy	精确率 Precision	召回率 Recall	F_1 值 F_1 value	
黄华占 Huanghuazhan	88.19	88.20	88.07	87.96	
C 两优华占 C Liangyouhuazhan	87.50	87.30	87.30	87.21	
甬优 7872 Yongyou 7872	87.92	88.32	87.96	87.88	
春优 927 Chunyou 927	87.00	87.11	86.87	86.91	

由表 7 可知，多层感知机融合方法在保留模型特征的同时也保留了模型各自的噪声，导致融合效果的下降。而随机森林和决策树算法对多模态特征进行决策级融合，性能基本相当。但决策树的参数量仅为随机森林的 11%，因此，我们最终采用决策树作为多模态融合算法。

2.3.3 MultiMRiceGS 对不同品种水稻生育期的识别结果与分析

MultiMRiceGS 对四种水稻生育期识别结果见表 8，MultiMRiceGS 模型在各个品种的水稻生育期识别任务中未出现明显的过拟合现象，表现出了良好的鲁棒性。


由表 8 可知，MultiMRiceGS 模型在各个品种

的水稻生育期识别任务中未出现明显的过拟合现象，表现出了较好的鲁棒性

2.3.4 不同模态的识别模型对不同水稻生育期的识别结果

基于图像的水稻生育期识别模型 BiIRiceGS、基于气象的水稻生育期识别模型 MDRiceGS 和基于多模态的水稻生育期识别模型 MultiMRiceGS 在 9 个水稻生育期识别结果混淆矩阵如图 13 所示。

从图 13 可以看出，图像和气象模态的两个识别模型在抽穗期和开花期这两个生育期容易发生误判，主要原因在于这两个生育期持续时间较短，且不同品种水稻的生育期存在交叉，仅图像或气象信息无法提取足够准确识别此生育期的特征。虽然



A: 图像模型混淆矩阵; B: 气象模型混淆矩阵; C: 多模态模型混淆矩阵。

A, Image model confusion matrix; B, Meteorological model confusion matrix; C, Multimodal model confusion matrix.

图 13 不同模型对 9 个水稻生育期识别的混淆矩阵

Fig. 13. Confusion matrix for recognizing 9 rice growth stages using different models

图像模型的整体识别准确率较高,但对不同生育期图像的误判结果分布较为分散,大部分误判结果分布在相邻的左右四个生育期。而气象模型的误判结果大多分布在左右两个生育期,在图像模型中较难识别的生育期图像可以通过气象模型进行校正。本研究使用决策级多模态融合算法对两个模态的识别结果进行融合,融合结果表明各生育期的识别准确率都有所上升,表现出了图像模型和气象模型识别结果的互补性,融合结果混淆矩阵如图 13-C 所示。

3 讨论

为评估 RGB 图像在水稻生育期识别任务中的应用潜力,本研究利用手机、固定摄像头、AR 眼镜等多种设备采集了 4 种水稻品种 9 个生育期的 RGB 图像数据,不同设备的拍摄角度和距离有较大差异,有助于提升数据的表征能力与模型的泛化性能。考虑到不同水稻品种在各生育期的形态特征存在一定差异,后续将采集更多品种水稻的图像数据进行训练和测试,进一步提升模型的适应性与泛化能力。

为降低光照变化对水稻生育期图像中颜色特征的影响,本研究利用 HSV 颜色空间的 H 通道图像,结合注意力机制和多尺度卷积设计了颜色注意力模块。该模块能够有效减轻光照对图像颜色分布的影响,增强各生育期图像中关键区域的显著性。然而,在穗分化期与抽穗期等颜色特征差异较小的阶段,该模块的特征提取能力仍存在一定局限性。在不同模型对比实验中, Vision-Transformer(ViT)结构模型识别效果均逊色于以卷积操作为核心的传统神经网络。原因在于规模较小的数据集无法提供足够的

多样性来训练 Vision-Transformer(ViT)结构模型的庞大参数量,未在大规模数据(如 JFT-300M)上预训练的 ViT,性能甚至低于 ResNet^[35]。Tan 等^[36]同样选择使用残差网络模型作为主干网络设计了 RiceRes2Net 模型,此模型通过目标识别算法从背景图中准确筛选出稻穗,再通过稻穗特征反推水稻生育期,但仅识别孕穗期、抽穗期和灌浆期这 3 个有穗的生育期;而本研究设计的 BiIRiceGS 模型识别 9 个水稻生育期,后续研究过程中可考虑引入目标检测机制,先对图像中的每个生育期关键特征进行精确定位,再通过特征反向推理实现生育期识别。

基于气象数据的 MDRiceGS 输入数据中的积温数据是通过固定的基础温度计算获得的。水稻生长过程中对于温度的响应并非非线性关系,极端温度影响水稻生长相关关键酶活性,造成积温误差显著增加^[37]。在后续研究过程中,可以考虑使用动态阈值计算水稻积温以减小极端气温对于积温计算的影响。

本研究使用决策树算法进行多模态特征的融合,虽然在测试集上表现出了较好的融合效果,随着不同水稻品种数据的扩展,决策树算法通过递归地选择“最优特征”和“最优分割点”来分裂节点,但这种选择是局部贪婪的(每一步追求当前最优,而非全局最优),这会导致模型过度关注训练数据的细节,忽略整体泛化性^[38]。后续研究过程中将探索更多融合方法,提高模型融合效果。

4 结论

水稻生育期是指导灌溉、施肥及病虫害防控等农艺管理措施的关键参考指标,准确识别水稻生育

期对优化水稻种植管理措施、提升水稻产量具有重要意义。为实现苗期、分蘖期、拔节孕穗期、抽穗期、开花期、乳熟期、蜡熟期、黄熟期和完熟期等 9 个水稻生育期的识别任务, 本研究设计了一个基于图像和气象数据的多模态水稻生育期识别模型 MultiMRiceGS。其中图像模态的 BiIRiceGS 识别模型通过添加颜色注意力模块, 有效降低了光照变化对图像颜色特征的干扰, 增强了生育期关键区域的显著性表达。同时结合残差网络与残差注意力模块, 提升了模型的识别准确率。实验结果表明 BiIRiceGS 模型的识别准确率、精确率、召回率、 F_1 值分别达到 84.25%、84.45%、84.20%、84.20%, 相较于传统图像分类模型, 在准确率、精确率、召回率等多项指标上都得到了提升。基于气象数据的 MDRiceGS 模型通过对输入的气象数据(日平均温度、每日太阳辐射值和累积生长度日)进行训练获得, 对水稻生育期识别准确率、精确率、召回率、 F_1 值分别为 77.87%、77.82%、77.75%、77.74%。通过决策树算法对两个模态的识别结果进行决策级融合, 使 MultiMRiceGS 模型的准确率、精确率、召回率、 F_1 值均取得了一定的提高, 分别达到了 87.66%、87.54%、87.56%、87.53%。

参考文献:

- [1] 丁颖. 中国水稻栽培学[M]. 北京: 农业出版社, 1961.
Ding Y. Rice Cultivation in China[M]. Beijing: Agriculture Press, 1961. (in Chinese)
- [2] Yoshida S. Fundamentals of Rice Crop Science[M]. Los Banos: International Rice Research Institute, 1981.
- [3] Counce P A, Keisling T C, Mitchell A J. A uniform, objective, and adaptive system for expressing rice development[J]. *Crop Science*, 2000, 40(2): 436-443.
- [4] Bouman B A M. ORYZA2000: Modeling Lowland Rice[M]. Los Banos: International Rice Research Institute, 2001.
- [5] Lampayan R M, Rejesus R M, Singleton G R, Bouman B A M. Adoption and economics of alternate wetting and drying water management for irrigated lowland rice[J]. *Field Crops Research*, 2015, 170: 95-108.
- [6] Dobermann A. Rice: Nutrient Disorders & Nutrient Management[M]. Los Banos: International Rice Research Institute, 2000.
- [7] 郝东川. 水稻病虫害诊断与防治技术[M]. 广州: 广东科技出版社, 2024.
Hao D C. Diagnosis and Control Techniques for Rice Diseases and Pests [M]. Guangzhou: Guangdong Science and Technology Press, 2024.
- [8] 杜余能, 贾贤生, 陈永忠, 杨兵, 胡超, 程大流. 水稻稻曲病防治适期研究[J]. 安徽农业科学, 2004, 32(1): 39.
Du Y N, Jia X S, Chen Y Z, Yang B, Hu C, Cheng D L. Study on the suitable time of the control of false smut of rice plant[J]. *Journal of Anhui Agricultural Sciences*, 2004, 32(1): 39. (in Chinese with English abstract)
- [9] 冯健昭, 潘永琪, 熊悦淞, 吴彻, 肖德琴. 基于 mRMR-XGBoost 的水稻关键生育期识别[J]. 农业工程学报, 2024, 40(15): 111-118.
Feng J Z, Pan Y Q, Xiong Y S, Wu C, Xiao D Q. Rice key growth stage identification based on mRMR-XGBoost[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2024, 40(15): 111-118. (in Chinese with English abstract)
- [10] 张梦茹. 基于 TCN-LSTM 深度学习模型的水稻生育期卫星遥感识别[D]. 武汉: 湖北大学, 2022.
Zhang M R. Satellite remote sensing identification of rice growth period based on TCN-LSTM deep learning model[D]. Wuhan: Hubei University, 2022. (in Chinese with English abstract)
- [11] 杨振忠, 方圣辉, 彭漪, 龚龔, 王东. 基于机器学习结合植被指数阈值的水稻关键生育期识别[J]. 中国农业大学学报, 2020, 25(1): 76-85.
Yang Z Z, Fang S H, Peng Y, Gong Y, Wang D. Recognition of the rice growth stage by machine learning combined with vegetation index threshold[J]. *Journal of China Agricultural University*, 2020, 25(1): 76-85. (in Chinese)
- [12] 徐建鹏, 王杰, 徐祥, 琚书存. 基于 RAdam 卷积神经网络的水稻生育期图像识别[J]. 农业工程学报, 2021, 37(8): 143-150.
Xu J P, Wang J, Xu X, Ju S C. Image recognition for different developmental stages of rice by RAdam deep convolutional neural networks[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2021, 37(8): 143-150. (in Chinese)
- [13] Qin J, Hu T, Yuan J, Liu Q, Wang W, Liu J, Guo L, Song G. Deep-learning-based rice phenological stage recognition[J]. *Remote Sensing*, 2023, 15(11): 2891.
- [14] Yang Q, Shi L, Han J, Yu J, Huang K. A near real-time deep learning approach for detecting rice phenology based on UAV images[J]. *Agricultural and Forest Meteorology*, 2020, 287: 107938.
- [15] 许轲, 孙圳, 霍中洋, 戴其根, 张洪程, 刘俊, 宋云生, 杨大柳, 魏海燕, 吴爱国, 王显, 吴冬冬. 播期、品种类型对水稻产量、生育期及温光利用的影响[J]. 中国农业科学, 2013, 46(20): 4222-4233.
Xu K, Sun Z, Huo Z Y, Dai Q G, Zhang H C, Liu J, Song Y S, Yang D L, Wei H Y, Wu A G, Wang X, Wu D D. Effects of seeding date and variety type on yield, growth stage and utilization of temperature and sunshine in rice[J]. *Scientia Agricultura Sinica*, 2013, 46(20): 4222-4233. (in Chinese)

- Chinese with English abstract)
- [16] 苏李君, 刘云鹤, 王全九. 基于有效积温的中国水稻生长模型的构建[J]. *农业工程学报*, 2020(1): 162-174.
Su L J, Liu Y H, Wang Q J. Rice growth model in China based on growing degree days[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2020(1): 162-174. (in Chinese with English abstract)
 - [17] 蔡昆争, 骆世明. 不同生育期遮光对水稻生长发育和产量形成的影响[J]. *应用生态学报*, 1999, 10(2): 193-196.
Cai K Z, Luo S M. Effect of shading on growth, development and yield formation of rice[J]. *Chinese Journal of Applied Ecology*, 1999, 10(2): 193-196. (in Chinese)
 - [18] Shimono H, Okada M, Kanda E, Arakawa I. Low temperature-induced sterility in rice: Evidence for the effects of temperature before panicle initiation[J]. *Field Crops Research*, 2007, 101(2): 221-231.
 - [19] Yano M, Katayose Y, Ashikari M, Yamanouchi U, Monna L, Fuse T, Baba T, Yamamoto K, Umehara Y, Nagamura Y, Sasaki T. Hd1, a major photoperiod sensitivity quantitative trait locus in rice, is closely related to the Arabidopsis flowering time gene CONSTANS[J]. *The Plant Cell*, 2000, 12(12): 2473-2483.
 - [20] Katsura K, Maeda S, Lubis I, Horie T, Cao W, Shiraiwa T. The high yield of irrigated rice in Yunnan, China[J]. *Field Crops Research*, 2008, 107(1): 1-11.
 - [21] Yin X, Kropff M J, McLaren G, Visperas R M. A nonlinear model for crop development as a function of temperature[J]. *Agricultural and Forest Meteorology*, 1995, 77(1/2): 1-16.
 - [22] Guo Y, Liu Y, Georgiou T, Lew M S. A review of semantic segmentation using deep neural networks[J]. *International Journal of Multimedia Information Retrieval*, 2018, 7(2): 87-93.
 - [23] Geusebroek J M, van den Boomgaard R, Smeulders A W M, Geerts H. Color invariance[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(12): 1338-1350.
 - [24] Kolkur S, Kalbande D, Shimpi P, Bapat C, Jatakia J. Human skin detection using RGB, HSV and YCbCr color models[EB/OL]. 2017: arXiv: 1708.02694. <https://arxiv.org/abs/1708.02694>
 - [25] Vaswani A, Shazeer N, Parmar N. Attention is all your need[J]. *Advances in Neural Information Processing Systems*, 2017, 30.
 - [26] Le P, Zuidema W. Quantifying the vanishing gradient and long distance dependency problem in recursive neural networks and recursive LSTMs[EB/OL]. 2016: arXiv: 1603.00423. <https://arxiv.org/abs/1603.00423>
 - [27] Schuster M, Paliwal K K. Bidirectional recurrent neural networks[J]. *IEEE Transactions on Signal Processing*, 1997, 45(11): 2673-2681.
 - [28] Yu Y, Si X, Hu C, Zhang J. A review of recurrent neural networks: LSTM cells and network architectures[J]. *Neural Computation*, 2019, 31(7): 1235-1270.
 - [29] Ramachandram D, Taylor G W. Deep multimodal learning: A survey on recent advances and trends[J]. *IEEE Signal Processing Magazine*, 2017, 34(6): 96-108.
 - [30] Loh W Y. Classification and regression trees[J]. *WIREs Data Mining and Knowledge Discovery*, 2011, 1(1): 14-23.
 - [31] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
 - [32] Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 7-12, 2015. Boston, MA, USA. IEEE, 2015: 1-9.
 - [33] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 27-30, 2016. Las Vegas, NV, USA: IEEE, 2016: 770-778.
 - [34] Liu Z, Mao H, Wu C Y, Feichtenhofer C, Darrell T, Xie S. A ConvNet for the 2020s[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 18-24, 2022. New Orleans, LA, USA: IEEE, 2022: 11966-11976.
 - [35] Dosovitskiy A, Beyer L, Kolesnikov A. An image is worth 16x16 words: Transformers for image recognition at scale[J]. *ICLR*, 2020: arXiv preprint arXiv: 2010.11929.
 - [36] Tan S, Lu H, Yu J, Lan M, Hu X, Zheng H, Peng Y, Wang Y, Li Z, Qi L, Ma X. In-field rice panicles detection and growth stages recognition based on RiceRes2Net[J]. *Computers and Electronics in Agriculture*, 2023, 206: 107704.
 - [37] van Oort P A J, Zhang T, de Vries M E, Heinemann A B, Meinke H. Correlation between temperature and phenology prediction error in rice (*Oryza sativa* L.)[J]. *Agricultural and Forest Meteorology*, 2011, 151(12): 1545-1555.
 - [38] Blockeel H, Devos L, Frénay B, Nanfack G, Nijssen S. Decision trees: From efficient prediction to responsible AI[J]. *Frontiers in Artificial Intelligence*, 2023, 6: 1124553.