



中国科学院大学
University of Chinese Academy of Sciences

博士学位论文

基于物候模型和机器学习的水稻产量估测及
气候适宜性种植策略

作者姓名： 谭姣姣

指导教师： 于强研究员、赵刚研究员

中国科学院教育部水土保持与生态环境研究中心

学位类别： 理学博士

学科专业： 生态学

培养单位： 中国科学院教育部水土保持与生态环境研究中心

2025 年 9 月

Rice Yield Prediction and Climate-Suitable Planting Strategies
Based on Phenological Models and Machine Learning

A dissertation submitted to
University of Chinese Academy of Sciences
in partial fulfillment of the requirement
for the degree of
Doctor of Natural Science
in Ecology

By

Supervisor:

Qiang Yu, Gang Zhao

Institute of Soil and Water Conservation, CAS & MWR

September, 2025

摘要

水稻是我国粮食安全体系的战略性主粮作物，其产量与气候变化密切相关。当前，正面临全球气温升高、极端气候事件频发、劳动力成本上升以及资源环境约束等挑战，日益威胁水稻生产的可持续性。鉴于这些挑战，当前水稻生产管理中有几个关键问题亟待解决。传统物候模型在大尺度应用时缺乏足够的准确性，作物模型难以有效整合多源异构数据，区域种植策略则存在适应性不足以及缺乏科学优化方法的问题。针对这些问题，本文研究了水稻生长发育与产量形成过程，围绕物候模拟、产量估算和管理决策优化构建了气候适宜性的技术体系。首先，通过环境聚类提升物候模型在区域尺度上的模拟精度，并为产量建模提供关键变量；然后，基于机器学习构建高精度产量估算模型，并明确影响产量形成的重要因素；最后，在前两部分基础上实现播期调整和品种选择的多目标优化，形成区域气候适应性种植策略。本文的主要研究成果如下：

（1）基于环境聚类的物候模型升尺度

本研究针对传统物候模型在大尺度应用中的理论与技术瓶颈，提出了基于环境聚类的物候模型升尺度方法，有效提高了传统物候模型在大区域应用中的精度。研究发现，即使对同一水稻品种汕优 63，其热需求参数在不同环境条件下仍表现出显著差异，挑战了传统物候模型基于常数积温的理论假设。本研究采用环境聚类方法，显著降低了区域尺度上水稻五个关键发育阶段的模拟误差，其中分蘖期从 1.8 天降至 1.4 天，拔节期从 5.3 天降至 3.7 天，孕穗期从 5.6 天降至 3.9 天，抽穗期从 4.7 天降至 3.3 天，成熟期从 6.6 天降至 3.7 天。研究还发现，三段式分段线性温度响应函数模型表现最佳，且随着研究尺度扩大，光周期对模型模拟精度的影响愈发显著。这一方法为物候模型在区域和全球尺度应用提供了新的技术路径。

（2）基于随机森林算法的水稻产量估算模型

根据 2007~2018 年全国水稻新品种试验数据，通过整合地理位置、气候条件、物候特征和水稻品种特性等多维因素，构建了高精度的随机森林水稻产量估算模型。研究结果表明，模型在测试集上解释方差达 77%，均方根误差为 39.47 kg/mu，平均绝对误差为 29.85 kg/mu。特征重要性分析表明，对水稻产量最重要的三个因素依次是水稻品种（8.82%），营养生长期的日长（8.07%）和海拔（7.65%）。研究还发现，水稻产量对不同发育阶段环境因子的响应不一致。播种至齐穗期的净太阳辐射（ $r=0.42$ ， $p<0.01$ ）和日长（ $r=0.38$ ， $p<0.01$ ）与产量的相关性最强，而齐穗至成熟期的日均温度（日最低温， $r=-0.23$ ；日平均温， $r=-0.20$ ；日最高温 $r=-0.18$ ）都对产量有显著负面影响。在农艺性状方面，每穗总粒数（ $r=0.45$ ，

$p<0.01$)和实粒数($r=0.51$, $p<0.01$)与产量呈强正相关,是决定产量的核心要素,通过品种改良增加每穗总粒数是提升产量的关键途径。

(3) 基于播期和品种优化的区域气候适应性种植策略

融合物候模型与机器学习,构建了水稻播期—品种多目标优化框架,系统评估了不同管理策略对产量水平及其稳定性的影响。结果表明,单纯播期调整可增产 5.04%,降低产量变异 3.41%;品种更替可增产 9.83%,降低产量变异 5.26%;而二者组合策略效果最佳,增产 10.57%,产量变异降低 6.06%。各策略效应呈现显著的区域分异特征,长江中下游和淮河平原地区组合策略增产效应最显著(13.15%),而宁夏平原区效应最低(3.54%)。从播期上看,早稻播期可略微推迟 1.1 天,一季稻和晚稻播期可适当提前 0.2 天和 3.7 天。但在考虑到品种更替时,不同农业生态类型区的宜播期和品种组合存在显著差异:若在长江中下游和淮河平原地区,通过单季早稻播期推迟、单季晚稻播期提前的策略,使全生育期延长,实现亩产增幅 13.15%,产量变异性降低 8.97%;若在北方农业生态区内,一季稻播期推迟使得全生育期延长,亩产增幅 8.56%,产量变异性降低 6.20%。这些区域气候适应性种植策略能够有效应对气候风险,保证高产和稳产。

本研究构建的水稻生长发育与产量估算技术体系,实现了从基础理论到应用实践的完整闭环,有效解决了传统农业决策中经验性强、精准度低、区域气候适应性差等问题。研究成果为气候变化背景下的水稻生产提供了精准的预测工具和科学的决策支持,特别是在气候适应性种植策略的制定与优化方面,具有重要的理论价值和应用前景。

关键词: 产量估测, 物候模型, 环境聚类方法, 随机森林

Abstract

Rice is a strategic staple crop in China's food security system, with its yield closely related to climate change. Currently, rice production is facing multiple challenges, including global warming, increasing frequency of extreme climate events, rising labor costs, and constraints on resources and the environment, all of which increasingly threaten the sustainability of rice production. In light of these challenges, there are several key issues in current rice production and management that urgently need to be addressed. Traditional phenological models often suffer from limited accuracy when applied at larger spatial scales. Yield models face difficulties in effectively integrating multi-source heterogeneous data. Furthermore, regional cropping strategies tend to lack suitability and scientific optimization methods. To address these challenges, this study investigates rice development and yield formation processes and establishes a climate-suitable technical framework encompassing phenology prediction, yield simulation, and management decision optimization. First, the accuracy of phenological models is enhanced at the regional scale by employing environmental clustering, providing essential variables for yield modeling. Second, a high-precision yield simulation model is developed using machine learning approaches, identifying key factors influencing yield formation. Finally, based on the preceding components, a multi-objective optimization framework is established for sowing date adjustment and cultivar selection, enabling the formulation of regionally climate-suitable planting strategies. The main contributions of this dissertation are as follows:

(1) Phenological Model Upscaling Based on Environmental Clustering

To address the theoretical and technical limitations of traditional phenological models at large spatial scales, this study proposes an upscaling approach based on environmental clustering. This method significantly enhances the simulation accuracy of traditional phenological models when applied across broad regions. Results demonstrate that even for the same rice cultivar, Shanyou 63, thermal requirement parameters exhibit substantial differences under different environmental conditions, thereby challenging the classical assumption of fixed accumulated temperature thresholds in conventional phenological modeling. By introducing environmental clustering, the simulation errors for five critical developmental stages of rice are markedly reduced at the regional scale: from 1.8 to 1.4 days for tillering, from 5.3 to 3.7 days for jointing, from 5.6 to 3.9 days for booting, from 4.7 to 3.3 days for heading, and from 6.6 to 3.7 days for physiological maturity. The study further reveals that the models with a segmented three-phase linear temperature response function outperform alternative models. Additionally, the influence of photoperiod on model simulation accuracy becomes increasingly significant as the spatial scale expands. This approach

offers a novel technical pathway for applying phenological models at regional and global scales.

(2) Rice Yield Prediction Model Based on Random Forest Algorithm

Based on the national rice variety trials data from 2007 to 2018, a high-accuracy rice yield prediction model is developed using the random forest algorithm by integrating multidimensional factors, including geographical location, climatic conditions, phenological characteristics, and varietal traits. The model achieves a coefficient of determination (R^2) of 0.77 on the test set, with a root mean square error (RMSE) of 39.47 kg/mu and a mean absolute error (MAE) of 29.85 kg/mu. The study further has revealed that the response of rice yield to environmental factors at different developmental stages is inconsistent. Net solar radiation ($r = 0.42$, $p < 0.01$) and daylength ($r = 0.38$, $p < 0.01$) during the period from sowing to full-heading show the strongest positive correlations with yield. In contrast, mean daily temperatures during the full-heading to maturity stage—including minimum temperature ($r = -0.23$), mean temperature ($r = -0.20$), and maximum temperature ($r = -0.18$)—are all significantly negatively correlated with yield. In terms of agronomic traits, the total number of grains per panicle ($r = 0.45$, $p < 0.01$) and the number of filled grains ($r = 0.51$, $p < 0.01$) show strong positive correlations with yield, underscoring their role as core determinants of productivity. These findings suggest that increasing the total grain number per panicle through breed improvement represents a key strategy for yield enhancement.

(3) Regionally Climate-Suitable Planting Strategies Based on Sowing Date and Variety Optimization

By integrating phenological modeling and machine learning techniques, this study develops a multi-objective optimization framework for sowing date and variety selection, enabling a systematic assessment of the impacts of different management strategies on yield level and yield stability. Results show that adjusting sowing dates alone can increase yield by 5.04% and reduce yield variability by 3.41%. Variety replacement leads to a 9.83% yield increase and a 5.26% reduction in yield variability. The combined strategy of sowing date adjustment and variety replacement yielded the best performance, with a 10.57% increase in yield and a 6.06% reduction in variability. The effectiveness of each strategy exhibits obvious spatial heterogeneity. The combined strategy is most effective in the middle and lower reaches of the Yangtze River and the Huaihe Plain, achieving a yield increase of 13.15%, while the lowest effect is observed in the Ningxia Plain (3.54%). In terms of sowing date, the sowing date of early-season rice can be delayed by approximately 1.1 days, while the sowing dates of single-season and late-season rice can be advanced by 0.2 and 3.7 days, respectively. When variety replacement is also considered, significant differences in optimal sowing windows and variety combinations are observed across agro-ecological zones. In the Yangtze River basin and Huaihe Plain, delaying the sowing date of early-season rice and advancing the sowing dates of late-season rice extend the total growth duration, resulting in a 13.15%

increase in yield and an 8.97% reduction in yield variability. In northern agro-ecological zones, delaying the sowing date of single-season rice also prolongs the growing period, leading to an 8.56% increase in yield and a 6.20% reduction in variability. These regionally climate-suitable planting strategies offer an effective means to mitigate climate-related risks while maintaining high and stable rice yields.

The rice growth and yield prediction framework developed in this study establishes a complete closed-loop system from fundamental theory to practical application. It effectively addresses key limitations of traditional agricultural decision-making, such as overreliance on empirical knowledge, low precision, and poor climatic suitability for regions. The research outcomes provide accurate predictive tools and scientific decision-making support for rice production under climate change scenarios. These contributions hold significant theoretical value and practical potential for the formulation and optimization of climate-suitable planting strategies in China.

Key Words: Yield Prediction, Phenology Models, Environmental Clustering Method, Random Forest

目 录

第 1 章 绪论.....	1
1.1 研究背景.....	1
1.2 国内外研究概况.....	2
1.2.1 作物模型研究进展.....	2
1.2.2 作物产量估测研究进展.....	5
1.2.3 基于机器学习的作物产量估测研究进展.....	7
1.2.4 产量构成的“源-库-流”理论与有机物分配研究进展.....	11
1.3 存在问题.....	13
1.4 研究内容及技术路线.....	14
1.4.1 研究内容.....	14
1.4.2 技术路线.....	15
第 2 章 数据来源与方法	17
2.1 数据来源.....	17
2.1.1 田间试验数据.....	17
2.1.2 气象数据.....	18
2.2 数据分析方法.....	18
2.2.1 描述性统计分析.....	18
2.2.2 相关性分析.....	19
2.2.3 聚类分析.....	19
2.2.4 随机森林.....	19
2.2.5 模型性能评价方法.....	20
第 3 章 基于环境聚类的物候模型升尺度	21
3.1 概述.....	21
3.2 材料与方法.....	22
3.2.1 研究区域和数据来源.....	22
3.2.2 水稻物候模型.....	24
3.2.3 基于热需求的模型校准.....	27
3.2.4 基于环境变量的站点聚类.....	30
3.3 结果与分析.....	31
3.3.1 观测站点间作物发育热需求的变异.....	31
3.3.2 不同模型组在两个尺度上模拟性能的表现.....	33
3.3.3 适用于本研究特定区域最优聚类参数.....	34
3.3.4 通过减少环境异质性提高模型性能.....	38

3.4 讨论.....	39
3.4.1 物候模型局限性的来源.....	39
3.4.2 聚类方法对物候模型模拟精度的影响.....	42
3.4.3 气候变暖对物候的影响.....	43
3.4.4 限制与不足.....	43
3.5 本章小结.....	45
第 4 章 基于随机森林算法的水稻产量估算模型	46
4.1 概述.....	46
4.2 材料和方法.....	47
4.2.1 研究区域和数据来源.....	47
4.2.2 水稻品种及作物性状数据分布.....	48
4.2.3 随机森林产量估算模型构建和性能评价方法.....	50
4.3 结果与分析.....	52
4.3.1 水稻种植点地理条件和发育期与产量的相关性分析.....	52
4.3.2 水稻发育期内气候条件与产量的相关性分析.....	54
4.3.3 水稻品种和农艺经济性性状与产量的相关性分析.....	57
4.3.4 构建模拟水稻产量的随机森林回归模型.....	59
4.3.5 基于所有特征变量的机器学习模型训练与测试结果.....	60
4.4 讨论.....	63
4.4.1 环境条件、管理措施和作物品种对水稻产量的影响.....	63
4.4.2 预测产量的重要因素筛选和模型评价.....	64
4.5 本章小结.....	66
第 5 章 基于播期和品种优化的水稻区域适宜性种植策略	67
5.1 概述.....	67
5.2 多目标优化策略.....	68
5.2.1 水稻生态类型区划分.....	68
5.2.2 区域适应性播期优化.....	68
5.2.3 区域适应性品种优化.....	69
5.2.4 播期和品种共同优化.....	70
5.2 结果与分析.....	71
5.2.1 采用环境聚类方法模拟物候的模型性能表现.....	71
5.2.2 播期调整对水稻产量和生育期的影响.....	73
5.2.3 品种更替对水稻产量和生育期的影响.....	75
5.3.4 品种更替结合播期调整对水稻产量和生育期的影响.....	77
5.4 讨论.....	80
5.4.1 播期调整和品种更替对水稻生产的影响.....	80
5.4.2 区域适宜性组合策略对水稻生产的影响.....	82

5.5 本章小结.....	84
第 6 章 结论与展望	87
6.1 结论.....	87
6.1.1 基于环境聚类的物候模型升尺度.....	87
6.1.2 基于随机森林算法的水稻产量模型.....	87
6.1.3 基于播期和品种优化的水稻区域气候适应性种植策略.....	87
6.2 创新点.....	88
6.3 问题与展望.....	88
6.4 未来研究方向.....	90
参考文献.....	93
致 谢.....	111
作者简历及攻读学位期间发表的学术论文与其他相关学术成果	115

图目录

图 1-1 技术路线图	16
图 3-1 物候观测点的地理位置 (a)，按纬度和日期划分的日长时数 (b)，研究区的平均温度 (c)，以及 (d) 物候发生时间	23
图 3-2 12 种物候模型综述	25
图 3-3 物候模型改进方法综述	29
图 3-4 相关环境变量的相关系数矩阵	30
图 3-5 观测物候期在移栽后的发生时间和不同地点—年份热需求的标准差	32
图 3-6 46 个站点 SY63 的平均热需求	33
图 3-7 模型在生理成熟期的平均绝对误差的比较	35
图 3-8 不同聚类类别数和聚类变量的 Inertia 值	36
图 3-9 不同聚类变量在不同发育阶段平均绝对误差的变化和所有发育阶段的平均	37
图 3-10 不同聚类变量在不同发育期绝对误差均值的下降趋势	38
图 3-11 在整个研究区内所有发育阶段和所有模型的平均绝对误差	39
图 4-1 水稻观测点的分布 (a) 和关键物候期发生时间 (b)	49
图 4-2 水稻观测点地理位置和发育期与产量的相关性和数据分布趋势图	52
图 4-3 水稻全生育期内的气象条件与产量的相关性和数据分布趋势图	53
图 4-4 水稻营养生长期内的气象条件与产量的相关性和数据分布趋势图	54
图 4-5 水稻生殖生长期内的气象条件与产量的相关性和数据分布趋势图	55
图 4-6 生育期内气象胁迫指标与产量的相相关性和数据分布趋势图	56
图 4-7 水稻品种性状与产量的相关性及相关数据分布趋势图	58
图 4-8 不同输入变量组合下随机森林回归模型 100 次迭代的平均性	

能.....	59
图 4-9 随机森林回归模型 100 次随机分割最优结果	60
图 4-10 不同输入变量对产量的相对重要性	61
图 4-11 基于变量重要性的偏依赖图	62
图 5-1 两个发育阶段水稻发育所需热求观测值的箱线图	72
图 5-2 综合不同农业生态类型区和品种的水稻物候模拟值与观测值对比	72
图 5-3 齐穗期和成熟期物候模拟误差分布情况	73
图 5-4 播期调整对不同生态类型区内的水稻产量、全生育期天数（GP）、营养生长期天数（VGP）和生殖生长期天数（RGP）的影响	74
图 5-5 品种更替对不同生态类型区内的水稻产量、全生育期天数（GP）、营养生长期天数（VGP）和生殖生长期天数（RGP）的影响	76
图 5-6 播期和品种共同优化对不同生态类型区内的水稻产量、全生育期天数（GP）、营养生长期天数（VGP）和生殖生长期天数（RGP）的影响	79

表目录

表 3-1 温度和光周期相关参数及取值	28
表 4-1 品种表型特征与气象因素之间的相关性	58

第 1 章 绪论

1.1 研究背景

水稻作为中国最重要的粮食作物,在国家粮食安全体系中具有不可替代的战略地位。中国是全球最大的水稻生产国,水稻产量居世界第一,种植面积居世界第二^[1,2]。目前,我国水播种面积约占全国粮食作物播种面积的 24%,产量约占全国粮食总产量的 30%,以水稻为主食的人口高达 65%^[3]。中国水稻生产动态不仅关系到国内粮食安全,也对全球粮食市场产生重大影响。

作物模型作为农业系统研究的核心工具,在过去几十年取得了长足发展。传统的作物生长模型通过模拟作物与环境的相互作用,可预测作物在不同条件下的生长发育进程和产量形成。然而,在大尺度应用中,这些模型面临参数本地化困难^[4-7]、模型结构不确定性^[8,9]和计算效率低等问题^[10,11]。特别是针对作物物候模型,多基于常数积温假设,即认为同一品种在不同环境条件下完成特定发育阶段所需的有效积温保持恒定^[6,8,12,13]。这一假设在区域尺度上受到挑战,因为水稻热需求参数实际上会随环境条件变化而显著变异^[14-16]。如何改进物候模型的区域适应性,提高大尺度应用的预测精度,成为当前迫切需要解决的科学问题。

水稻产量估测是农业决策支持系统的关键组成部分。传统产量估测方法主要依赖统计回归或机理模型,前者过于简化而忽略了复杂的生物物理过程^[17,18],后者则需要大量参数且难以整合多源异构数据^[19,10]。实际上,水稻产量形成是一个受多种因素影响的复杂系统过程,包括气候条件、土壤特性、管理措施和品种特性等^[20,21,19]。这些因素之间存在复杂的非线性交互关系,难以用简单的线性模型准确描述。传统产量估测模型在空间和时间上的可迁移性较差,难以应对区域间的环境异质性和年际间的气候变异性^[8,22-24]。因此,发展能够捕捉这种复杂性并具有较强泛化能力的产量估测方法,对提升水稻生产的精准管理和风险防控能力具有重要意义。

随着大数据和计算能力的快速发展,机器学习算法在农业领域的应用日益广泛^[25-27]。这些算法能够从海量历史数据中自动学习复杂的模式和关系,无需显式编程和先验假设。在作物产量估测中,随机森林、支持向量机和深度学习等机器学习方法展现出优于传统方法的预测性能^[28-30]。将机器学习与农学知识有机结合,发展区域适应性的播期调整和品种布局优化策略,对提高水稻生产对气候变化的适应能力具有重要实践意义^[31,32]。

基于上述背景,本文研究了水稻生长发育与产量形成过程,围绕物候预测、产量估测和管理决策优化构建了完整的技术体系。旨在说明水稻发育热需求参数在不同环境条件下的变异规律,提高传统物候模型在区域尺度上的预测精度和适

应性，阐明水稻产量形成的多因素非线性交互机制，提供区域适应性种植策略，以期支撑中国水稻生产系统应对气候变化的适应性管理，为保障国家粮食安全战略目标的实现提供重要支撑。

1.2 国内外研究概况

1.2.1 作物模型研究进展

作物模型（也称作物生长模型）是作物科学结合系统分析方法，基于作物生理过程机制与农业气象学、土壤肥料学等多学科的理论研究成果，将气象条件、土壤参数、作物品种、田间管理措施等对作物发育过程和产量形成过程的影响与交互关系进行概括描述和数量分析，形成一系列对应的数学模型，进而能够基于计算机进行定量化分析与模拟研究的数值模拟系统。目前全球已有超过 100 种作物模型，应用于 150 多种作物的生长模拟。由于应用领域和适用作物的多样性，近几十年来发展的各种作物模型通常有其针对性，模型核心模块的侧重与应用各不相同。根据模型获取方式的不同，可以分为机理模型和经验模型两种。

（1）机理模型研究进展

在现代农业研究和管理中，机理模型，也叫基于过程的作物模型（Crop Models, CMs），已成为模拟作物单产以及研究气候变化对作物单产影响的关键工具之一^[19,33-35]。这些模型通过高度集成的数学算法，借助经验和半经验公式，精确地描述了作物生长发育过程对土壤水氮热、大气条件、基因型以及管理措施的响应，从而为系统分析作物生理生态过程提供了有力支持^[36]。

作物模型的研究可追溯至 20 世纪 60 年代，荷兰学者 de Wit^[37]和 Duncan 等^[38]开创了这一研究领域。荷兰 de Wit 学派的系列模型以冠层光合作用为基础，主要考虑土壤、气候等因素的作用，具有较强的通用性，不同作物仅需调整参数。经过 40 多年的发展，该学派先后建成不同用途的作物模型，如 ELCROS（初级作物生长模型）^[37]、BACORS（基础作物生长模型）^[39]、SUCROS（简单通用作物生长模拟）^[40]、MACROS（一年生作物生长模型）^[41]和 WOFOST^[42]（世界粮食研究模型），并在 MACROS 和 SUCROS 基础上专为热带水稻模拟开发了 ORYZA 系列模型^[43]。ORYZA 系列模型是目前最为通用的水稻生长模拟模型之一，广泛应用于不同环境条件下的水稻产量估测、不同播种期水稻适应性研究及与遥感结合等相关研究。

美国也于 20 世纪 60 年代末开始作物模型研究。1987 年，Ritchie^[44]等人基于 CERES-Maize 模型，推出了 CERES-Rice 模型。该模型在 IBSNAT（国际农业技术转移的标准基点网络）的推动下发展为覆盖水稻、高粱、花生、大豆等 10 多种作物的模型系列，形成了 CERES 模型体系并在发展中国家得到广泛验证。

CERES 模型系列的每一种作物都有其独立的模块,考虑了品种的遗传特性、土壤天气和管理措施等因素的作用以及土壤碳循环,尤其关注相同作物不同品种之间的特性差异,在气候影响评价领域应用比较广泛。1996 年,澳大利亚开发的 APSIM 模型问世^[45],该模型最大的特点是不同模块之间可以相互置换,以配置最适合相关研究的模型组合,广泛应用于作物模拟、外来物种介入对水稻生长影响和水分对水稻生长影响等研究。

与国外相比,我国作物模型的研究起步较晚且规模较小。上海植物生理所首先对水稻模型进行了研究,1986 年研制出我国第一个水稻模型——水稻群体物质生产模拟模型(RSM)^[46]。该模型在生育期模拟方面比较简单,播种到移栽固定为 35 天,抽穗到成熟固定为 30 天。之后,在江苏省农科院高亮之等的指导和参与下发展了较为完整的 RCSODS^[47]。此外,还有华南农业大学的水稻模拟模型(RSM)^[48]、江西农业大学的水稻生长日历模拟模型(RICAM)^[49,50]、中国合肥智能研究所熊范纶^[51]和北京市农科院赵存江等^[52,53]在 90 年代推出的系列农业专家系统等。

这些传统作物模型的结构和参数差异很大。首先,不同作物模型的物候子模块在发育阶段划分上各不相同。如 ORYZA 模型将水稻生长分为基本营养生长期、光敏感期和籽粒灌浆期三个主要阶段,而 CERES-Rice 模型则采用九阶段划分法,这导致发育阶段的定义和转换条件存在差异。其次,模型参数设定差异大。例如,温度三基点(基础温度 T_b ,最适温度 T_o 和最高温度 T_c)的设定,通常 T_b 在 8~13℃ 之间, T_o 在 28~32℃ 之间, T_c 在 40~42℃ 之间,不同模型对同一作物品种的参数设定可能相差 5℃ 以上。例如,对于粳稻品种,ORYZA 模型设定 T_b 为 8℃,而 CERES-Rice 模型设定为 12℃,这种差异会导致累积温度计算结果存在显著偏差。再者,发育速率的温度响应函数形式多样,包括线性、双线性、多线性和曲线函数等。APSIM、CERES-Rice、WOFOST 和 ORYZA2000 主要采用线性或分段线性函数描述温度对发育速率的影响,而 RCSODS^[47]、RSM^[54]、RICAM^[49,50]、RICEGROW^[55]等模型则采用更为复杂的曲线响应函数,如 Beta 函数或指数函数。还有,在光周期响应函数的处理上,部分模型如早期 CERES 采用简单阈值法处理日长效应,而 ORYZA 和 WOFOST 则采用更为复杂的连续函数描述光周期对发育速率的调节作用。这些结构和参数的差异最终导致模型预测结果存在较大不确定性,特别是在极端气候条件下的预测偏差更为明显。

(2) 物候模型研究进展

作物发育期的预测是产量估测的关键依据之一,是作物模型研究气候变化影响评估和管理实践指导的前提^[6,7,24,56]。物候模型作为作物模型的重要组成部分,在作物生长模拟和优化决策研究中具有“时间尺度”的重要作用,它控制作物生长模型在不同生长阶段调用相应的子模型或模型参数。作物模型中的许多参数取

决于相关的发展阶段，只能在特定的发展阶段发挥作用。例如，光周期效应仅在水稻播种至开花之间的光敏期有效^[57,58]，在苗期和分蘖期叶面积指数是关键参数^[59]，在抽穗扬花期水分胁迫相关参数（如土壤水分胁迫系数、水分利用效率等）影响最大^[60]。

现有的水稻物候模型主要分为两类：仅由温度驱动模型和温度—光周期共同驱动模型^[61–64]。两种模型均使用基点温度计算日热时间，使用累积热时间预测物候的发生。不同之处在于，温度—光周期驱动模式调整了对日长敏感的发育阶段的日热时间，即考虑了光周期效应。

在仅由温度驱动的水稻物候模型中，根据作物发育速度对温度的响应形式主要分为三种类型：第一种类型假设有作物发育的基础温度 (T_b) 和最适温度 (T_o) 但没有最高温度 (T_c)，发育速率从 T_b 开始随升温线性增加到 1，当 $T \geq T_o$ 时发育速率最大且保持不变，如 CERES-Rice^[20,65,66]、STICS^[67]、WOFOST^[42] 等模型；第二种类型假设有 T_b ，最适温度是一个适宜的范围，有最高温度 (T_c)，发育速率在适宜温度范围内保持最大，超出范围则线性减少，如 GLAM-Rice 模型、CropSyst 模型；第三种类型定义了三个基本温度，即基础温度 (T_b)、最适温度 (T_o) 和最高温度 (T_c)，模拟温度从 T_b 到 T_o 以曲线递增速率以及从 T_o 到 T_c 以曲线递减速率，呈 β 曲线形式，如高亮之^[68]研制的“水稻钟”模型，曹卫星研制的 RiceGrow 模型^[55]，殷新佑^[12]的水稻发育温度效应的非线性模型。

在温度—光周期共同驱动的水稻物候模型中，水稻被广泛认为是短日照作物，这意味着短日照时间加速其发育，而长日照时间会延长其开花或抽穗的天数^[69–72]。水稻发育速度的温度响应与光周期响应通常以乘法形式相结合。发育速率对光周期的响应形式主要有两种：第一种是两段式的光周期响应，其中包括两段式线性和两段式非线性响应两种形式，即在日长 (DL) 不大于最佳日长 (DL_o) 时，发育速率不受 DL 变化的影响，当 $DL > DL_o$ 时发育速率随着 DL 增加而以线性或负指数形式不断减小，如 WOFOST 模型、ORYZA2000 模型和负指数模型^[73]中采用的光周期响应模式；第二种是水稻发育速率对日长的 S 型响应曲线，随着 DL 从零增加到 DL_o ，发育速率增加到最大值，当 $DL > DL_o$ 时发育速率逐渐减小，如殷新佑^[74]等人提出的 Beta 光周期函数。

现有物候模型的一个核心假设是基于恒定积温理论，即认为同一作物品种在不同环境条件下完全成熟所需的累积热时间是不变的。但大量研究表明，作物发育期所需要的热时间并非恒定，会随环境条件变化而调整。Wu 等 (2019, 2020)^[15,16,75]对中国不同地区小麦、玉米和水稻的物候观测数据分析，发现同一种作物类型在不同年份和地点的热时间需求相差 5.8%~23.4%，即使是相同的作物品种其热需求变化趋势也有差异较大，特别是在极端气候年份，这种差异更为显著。Zhang 等 (2008)^[14]的研究也证实，作物生长发育所需的气候资源如光温的波动呈明显的区域变化，热需求的可变性是植物适应环境变化的重要机制。其次，作

物发育受多因素复杂调控。作物的发育进程是由遗传特性与环境因素交互作用共同决定的复杂过程^[76-79]。Olsson 等（2015）^[80]指出，使用固定的累积热量需求模拟大区域的植物发育是不充分的，需要考虑降水、土壤条件和其他气候因子的综合影响。抽穗受光信号与内源生物钟系统的复杂调控，万建民等（2025）^[81]通过挖掘光信号调控水稻抽穗期的全新机制，为培育适应不同环境条件的高产水稻品种提供理论指导。

1.2.2 作物产量估测研究进展

作物产量预测估算是农业科学研究的核心问题之一，也是支撑国家粮食安全战略的重要技术手段。根据预测方法的理论基础和实现方式，产量估测研究主要经历了统计模型、过程模型和遥感估产三个发展阶段，近年来三种方法的融合应用成为研究热点。

（1）经验统计模型产量估测

基于农田抽样统计的作物估产，通过对田间样方或抽样农田进行实地调查和数据采集，来推断整个农田或作物群体的产量水平^[18]。研究人员在样方设计和采样方法上进行了优化和改进，例如，采用系统抽样、随机抽样或分层抽样等方法，合理选择样方的位置和数量，以提高预测精度和效率。这种方法虽然直观可靠，但工作量大，难以应用于大尺度预测。首先，实地调查需要投入大量人力和时间，中国水稻种植面积超过 4.34 亿亩，分布在不同气候区和地形条件下，全面调查几乎不可能实现。

另一种是以历史产量数据和关键环境因子为基础，通过回归分析建立产量与若干选定的环境影响因素间的数量关系。早期的统计模型多采用简单线性回归或多元线性回归方法^[82]，后来逐步发展出包括时间序列分析、主成分回归和偏最小二乘回归、贝叶斯方法更复杂的统计方法^[83-85]。比如根据某一地区的历史观测所得的气象因素或植被指数（地面或遥感计算得出）^[86]，使用回归方程作为该地区或类似地区其他年份的输入函数，以预测产量。这类方法操作简便，数据需求相对较少，通常表现出令人满意的性能，特别是在受到若干因素驱动、产量每年大幅波动的情况下。然而，目前大多数统计回归模型基于线性假设，如多元线性回归，无法有效捕捉环境因子与产量之间的复杂非线性关系。大量研究表明，作物产量对极端气候事件通常表现出强烈的非线性响应^[77,87]。在气候变化背景下，这种非线性关系更加凸显，而线性回归模型在这种情况下表现不佳。其次，统计模型缺乏对生长发育阶段差异性的考虑。例如，在花期发生的高温或干旱事件可能比在营养生长期造成更大的产量损失^[88-90]。传统统计模型通常使用整个生长季的气象指标作为预测变量，忽略了这种阶段特异性影响，导致对关键敏感期环境胁迫的响应模拟不足。再者，历史数据依赖导致对新环境条件预测能力有限。统计

模型主要基于历史数据训练,其预测能力受限于历史数据的范围和质量。在气候变化背景下,许多地区正经历前所未有的气候条件,超出历史记录范围的极端事件增多,仅依赖历史关系的统计模型在这种情况下的预测可靠性显著降低。此外,品种更新和栽培技术进步也会改变作物与环境的响应关系,进一步限制了基于历史数据的统计模型的适用性。

(2) 过程模型产量估测

过程模型是基于作物生理生态机理构建的产量估测方法,通过模拟作物生长发育全过程来预测最终产量。代表性的过程模型包括 DSSAT、APSIM、CERES 和 WOFOST 等集成建模平台^[21,42,45]。这类模型能够模拟作物对气候变异、水分胁迫和养分限制等复杂环境条件的响应,具有较强的机理解释力和情景分析能力。

基于动态过程的作物模型通常基于作物的生理生态特性,如光合作用、蒸腾作用、碳氮平衡等,根据环境因素(如光照、温度、水分、土壤质量等)和农业管理措施(如施肥、灌溉、病虫害控制等)模拟作物生长过程。模型采用计算机模拟植物生长的过程,以各组成器官的干物质为标尺,计算出作物在某一天内的能量(干物质)积累,再通过该生长阶段水稻各器官发育的规律分配所积累的干物质,模拟出作物的生长发育过程。Challinor^[91]对 67 项作物模型研究进行的 meta 分析表明,过程模型在考虑适应性措施的情况下,能够有效评估气候变化对作物产量的影响。然而,过程模型对参数校准和输入数据质量要求高,在大尺度应用中面临参数区域化和计算效率等挑战^[92]。

目前,国内外研究人员对基于动态过程的作物模型的研究主要有以下几个方面:一是进行模型结构改进(如加入作物水分利用效率、碳氮平衡等模块)和参数的优化(如叶面积、叶绿素含量、干物质积累、气象数据、土壤水分数据等),以及对水稻、小麦、玉米等主要农作物的适应性调整,以适应不同地区和作物的特点^[65,93-96];二是高分辨率遥感数据普遍应用,提高了模型的精度和空间分辨率,利用多源数据(高分辨率遥感数据、气象数据、土壤数据和农田实测数据),结合作物模型进行作物产量估测,从而更准确地估计大区域作物产量和监测农田变化^[97-100];三是将作物模型与全球气候模型、经济模型和机器学习模型引入到农业生产研究中^[101-103],构建更具普适性的混合模型,开发农业决策支持系统,一方面有利于研究气候变化下不同作物的适应性和脆弱性,另一方面有利于更全面地评估农业系统的可持续性和经济效益,帮助农民制定种植策略、灌溉管理、施肥调控等决策,以提高农业生产效益。

作物模型数量众多且具有较强的机理基础,但不同模型之间存在差异,给作物产量估测带来很多不确定性。首先,模型存在不确定性。研究表明,模型结构、模型参数和输入数据是模型不确定性的三个主要来源^[104,105]。例如,Asseng 等(2013)^[106]对全球 4 个代表性地点的小麦产量研究发现,27 种作物模型造成

的产量估测的不确定性大于 17 种 GCMs 带来的不确定性，并且做这种模型的不确定性源于模型结构的差异。此外，当前作物品种繁多，不同品种在形态特征、生理生态特性和环境适应性方面差异显著。统计表明，20 世纪 50 年代以来，中国水稻育种经历了三个阶段更迭阶段，中国主要稻区已更换了 4~6 代主导品种，水稻品种的生命周期通常仅为 3~5 年，每一代品种在产量潜力、抗逆性和品质特性等方面均有显著差异^[107,108]。这要求模型参数针对不同品种进行校准。然而，在大规模应用中，详细的品种参数往往难以获取，特别是近年来随着新品种快速推广，参数本地化滞后问题更加突出。再者，模型对极端气候事件的响应模拟能力有限。大多数作物模型在模拟极端气候事件（如热浪、霜冻和干旱）对产量的影响方面表现不佳。这些限制部分源于参数不确定性和某些过程的模糊描述或过度简化^[109,110]。特别是在热胁迫影响模拟方面，现有模型存在显著不足^[111]。大多数作物模型主要模拟极端温度对茎碳水化合物积累、分布或叶片衰老的影响，而非直接模拟极端温度对生殖过程或器官的损害^[112]，这导致在高温胁迫条件下产量估测偏差增大。

（3）遥感估产技术

遥感估产技术利用卫星遥感数据监测作物生长状况，建立植被指数与产量间的关系模型进行产量估测。早期研究主要采用经验统计方法，建立 NDVI 等植被指数与产量的回归关系，随着遥感技术的发展，光合效率模型和生态系统过程模型逐渐成为遥感估产的主流方法^[97,113,114]。

MODIS-GPP 产品和 CASA 模型是基于光合效率理论的代表性产品^[115]。其优势在于能够获取大尺度、实时的作物生长信息，但受云雾影响大，且对高分辨率影像的处理仍面临技术挑战^[116,114]。近年来，多源数据融合和多模型集成成为产量估测研究的新趋势。中国科学院开发的“中国粮情遥感速报系统”(CropWatch)集成了遥感监测、气象数据和统计模型，实现了全国主要粮食作物的产量预报^[117]。这类集成方法充分发挥了各种预测方法的互补优势，提高了产量估测的时空精度。

目前与机器学习耦合的遥感估产技术已经被广泛用于估计或预测农作物产量。例如，Filippi 等（2019）^[118]利用澳大利亚西部的多层农场调查数据集，使用随机森林（RF）模型估算作物产量，结果表明 RF 模型可以准确地预测农作物的产量，并且在可获得现场监测数据的其他地区具有潜在的应用前景。Shari 等（2020）^[119]基于遥感和气候数据，使用了四种机器学习模型（包括反向传播神经网络、决策树、K 近邻和高斯过程回归算法）对伊朗南部的大麦产量进行了准确预测。

1.2.3 基于机器学习的作物产量估测研究进展

机器学习技术近年来在作物产量估测领域取得了突破性进展，其强大的数据

挖掘能力和灵活的非线性建模能力为传统预测方法提供了新的研究路径。随着计算能力的提升和农业大数据的积累,机器学习方法在作物产量估测中的应用日益广泛,形成了从简单统计学习到深度学习的技术路线。与传统统计和过程模型相比,机器学习方法能够自动识别复杂的非线性关系和高阶交互效应,无需预先假设变量间的具体函数关系,从而更准确地捕捉环境因素与作物产量间的复杂关联,特别是在异常气候条件下的响应模式。

(1) 经典机器学习方法在产量估测中的应用

支持向量机(SVM)是最早应用于作物产量估测的机器学习方法之一。基于结构风险最小化原理,SVM通过核函数将低维数据映射到高维特征空间,寻找最优分类或回归超平面。Zhou等(2022)^[30]在预测中国县级小麦产量时,比较了SVM与其他机器学习方法的表现,结果表明SVM在整合气候变量和卫星遥感数据方面表现出色,尤其是在样本量有限的区域。Karimi等(2006)^[28]将SVM应用于玉米产量估测,结果显示其预测精度显著优于传统回归方法。国内学者杨晓华等(2008)^[120]基于SVM开发了水稻叶面积指数高光谱估算模型,其RMSE比相应的统计模型降低11个百分点。Yoon等(2011)^[29]比较了SVM、神经网络和多元回归在土耳其小麦产量估测中的表现,发现SVM在处理非线性气候—产量关系时具有明显优势。SVM的核函数特性使其能够有效捕捉作物生长与环境因子间的复杂非线性关系,这一点在Khanal等(2018)^[121]的研究中得到验证,他们将高分辨率遥感数据与SVM结合用于预测土壤特性和玉米产量,模型表现优于传统回归方法。SVM具有良好的泛化能力和对小样本的适应性,特别适合农业领域典型的“小样本、高维特征”数据特点,但其核函数选择和参数优化仍存在一定主观性,且计算复杂度随样本量增加而迅速上升,限制了其在大数据场景下的应用。

随机森林(RF)作为一种集成学习方法,通过构建多棵决策树并取其平均预测结果,有效减少了单一模型的方差和过拟合风险。其对异常值不敏感、可处理高维数据且计算效率高等优势,使其在作物产量估测中表现出色。Jeong等(2016)^[122]利用随机森林模型分析了美国玉米带的产量与气候因子关系,准确捕捉了产量对极端气候事件的非线性响应,特别是对于春季过度降雨和夏季高温胁迫的复合影响模拟效果优于传统统计模型。Everingham等(2016)^[123]将随机森林应用于澳大利亚甘蔗产量估测,不仅提高了预测精度还识别了关键预测因子的相对重要性,发现南方涛动指数和生长季初期降水是影响产量的主导因素。Leng与Hall(2020)^[124]系统比较了RF与回归和过程模型在作物产量估测中的表现,发现RF在捕捉空间和时间变异性方面具有明显优势,尤其是在整合多源异构数据时表现更为稳健。RF模型的并行计算能力和对缺失值的鲁棒性使其在大规模农业

数据处理中具有实用价值,如 Cai 等(2018)^[125]成功应用 RF 构建了高性能的田间作物类型分类系统,为产量预测奠定了基础。此外,RF 在处理非平衡数据和降低过拟合风险方面也表现出色,Khanal 等(2018)^[126]的研究证明,基于 RF 的空间预测模型在整合高分辨率遥感数据预测玉米产量时准确度高,且计算效率优于其他复杂模型。随着集成学习理论的发展,RF 算法在农业领域的应用前景将更加广阔,特别是在多时空尺度产量预测方面有望取得突破性进展。

除 SVM 和随机森林外,多种机器学习方法也被应用于作物产量估测。人工神经网络(Artificial Neural Networks, ANN)在处理复杂非线性关系方面表现出色,Khaki 和 Wang(2019)^[127]将 ANN 应用于美国玉米产量预测,通过优化网络结构显著提高了预测精度。贝叶斯网络模型则因其能够表达变量间概率依赖关系和不确定性,在风险评估方面具有独特优势,Soliman^[128]等利用贝叶斯网络构建了考虑气候变异风险的小麦产量预测模型。

为了提高模型的可解释性与可信性,Lundberg 等^[129]提出的 SHAP(SHapley Additive exPlanations)框架为模型解释提供了统一方法论基础,该方法基于博弈论中的 Shapley 值,能够量化各输入特征对预测结果的贡献。在作物产量估测领域,可解释人工智能技术已展现出显著应用价值。研究表明,将可解释 AI 模型应用于产量预测不仅提高了预测准确性,更增强了模型可信度,为精准农业实践提供了科学依据^[32]。深入分析气候因素与作物产量的关系是可解释 AI 的重要应用方向。通过可解释机器学习方法,研究者揭示了玉米、高粱和大豆产量对生长期气候的响应机制,识别出关键生长阶段的气候敏感性,为适应气候变化的作物管理提供了精准指导^[130]。在资源利用效率研究方面,Hosseini 等(2022)^[31]基于灌溉和气候多特征选择,利用自适应神经模糊推理系统和季节优化的混合方法,估算苹果园的水分利用效率和产量,为科学灌溉提供了理论支撑。知识图谱作为提升模型可解释性的重要工具,已在农作物灾害损失及产量预测系统中得到应用。通过构建农业领域知识图谱,研究者实现了对灾害影响机制的形式化表达,增强了产量预测模型的可解释性和可信度^[131]。

机器学习模型的性能很大程度上依赖于训练数据的质量、数量和代表性,而农业领域高质量数据的获取面临诸多困难。首先,农业数据的空间异质性和时间不连续性问题突出。作物生长受多种因素影响,包括气候条件、土壤特性、管理措施和品种特性等,这导致数据在空间上呈现高度异质性。同时,历史产量数据往往存在断点和缺失,特别是在落后地区,长期连续的作物产量观测数据和配套环境监测设备和数据较为缺乏。其次,多源数据的时空分辨率不匹配增加了数据预处理和融合的复杂性。作物产量预测通常需要整合气象数据(通常为站点数据)、遥感数据(栅格数据)、土壤数据(离散采样点)和产量统计数据(行政单元)等多源异构数据。这些数据在时空分辨率、获取方式和格式上存在显著差异,如何进行有效的数据匹配、插值和融合,是应用机器学习方法的首要技术障碍。例

如, Zhao 等 (2015) ^[132] 研究发现, 不同空间分辨率下产量偏差的空间分布与像素内空间异质性一致。

(2) 深度学习在产量估测中的应用与创新

深度学习作为机器学习的前沿分支, 以其强大的特征提取和表示学习能力, 为高维复杂农业数据的处理提供了新工具。卷积神经网络 (Convolutional Neural Networks, CNN) 在处理空间结构数据方面表现出色, 特别适合遥感影像分析; 而循环神经网络 (Recurrent Neural Networks, RNN) 及其变体如长短期记忆网络 (Long-shot Time Memory, LSTM) 则擅长捕捉时间序列数据中的长期依赖关系, 适用于气象时序和作物生长动态模拟。

Sun 等 (2019) ^[133] 开发了基于 CNN 和 LSTM 的混合深度学习框架 (CNN-LSTM), 整合卫星影像和气象数据, 精准预测了美国县级大豆产量。Li 等 (2022, 2025) ^[134,135] 将深度学习与多源遥感数据结合, 实现了中国东北地区玉米产量的高精度预测, 模型验证 R^2 达到 0.86。Khaki 等 (2020) ^[136] 提出了一种基于卷积—循环结构的深度神经网络, 同时考虑了环境因素、管理措施和品种特性对玉米产量的影响, 在基因型—环境—产量关系建模方面取得了突破性进展。

集成系统的计算复杂性和资源需求高。多源数据处理和多模型集成通常需要较高的计算资源, 特别是在大区域、高时空分辨率的应用场景中。这种高计算复杂性限制了集成方法在资源有限的基层农业推广部门的应用, 也为实时决策支持系统的开发带来挑战。例如, Zhao 等 (2013) ^[11] 使用 APSIM 对 12707 个气候土壤区进行了 122 年的 325 种管理情景 (施氮量与茬口管理) 的模拟, 这些模拟在单台计算机上要花费 30 年以上的时间, 通过 Condor 网格计算池利用约 1800~2000 台计算机进行并行需要 10.5 天随时间。

未来机器学习在作物产量估测中的应用, 可能需要重点关注面向小样本和不平衡数据的学习方法, 通过迁移学习、元学习和数据增强等技术提高数据利用效率, 加强机器学习与领域知识的深度融合, 提高模型的可解释性和透明度, 发展自适应和鲁棒的学习算法, 简化模型部署和应用流程。通过多学科交叉融合和技术创新, 有望开发出更加精准、可靠、可解释且实用的新一代产量预测系统, 为保障粮食安全和农业可持续发展提供有力支持。

(3) 机器学习与传统作物模型的融合

机器学习与传统作物模型的融合是近年来的研究热点, 这种混合建模方法既保留了作物模型的生理生态基础, 又利用机器学习克服了参数区域化的困难, 代表了未来作物产量预测的发展方向。

Shahhosseini 等 (2021) ^[137] 在美国玉米带的研究中证明, 将机器学习与作物

模型耦合使用显著优于单独应用任一方法，这种融合方法不仅提高了预测精度，还增强了模型的适应性，特别是在气候异常年份表现出色。该研究通过将过程模型的生理机制知识与机器学习的数据挖掘能力相结合，创造性地解决了单一模型难以应对的复杂环境交互问题。Wang 等（2023）^[138]提出了“辐射传输过程引导的机器学习”方法，通过将物理模型的先验知识融入机器学习算法，实现了高光谱遥感数据在覆盖作物监测中的高效应用。这种方法不仅继承了机器学习的高精度特性，还保留了物理模型的生物学解释性，为遥感与农业模型融合提供了新思路。类似地，国内研究者刘峻明等（2018）^[139]利用长时间序列气象数据结合随机森林算法，构建了冬小麦早期产量预测模型。研究表明，通过选择关键生育期的气象因子作为输入特征，并融入小麦生长发育的物理过程约束，能够显著提高机器学习模型的时空稳定性，为季节内产量预报提供了有效工具。在遥感监测与模型融合方面，李瑞杰等（2025）^[140]系统总结了水稻生育期遥感监测的研究进展，指出当前的瓶颈问题在于遥感观测与作物生理过程的脱节。研究建议通过构建“遥感—作物模型—机器学习”三位一体的监测框架，实现多源数据融合和多尺度信息集成，从而克服单一模型的局限性。这种集成方法特别适合解决复杂地形和碎片化种植区的监测困难，为我国南方丘陵山区的稻作生产提供了技术支持。陈晓玲^[141]等（2024）开发了基于 Bayesian-LightGBM 的粮食产量预测模型，通过贝叶斯优化框架自动调整模型超参数，同时融入农艺知识作为先验约束，实验结果表明，与传统机器学习和统计模型相比，该融合模型运算效率高、预测精度高。

1.2.4 产量构成的“源-库-流”理论与有机物分配研究进展

在产量预测估算方法不断演进的背后，产量本质上是植物能量在营养生长与生殖生长间分配的最终表现，其形成过程受到多种生理机制和环境因子的综合影响。过去半个世纪，全球水稻单产增长速率经历了先快后慢的变化，气候变暖、弱光寡照与资源约束被认为是产量差持续扩大的三大主因^[142]。传统栽培与育种多聚焦单一器官或单一因子，难以解释“高产不优质”和“优质不高产”并存的生态学权衡现象。自 Mason 和 Maskill 于 1928 年首次提出光合产物分配的源、库概念^[143]后，“源-库-流”系统框架逐渐成为解析环境因子如何系统调控植物能量固定、代谢与分配的关键视角。

水稻的“源”指输出光合同化物的器官，主要由叶片和光合活性茎鞘构成，其强度由光合能力和叶面积共同决定，直接关系到植物固定大气碳的总量^[144,145]。籽粒是水稻的终极“库”，其大小由单位面积穗数、每穗实粒数和千粒重决定，体现了植物对繁殖投入的调控。库容包括“数量容量”和“生理强度”，前者决定潜在产量上限，后者决定实际灌浆效率^[146]。“流”是连接源与库的输导系统，穗颈大维管束的数量、截面积及韧皮部装载/卸载效率决定了同化物由源向库运

输的通畅程度，不仅是物质运输的通道，也是植物整合环境信号和内源信号的网络。

环境因子通过调控植物基因表达、酶活性和代谢途径，影响“源-库-流”系统功能，最终反映在产量构成上。温度是影响水稻发育进程和代谢速率的核心因子，通过调控植物激素平衡影响颖花分化与退化，温度上升可使花药开裂异常，传粉受阻，颖花退化率增加^[147,148]。光照通过光能利用和光周期信号双重途径影响水稻产量，弱光条件降低光合碳同化，导致源不足；光质变化则通过光敏色素介导的信号通路影响穗部发育^[149]。水分胁迫通过脱落酸加速植株衰老，影响源-库关系，轻度干旱促进茎鞘储存碳水化合物向籽粒转运，而严重干旱则抑制关键酶活性^[150]。氮素通过调控 Rubisco 含量和活性影响光合效率，通过影响细胞分裂素合成影响颖花分化，通过调控碳氮代谢平衡影响同化物分配格局^[151]。

在资源有限的条件下，水稻通过发育阶段的有机物重分配，实现对库、源的优化调控。幼穗分化期，环境主导颖花数量与潜在库容量的形成（“环境定库容”）；灌浆期，源器官的功能维持与物质运输效率成为产量的主要限制因素（“环境决源流”）；而在结实期，环境则通过调节流系统与库器官的耦合效率影响最终籽粒充实度（“环境调流-库耦合”）。值得注意的是，环境因子的综合作用并非线性叠加，而是通过作物体内的结构-功能-信号网络产生复杂的非线性响应。当多种胁迫（如高温、干旱、低光）同时作用时“源-库-流”系统的协调性被打破，产量损失呈指数级放大^[152]。这解释了为何温度、光辐射、光周期等生态因子对水稻产量的影响往往依赖于具体的生育阶段，而非一个固定的强度阈值。

在此背景下，播期调整作为一种典型的农艺调控手段，本质上是将作物关键生育期与最优环境窗口相匹配，以实现“源-库-流”系统的最优配置。合理的播期安排可使幼穗分化期避开高温与寡照胁迫，确保穗分化充分、库容量最大化；同时使灌浆期处于适宜温度和光照条件下，延长功能叶片寿命，维持源强与流效率，从而提高籽粒灌浆速率与结实率。另外，遗传改良作为另一种更为根本和长期的调控方式，已成为提升水稻产量的核心手段。与环境调控着眼于“外部适应”不同，品种改良强调通过基因组调控重塑作物内部的源、库、流结构，从而实现对资源获取、分配与利用效率的系统优化。我国水稻育种经历了三次关键飞跃，分别从流、源、库三个维度推动了产量潜力的提升：第一次（1960s-1970s）矮化育种优化了“流”系统，穗颈加粗、维管束数增加；第二次（1980s-1990s）理想株型育种优化了“源”系统，通过叶角基因和持绿基因改良，提高光能截获和延长光合期；第三次（2000s-2010s）大穗育种优化了“库”系统，改良颖花发育和灌浆相关基因^[107,153]。这种持续的系统优化展现了植物生态适应性与人工选择的互动，也为未来面对气候变化的适应性育种提供了方向：即通过分子设计调控“源-库-流”关键节点，优化植物对环境变化的响应能力，提高资源利用效率和产量稳定性。

1.3 存在问题

水稻生长发育与产量形成的准确模拟对保障国家粮食安全、优化农业生产管理和应对气候变化具有重要战略意义。近年来，国内外学者在水稻物候模型、产量预测估算和气候适宜性种植策略优化方面开展了广泛研究，取得了一系列重要进展。然而，受数据可获取性、模型理论基础和方法技术等客观因素的限制，当前研究仍面临一系列关键科学问题和技术瓶颈，制约了相关成果在大区域尺度和变化环境下的应用效果。主要体现在以下三个方面：

（1）物候模型中的理论与技术瓶颈

当前物候模型存在结构参数差异大、参数本地化不足和恒定热需求假设局限性等问题。不同作物模型的物候子模块在发育阶段划分上各不相同，发育速率的温度响应函数形式多样，从简单线性到复杂曲线函数不等；光周期响应函数处理方法各异。此外，作物模型通常基于特定试验站点和有限品种的数据开发和校准，推广应用面临严重的参数本地化问题，同一品种在不同环境条件下表现出的生理特性可能存在显著差异；作物生长发育由基因型与环境因素复杂交互作用决定，同一基因型在不同环境下可能表现出不同的发育模式。更为关键的是，传统物候模型基于恒定积温理论，而热需求的可变性是作物适应环境变化的重要机制；作物发育受多因素复杂调控，使用固定累积热量需求模拟大区域植物发育是不充分的。因此，亟需构建基于环境聚类的物候模型升尺度方法，实现物候模型参数对环境条件的动态响应，以提高模型在大尺度异质环境下的模拟精度和模型泛化能力。

（2）产量估算中的数据与方法局限

现有研究在作物产量模拟和预测研究中存在两个关键不足。一是，作物品种记录数据缺乏，严重制约品种因素在产量模拟和预测模型中的有效整合。与气象和农艺管理等数据不同，品种信息在历史农业生产记录中往往缺失或不完整，导致难以建立品种特性与产量形成的定量关系。品种是决定作物产量潜力和环境适应性的核心因素，但在大多数产量估算研究中，品种因素往往被简化处理或完全忽略，导致产量预测中无法准确捕捉不同品种的差异。二是，品种更替频繁，使得产量模拟模型难以保持时效性和准确性。新品种的推广使用可使区域平均产量显著提升，这一动态变化难以被传统模型准确捕捉，导致产量预测模型无法为区域性品种布局优化提供科学依据，最终限制了农业生产系统对气候变化的适应能力。因此，将作物品种特性作为关键变量纳入产量模型和管理优化框架，对提高模型模拟精度和增强农业系统气候适应性具有重要意义。

（3）机器学习方法在农业应用中的限制

机器学习方法凭借其强大的数据挖掘能力和灵活的非线性建模能力，在作物产量预测领域取得了显著进展。然而，将这些方法应用于复杂的农业生态系统时，

机器学习方法面临跨区域应用的适应性挑战。在一个地区训练的机器学习模型应用到其他地区时，由于土壤条件、品种结构和管理实践的差异，模型性能通常会显著下降。在中国不同水稻生态区之间转移应用随机森林模型时，由于不同区域的气候和产量分布存在差异，导致系统误差增加。再者，品种更新和管理技术变革带来的时间外推挑战，随着作物育种技术进步和农业管理方式变革，作物品种特性和对环境的响应模式不断变化，基于历史数据训练的模型可能无法准确反映新品种和新技术条件下的作物—环境关系。因此，亟需构建融合多源数据的机器学习框架，优化算法结构和训练策略，以提高模型在时空尺度上的泛化能力，增强对新品种和新环境条件的适应性。

1.4 研究内容及技术路线

1.4.1 研究内容

本研究以水稻生长发育与产量形成的综合优化为核心，通过三个相互关联的研究内容，构建了从基础理论探索到应用实践的完整科学链条，具体研究内容如下：

（1）基于环境聚类的物候模型升尺度

本研究针对传统物候模型在大尺度应用中面临的理论与技术瓶颈，提出了基于环境聚类的物候模型升尺度改进方法。研究创新性地整合了中国南方 46 个代表性地点长达 27 年的水稻物候观测数据，对比分析了 12 种主流物候模型的模拟性能。通过定量评估作物发育热需求 (TR) 参数在时空尺度和模型间的变异特征，揭示了基于常数积温假设理论的发育模式缺陷；提出并验证了基于环境相似性的聚类方法，降低了环境异质性对模型模拟精度的干扰；通过多模型比较与误差分析，系统评估了不同物候模型的适用边界；开发参数自适应优化算法，实现了物候模型参数对环境条件的动态响应，显著提升模型在异质环境下的泛化能力。

（2）构建基于随机森林算法的水稻产量估算模型

本研究基于中国主要水稻种植区 2007~2018 年的品种试验观测数据，系统整合了地理位置、气候条件、物候特征、水稻品种特性等 4 类共计 47 个影响因子，分析了与水稻产量与 47 个影响因子的相关性，确定了影响产量形成的 24 个关键因子；以实际产量为目标变量，运用随机森林算法自动识别各变量间的复杂非线性关系，构建基于多变量组合的随机森林回归模型预测水稻产量，并评估不同变量组合对预测精度的影响；基于最佳预测模型，通过特征重要性分析，确定了影响水稻产量的各因素的相对重要性。最终构建了包含关键因子筛选、特征重要性评估及模型优化的精确预测水稻产量的机器学习框架。

（3）基于播期和品种优化的水稻区域气候适宜性种植策略

本研究融合了作物模型与机器学习技术的多目标优化框架，实现了水稻播期

调整和品种选择的区域气候适宜性优化。研究创新性地整合了播期、作物品种特性与区域环境因子等多维度影响因素，突破了传统单一因素研究的局限；基于大数据分析和田间试验验证，建立了包含产量水平、产量稳定性和气候适宜性的综合目标函数；深入剖析了品种—环境—管理措施交互作用的内在机理，揭示了不同管理组合在区域尺度上的适应性规律；提出了区域适应性水稻种植建议，为精准农业提供了科学依据和有效工具。

1.4.2 技术路线

本研究基于水稻生长发育与产量形成的系统性认识，构建了从物候模拟、产量估测到管理决策的完整技术体系，为发展智能化、精准化的水稻生产管理系统提供科学支撑。整体技术路线如图 1-1 所示。

(1) 针对传统物候模型在大尺度应用中的理论与技术瓶颈，提出基于环境相似性聚类的物候模型升尺度方法。本研究利用中国 46 个站点 27 年的水稻物候观测数据和相应气象资料，系统分析了不同站点—年份间热需求参数的变异特征。通过评估温度响应函数和光周期响应函数的不同组合，比较了 12 种物候模型的模拟性能，识别出精度最优的物候模型结构。提出了基于环境相似性的聚类参数化方法，以纬度和生长季平均温度为关键聚类变量，将环境异质性高的区域划分为多个环境相似性高的子区域，针对各子区域单独进行模型参数化，显著提高了物候模拟精度。在此基础上，开发了参数自适应优化算法，实现了物候模型参数对环境条件的动态响应，进一步增强了模型在区域尺度上的适用性。

(2) 基于中国主要水稻种植区 2007~2018 年的品种试验观测数据，构建了随机森林产量估算模型。研究从中国水稻新品种试验集收集了 2,175 个水稻品种在 327 个地点的试验数据，并从 ERA5-Land 数据集中提取了相应的气象资料。通过描述性统计分析和斯皮尔曼秩相关性分析，系统评估了地理位置特征、物候特征、气候条件和水稻品种特性与产量的关联模式。在数据预处理基础上，设计了七种不同特征组合的随机森林模型，通过网格搜索和交叉验证优化模型超参数，得到了高精度的产量估算结果。利用特征重要性排序，识别出影响水稻产量的重要变量。

(3) 在前两部分研究基础上，构建了水稻播期和品种优化的多目标决策框架。研究以田间观测试验记录的实际播期为基准点，构建了前后各 15 天的滑动窗口，并考虑区域异质性限制，设计了基于 NSGA-II 算法的多目标优化流程。优化目标综合考虑了产量最大化与高温、低温胁迫最小化，通过并行计算高效筛选出最优播期方案。同时，对各水稻生态类型区内的品种进行综合排序，基于产量水平和产量稳定性筛选出可供替换的候选品种集合。在此基础上，通过物候模型和产量模型的联合应用，实现了播期调整和品种更替的共同优化，提出了区域气候适应性水稻种植建议。

三个研究部分相互支撑、有机衔接：通过环境聚类方法和物候模型，为后续产量估算模型提供了准确的输入变量以及环境分区框架；随机森林产量估算模型立足于水稻产量形成机制，关键的气象胁迫指标被纳入多目标优化的约束条件；机器学习方法贯穿全过程，实现了从数据到决策的有效转化。这一技术路线有效解决了传统农业决策中经验性强、精准度低、区域适应性差等问题，为推动我国水稻生产向精准化和可持续方向发展提供了参考。




图 1-1 技术路线图。

Figure 1-1 The workflow of the thesis.

第2章 数据来源与方法

2.1 数据来源

2.1.1 田间试验数据

(1) 汕优 63 物候观测数据

本研究采用的汕优 63 水稻物候观测资料来源于国家气象信息中心 (<http://data.cma.cn/>)，涵盖中国南方稻区 1984~2005 年的详细记录。该数据集以固定品种汕优 63 为研究对象，系统记录了播种、出苗、移栽、返青、分蘖、拔节、孕穗、抽穗和成熟等关键生育期信息。观测站点分布于中国南方水稻主产区 12 个省份的 38 个农业气象试验站，每个站点的汕优 63 连续种植记录均在 4 年及以上，确保了数据的时空代表性和连续性。

(2) 中国水稻新品种试验数据

本研究使用的中国水稻新品种试验数据来源于 2007~2018 年出版的《中国水稻新品种试验》系列书籍^[154-165]。这些书籍由中国农业科学技术出版社出版，详细记录了国家水稻品种区试及生产试验的相关情况。区域试验是在特定生态区挑选具有代表性的地点，这些地点能够反映当地的土壤、气候、耕作方式和生产水平，进行品种试验，目的是评价不同品种的区域适宜性。区域试验采用完全随机区组排列，每个品种 3 次重复，小区面积 0.02 mu (1 mu=666.67 m²)。生产试验是在区域试验的基础上，在接近大田生产的条件下，对单个品种在种植区的产量表现进行进一步验证。生产试验，采用大区随机排列，不设重复，每个杂交种一个地块种植，大区面积 0.5 mu (约为 333.34 m²)。每本书概述了试验点基本情况，列出了参试品种、品种在各试验点的发育特性、产量及其他重要经济性状、品种抗性鉴定和米质检测结果。

本研究共收集 2007~2018 年 2175 个水稻品种在 327 个地点的田间试验数据。数据内容包括：试验点地理位置特征，主要有经度、纬度和海拔高度；品种实际产量数据：记录了分品种在各试验点的实际产量；物候相关数据，主要包括播种期、移栽期、齐穗期和成熟期，齐穗期被记录为 80% 稻穗露出剑叶鞘的日期，其中成熟期被记录为籼稻 85% 以上、粳稻 95% 以上实粒黄熟的日期；农艺经济性状数据，主要包括单位面积有效穗、每穗总粒数和实粒数、结实率、千粒重、株高和穗长。对于区试点试验中误差较大或遭受自然灾害、病虫害影响的试验结果，均未纳入统计汇总结果，以确保数据的准确性和可靠性。此外，根据稻作区的气候环境条件和栽培季节，我们将所有水稻划分为早稻、晚稻和一季稻三种水稻季节生态型，早稻一般于 5 月中下旬前播种，晚稻一般于 5 月后播种；南方可种植双季稻，北方仅种植一季稻。

2.1.2 气象数据

(1) 气象台站逐日气象数据集

本研究中与汕优 63 物候观测数据相匹配的气象数据，来源于国家气象信息中心 (<http://data.cma.cn/>)。通过精准匹配汕优 63 物候观测农业气象观测站对应的气象台站，我们提取了逐日气象数据，涵盖了每日平均气温 (°C)、最高气温 (°C)、最低气温 (°C)、降水量 (mm)、风速 (m/s)、日长 (h) 以及相对湿度 (%) 等关键气象要素。

(2) ERA5-Land 日汇总数据集

本研究中与中国水稻新品种试验数据相匹配的气象数据，来源于 ERA5-Land (<https://cds.climate.copernicus.eu/datasets>) 日汇总数据集，这是由欧洲中期天气预报中心 (European Centre for Medium-Range Weather Forecasts, ECMWF) 开发和维护的一种全球范围内的高分辨率大气再分析数据集，提供了多种气象和气候变量的连续、一致和高质量的数据。该数据集涵盖了从 1940 年至今的时间段，提供了包括温度、湿度、风速、降水、云量、地表辐射等在内的多个气候变量的日估计值。我们按试验点经纬度提取出 2007~2018 年间逐日气象数据，并进行变量的单位转化，得到日最低温度 (°C)、日最高温度 (°C)、日平均温度 (°C)、日降水量 (mm)、日相对湿度 (%) 和日净太阳辐射量 ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{d}^{-1}$)。特定位置和日期的日长 (h) 根据经度、纬度和年月日日期计算得出^[166]。

2.2 数据分析方法

2.2.1 描述性统计分析

描述性统计分析用于总结数据集的基本特征，包括集中趋势、离散程度和分布形状。均值 (Mean)、标准差 (Std) 和变异系数 (CV) 是常用的统计量，它们分别描述了数据的集中趋势、离散程度和相对离散程度。

均值是数据集中的所有样本的平均值，计算公式为：

$$Mean = \frac{1}{n} \sum_{i=1}^n x_i \quad (2-1)$$

其中， $Mean$ 是数据集中某个指标的均值， x_i 是数据集中该指标的第 i 个值， n 是数据集中该指标的样本量。

标准差是衡量数据集中值的离散程度的统计量，它表示每个样本值与其均值的平均偏差，其计算公式为：

$$Std = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - Mean)^2} \quad (2-2)$$

其中， Std 是数据集中某个指标的标准差。

变异系数是标准差与均值的比值，它是一个无量纲的统计量，用于比较不同

数据集的离散程度，其计算公式为：

$$CV = \frac{Std}{Mean} \times 100\% \quad (2-3)$$

2.2.2 相关性分析

斯皮尔曼秩相关系数用于衡量两个变量之间的单调关系，是一种非参数的统计方法。它通过将原始数据转换为秩次（排序后的位置）来计算相关性，不依赖于数据的分布形态，能够有效处理非线性关系或非正态分布的数据。由于不是所有变量均服从正态分布，并且不是每两个变量之间都是线性关系，所以我们使用斯皮尔曼秩相关系数来评估产量与各个影响变量之间的相关关系，并生成相关性矩阵热力图和数据分布图。斯皮尔曼等级相关系数的计算公式为：

$$r = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (2-4)$$

其中， d_i 是每对统计值的秩差， n 是统计指标的样本量。

2.2.3 聚类分析

聚类分析是一种无监督学习算法，用于将数据分为不同的簇，使同一簇内的数据相似度高，不同簇之间的数据相似度低。K-means 是最常用的聚类方法之一，该方法是基于距离的聚类算法，旨在将数据集划分为 K 个簇组，使得每个数据点属于距离最近的簇组中心。其核心思想是通过最小化簇组内距离的平方和，使得数据点在簇组内尽可能聚集。Inertia（惯性）值，也称为 Within-Cluster Sum of Squares（WCSS，簇内平方和），是衡量簇组内数据点紧密程度的指标，它定义为每个簇组内所有数据点到簇中心的距离平方和。公式如下：

$$Inertia = \sum_{i=1}^K \sum_{x \in C_i} \|x - \mu_i\|^2 \quad (2-5)$$

式中， K 是簇组的数量， C_i 是第 i 个簇组的点集。 x 是属于 C_i 的数据点， μ_i 是第 i 个簇组的质心， $\|x - \mu_i\|^2$ 表示数据点 x 与簇组中心 μ_i 之间的欧氏距离平方。Inertia 值越小，簇内数据点越紧密。随着 K 的增加，Inertia 值会减小。

肘部法则是一种基于 Inertia 值变化的直观方法，用于选择合适的 K 值。通过计算不同簇组 K 的 Inertia 值作为横坐标，Inertia 值作为纵坐标，绘制曲线，观察曲线的形状，找到一个“肘部”点，即 Inertia 值下降速度明显减缓的点，这个点通常对应一个合适的 K 值。

2.2.4 随机森林

随机森林回归是一种基于集成学习的非线性回归方法，通过构建多个决策树并集成其预测结果，能够有效处理复杂的非线性关系，同时具备较高的鲁棒性和对噪声数据的抗干扰能力。此外，该模型还能够量化每个特征的重要性，从而为

识别重要影响因素提供依据。在本研究中，随机森林回归模型（Random Forest Regression）被用于分析种植区域地理特征、物候发育、气候条件、作物品种特性以及管理措施对中国水稻产量的综合影响。

2.2.5 模型性能评价方法

三个统计指标被用于评估模型模拟精度，包括平均绝对误差（MAE，式 2-6），均方根误差（RMSE，式 2-7）以及决定系数（ R^2 ，式 2-8）。整体上，MAE 和 RMSE 越接近于 0，表明模拟误差越小； R^2 越接近于 1，表明模型拟合越好。

MAE、RMSE 和 R^2 的计算方法如下所示：

$$MAE = \sum_{i=1}^n |S_i - O_i| / n \quad (2-6)$$

$$RMSE = \sqrt{\left(\frac{1}{n} \sum_{i=1}^n (S_i - O_i)^2\right)} \quad (2-7)$$

$$R^2 = \frac{\left(\sum_{i=1}^n (S_i - \bar{S})(O_i - \bar{O})\right)^2}{\sum_{i=1}^n (S_i - \bar{S})^2 \sum_{i=1}^n (O_i - \bar{O})^2} \quad (2-8)$$

式中， O_i 为第 i 个观测值， S_i 为第 i 个模拟值， n 为观测指标的样本量， $\bar{O}$ 为观测值的平均值， $\bar{S}$ 为模拟值的平均值。

第3章 基于环境聚类的物候模型升尺度

3.1 概述

物候模型作为作物生长的“计时器”，在作物模型体系中扮演着核心角色，不仅调控不同物候事件的发生时序，还影响整个作物系统的物质和能量循环。物候模拟的准确性直接决定了作物模型在优化农业管理实践^[167]、评估气候变化影响^[168]以及指导适应性策略制定^[101]等方面的有效性。

作物物候发育主要受温度和光周期调控，并在一定程度上受干旱和营养状况的影响^[169,170]。传统物候模型普遍采用热需求（TR）概念，即假设特定作物品种在各发育阶段所需的累积热时间为恒定值，这一理论框架在单点或环境均质区域应用良好，但在具有显著环境异质性的的大尺度区域应用时常导致较大误差^[171,16,172]。尽管研究者已观察到不同地点和气候条件下作物热需求存在系统性变异^[173–175]，但传统模型参数化方法仍局限于品种替代或简单区域划分的思路，缺乏对作物发育适应性机制的系统考量，制约了模型在大尺度异质环境中的应用精度。

本研究针对物候模型在大尺度应用面临的理论与技术瓶颈，构建了系统的研究框架，探索水稻物候模型在升尺度应用中的精确性提升路径。研究创新性地整合了中国南方46个代表性地点长达27年的水稻物候观测数据，以汕优63为研究对象，对比分析了12种主流物候模型的模拟性能，从四个相互关联的科学问题出发，提出了基于环境聚类的物候模型改进方法：

第一，通过多模型比较方法定量评估了作物发育所需TR在时空尺度和模型间的变异特征。研究发现，即使对同一品种，TR值在不同环境条件下仍表现出显著的变异，且这种变异在不同模型结构间具有一致的模式。这一发现从根本上挑战了传统物候模型基于常数积温假设的理论基础，揭示了现有模型缺乏对作物适应性机制表达的内在缺陷。

第二，创新性地提出并验证了基于环境相似性的聚类方法。该方法首先基于关键气候因子对研究区域进行层次聚类，将环境异质性高的大区域划分为多个环境相似性高的子区域，然后针对各子区域单独进行模型参数化。研究结果表明，这种方法有效降低了环境异质性对模型精度的干扰，平均将物候模拟误差降低了44%，为区域尺度物候模拟提供了新的方法论思路。

第三，通过系统的多模型比较与误差分析，评估了不同结构物候模型在复杂环境条件下的适用边界和模型的局限性。研究发现，模型表现不仅与模型结构复杂度相关，还与环境区域的气候特征密切相关。基于三段式温度响应函数的模型在环境条件变异性大的区域表现优越，而大多数过程模型在环境稳定区域具有足够精度。这一发现为模型选择和改进提供了明确方向，并强调了模型适用性评估

的重要性。

第四，基于上述研究发现，开发了一种参数自适应优化算法，实现了物候模型参数对环境条件的动态响应。该算法通过建立 TR 参数与关键环境因子之间的函数关系，使模型参数能够根据环境条件自动调整，有效克服了传统物候模型在异质环境中参数固定的机理性限制。验证结果表明，改进后的自适应物候模型在异质环境下的模拟精度显著提升，成熟期的平均误差降低了 44%，为物候模型在区域和全球尺度应用提供了新的技术路径。

本研究从理论和方法两个层面创新性地解决了物候模型在大尺度应用中面临的关键科学问题。通过揭示作物热需求的环境适应性机制，突破了传统物候模型的理论局限；通过环境聚类 and 参数自适应优化方法，提供了物候模型区域化应用的有效技术路径。

3.2 材料与方法

3.2.1 研究区域和数据来源

研究区域位于中国南方的水稻种植区。该地区纬度跨度大，地形起伏（图 3-1a），占中国水稻种植面积的 90% 以上，占中国水稻总产量的 88%^[176]。该地区以亚热带温暖湿润的季风气候为主，地貌多样，包括亚热带高原、丘陵地带、西南地区高原以及长江中下游平原地区。海拔从 3 米到 1105 米不等，纬度和经度从 19° N 到 35° N 和 98° E 到 120° E，显示出该地区气候的多样性。在所有地点，平均日照时间从 10.2 小时到 14.5 小时不等（图 3-1b），生长季节的日平均温度变化范围从 13°C 到 28 °C（图 3-1c）。

我们从 46 个农业气象站获取了 1984 年到 2010 年籼稻品种“汕优 63”（简称“SY63”）的物候观测数据（<http://www.cma.gov.cn/>）。记录了关键的物候日期：移栽、返青、分蘖、拔节、孕穗、抽穗和生理成熟。这些日期是在实验田中 50% 的植株显示出特定的指定物候特征时记录的，根据农业气象观测标准（中国气象局，1993 年）。为了消除移栽冲击的影响，只选择了返青及以后阶段的数据（移栽、返青、分蘖、拔节、孕穗、抽穗和成熟）。然后将物候日期之间的时间分为五个阶段：返青至分蘖、分蘖至拔节、拔节至孕穗、孕穗至抽穗以及抽穗至成熟。1984~2010 年的气象数据集是从中国气象数据共享服务网站（<http://data.cma.cn/>）获取的。数据集包括，日最低温度（°C）、日最高温度（°C）、日平均温度（°C）和日降水量（mm）。

根据物候观测记录，“SY63”同一物候事件在不同地点、年份的发生时间存在差异（图 3-1d）。返青期发生在 3 月 20 日至 8 月 20 日之间（日长为 12.0 小时到 14.5 小时之间），抽穗期发生在 5 月 14 日至 9 月 30 日之间（日长为 11.6 小时到 14.5 小时之间），生理成熟期发生在从 6 月 10 日到 11 月 18 日之间。与此

同时，我们观察到整个发育期间平均温度有显著波动。站点间抽穗期的平均气温差异大约为 3~8 °C（图 3-1c）。




图 3-1 物候观测点的地理位置 (a)，按纬度和日期划分的日长时数 (b)，研究区的平均

温度 (c)，以及 (d) 物候发生时间。(a) 图基于自然资源部标准地图服务网站下载的审图号为 GS(2019)1719 号的标准地图制作，底图边界无修改。图中不同的颜色和形状的符号表示不同的观测年数。(b) 日长根据日序和纬度计算。(c) 所有地点在 1984 年~2010 年生长季的日平均气温以平均值计算。(d) 箱形图显示物候发生时间范围，黑点表示偏差，红点表示平均值，黑色中线表示中位数。箱线图显示了所有数据的第 25 和 75 百分位数。

Figure 3-1 Geographical location of phenology observation sites (a), daylength hours by latitudes and dates (b), mean temperature (c) of the study area, and (d) phenological occurrence dates. (a) This map was created based on the standard map from the National Natural Resources Department's map service website, with the review number GS(2019)1719. The boundary of the base map has not been modified. Different colors and shapes of symbols in the figure represent different numbers of observed years. (b) Daylength was calculated from the day of year and latitude. (c) Daily mean temperatures were calculated as averages across all sites during the growing seasons from 1984 to 2010. (d) The box charts showed the range of phenological occurrence dates, with black points indicating the outliers, red points indicating the means, and the black center lines indicating the medians. The left and right box boundaries are the 25th-to-75th percentiles.

3.2.2 水稻物候模型

水稻物候模型通常使用两种形式：温度驱动和温度—光周期驱动^[64,62,61,63]。两种模型均使用生长期日计算热时间，使用累积热时间预测物候期的发生。不同之处在于，温度—光周期驱动模型利用光周期效应调整了感光阶段的热时间。此外，不同功能函数还利用了不同的方式，将日平均温度转化为有效热时间，将日长转化为光周期效应。不同功能函数的组合产生了不同的模型。在本研究中，我们测试了 12 个水稻物候模型，包括 3 个温度驱动模型（图 3-2，M1–3）和 9 个温度—光周期驱动模型（图 3-2，M4–12）。我们根据不同的温度响应函数将 12 个模型分为 3 组（图 3-2，G1, G2, G3）。在同一模型组内，温度响应函数保持一致，不同的是光周期响应函数。

(1) 温度响应函数

所使用的三种温度响应函数 (M1, M2, M3) 如图 3-2 所示。对于两段分段线性温度响应函数，如图 3-2 所示 (M1, M4, M5, M6)，发育速率从基础温度 (T_b) 到最适温度 (T_o) 呈线性增长，然后在 $T > T_o$ 下发育速率不受温度的影响保持不变。

$$f_T(T, T_b, T_o) = \begin{cases} 0, & \text{if } T < T_b, \\ \frac{T - T_b}{T_o - T_b}, & \text{if } T_b \leq T \leq T_o \\ 1, & \text{if } T > T_o \end{cases} \quad (3-1)$$

式中， T 为日平均温度 ($^{\circ}\text{C}$)， T_b 为基础温度， T_o 为最适温度。




图 3-2 12 种物候模型综述。M1–M3 为温度驱动物候模式，M4–M12 为温度和光周期共同驱动物候模式。G1、G2 和 G3 代表三个不同的模型组。G1 采用两段分段线性温度响应函数，G2 采用三段分段线性温度响应函数，G3 采用 Beta 温度响应函数。每个模型组内的第一个模型均不考虑光周期效应，第 2 至第 4 个模型分别考虑了两段分段非线性、两段分段线性和 Beta 光周期响应函数。

Figure 3-2 An overview of 12 phenological models. M1–M3 represent temperature-driven phenological models, M4–M12 represent phenological models driven by both temperature and photoperiod. G1, G2, and G3 represent three distinct model groups. G1 used the two-segment piecewise linear temperature response function, G2 used the three-segment piecewise linear temperature response function, and G3 used the Beta temperature response function. The first model of each group disregarded photoperiodic effect, whereas the second to fourth models incorporated the two-segment piecewise nonlinear, the two-segment piecewise linear and the Beta photoperiod response function, respectively.

对于三段分段线性温度响应函数（图 3-2，M2, M7, M8, M9），如式 3-2 所示，发展速率从 T_b 到下限最优温度 (T_l) 呈线性增加，之后保持不变直至上限最优温度 (T_h)，当 $T > T_h$ 时发育速率线性减少，直到临界温度 (T_c) 处发育速率线

性减小为 0。

$$f_T(T, T_b, T_l, T_h, T_c) = \begin{cases} \frac{T - T_b}{T_l - T_b}, & \text{if } T_b \leq T \leq T_l, \\ 1, & \text{if } T_l < T < T_h \\ \frac{T_c - T}{T_c - T_h}, & \text{if } T_h \leq T \leq T_c \\ 0, & \text{if } T < T_b \text{ or } T > T_c \end{cases} \quad (3-2)$$

对于 Beta 温度响应函数，温度对水稻发育速率的影响用 Beta 形式来描述^[177]。该函数通过三个基准温度 T_b 、 T_o 和 T_c 定义了发育速率对温度的响应（公式 3-3）。

$$f_T(T, T_b, T_o, T_c) = \begin{cases} \frac{2(T - T_b)^\delta (T_o - T_b)^\delta - (T - T_b)^{2\delta}}{T_o - T_b^{2\delta}}, & \text{if } T_b \leq T \leq T_c \\ 0, & \text{if } T < T_b \text{ or } T > T_c \end{cases} \quad (3-3)$$

式中，其中 $\delta = \ln 2 / \ln[(T_c - T_b) / (T_o - T_b)]$ 描述温度响应函数曲率的灵敏度参数。

在上述三种温度响应函数中，基准温度分别为 $T_b=8^\circ\text{C}$ ， $T_o=30^\circ\text{C}$ ， $T_l=25^\circ\text{C}$ ， $T_h=35^\circ\text{C}$ ，和 $T_c=42^\circ\text{C}$ 。

(2) 光周期响应函数

水稻被广泛认为是短日照作物，即短日照加速水稻发育，而长日照减缓其发育^[71,72]。光周期效应仅在水稻发育的特定时期内起作用，不同模型描述光周期效应的方式也有所不同^[65,42,43,178,179]。在本研究中，我们假设光敏期是从拔节到抽穗。因此，我们选择了三个广泛使用的光周期响应函数来量化日长对水稻发育速度的影响^[42,43,74]。

对于两段分段非线性光周期响应函数（图 3-2，M4、M7、M10），如式 3-4 所示。在最佳日长（ DL_o ）之前，发育速度不受日长（DL）的影响。随后，当 $DL > DL_o$ 时，发育率呈现非线性下降，渐近于 0.1^[21,180]。

$$f(DL) = \begin{cases} 1, & \text{if } DL \leq DL_o \\ [1 + \frac{P2R}{136} \times (DL - DL_o)]^{-1}, & \text{if } DL > DL_o \end{cases} \quad (3-4)$$

式中， $f(DL)$ 表示日长的影响，范围是 $[0, 1]$ 。P2R 是一个光敏参数，表示作物幼穗分化开始至圆锥花序形成的延迟程度。

对于引入光敏参数（PPSE）的两段分段线性光周期响应函数（图 3-2，M5、M8、M11），如式 3-5 所示，当 $DL \leq DL_o$ 时，发育速率不受影响，当 $DL \geq DL_o$ 时，受作物特异性 PPSE 和 DL 的影响，发育速率线性下降趋近于 0^[43]。

$$f(DL) = \begin{cases} 1, & \text{if } DL \leq DL_o \\ 1 - (DL - DL_o) \times PPSE, & \text{if } DL > DL_o \end{cases} \quad (3-5)$$

式中, PPSE 通过参数优化后被设置为 0.2。

对于 Beta 光周期响应函数 (图 3-2, M6、M9、M12), 日长对水稻发育速率的影响采用 Beta 曲线, 如式 3-6 所示。式 3-6 将最小日长和最大日长分别定义为 0 和 24 小时^[74]。发育速率先增大到最大值, 然后逐渐减小, 趋于 0。此外, 在函数的最大值附近, 发展速度变化较快, 但在函数的边缘变化较慢。DL 对水稻发育速率的 Beta 光周期响应函数, 如式 3-6 所示。将最小日长和最大日长分别定义为 0 和 24h, 发育速率先增后减, 逐渐趋于 0。

$$f(DL) = \exp(\mu) DL^{\delta} (24 - DL)^{\varepsilon} \quad (3-6)$$

式中, μ , δ 和 ε 是模型参数。

3.2.3 基于热需求的模型校准

如图 3-2 中所示模型 G1 和 G3, 其计算热需求 ($^{\circ}\text{C d}$), 如下式:

$$Thermal_D = \sum_{d=Reg}^D [f_d(T) \times \Delta T] \quad (3-7)$$

式中, D 为返青期后的物候期。d=Reg 表示返青期, 即计算热需求的开始日期。 ΔT 表示温差。对于等式 3-1, ΔT 的计算方法是用最适温度 (T_o) 减去下限温度 (T_b)。对于式 3-3, ΔT 是 T 和 T_b 之间的温差。

如图 3-2 中所示模型 G2, 其计算热需求 ($^{\circ}\text{C d}$), 如式 3-8 所示。

$$Thermal_D = \sum_d^D thermal_d$$

$$thermal_d = \begin{cases} 0, & \text{if } T < T_b \text{ or } T > T_c, \\ T - T_b, & \text{if } T_b \leq T \leq T_l \\ T_l - T_b, & \text{if } T_l < T < T_h, \\ (T_l - T_b) - \frac{T - T_h}{T_c - T_h} \times (T_l - T_b), & \text{if } T_h \leq T \leq T_c \end{cases} \quad (3-8)$$

式中, $thermal_d$ 为日有效热量 ($^{\circ}\text{C d}$)。

模型 G1 和 G3 通过将日有效热量乘以每天的日长效应 $f_d(D)$ 计算光—热需求 ($^{\circ}\text{C d}$), 如式 3-9 所示。

$$Photothermal_D = \sum_{d=Reg}^D [f_d(T) \times \Delta T \times f_d(DL)] \quad (3-9)$$

模型 G2 计算光—热需求 ($^{\circ}\text{C d}$) 如式 3-10 所示。

$$Photothermal_D = \sum_{d=Reg}^D [thermal_d \times f_d(DL)] \quad (3-10)$$

采用 3 个温度驱动模型 (图 3-2, M1, M2, M3) 和 9 个温度—光周期驱动模型 (图 3-2, M4-M12) 在 3 个尺度 (整个研究区尺度、局部聚类尺度和站点尺度) 模拟水稻物候。所有的模拟都从返青期开始, 以消除移栽休克期的影响。在

表 3-1 温度和光周期相关参数及取值

Table 3-1 Temperature-photoperiod parameters and values

参数	描述	取值	参考文献
T_b	最低发育温度	8 °C	Van Oort et al., 2011 ^[181]
T_o	最适发育温度	30 °C	Bouman et al., 2001 ^[43] ; Van Oort et al., 2011 ^[181] ; Boogaard et al., 2014 ^[42] ; Wang et al., 2017 ^[182]
T_l	最适发育温度的 下限	25 °C	Jia 1989 ^[183] ; Yin 1995 ^[12] ; Ahmad et al. 2012 ^[65] ; Bouman et al. 2001 ^[43] ; Boogaard et al. 2014 ^[42] ; Wang et al. 2017 ^[182]
T_h	最适发育温度的 上限	35 °C	Jia 1989 ^[183] ; Yin 1995 ^[12] ; Ahmad et al., 2012 ^[65] ; Bouman et al., 2001 ^[43] ; Boogaard et al., 2014 ^[42] ; Wang et al., 2017 ^[182]
T_c	发育温度上限	42 °C	Van Oort et al., 2011 ^[181]
μ	光敏感系数	-15.46	Yin, 1996 ^[184]
δ	光促进系数	2.06	Yin, 1996 ^[184]
ε	光抑制系数	2.48	Yin, 1996 ^[184]
DL_c	关键日长	16 h	Liang and Cai ^[185]
DL_o	最适日长	12.5 h	Yin, 1997 ^[63] ; Jia, 1989 ^[183]

整个研究区尺度上计算模拟误差步骤如下（图 3-3）：首先，将整个水稻全生长期划分为 D_1 – D_5 5 个发育阶段。随后，计算和校准了每个模型在特定发育阶段的 TR（热需求）。然后，将校正后的 TR 作为固定参数来模拟水稻物候。一旦累积的 TR_{daily} （日有效热量）超过校准后的 TR，作物就完成特定阶段的发育进入下一个物候阶段。作物完成特定发育阶段的模拟日期记为 $Y_{i,sim}$ ，而相对应的观测日期记为 $X_{i,ob}$ 。模拟误差是模拟日期和观测日期之间的天数差。同时，为了确保所有模拟都能够预测到生理成熟，我们将未模拟出成熟期的情况进行了特殊处理，设定从返青到生理成熟的最长持续天数为 124 天，这是我们观测记录的最长时间。

在区域和站点水平上的 TR 标定方法与上述步骤相似。三个尺度的差异为：整个研究区域的聚类类别数为 1 个，局部尺度的聚类类别数为 2~45 个，站点尺度的聚类类别数为 46 个。对于站点水平 TR 的校准，由于没有空间差异，因此我们只关注 TR 的年际变化，并针对每个站点定制了特定的站点参数。而在整个研究区域和局部聚类尺度，我们不仅考虑了 TR 的年际变化，还考虑了 TR 的空间变化。校准的参数 TR 用于具有类似环境条件的集群。




图 3-3 物候模型改进方法综述。▲, ●, ■, ◆ 代表具有独特环境条件的站点。▲ 和 ● 表示通过聚类方法划分的不同聚类类别。↔ 表示区分具有环境异质性的站点的过程。步骤 3: D₁-D₅ 代表 5 个发育阶段。TR 表示校准后的热需求。TR_{daily} 表示日有效热量。作物完成某一特定发育阶段的模拟日期记为 $Y_{i, sim}$, 对应的观测日期记为 $X_{i, ob}$ 。Δ 是模拟日期和观测日期之间的天数之差。

Figure 3-3 An Overview of the proposed method to improve phenology models. ▲, ●, ■, ◆ represent individual sites with unique environmental conditions. ▲ and ● represent different clusters divided by the clustering method. ↔ signifies the process of distinguishing sites with environmental heterogeneity. Step 3: D₁-D₅ represent five developmental periods. TR represents the calibrated thermal requirement. TR_{daily} represents daily effective heat. The simulated date on which the crop completed a specific stage was denoted as $Y_{i, sim}$, while the corresponding observed date was denoted as $X_{i, ob}$. Δ is the difference in days between simulated and observed dates.

3.2.4 基于环境变量的站点聚类

本研究利用 K-Means 聚类分析方法，根据样本间距离的相似性将样本划分为不同的类别。我们的目标是将具有相似环境的站点分组到同一集群中，以减少环境异质性，并测试聚类方法是否可以减少模型的模拟误差。我们基于气候和地理因素，在 Python 中使用 scikit-learn 库的 K-means 聚类方法进行相关分析^[186]。

优化聚类参数的步骤如下。首先，我们根据专家知识和观测数据的特点，选择出所有影响作物物候的潜在变量^[187,7,4]。这些变量包括地理信息（纬度、经度、海拔）、管理实践（移栽日期）和气象数据（日平均温度、热积累、日长）。因为我们的研究作物是在中国南方水田种植的水稻，并且品种固定为“SY63”，排




图 3-4 相关环境变量的相关系数矩阵。单元格颜色的深浅对应于相关性的强度，颜色越深表示相关性越强。变量包括纬度（Lat）、经度（Lon）、海拔（Elev）、移栽日序（TDOY）、年平均气温（ATM）、年平均有效积温（ATS）、年生长季（移栽后 120 天内）平均气温（STM）和有效积温（STS）、移栽后 60 天内有效积温（TD60_TS）、移栽后 70 天内有效积温（TD70_TS）。

Figure 3-4 Correlation coefficient matrix of the important environmental variables. The shade of the cell color corresponds to the strength of the correlation, with darker shade indicating stronger correlations. Variables include Latitude (Lat), Longitude (Lon), Elevation (Elev), The Day of Year for Transplanting date (TDOY), Annual Mean Temperature (ATM), Annual Accumulation of Growing Degree Days (ATS), Mean Temperature (STM) and Thermal Accumulation (STS) during the growing season (within 120 days after transplanting), Thermal Accumulation within 60 days after transplanting (TD60_TS), Thermal Accumulation within 70 days after transplanting (TD70_TS).

除了与作物品种和水分供给相关的因素。由于水稻被普遍认为是短日照作物，其发育受光周期的影响，我们还考虑了每天的日长及其在不同纬度上的变化。此外，

我们的数据缺乏施肥和农药等管理实践的记录，因此我们没有包括这些因素。重点是不同环境条件对作物生长的影响。最后，潜在变量集合包括纬度（Lat）、经度（Lon）、海拔（Elev）、移栽期的日序（TDOY）、年平均温度（ATM）、年生长季积累的有效积温（ATS）、从移栽到孕穗的有效积温（Boot_TS）、从移栽到抽穗的有效积温（Hea_TS）和从移栽到生理成熟的有效积温（Mat_TS）。

其次，我们研究了所有潜在影响因子与发育天持续数（从移栽到生理成熟的持续天数，Days_Trans_Mat）之间的相关性。该分析排除了不相关因素 Lon（ $r = -0.15, P > 0.05$ ，表 3-1）。随后，我们量化了剩余影响因素对 Days_Trans_Mat 的影响程度，建立了重要性层次结构：Mat_TM > ATM > Lat > Mat_TS > Elev > TDOY > ATS > Boot_TS > Head_TS。但是，由于 Mat_TM、Mat_TS、Boot_TS 和 Head_TS 的值依赖于物候观测数据，所以不能直接将它们作为物候预测的聚类参数。因此，我们计算了独立于物候观测的生长季（移植后 120 天内）的平均温度（STM）和有效积温（STS），以替代依赖于物候观测的变量（如 Mat_TS）。同样，我们使用移栽后 60 天内的有效积温（TD60_TS）和移栽后 70 天内有效积温（TD70_TS）来代替 Bot_TS 和 Hea_TS^[188]。随后，分析新变量之间的相关性，以选择合适的聚类变量（图 3-4）。需要注意的是，所选择的变量应该相互关联，以便将具有相似环境的站点归入同一类别。然而，高度相关的变量可能会错误地将条件相似的站点划分到不同的类别中。因此，用于聚类的变量应该具有弱相关性。根据图 3-4，我们初步确定可以使用 STM、Lat、Elev、TDOY 或这些变量的组合作为聚类变量。以上所有数据分析代码已公开。

3.3 结果与分析

3.3.1 观测站点间作物发育热需求的变异

图 3-5 显示了各发育期的发生时间和跨年份、站点间的热需求（TR）的显著变化。随着水稻物候发育的推进，同一物候期发生时间在站点间的变异性逐渐增加（图 3-5 a）。例如，从移栽到返青的持续时间从 3 天到 11 天不等，平均为 6 天。从移栽到抽穗历时 51~82 天，平均为 68 天。从移栽到生理成熟的周期为 86~124 d，平均为 103 天。

我们使用热需求标准差（TR_{std}）来量化每个模型在不同地点-年份间热需求变化的变异性。地点-年份温度的波动导致了日有效积温具有地点特异性的特征，最终体现在 TR 上也具有地点特异性。随着水稻发育期的推进，所有模型在不同地点-年份间的 TR_{std} 更加明显（图 3-5 b）。以模型 M3 为例，在分蘖期，TR_{std} 在不同地点-年份间为 34 °C d，而到了生理成熟期，TR_{std} 增加到了 167 °C d。在 12 个模型中，M3、M10、M11 和 M12 表现出较大的 TR_{std}。这四个模型都基于 Beta 温度响应函数（图 3-2，G3）。相比之下，采用三段式分段线性温度响应函




图 3-5 观测物候期在移栽后的发生时间和不同地点一年份热需求的标准差 (TR_{std})。
(a) 展示了从移栽日期到后续物候事件日期的时间跨度，(b) 展示了所有模型在不同地点—年份热需求的标准差 (TR_{std})。(a) 中，箱形图和须线分别代表从移栽日期到后续物候日期时间跨度的第 25 到第 75 百分位和第 10 到第 90 百分位范围。(b) 中，M1–M12 代表 12 个物候模型，详细描述见图 2 和表 1。单元格的颜色越深表示变异性越大。

Figure 3-5 The observed phenological events occurred on the date after transplanting and the standard deviation of thermal requirements (TR_{std}) across site-years. Panel (a) showed the durations from transplanting date to the dates of subsequent phenological events across site-years, and panel (b) showed the standard deviation of thermal requirements (TR_{std}) across site-years for all models. In panel (a), boxes and whiskers represent the 25th–to–75th and the 10th–to–90th percentile ranges, respectively, of the duration from transplanting date to subsequent phenological dates. In panel (b), M1–M12 represent the 12 phenology models, with detailed descriptions given in Figure 2 and Table 1. The cell colors represent the value of TR_{std} across site-years, where darker colors indicate higher variability.

数的模型（图 3-2, G2），如 M2、M7、M8 和 M9，显示出较小的 TR_{std} 。此外，光周期可以影响日有效积温的积累。包含光周期效应的模型（M5–M12）与没有光周期效应的模型（M1–M3）相比，表现出较低的 TR 和较小的 TR_{std} 。例如，在生理成熟期，M4–M12 的 TR 范围从 1396 °C d 到 1759 °C d，而 M1–M3 的 TR 范围从 1656 °C d 到 1844 °C d。M10–M12 在不同地点–年份间的 TR_{std} 范围从 128 °C d 到 150 °C d，而 M3 在不同地点–年份间的 TR_{std} 为 167 °C d。




图 3-6 46 个站点 SY63 的平均热需求 (TR)。M1-M12 代表 12 种物候模型，详细描述见图 2 温度响应曲线和光周期对发育速率的响应曲线。框内的值表示 46 个站点的平均 TR。

Figure 3-6 Mean thermal requirements (TR, °C d) at different developmental periods for rice cultivar ‘SY63’ across 46 sites. M1–M12 represent 12 phenological models, with detailed descriptions given in Figure 2 (Temperature response curves and photoperiod response curves for rice development rate). The numbers in the cells represent the mean TR values across 46 sites.

3.3.2 不同模型组在两个尺度上模拟性能的表现

模型组 G1（采用两段分段式温度响应函数）和 G2（采用三段分段式温度响应函数）在站点尺度和整个研究区尺度上表现出相似的较好的模拟性能，而模型组 G3（采用 Beta 温度响应函数）则表现最差（见图 3-7）。随着研究区域从站点尺度扩展到整个研究区尺度上，高性能模型组和低性能模型组之间的性能差距

变得更加明显（见图 3-7）。对于站点尺度的模拟，在生理成熟阶段的平均绝对误差（MAE），对于 G1 是 1.7 天，MAE 变动范围为 0 到 10 天；对于 G2 是 1.8 天，MAE 变动范围为 0 到 10 天；而对于 G3 是 3.4 天，MAE 变动范围为 0 到 23 天。在整个区尺度上的模拟，在生理成熟阶段的 MAE，对于 G1 是 6.0 天（ ± 5.6 天），对于 G2 是 4.5 天（ ± 4.1 天），而对于 G3 是 9.4 天（ ± 8.0 天）。模型组 G3 在 2 个尺度上始终显示出较高的 MAE。值得注意的是，像 G3 这样具有较大 MAE 的模型组，相比原本就具有较低 MAE 的模型组，G3 通过聚类后 MAE 的降低幅度更大。例如，当从整个研究区尺度（不进行分类处理）逐渐到到站点尺度上（划分为 46 个类别）时，M2 的 MAE 在生理成熟阶段从 5.1 天减少到 1.8 天，总计减少了 3.3 天；而 M3 模型的 MAE 则从 10.5 天减少到 3.5 天，总计减少了 7 天。

通过比较是否包含光周期效应对模型模拟性能的影响时发现，包含光周期效应的模型比没有光周期效应的模型表现出更高的准确性。例如，在整个研究区尺度上，模型组 G2 中的 M2（未考虑光周期效应）、M7、M8 和 M9 的 MAE 分别为 5.1 天、4.4 天、4.0 天和 4.4 天。同样，在模型组 G3 中，M3（未考虑光周期效应）、M10、M11 和 M12 的 MAE 分别为 10.5 天、9.2 天、8.4 天和 9.5 天（见图 3-7b）。此外，光周期响应函数在不同尺度上对模型性能的影响也存在差异。在站点尺度上，模型性能主要取决于温度响应函数的结构，光周期的影响较小（见图 10a）。然而，随着模拟的尺度从站点扩展到整个研究区上，光周期响应函数对模型准确性的积极影响逐渐凸显。以模型组 G1 在生理成熟的模拟误差为例，我们比较了不考虑光周期效应的 M1 和纳入光周期效应的 M4。在站点尺度上，M1 在生理成熟的 MAE 是 1.8 天，而 M4 的 MAE 也是 1.8 天。然而，当模拟尺度扩展到整个研究区上时，M1 的 MAE 是 6.8 天，相比之下，M4 的 MAE 是 6.1 天。

3.3.3 适用于本研究特定区域最优聚类参数

Inertia 值表明不同变量的最优聚类类别数会有所不同（图 3-8）。1 到 24 个聚类类别范围内的平均绝对误差（MAE）被用来衡量不同聚类变量的对模型模型性能影响，这些聚类变量包括“STM”（作物生长季热需求）、“Lat”（纬度）、“Lat+STM”（纬度和作物生长季热需求）、“Lat+STM+Elev”（纬度、作物生长季热需求、海拔）、“Lat+STM+TDOY”（纬度、作物生长季热需求和移栽日序）和“Lat+STM+TDOY+Elev”（纬度、作物生长季热需求、移栽日序和海拔）。对于以上聚类变量，它们各自聚类类别数的适当范围分别为 6–12、8–15、12–18、18–24、18–24 和 20–30。图 3-9 展示了在不同发育期以及整体平均情况下，不同聚类变量的 MAE 的变化。例如，在生理成熟阶段，使用“STM”作为聚类变量，当聚类类别数为 9 时，MAE 最小为 4.6 天（图 3-9 a, Figure 3-10）。为了确定最




图 3-7 模型在生理成熟期的平均绝对误差 (MAE, 天) 的比较。M1-M12 代表 12 种物候模型, 详细描述见图 2。G1、G2、G3 为 3 个模型组。(a) 在站点尺度的 MAE。(b) 在整个研究区尺度的 MAE。相同颜色的箱形框表示不考虑光周期效应, 或使用相同光周期响应函数, 但基于不同温度响应函数的模型。箱形图和图中的须线分别代表 MAE 的第 25–75 和第 10–90 百分位范围。箱形框中的黑粗线表示中位数, 红点表示平均值。黑色菱形表示 MAE 值超过第 10 和第 90 百分位范围的离群点。

Figure 3-7 Comparison of mean absolute error (MAE, days) for models at physiological maturation stage. M1–M12 represent the 12 phenological models, with detailed descriptions given in Figure 2. G1, G2, and G3 represent three model groups. (a) MAE for the site-level. (b) MAE for the whole study region. Boxes of the same color represent models that use the same photoperiod response function but different temperature response functions. Boxes and whiskers represent the 25th–to–75th and the 10th–to–90th percentile ranges of MAE, respectively. The thick lines in the boxes represent the median values. The red dots represent the mean values. The black diamonds outliers whose MAE values exceeded the 10th and 90th percentile range.

佳的聚类类别数量和最佳聚类变量, 图 3-10 展示了所有发育期 (分蘖、拔节、

孕穗、抽穗和生理成熟) 的 MAE 变化。尽管“STM”在聚类类别数为 6 时快速收敛, 此时 MAE 为 4.0 天, 但其 MAE 并没有随着聚类类别数量的增加而持续减少。然而, 当聚类类别数超过 6 时, “Lat+STM”、“Lat+STM+Elev”和“Lat+STM+TDOY+Elev”的 MAE 值均低于“STM”。当聚类数量为 12 时, “Lat+STM”、“Lat+STM+Elev”和“Lat+STM+TDOY+Elev”的 MAE 值比“STM”的 MAE 低了 0.4 天。考虑到变量“Lat+STM”、“Lat+STM+Elev”和“Lat+STM+TDOY+Elev”, 它们在模拟精度方面表现相似。然而, “Lat+STM+TDOY+Elev”比“Lat+STM”多包含两个变量, “Lat+STM+Elev”比“Lat+STM”多包含一个变量。因此, 在考虑了准确性(模型模拟的精度)和运算效率(即模型运行的速度和资源消耗)之间的平衡后, 这项工作最终选择了“Lat+STM”作为最优变量, 最佳聚类类别数为 12。




图 3-8 不同聚类类别数和聚类变量的 Inertia 值。STM 为生长季(移栽后 120 天内)平均温度。Lat 代表纬度。Elev 代表海拔高度。TDOY 表示从移植期日序。Inertia 值表示聚类对变量变异性的影响程度。较低的 Inertia 值表明同一聚类类别内的变异性较小。

Figure 3-8 Response of Inertia value to cluster number and variable combination. STM represents the mean temperature within 120 days after transplanting. Lat represents latitude. Elev represents elevation. TDOY represents the day of year from transplanting date. Inertia indicates the effects of clustering on variable variability. The lower Inertia values indicate smaller variability within the same clusters.




图 3-9 不同聚类变量在不同发育阶段平均绝对误差的变化和所有发育阶段的平均。所有时期平均表示分蘖、拔节、孕穗期、抽穗和生理成熟 5 个发育期的平均。

Figure 3-9 The variation of mean absolute error with different clustering variables at different development stages and all stages mean. All stages represent mean absolute error of five development stages (tillering, jointing, booting, heading, and physiological maturation).




图 3-10 不同聚类变量在不同发育期（分蘖、拔节、孕穗期、抽穗和生理成熟）绝对误差平均值的下降趋势。

Figure 3-10 The decreasing trend of mean absolute error for different clustering variables across all stages (tillering, jointing, booting, heading, and physiological maturation).

3.3.4 通过减少环境异质性提高模型性能

在整个研究区尺度上，所有模型模拟性能的表现如图 3-11 所示。所有模型的平均绝对误差（MAE）在 1.6~10.5 天之间，并且模型的模拟精度随着水稻物候发育的推进而降低。在不同发育阶段，模型的 MAE 存在差异，在分蘖期模型 MAE 的变动范围为 1.6~2.0 天，在拔节期为 3.5~8.6 天，在孕穗期为 4.1~8.5 天，在抽穗期为 3.4~7.1 天，在生理成熟期为 4.0~10.5 天。集成 MAE（12 个模型的平均）在分蘖期、拔节期、孕穗期、抽穗期和生理成熟期的 MAE 分别为 1.8、5.3、5.6、4.7 和 6.6 天。其中，M3 和 M10-M12 的 MAE 最高，模型模拟性能较差，而 M2 和 M7-M9 的 MAE 较低，模型模拟性能较好。然而，在不同的发育阶段，表现最佳的模型和表现最差的模型并不总是固定的。例如，在拔节期和孕穗期，M2 的模拟性能最好，其 MAE 最小，分别为 3.5 天和 4.1 天。在抽穗期，M8 和 M9 的模拟性能最好，它们的 MAE 最小，均为 3.4 天。在生理成熟期，M8 的模拟性能最好，其 MAE 最小，为 4.0 天。在不区分具体发育阶段的情况下，对所有发育阶段的 MAE 进行平均，M2 和 M9 的模拟性能最佳，具有最小的 MAE，为 3.6 天。

增加聚类类别数能够显著降低所有模型和在所有发育阶段的 MAE（图 3-9）。基于 ‘Lat+STM’ 的聚类分析表明（图 3-9 c），分蘖期、拔节期、孕穗期、抽穗

期和生理成熟期, 5 个发育阶段的 MAE 均随着聚类类别数从 1 类增加到 24 类一致降低。由于分蘖期是模拟的第一个物候期, 其 MAE 从聚类类别数 1 类到 24 类的变化最小, 仅减少了 0.4 天。在拔节期, MAE 从起始聚类类别数 1 类的 5.3 天减少到最终类别数 24 类的 3.7 天, MAE 减少了 1.6 天。在孕穗期、抽穗期和生理成熟期也有类似的变化, 其 MAE 分别减少了 1.7、1.4 和 2.9 天。不区分发育阶段的情况下 (Allstages), MAE 从聚类类别数 1 类的 4.8 天显著下降到聚类类别数 24 类的 3.2 天。通过不同的发育期阶段的对比发现, 随着聚类类别数的增加, 生理成熟期的模拟精度改善最为显著, 并且生理成熟期的 MAE 逐渐向不区分发育阶段时的 MAE 收敛。此外, 在聚类类别数从 1 类增加到 24 类的过程中, 所有发育阶段 MAE 的减少速率逐渐趋缓。




图 3-11 在整个研究区内所有发育阶段和所有模型的平均绝对误差 (MAE)。M1-M12 代表 12 个物候模型, 详细描述见图 2。集合模型表示所有模型 (M1-M12) 平均的 MAE。所有时期表示不区分发育阶段, 对分蘖、拔节、孕穗期、抽穗期和生理成熟期 5 个发育阶段平均得到的 MAE。每个单元格中的数字对应于 MAE 值。单元格颜色较深表示 MAE 的值越高。

Figure 3-11 Mean Absolute Errors (MAE) for all development stages and models across the whole study region. M1-M12 represent the 12 phenology models, with detailed descriptions given in Figure 2. The last row (Ensemble) represents the MAE of all models (M1-M12), and the last column (Allstages) represents the MAE obtained by averaging of all development stages (tillering, jointing, booting, heading, and physiological maturation) without distinguishing development stages. The numbers within each cell correspond to MAE values. Cells with a darker shade indicate higher MAE values.

3.4 讨论

3.4.1 物候模型局限性的来源

我们使用 12 个物候模型, 充分描述了 1984~2010 年间 46 个站点的一个水稻

品种“SY63”在不同发育阶段的热需求（TR）及 TR 的差异。我们观察到 TR 在不同站点—年份间的变异性。我们的结果与之前研究一致，这些研究也表明了存在地点特异性的 TR^[189,181,14]。这种变异性源于作物在其特定的生长环境中对温度和日长变化做出的物候发育的调整和适应。

具体来说，物候受到温度的年纪波动、季节变化和光周期等多种环境因素的影响^[190,167,191,182]。为了减轻环境变化对作物自身发育的影响，不同种植地采取了适当的管理措施，如调整播种日期^[102]。我们观察到，播种日期从 3 月下旬到 7 月中旬不等，且从移栽到后续同一物候事件的持续时间，在不同地点—年份之间相差大约 10~40 天（见图 3-7 a）。这一结果可以归因于中国南方地区因地制宜的播期调整和地理环境差异，导致“SY63”在不同地点的生长季节平均温度显著不同。例如，在 8 月 1 日左右抽穗的站点，其平均温度比其他站点抽穗时的平均温度高出 5~8 °C（见图 3-3 c, d）。此外，光周期在整个研究区域内从 11.6 小时到 14.5 小时之间变化（见图 3-3 b），SY63 抽穗时的热需求的标准差（TR_{std}）在 64 °C d~119 °C d 之间变化（见图 3-7 b）。纬度已被证明会通过温度和光周期影响 TR。Liu 等人（2013）^[192]证明，向北纬度每增加 1°，TR 就会减少 25.6 摄氏度天。因此，每天的有效积温对发育速率的贡献在不同环境条件下是不同的。这些结果表明，TR 不仅受作物品种的遗传特性影响，还受特定地点环境条件的影响。

地点特异性的作物发育热需求有别于被广泛接受的概念，即作物发育所需要的热需求仅由品种特定特征和遗传基因决定^[193]。这种差异可能源于模型的局限性，这些模型未能考虑到作物适应其特定栽培环境的能力。已有研究表明，植物在各种表型上表现出环境可塑性^[194,195,182]。例如，根系在土壤剖面中的分布可以变化，以适应水和养分可用性的自然波动^[196]。随着环境温度的变化，光合作用的温度敏感性在不同时间尺度上发生了变化^[197]。Wu 等人（2019）^[15]研究证明，将塑性温度响应函数纳入生长速率的温度敏感性中，可以将生理成熟阶段的模拟误差减少一半。这些结果强调了未来模型改进的重要的方向，需要考虑作物对多样化环境条件的适应机制。

然而，以往证明作物模型参数化具有环境特异性的研究往往依赖于单一模型或仅考虑有限的几个模型来计算 TR^[198,173,199]。因此，与模型相关的不确定性没有得到彻底解决。为了综合评价物候模型的模拟精度，探讨模型不确定性的来源。我们选择了 12 个不同的物候模型，包括 3 个温度驱动的和 9 个光—温驱动模型。根据作物生长速率对温度响应的不同方式，我们将 12 个模型分为三组（G1–G3，见图 3-5）。不同模型组之间的区别归因于它们各自的温度响应函数。与仅由温度驱动模型相比，同时考虑光周期和温度的模型在非站点尺度上有效提高了物候模拟的准确性。另一方面，具有分段线性温度响应函数的模型比使用 Beta 函数的模型表现更好（见图 3-5 和图 3-11，G1 和 G2 与 G3）。这一结果可

以归因于这些模型中用于描述作物发育速率对温度响应的不同机制。**Beta** 温度响应函数使用特定的最适发育温度（30 °C），而三段分段式线性温度响应函数具有最适发育温度范围（25~35 °C）。当超过特定最适温度点时，**Beta** 函数的发育速率显著下降。表现不佳的模型倾向于在非最适温度下低估作物发育速率^[8]，导致模型模拟的持续时间比实际观测到的持续时间长。这些发现与之前的研究一致，这些研究强调了在非最适温度下准确描述作物发育速率的潜在局限性^[189,182,13]。

同一模型组内的差异归因于光周期响应函数。具体来说，每个模型组内的第一个模型忽略了光周期效应，而第二至第四个模型分别采用了两段分段式非线性、两段分段式线性和 **Beta** 光周期响应函数。其中，采用两段分段式线性光周期响应函数的模型（M5、M8 和 M11）显示出较小的误差（见图 3-11）。与其他光周期响应函数相比，**Beta** 光周期响应函数对日长的敏感性最低，其准确性取决于模型的温度响应函数。这与 Wang 等人（2015）^[8]的发现一致。对于两段分段式非线性光周期响应函数，其特性是，在 DLo 附近发育速率对日长的变化非常敏感，之后发育速率对日长变化的反应明显减弱，导致不同站点作物发育热需求的差异显著。此外，使用有限的环境中推导出的默认参数阈值进行参数优化也增加了模拟误差。以前的研究表明，仅在特定温度范围内校准的物候模型在气候变暖时可能变得不那么准确。Iizumi 等人（2009）^[200]揭示了基础温度和低温引起的小穗不育曲率因子等参数后验分布的区域差异。同样，van Oort 等人（2011）^[181]也证明，使用默认参数阈值校准的模型可能无法准确模拟变暖气候下从萌芽到开花的持续时间。

尽管物候模型之间存在差异，但在整个研究区域、地方和站点三个尺度上，所有物候模型的误差趋势一致。12 种物候模型的模拟误差从站点水平到整个研究区域逐渐增大。有趣的是，我们还观察到模型在不同尺度上的表现是一致的。使用矩形温度响应函数的模型一直被认为是性能最好的，而使用 **Beta** 温度响应函数的模型一直被认为是精度最低的。这与以往的研究结果形成了鲜明对比^[13]，以往的研究结果强调要根据特定地区的当地作物种植制度选择具体的模型。造成这种差异的主要原因是我们在研究中没有区分早稻、晚稻和单季稻，因为我们的数据主要集中在单季稻上。此外，我们的研究区域是华南亚热带季风气候区，不包括东北温带季风气候区。以往的研究通常基于站点级别或局部级别的数据校准所有参数^[8,13]。相比之下，我们基于特定尺度下的品种特异性热需求模拟了水稻物候。该方法具有尺度专一性、品种适应性和参数标定简化等优点，能够更准确、适应性地模拟不同品种和环境条件下的水稻物候。

尽管物候模型之间存在差异，但随着模拟尺度从站点级别扩展到整个研究区，这些模型的误差显示出一致且逐渐增加的趋势。有趣的是，我们还观察到模型性能不同的尺度具有一致性。使用两段分段式线性（图 3-5 和图 3-11 中的 G2）温度响应函数的模型，其表现始终是最佳的。相比之下，使用 **Beta** 温度响应函数

的模型（图 3-5 和图 3-11 中的 G3）始终是模拟最不准确的。这一结果与之前强调要根据特定地区和当地作物种植系统选择特定模型的研究结果形成对比^[13]。这种差异的主要原因是我们的研究没有区分早稻、晚稻和单季稻，因为我们的数据主要集中在单季稻上。此外，我们的研究区位于中国南方亚热带季风气候区，不包括中国东北温带季风气候区，没有跨越不同气候区。以往的研究通常基于站点尺度进行参数校准^[8,13]，相比之下，我们在特定的尺度上，根据校准后特定品种发育所需的热需求去模拟作物物候，这种方法在尺度特异性、品种适应性和简化参数校准方面具有优势，能够更准确、高效地模拟不同品种和环境条件下的作物物候。

3.4.2 聚类方法对物候模型模拟精度的影响

物候模型通常在稳定且均质的田间条件下开发和验证^[201,202]。然而，随着模型越来越多地应用到超出田块水平的更大尺度上，如果忽略作物对不同环境的适应机制，模型的准确性可能会受到影响，导致不同模型和不同研究区域的物候模拟误差可能会有所不同。在这项研究中，我们通过使用聚类方法，识别出环境条件相似的站点并将它们划到同一类别中，提高了不同空间尺度上物候模拟的准确性。我们的目标是通过确定最佳聚类变量和聚类类别数，以提高模型的模拟精度。

聚类方法可以减轻模型中由于地形、地理位置和环境异质性的变化带来的不确定性^[36]。通过仔细筛选最佳的聚类变量和适宜的聚类类别数，可以将不同的环境因子作为优化参数集成到基于过程的物候模型中。将环境条件相似的站点聚类到作物对环境具有相似适应性的同一类别中，基于聚类等人，这种方法有效地弥补了物候模型中作物适应过程的缺失，从而减少了模拟误差。该方法提高了物候模型在环境异质性地区的模拟性能。我们的研究表明，使用“Lat”和“STM”作为聚类变量可以显著降低模型的模拟误差。“STM”是影响发育速度的最关键因素通过温度和光周期等作物物候。例如，Liu 等人^[192]在中国不同纬度下，研究玉米对环境变化的物候响应，发现纬度越高玉米的营养生长期越长，生殖生长期越短。同样，中国杂交水稻气象研究协作组（1981）的研究结果表明，4~10 月为中国南北温差年度内的低值期，作物发育更多地受到地势起伏的影响，纬度每升高 1°，汕优 6 号从播种到抽穗的热需求（TR）相应地增加 19 °C d，发育期平均日长延长 0.11 h。此外，应该注意到环境条件和作物适应性因地区而异。因此，将该聚类方法应用于其他区域时，根据特定研究区的具体特点重新调整和优化聚类参数是~关重要的。具体来说，一方面是聚类因子的选择应考虑区域特定变量，如海拔高度、土壤湿度、土壤特征、水资源有效性等相关因素，另一方面是最佳聚类类别数的选择也需要重新确定。

虽然聚类方法有效地降低了环境异质性引起的物候模拟误差，但它没有考虑到时间异质性，因此不能充分解决时空变异引起的误差。各种与时间有关的因素，

包括季节波动和气候变化,对作物生长和发育产生重大影响。例如,整个季节的温度波动、光周期年际变化和土壤有效氮含量都会影响作物的发育速度和物候事件的时间^[185,20,203,204]。此外,气候变化引起环境条件的变化,如温度、湿度和降水,也会影响作物的生长和发育^[205,206]。其他与农耕时序相关的因素,如农业管理措施和品种的变化,也会影响物候模拟的准确性^[102]。这些因素在不同时间和地点表现出差异,导致物候事件发生的时空差异。进一步的工作可以结合时间相关的数据分析方法,如时间序列分析、动态建模和混合模型,以更好地解释和预测物候变异性。

3.4.3 气候变暖对物候的影响

在过去的几十年里,全球大部分地区都经历了变暖趋势,预计未来还会加速^[101,207,205]。因此,了解作物物候如何响应并适应气候变暖是准确评估未来作物产量的前提条件。理论上,物候模型基于一定的热需求(TR)值来预测作物物候,随着气候变暖,积累TR所需的时间将减少,作物发育期缩短。先前的研究表明,在气候变暖的未来情景下,基于过程的作物模型通常模拟出物候事件提前、发育期缩短和产量下降^[190,23,208,8]。然而,一些研究也表明,通过调整作物品种和采取适当的管理措施,气候变暖导致的作物发育期缩短和产量下降等负面影响得到了有效缓解^[78,76,209,210]。但以往的研究并没有将作物品种改变从多种影响因素中分离出来,也没有考虑作物对长期气候变化和作物种植环境的适应性。因此,物候模型的假设是热需求恒定,这导致理论模拟结果与实际情况不完全一致。

我们的研究结果证实,特定水稻品种“SY63”发育所需的热需求受地点特异性的显著影响。由于作物模型不能有效反映作物对不同生长环境的适应机制,随着模拟区域的扩大,物候模拟误差不断增加。Wu 等人(2019b)^[211]也证明了作物对气候变暖的适应性,即使品种不变,温度升高也不会普遍导致物候日期提前和生育期缩短。此外,随着气候变暖,不同模型在非最适温度下的响应差异变得更加明显^[23]。Wang 等人(2017)^[182]也证实,在非最佳温度下,不同模型模拟的物候相互偏离,与观测值不匹配。这些结果表明,基于现有实验的模型参数将不再适用于气候变暖的情况。温度是物候的主要驱动因素之一,但随着气候变暖,其他环境因素,如高温胁迫和极端降水,也将对作物生长和发育产生重大影响^[212-215]。目前,物候模型尚不能充分量化各种环境因素对物候的综合影响。因此,不完善的物候模型往往会高估气候变暖对作物生长和发育的影响。

3.4.4 限制与不足

模型的准确性取决于输入数据的精度和参数校准的准确性。通过使用大量观测物候数据来校准模型参数,可以输出准确反映实际种植条件的参数,从而提高模型的准确性和可靠性。我们研究的一个限制是物候数据存在观测误差。物候观

测是从试验田块中获取的,当试验田中的单个观测植株上出现某一发育期特征时,即为该个体进入了某一发育期。当进入某一发育期的植株数占田块观测的总植株数的 50%时,认为该田块作物群体进入某一发育期,将这个发育期的日期记录在册(中国气象局,1993 年)。然而,田间的水稻植株并不能同时进入相同的发育期,观测数据没有详细记录每个发育期的特定日期。例如,从第一次有效分蘖达到最大分蘖数通常需要大约 30 天。我们获取的数据没有记录当田块达到分蘖普遍期时时田间作物的第几次分蘖,假设模拟从第一次有效分蘖的观测日期开始,那么从分蘖到后续发育期的预测天数会产生累积偏差。

调整移栽日期等管理措施对水稻发育有重要影响,我们尝试将其作为模型模拟的起始日期。由于将水稻的幼苗从苗床或育苗盘移栽到大田中,会对水稻根系产生不同程度的人为损伤,生长恢复期从 3 天到 11 天不等(图 3-7a)。为了减少移栽对模拟准确性的影响,我们选择将返青期作为物候模拟的起始日期。返青期的变化也可以反映出移栽日期的调整。此外,在选择聚类变量时,我们考虑了调整移栽日期对作物发育的影响,如图 3-6 所示。移栽日期的调整取决于地理和气候因素(如纬度、生长季节平均温度、降水和日照小时数),这些因素共同影响物候。然而,我们发现将移栽日期作为聚类变量并没有提高 12 个物候模型的模拟性能(图 3-9)。对于生理成熟阶段,以“Lat+STM”为聚类变量的 MAE(平均绝对误差),从 3 个聚类类别的 5.9 天减少到 24 个聚类类别的 3.7 天,误差减少了 2.2 天,模拟精度显著提高。而以“Lat+STM+TDOY”为聚类变量的 MAE,从 3 个聚类类别的 6.2 天减少到 24 个聚类类别的 4.9 天,误差减少了 1.3 天。因此,我们决定将“Lat+STM”作为比“Lat+STM+TDOY”更为关键的聚类变量。

再者,我们认识到氮肥限制会影响作物的生长和发育,导致物候阶段的延迟。然而,由于长期和过量的施肥措施,我们的研究区域存在氮肥过量的情况,导致显著的 N_2O 排放和与氮素相关的环境负荷。因此,尽管氮肥管理措施在不同种植地点有所不同,我们认为该研究区内的水稻并未受到氮肥不足的限制,并从我们的建模框架中排除了这一因素。尽管其他管理措施(移栽日期调整、品种更替和氮肥施用除外)也可能会影响模型模拟的准确性,但广泛的研究表明其他管理措施对作物物候的影响较小^[216,77,79],作物发育主要受温度、日长和氮肥供应的限制。

考虑到不同地区环境条件的差异,为我们特定研究区域优化的聚类参数并不能直接应用或外推到其他区域。不同地区气候条件、土壤类型、地理特征和人类管理实践的多样性会直接影响聚类参数的选择和性能。将该聚类方法应用于其他地区时,我们需要重新优化适用于特定地区的聚类参数。

3.5 本章小结

固定水稻品种汕优 63 在不同地点的热需求存在显著差异,这表明环境条件对作物发育有强烈影响。这一结果揭示了基于恒定热需求理论的物候模型的局限性,即不能有效地捕捉作物对环境变化的响应和适应机制。因此,我们提出了一种旨在降低环境异质性的聚类方法。通过将纬度和生长期平均温度作为关键聚类变量,选择合适的聚类数,有效提高了物候模拟的准确性。分蘖期从 1.8~1.4 天,拔节期从 5.3~3.7 天,孕穗期从 5.6~3.9 天,抽穗期从 4.7~3.3 天,生理成熟期从 6.6~3.7 天,12 个模型的模拟误差均显著减小。然而,12 个模型的模拟性能不同,具有三段式分段线性温度响应函数的模型提供了更精准的预测结果。相比之下,包含 Beta 温度响应函数的模型则表现不佳。这种差异归因于用于描述作物发育速率对温度的响应的不同机制,特别是在非最佳温度下。此外,随着模拟尺度的扩大,光周期对模型精度的影响越来越显著。当将该聚类方法应用于包含多种气候带的大地理区域时,物候模拟的不确定性将由于环境的多样性而增加,因此需要重新优化适用于特定地区的聚类参数。

第 4 章 基于随机森林算法的水稻产量估算模型

4.1 概述

水稻作为全球重要的粮食作物，其产量受到多种环境和遗传因素的复杂影响。地理位置（经度、纬度和海拔高度）决定了水稻生长的基本环境条件，温度作为影响水稻发育最为关键的因素，不仅控制着生长速率，其日变化幅度还调控着植株形态特征。不同水稻品种对环境条件表现出差异化的适应性，如早熟品种与晚熟品种在特定气候条件下各具优势。此外，水稻在不同发育阶段对环境因子的敏感性各异，营养生长期的升温促进生物量积累，幼穗分化期的高温影响颖花发育，而抽穗开花期则对高温胁迫最为敏感，直接关系到最终产量形成。

在气候变化背景下，准确理解和预测水稻产量对多因素响应的复杂机制变得尤为重要。传统线性统计模型难以捕捉这种复杂的非线性关系和交互作用，而前述基于聚类方法改进的过程物候模型虽提高了发育预测精度，但在产量形成的综合模拟方面仍面临参数区域化和机理表达的挑战。因此，探索能够高效处理高维数据、自动识别复杂非线性关系的新型建模方法，对提升水稻产量模拟和预测能力具有重要意义。

本研究基于中国主要水稻种植区 2007~2018 年的品种试验观测数据，构建了系统完整的研究框架，探索地理位置、气候条件、物候特征、水稻品种特性及其农艺性状对水稻产量的综合影响机制，开发了基于随机森林算法的高精度水稻产量估算模型。研究框架围绕四个相互关联的科学问题展开：

第一，系统整合了水稻产量形成的多维度影响因素，建立了包含地理环境、气候条件、物候特征和作物品种特性及其农艺性状的综合数据集。区别于传统研究仅关注部分因素，忽略作物品种差异的局限性，本研究丰富了产量估算的信息维度，形成了更加完整的水稻产量影响因素分析框架。

第二，应用随机森林算法构建高精度的水稻产量估算模型。该算法通过集成多棵决策树的预测结果，有效克服了单一模型的局限性，能够自动识别复杂的非线性关系。验证结果表明，模型模拟精度较好，解释方差达到 77%，均方根误差为 39.47 kg/mu，平均绝对误差为 29.85 kg/mu，且在不同区域和年份间表现出良好的稳定性。

第三，通过特征重要性分析，深入揭示了多变量对水稻产量形成的重要性程度。研究发现，地理位置和气候条件是决定产量区域性差异的基础因素，品种类型和物候发育则在产量形成中起到关键的调节作用。特别是，模型捕捉到了水稻在不同生育阶段对光温的差异化响应模式，如营养生长期的日长和太阳辐射量，生殖生长期的日最低气温，对最终产量相对重要，这些发现与前述物候模型研究中关于产量在不同生育期对环境条件存在差异响应的结论一致。

最后,本研究通过随机森林算法成功构建了高精度水稻产量估算模型,在理论和应用两个层面具有重要价值:在理论层面,研究揭示了水稻产量形成的复杂影响机制,特别是量化了地理位置、气候条件、物候发育和作物品种特性等因素的相对贡献及其重要性,丰富了作物生长与环境互作的理论体系;在应用层面,模型不仅提供了准确的产量估算工具,还可以为区域品种布局优化、栽培措施改进和应对气候变化的适应性策略制定提供科学依据。结合前述物候模型研究,两者共同构建了从水稻发育过程到产量形成的完整预测体系,为气候适宜性管理策略的制定提供了更科学的参考。未来研究将进一步探索两类模型的深度融合,发展兼具机理性和数据驱动优势的综合模型体系,为保障粮食安全做出更大贡献。

4.2 材料和方法

4.2.1 研究区域和数据来源

研究区域为中国水稻种植区,各地自然生态环境、社会经济条件和水稻种植状况存在巨大差异。水稻品种试验点遍布我国的六大稻作区,包括华南双季稻稻作区、华中单双季稻稻作区、西南高原单双季稻稻作区、华北单季稻稻作区、东北单季稻稻作区和西北干燥区单季稻稻作区。研究区纬度为 $19^{\circ}09'N\sim46^{\circ}40'N$, 经度为 $80^{\circ}07'E\sim130^{\circ}30'E$, 气候类型多样,纵跨热带、亚热带到温带,海拔从 1 米~1318 米不等。整个水稻种植区可划分为南方和北方两大生态类型区,南方农业生态类型区,得益于较为优越的气候资源条件,可以种植双季稻,或选择性地种植单季早稻或晚稻;北方农业生态类型区内种植一季稻。

本研究从中国水稻新品种试验数据集^[154-165]中共收集了 2175 个水稻品种,12 年(2007~2018 年)期间在 327 个地点共计 46293 条有效观测结果。试验点分布见图 4-1a。由于观测记录中的移栽期空缺值较多,本研究仅选择播期、齐穗期和成熟期。我们将整个发育期分为两个阶段:营养生长期(播种至齐穗,VGP)和生殖生长期(齐穗至成熟,RGP)。其他农艺性状包括单位面积有效穗、每穗总粒数、每穗实粒数、结实率、千粒重、株高和穗长。

气象数据源于由欧洲中期天气预报中心(European Centre for Medium-Range Weather Forecasts, ECMWF)开发和维护的 ERA5-Land 日汇总数据集。我们按试验点经纬度提取出 2007~2018 年间逐日气象数据,并进行变量的单位转化,得到日最低温度($^{\circ}C$)、日最高温度($^{\circ}C$)、日平均温度($^{\circ}C$)、日降水量(mm)、日相对湿度(%)和日净太阳辐射量($MJ\cdot m^{-2}\cdot d^{-1}$)。特定位置和日期的日长(h)根据经度、纬度和年月日日期计算得出^[166]。针对关键生育阶段,我们还提取并计算了一系列气象胁迫指标,包括高温发生频次(连续 3 天日平均气温 $\geq 30^{\circ}C$, HN)、高温总天数(日平均气温 $\geq 30^{\circ}C$, HD)、冷害发生频次(北方地区连续 3 天日平均气温 $\leq 17^{\circ}C$ 或南方地区连续 3 天日平均气温 $\leq 20^{\circ}C$, CN)、冷害总天数

（北方地区日平均气温 $\leq 17^{\circ}\text{C}$ 或南方地区日平均气温 $\leq 20^{\circ}\text{C}$ ，CD）以及利于病害发生的湿热天（日均温 $\geq 25^{\circ}\text{C}$ 且相对湿度 $\geq 90\%$ ，HWD）总天数。

根据品种观测记录，在不同试验区水稻同一物候事件的发生时间存在显著差异（图 4-1b）。在 2007~2018 年的研究期内，各地播期发生在 2 月~7 月之间，齐穗期发生在 4 月~10 月之间（播种到齐穗的平均日照时间为 12.6 小时到 14.4 小时），成熟期发生在 5 月到 11 月之间。我们还观察到水稻主要生长季节（3-11 月）内的气象条件有显著的时空波动。研究区气候条件极具异质性，所有试验点生长季节内多年日平均气温、日最高气温和日最低气温的变化分别为 $9.0^{\circ}\text{C} \sim 27.1^{\circ}\text{C}$ ， $13.8^{\circ}\text{C} \sim 29.7^{\circ}\text{C}$ 和 $4.6^{\circ}\text{C} \sim 25.3^{\circ}\text{C}$ ，累积降雨量变化为 25mm~2812mm，日均相对湿度的变化为 26.82%~84.15%，累积获得的净太阳辐射量变化为 $2482 \text{ MJ}\cdot\text{m}^{-2}\cdot\text{d}^{-1} \sim 4622 \text{ MJ}\cdot\text{m}^{-2}\cdot\text{d}^{-1}$ 。根据稻作区的气候环境条件和栽培季节，我们将所有水稻划分为早稻、晚稻和一季稻三种水稻季节生态型，早稻一般于 5 月中下旬前播种，晚稻一般于 5 月后播种。

4.2.2 水稻品种及作物性状数据分布

2007~2018 年收集的 2175 个水稻品种发育期数据共 46293 条，数据显示：播期日序的范围为 33~207，平均值为 119.6，标准差为 34.7，四分位数范围(92~137)较宽，表明播种日期存在较大差异；齐穗期日序介于 114~293 之间，平均为 220.5，标准差为 28.3，四分位数范围（209~237）较窄，齐穗期较播期而言相对集中；成熟期日序在 142~331 的区间内，均值为 256.2，标准差为 31.9，四分位数范围（242~276），成熟日期的分布较离散。全生育期天数从 89 天至 194 天不等，平均为 137.6 天，标准差为 17.3 天，四分位数范围（124~151）较窄，不同稻季的全生育期天数显示出一定的集中趋势。VGP（播种到齐穗）天数的范围是 60~149 天，平均为 100.9 天，标准差为 16.0 天，四分位数范围（87~114）较宽，离散程度较大，数据分布较为分散；RGP（齐穗到成熟）天数最大值为 80 天，最小值为 16 天，平均为 36.7 天，标准差为 6.8 天，四分位数范围（32~41）较窄，数据分布相对集中。综上所述，播种日期、齐穗日期和成熟日期的数据分布比较离散，全生育期天数在不同稻季中有一定的集中趋势，其中 RGP（齐穗到成熟期）的数据最为集中，VGP（播种到齐穗期）的数据则相对离散。

本研究还对水稻的产量及相关农艺性状进行了统计分析，产量数据齐全，但相关农艺性状数据存在缺失。总样本量为 46293，就单个农艺性状数据来说，单位面积有效穗数据缺失占比 11.48%，每穗总粒数数据缺失占比 11.49%，每穗实粒数数据缺失占比 13.53%，结实率数据缺失占比 11.49%，千粒重数据缺失占比 11.49%，株高数据缺失占比 11.49%，穗长数据缺失占比 11.80%，七个农艺性状均为非空值的样本占比 88.19%。产量范围为 $153.90 \sim 993.33 \text{ kg}/\mu$ （ $1\mu=666.67\text{m}^2$ ， $1\text{kg}/\mu=15\text{kg}/\text{ha}$ ），平均 $577.60 \text{ kg}/\mu$ ，标准差为 $86.02 \text{ kg}/\mu$ ，四分位数范围




图 4-1 水稻观测点的分布 (a) 和关键物候期发生时间 (b)。(a) 不同的颜色和形状的点表示不同的农业生态类型区范围。SC 表示华南地区 (●), YGP 表示云贵高原周边地区 (■), MLYZ-HHP 表示长江中下游和淮河地区 (★), SBSA 表示四川盆地及其周边地区 (▲), BTH-NEP 表示京津冀平原和东北平原区 (◆), NXP 表示宁夏平原区 (▲), XJOA 表示新疆绿洲农业区 (▲)。(b) 显示了所有数据的第 25 到 75 百分位数, 黑点表示离群值, 红点表示平均值, 黑色中线表示中位数。注: 该图基于自然资源部标准地图服务网站下载的审图号为 GS(2019)1719 号的标准地图制作, 底图边界无修改。

Figure 4-1 Distribution of rice observation sites (a), and the occurrence dates of key phenological events (b). (a) Different colors and shapes of symbols represent different ecological zones. SC represents the Southern China (●), YGP represents the Yunnan-Guizhou Plateau and surrounding areas (■), MLYZ-HHP represents the middle and lower reaches of the Yangtze River and Huaihe River areas (★), SBSA represents the Sichuan Basin and its surrounding areas (▲), BTH-NEP represents the Beijing-Tianjin-Hebei Plain

and Northeast Plain regions (◆), NXP represents the Ningxia Plain region (▲), and XJOA represents the Xinjiang Oasis Agricultural region (▶). (b) The box charts show the temporal span during which key phenological events occurrence. The left and right box boundaries are the 25th and 75th percentiles. Note: This map was created based on the standard map from the National Natural Resources Department's map service website, with the review number GS(2019)1719. The boundary of the base map has not been modified.

(519.17~636.30) 较宽, 表明产量的变异性较大; 有效穗的范围是 7.9~55.9 万穗/亩, 平均为 17.2 万穗/亩, 标准差为 3.7 万穗/亩, 四分位数范围 (14.6~19.3) 较窄, 数据分布较为集中但存在较大的极值偏差; 每穗总粒数在 51.6~518.8 粒之间, 平均为 170.8 粒, 标准差为 41.1 粒, 四分位数范围 (142.5~195.2 粒) 较宽, 数据离散程度较大; 每穗实粒数介于 20.8~369.8 粒, 平均为 138.5 粒, 标准差为 32.9 粒, 四分位数范围 (116.1~158.7 粒) 较宽, 分布较为分散; 结实率从 8.50%~100%, 平均为 81.26%, 标准差为 8.24%, 四分位数范围 (76.50~87.20%) 较窄, 显示出一定的集中性, 但极大、极小值偏差大; 千粒重在 16.2~38.7 克范围内, 平均为 27.0 克, 标准差为 2.9 克, 四分位数范围 (24.9~29.1) 较窄, 千粒重数据分布较为集中; 株高范围为 18.0~202.0 厘米, 平均为 112.6 厘米, 标准差为 14.02 厘米, 四分位数范围 (103.6~122.5 厘米) 较宽, 数据分布离散; 穗长在 11.2~38.0 厘米之间, 平均为 23.7 厘米, 标准差为 2.9 厘米, 四分位数范围 (22.0~25.7 厘米) 较窄, 穗长的离散程度较小。综上所述, 有效穗、结实率、千粒重和穗长的数据分布较为集中, 但极值偏差大, 而产量、每穗总粒数、每穗实粒数和株高的数据分布则相对离散。

4.2.3 随机森林产量估算模型构建和性能评价方法

随机森林回归算法作为一种强大的非参数统计方法, 用于处理复杂的非线性关系和高维数据, 以预测作物产量。在数据预处理阶段, 采用 IQR (四分位距) 方法对产量进行异常值处理, 小于 $Q1-1.5 \times IQR$ 或大于 $Q3+1.5 \times IQR$ 的极端值被剔除, 排除可能由测量误差或其他非正常因素导致的异常值, 确保了数据集的质量和可靠性。特别地, 我们对每个品种类别进行了编码, 以确保模型能够正确处理这一分类特征。

我们在选择随机森林输入的特征变量时, 涵盖了地理位置信息 (Loc)、物候信息 (Phen)、气候因素 (Env) 以及品种特性 (Variety), 共计四个维度, 这样的多维度特征组合能够全面捕捉影响作物产量的各种潜在因素。其中, 地理位置信息包括经度 (Lat)、纬度 (Lon)、海拔 (Elev); 物候期信息包括播期 (DOY_Sow)、齐穗期 (DOY_Fulpani)、播种至齐穗期天数 (VGP)、齐穗至成熟期天数 (RGP); 气候因素 (Env) 包括生育期内的日平均气温 (TMean, °C)、日最高气温 (TMax, °C)、日最低气温 (TMin, °C)、 $\geq 8^\circ\text{C}$ 有效积温 (TS, °Cd)、累积降雨量 (PRE, mm)、相对湿度 (RHU, %)、日长 (DL, h) 和净

太阳辐射量 (Rns , $MJ \cdot m^{-2} \cdot d^{-1}$)。由于最终产量可通过单位面积有效穗、每穗总粒数和实粒数、千粒重直接算出,所以我们剔除了这些农艺经济性状,保留了被编码的品种类别标签 (*Variety*)。然后,运用最大—最小归一化方法对输入的特征变量进行标准化处理,使得各特征变量的数据分布在同一尺度上,这一处理不仅有助于提升模型的收敛速度,还能避免因不同特征量纲差异过大而对模型权重分配产生的不良影响。为了评估不同特征变量组合对作物产量估算精度的影响,我们设计了一系列逐渐添加变量的实验。具体步骤如下:

作物产量始终作为目标变量。首先,单一维度特征实验。第一次实验仅使用地理位置信息 (*Loc*) 作为特征变量,第二次实验仅使用物候期信息 (*Phen*) 作为特征变量,第三次实验仅使用环境因素 (*Env*) 作为特征变量。然后,是两个维度的特征组合实验。第四次实验结合地理位置信息 (*Loc*) 和环境因素 (*Env*) 作为特征变量,第五次实验结合物候期信息 (*Phen*) 和环境因素 (*Env*) 作为特征变量。接下来,是三维特征组合实验。第六次实验结合地理位置信息 (*Loc*)、物候期信息 (*Phen*) 和环境因素 (*Env*) 作为特征变量。最后,是全维度特征组合实验。第七次实验加入品种类型 (*Vars*),使用所有特征变量,包括地理位置信息 (*Loc*)、物候期信息 (*Phen*)、环境因素 (*Env*) 和品种标签。

在每次模型构建时,我们都通网格搜索和 5 折交叉验证,对随机森林回归器的多个关键超参数进行了全面的网格搜索优化,包括树的数量、树的最大深度、节点分裂所需的最小样本数、叶子节点的最小样本数、最大特征数量以及是否采用有放回的抽样等,最终以决定系数 (R^2) 为指标确定最佳参数组合,这一参数优化过程确保了模型能够达到最优的性能表现。

在模型训练与评估环节,均采用了 100 次迭代的训练—测试划分方法,并进行并行计算以提高效率。每次迭代中,数据集按照地理位置要素 (*Lon* 和 *Lat*) 分层,被随机划分为训练集和测试集,其中训练集占比为 80%,测试集占比为 20%,这样可以保证训练集和测试集中地理分布的均衡性,对避免因地理位置差异导致的模型过拟合或欠拟合具有重要意义。在每次训练过程中,模型的性能指标包括均方根误差 (*RMSE*)、平均绝对误差 (*MAE*) 以及决定系数 (R^2) 均被详细记录,这些指标从不同角度全面反映了模型的准确性和泛化能力。

最终,通过对多次迭代结果的平均分析,得出了模型在训练集和测试集上 100 次迭代的平均性能指标,包括 *RMSE*、*MAE* 和 R^2 的均值,这些数据直观地展示了随机森林回归模型在模拟作物产量任务中的稳定性和可靠性,为后续的农业决策和产量预测估算研究提供了有力的模型支持和理论依据。

4.3 结果与分析

4.3.1 水稻种植点地理条件和发育期与产量的相关性分析

我们综合考虑种植点地理位置特征、关键物候期 and 不同发育阶段持续天数等变量对水稻的产量的影响。其中，地理位置特征包括：经度（Lon）、纬度（Lat）和海拔高度（Elev）；关键物候日期包括：播期日序（DOY_Sow）、齐穗期日序（DOY_Fulpani）；发育期持续天数变量包括：营养生长期天数（播种至齐穗，VGP）、生殖生长期天数（齐穗至成熟，RGP）、全生育期天数（播种至成熟，GP）。以上变量与产量之间的关系如图 4-2 所示。




图 4-2 水稻观测点地理位置和发育期与产量的相关性和数据分布趋势图。下三角显示变量间的显示皮尔逊相关系数热图及其显著性水平（p 值），上三角绘制每个变量的散点图并叠加拟合线，以及对角线展示每个变量的直方图和核密度估计。*表示在 $p < 0.01$ 时存在显著相关关系。

Figure 4-2 Correlation and data distribution trend chart of rice observation site geographical locations and developmental stages with yield. The lower triangle displays a heatmap of Pearson correlation coefficients between variables and their significance levels (p-values), the upper triangle shows scatter plots for each variable with fitted lines, and the

diagonal displays histograms and kernel density estimates for each variable. * indicates significant correlation at $p<0.01$.

水稻产量与纬度 (Lat) 和海拔 (Elev) 存在显著线性相关性 ($P<0.01$)，相关系数分别为 0.25 和 0.18；与经度 (Lon) 相关性较弱为-0.07。水稻产量与营养生长期 (VGP)、生殖生长期 (RGP) 和全生育期 (GP) 长度均呈现显著正相关 ($P<0.01$)，相关系数分别为 0.37, 0.33, 0.45，表明较长的生长周期有利于提高产量。产量与播期日序 (DOY_Sow) 和齐穗期日序 (DOY_Fulpani) 的线性相关性均较弱，相关系数分别为 0.02 和 0.08，但根据上三角的回归图显示，播期日序 (DOY_Sow) 和齐穗期日序与产量存在显著的非线性关系。




图 4-3 水稻全生育期内的气象条件与产量的相关性和数据分布趋势图。*表示在 $p<0.01$ 时存在显著相关关系。

Figure 4-3 Correlation and data distribution trend chart of meteorological conditions during the entire growth period of rice and yield. * indicates significant correlation at $p<0.01$.

通过各自变量间的相关性分析发现，经度 (Lon) 和海拔 (Elev) 显著负相关

($r = -0.78$, $p < 0.01$)。纬度 (Lat) 与作物发育期持续天数存在显著正相关关系, 与 VGP, RGP 和 GP 的相关系数分别为 0.22, 0.26 和 0.31。播期 (DOY_Sow) 和齐穗期 (DOY_Fulpani) 均受海拔 (Elev) 和经度 (Lon) 的显著影响, 两者与海拔 (Elev) 显著负相关, 相关系数分别为 -0.41 和 -0.26; 与经度 (Lon) 显著正相关, 相关系数分别为 0.50 和 0.32。作物发育期持续天数受种植点地理位置的显著影响, VGP、RGP 和 GP 随着纬度和海拔升高不断延长; 还受播期 (DOY_Sow) 和齐穗期 (DOY_Fulpani) 的影响, VGP 和 GP 随着播期和齐抽穗期推迟而缩短, RGP 随着播期和齐穗期推迟而延长。




图 4-4 水稻营养生长期内的气象条件与产量的相关性和数据分布趋势图。*表示在 $p < 0.01$ 时存在显著相关关系。

Figure 4-4 Correlation and data distribution trend chart of meteorological conditions during the vegetative growth period of rice and yield. * indicates significant correlation at $p < 0.01$.

4.3.2 水稻发育期内气候条件与产量的相关性分析

不同栽培期内的气候条件对水稻生长、发育和最终产量的影响存在显著差异,

水稻在不同发育阶段对气候条件的响应也不同。因此，我们分别分析了营养生长期（VGP）、生殖生长期（RGP）和全生育期（GP）的日平均气温（TMean, °C）、日最高气温（TMax, °C）、日最低气温（TMin, °C）、 $\geq 8^{\circ}\text{C}$ 有效积温（TS, °C d）、累积降雨量（PRE, mm）、相对湿度（RHU, %）、日长（DL, h）和净太阳辐射量（Rns, $\text{MJ}\cdot\text{m}^{-2}\cdot\text{d}^{-1}$ ）与产量的关系，见图 4-3、图 4-4 和图 4-5。




图 4-5 水稻生殖生长期内的气象条件与产量的相关性和数据分布趋势图。*表示在 $p<0.01$ 时存在显著相关关系。

Figure 4-5 Correlation and data distribution trend chart of meteorological conditions during rice reproductive growth period and yield. * indicates significant correlation at $p<0.01$.

在整个发育期内，水稻产量与净太阳辐射量（SRns）、 $\geq 8^{\circ}\text{C}$ 有效积温（STS）、日长（SDL）、累积降雨量（SPRE）显著正相关，相关系数分别为 0.46, 0.30, 0.26 和 0.14；相比而言，发育期内的日最低气温（STMin）、日平均气温（STMean, °C）和日最高气温（STMax）对产量的影响较弱（ $|r|\leq 0.13$ ）。温度相关变量（STMin, STMean, STMax）与水分相关变量（SPRE, SRHU）呈负相关，相关系数约在-

0.23~-0.44 之间；水分相关变量（SRHU）和太阳辐射量（SRns）也存在一定负相关关系，这反映了气候条件的交互效应。在 VGP 阶段，产量的主要影响因素是净太阳辐射量（VGP_Rns）、日长（VGP_DL）、 $\geq 8^{\circ}\text{C}$ 有效积温（VGP_TS）、累积降雨量（VGP_PRE），相关系数分别为 0.42，0.38，0.29 和 0.17；产量与温度（VGP_TMean、VGP_TMax、VGP_TMin）呈负相关（ $-0.08 \leq r < 0$ ）。在 RGP 阶段，产量的主要影响因素是净太阳辐射量（RGP_Rns）、日最低气温（RGP_TMin）、日平均气温（RGP_TMean）、日最高气温（RGP_TMax）和 $\geq 8^{\circ}\text{C}$ 有效积温（RGP_TS），相关系数分别为 0.28，-0.23，-0.20，-0.18 和 0.18。




图 4-6 生育期内气象胁迫指标与产量的相相关性和数据分布趋势图。*表示在 $p < 0.01$ 时存在显著相关关系。

Figure 4-6 Correlation and data distribution trend chart of meteorological stress indicators during the entire growth period and yield. * indicates significant correlation at $p < 0.01$.

在整个发育期内，高温热害、低温冷害和湿热天气发生频次均很低，如图 4-6 所示。但湿热天总天数（HWD）对产量有显著负影响，相关系数为 -0.12。除此之外，高温热害发生频次（HN）和总天数（HD）、高温累积值（HDD）、低温冷害发生频次（CN）和总天数（CD）、低温累积值（CDD）的数据量少，数据

点分布非常离散，与产量的相关性低 ($|r| \leq 0.02$)，但这些低频率的极端气象事件对最终产量的形成通常具有决定性作用。

综合上述分析，单一气候变量难以直接解释产量的变化，需要考虑多环境要素交互作用。在 VGP 阶段，VGP_Rns、VGP_DL、VGP_TS 和 VGP_PRE 的影响较大；在 RGP 阶段，产量受 RGP_Rns、RGP_TMin、RGP_TMean、RGP_TMax 和 RGP_TS 的影响较大；在整个发育期内，湿热天总天数 (HWD) 对产量也有一定程度的负影响。

4.3.3 水稻品种和农艺经济性状与产量的相关性分析

本研究通过相关性分析探讨了不同水稻品种及其农艺经济性状对产量的影响，如图 4-7 所示。首先，从相关性矩阵中可以观察到，水稻产量与多个关键农艺性状存在显著相关性。其中，产量和每穗总粒数和每穗实粒数均表现出较强的正相关性，相关系数分别为 0.45 和 0.51 ($p < 0.01$)，表明这些性状对水稻产量具有决定性作用。每穗总粒数和每穗实粒数之间高度相关 ($r = 0.90$, $p < 0.01$)，说明了总粒数的增加有利于实粒数的增长。其次，株高和穗长对产量也表现出显著正相关性，相关系数分别为 0.33 和 0.27 ($p < 0.01$)。水稻品种 (Variety) 与产量的相关系数为 0.27 ($p < 0.01$)，表明水稻品种对产量是有显著影响的。千粒重、结实率和单位面积有效穗与产量之间的相关性低于其他经济性状，相关系数分别为 0.16、0.14 和 -0.08 ($p < 0.01$)，其中千粒重与单位面积有效穗负相关 ($r = -0.31$, $p < 0.01$)，结实率与每穗总粒数负相关 ($r = -0.21$, $p < 0.01$)，表明产量构成要素之间存在相互制约作用。进一步分析其他农艺性状之间的交互作用可以发现，水稻品种 (Variety) 与每穗总粒数和每穗实粒数存在正相关性 ($r > 0.2$, $p < 0.01$)，即品种的遗传特性对穗粒数和总籽粒数有重要影响。另外，每穗总粒数和每穗实粒数与株高和穗长存在较强的正相关性 ($r \approx 0.5$, $p < 0.01$)，即在一定范围内较高的植株和较长的穗长通常伴随着更多的籽粒数，这均与品种遗传特性有关。但单位面积有效穗与每穗总粒数和每穗实粒数均呈现负相关 ($r = -0.57$ 和 $r = -0.59$, $p < 0.01$)，这表明过多增加有效穗数可能导致单穗粒数下降，从而对总产量造成抑制作用。

水稻的表型特征深受气象条件的影响 (表 4-1)。在营养生长阶段，较高的温度 (VGP_TMean、VGP_TMax 和 VGP_TMin) 能够促进单位面积有效穗增加和株高增长 ($0.14 \leq r \leq 0.17$)，但会降低千粒重 ($-0.26 \leq r \leq -0.24$)；降水量 (VGP_PRE) 增加会降低单位面积有效穗 ($r = -0.24$)，但会增加穗粒数、千粒重、株高和穗长 ($0.11 \leq r \leq 0.19$)。在营养生长和生殖生长阶段，有效积温 (VGP_TS 和 RGP_TS) 日长 (VGP_DL) 和均对穗粒数、株高和穗长有积极影响 ($0.17 \leq r \leq 0.50$)。在两个发育阶段，除 VGP_Rns 对单位面积有效穗 ($r = -0.26$) 和结实率 ($r = -0.04$) 有负影响以外，净太阳辐射量对所有品种的表

型特征均呈现显著的积极影响（ $0.04 \leq r \leq 0.35$ ）。




图 4-7 水稻品种性状与产量的相关性 & 数据分布趋势图。*表示在 $p<0.01$ 时存在显著相关关系。

Figure 4-7 Correlation and data distribution trend chart of rice varieties' traits and yield. * indicates significant correlation at $p<0.01$.

表 4-1 品种表型特征与气象因素之间的相关性

表 4-1 The correlation between cultivar traits and meteorological factors

	单位面积 有效穗	每穗总 粒数	每穗实 粒数	结实率	千粒重	株高	穗长
VGP_TMean	0.16*	0.02*	0.00	-0.07*	-0.25*	0.17*	0.01
VGP_TMax	0.17*	0.01	-0.02*	-0.08*	-0.24*	0.16*	0.01
VGP_TMin	0.14*	0.03*	0.00	-0.08*	-0.26*	0.14*	0.00
VGP_TS	-0.21*	0.36*	0.31*	-0.11*	0.07*	0.47*	0.33*
VGP_PRE	-0.24*	0.18*	0.19*	0.01*	0.13*	0.11*	0.14*
VGP_RHU	-0.07*	0.05*	0.07*	0.04*	-0.09*	-0.03*	-0.02*
VGP_DL	-0.18*	0.30*	0.34*	0.08*	0.06*	0.50*	0.26*
VGP_Rns	-0.26*	0.31*	0.28*	-0.04*	0.32*	0.35*	0.34*
RGP_TMean			-0.02*	0.12*	-0.06*	0.08*	0.07*
RGP_TMax			-0.01	0.12*	-0.06*	0.09*	0.08*
RGP_TMin			-0.04*	0.10*	-0.08*	0.06*	0.05*

RGP_TS		0.32*	0.11*	-0.10*	0.30*	0.17*
RGP_PRE		0.03*	-0.07*	0.05*	-0.02*	0.02*
RGP_RHU		-0.04*	-0.07*	0.07*	-0.02*	0.00
RGP_DL		-0.06*	0.14*	0.08*	-0.03*	0.00
RGP_Rns		0.26*	0.16*	0.04*	0.15*	0.10*

*表示在 $p < 0.01$ 时两因素间显著相关。

4.3.4 构建模拟水稻产量的随机森林回归模型

图 4-8 中展示了基于不同特征变量，随机森林产量估算模型的性能表现，分别从均方根误差（RMSE）、平均绝对误差（MAE）和决定系数（ R^2 ）三个指标进行评估。为确保评估结果的可靠性与稳定性，分别基于不同特征变量，进行了 100 次随机分割迭代计算，取 100 次结果的平均值作为最终的评估依据。




图 4-8 不同输入变量组合下随机森林回归模型 100 次迭代的平均性能。(a) 均方根误差 (RMSE)、(b) 平均绝对误差 (MAE)，和 (c) 决定系数 (R^2)。地理位置变量 (Loc)，物候变量 (Phe)，气候变量 (Env) 以及品种 (Variety)。

Figure 4-8 The average performance of the Randomforest regression model after 100 iterations based on different combinations of input variables. (a) Root Mean Square Error (RMSE), (b) Mean Absolute Error (MAE), and (c) Coefficient of Determination (R^2). Geographical location variables (Loc), phenological variables (Phe), climate variables (Env), and variety (Variety).

从 RMSE (图 4-8 a) 和 MAE (图 4-8 b) 的结果来看，单独使用位置 (Loc) 或物候 (Phe) 变量时，模型的误差较大， $RMSE > 56.34 \text{ kg/mu}$ ， $MAE > 43.28 \text{ kg/mu}$ 。尤其是仅使用地理位置特征 (Loc) 时，其 RMSE 为 57.54 kg/mu ，MAE 为 44.85 kg/mu 。相比之下，单独使用物候 (Phe) 变量时，误差有所下降，但仍较高。随着气候因子 (Env) 的加入，例如 Phe_Env、Loc_Env 和 Loc_Phe_Env，RMSE 和 MAE 均显著逐渐降低，RMSE 在 $41.21 \sim 41.98 \text{ kg/mu}$ 之间变动，MAE 在 $31.16 \sim 31.68 \text{ kg/mu}$ 之间变动，表明必须考虑气候变量对模型准确性的影响。特别地，当 Loc_Phe_Env 变量组合时，RMSE 和 MAE 分别为 41.25 kg/mu 和 31.16

kg/mu，已接近最低水平，表明该组合已能较好地预测水稻产量数据。然而，当所有变量(All)被纳入模型时，即在 Loc_Phe_Env 的基础上加入水稻品种(Variety)，RMSE 和 MAE 进一步小幅下降至 40.52 kg/mu，30.45 kg/mu，表明水稻品种(Variety 对模型精度提升有贡献。从误差分析总体来看，增加特征变量，尤其是将气候因素纳入模型后，能够有效降低模拟误差，作物品种能够进一步提高模型的精度。

从决定系数 R^2 (图 4-8 c) 来看，不同特征组合的模拟能力存在明显差异。单独使用地理位置特征(Loc)变量时， R^2 为 0.52，表明该变量的独立预测能力较弱；当单独使用气候(Env)类变量时， R^2 显著提升，接近 0.75，进一步验证了环境因子对水稻产量估算的重要性。当输入特征变量增加时， R^2 逐步提高，特别是 Loc_Env、Phe_Env 和 Loc_Phe_Env 组合下 $R^2 \geq 0.75$ ，说明这些特征组合能够更好地模拟和解释水稻产量的变化。最终，包含所有变量(All)时， R^2 达到最高值为 0.77。这表明在气候因素与物候变量的基础上，考虑水稻品种变化能够提升整体模型精度和稳定性，但在大规模模拟和预测任务中，仅凭品种信息可能无法准确估算出最终产量。




图 4-9 随机森林回归模型 100 次随机分割最优结果。在训练集 (a) 和测试集 (b) 上的模型解释度

Figure 4-9 Model explainability of Randomforest regression model in train set (a) and test set (b)

4.3.5 基于所有特征变量的机器学习模型训练与测试结果

利用随机森林模型，基于包括地理位置(Loc)、发育期(Phe)、环境(Env)和作物品种特性(Variety)在内的所有特征变量，对水稻进行产量估算。模型采用了最优参数设置：最大深度设为 20，特征选择采用总特征数的平方根，叶节点的最小样本数为 4，分裂所需最小样本数为 10，共构建 300 棵树。通过 100 次随机分割，选取了结果较好的一次展示如图 4-9。在训练集上模型解释能力为 89%，

RMSE 为 27.23 kg/mu, MAE 为 20.31 kg/mu; 在测试过程中, 模型的解释能力为 77%, RMSE 为 39.47 kg/mu, MAE 为 29.85 kg/mu。

图 4-10 评估了各类输入变量对产量的重要性, 排序依次为环境变量 (占 53.59%), 物候变量 (占 20.39%), 地理位置变量 (占 17.2%), 以及作物基因型 (占 8.82%)。就单个变量而言, 水稻品种 (Variety) 是影响产量的最关键因素, 贡献率达到 8.82%, 表明不同品种在遗传特性上的差异对产量具有决定性影响。此外, VGP 期间的日长 (VGP_DL, 8.07%) 和 VGP 期间的净太阳辐射 (VGP_Rns, 6.69%) 也在产量形成过程中起到了重要作用。同时, 播种日期 (DOY_Sow, 5.81%) 和齐穗日期 (DOY_Fulpani, 6.55%) 也对产量有较大贡献。再者, 地理位置特征如海拔 (Elev, 7.65%)、纬度 (Lat, 5.93%) 和经度 (Lon, 3.64%) 也具有较高的重要性。总体来看, 水稻产量的决定因素呈现出品种、光周期、温度、辐射和地理因素的综合作用, 其中品种的主导作用最为明显, 而气候因素则主要通过调节水稻生长过程影响产量。




图 4-10 不同输入变量对产量的相对重要性

Figure 4-10 Relative importance of different input variables to yield

进一步分析气候变量在不同发育阶段影响可以发现, VGP 期间最高温度 (VGP_TMax, 3.62%)、累积降水量 (VGP_PRE, 3.30%)、平均温度 (VGP_TMean, 3.30%) 和最低气温 (VGP_TMin, 3.09%) 相对重要。相比之下, RGP 期间的最低气温 (RGP_TMin, 3.09%) 对产量相对重要。这说明水稻在 RGP 期内对环境

条件的需求与 VGP 期有所不同，VGP 期间对温度和水分要求高，而 RGP 开始时间和 RGP 期间的低温可能会对水稻产量形成产生不利影响。值得注意的是，湿热天天数（HWD，1.00%）的重要性最低，表明相较于其他气候变量，湿热天天数对产量整体水平的影响较弱。综上，水稻产量水平不仅依赖于品种特性，还依赖于光周期、温度、降水及辐射等环境条件的协同作用。

偏依赖图（图 4-11）展示了多个因素通过非线性机制对水稻产量的影响。Variety、Elev、VGP、RGP、VGP_Rns 和 VGP_TS 呈现阈值效应，在关键阈值处会出现梯度式的产量变化。Lat 和 Lon 则反映了不同种植区域的产量空间差异。播种日期（DOY_Sow）和抽穗日期（DOY_Hea）显示出明显的季节性影响，确定了不同的最佳窗口期：理想的播种日期在 109 至 125 天之间（4 月中旬至 5 月初），最佳抽穗日期在 189 至 246 天之间（7 月初至 9 月初）。VGP_DL 产生显著的非线性正向影响；在 14~14.7 小时的范围内，每天长度每增加 1 小时，产量就会稳步提高；相反地，RGP_DL 值超过 13.7 小时会导致产量下降。




图 4-11 基于变量重要性的偏依赖图。海拔（Elev）、纬度（Lat）、播期日序（DOY_Sow）、齐穗期日序（DOY_Fulpani）、营养生长期期（VGP）、生殖生长期（RGP）、最低温度（TMin）、最高温度（TMax）、平均温度（TMean）、累积降水量（PRE）、相对湿度（RHU）、净太阳辐射（Rns）、日长（DL）、 $\geq 8^{\circ}\text{C}$ 热量累积量（TS）以及湿热天数（HWD）。

Figure 4-11 Partial dependence plots based on the importance of variables. Elevation (Elev), Latitude (Lat), DOY_Sow (the day of year for sowing date), DOY_Fulpani (the day of year for full heading date), VGP (the vegetative growth period), RGP (the reproductive growth period), minimum temperature (TMin), maximum temperature (TMax), average temperature (TMean), accumulated precipitation (PRE), relative humidity (RHU), net solar radiation (Rns), daylength (DL), $\geq 8^{\circ}\text{C}$ thermal summation (TS), and total days of high-heat and high-humidity (HHD).

4.4 讨论

4.4.1 环境条件、管理措施和作物品种对水稻产量的影响

本研究基于中国水稻种植区多年试验观测数据,通过相关性分析,揭示了水稻产量的差异与地理位置、气候条件、物候和作物品种间的复杂关系。结果表明,水稻产量在不同种植地点表现出显著的差异,这主要受到地理位置(如纬度、海拔)、物候发育、管理措施(如播期调整)、气候条件和品种遗传特性的综合影响。

地理位置对水稻产量的影响显著。纬度和海拔与产量呈显著正相关,而经度与产量显著负相关。这一发现与先前的研究结果一致。例如,Wang 等人(2019)^[217]的研究表明,海拔高度可以通过调控气象因素(如温度、光照)和土壤类型直接影响水稻发育期和产量。Wang 等(2021)^[218]也指出,由于地理位置和光温条件的显著差异,长江上游至中下游的水稻生育期、作物经济性状和产量存在显著的地理变异。地理位置与当地气候条件高度相关,并潜在包含了特定地点的种植策略和田间管理措施等信息。例如,高纬度和高海拔地区的气候条件可能通过延长生育期来促进产量增加。气候的区域变化必然会导致品种性能和种植管理的区域变化^[218,219]。例如,不同地区的温度、光照和降水等气候因素的差异会影响水稻的生长发育和产量表现。因此,在水稻种植中,综合考虑地理条件和生育期管理至关重要。未来的研究可以进一步探讨不同地理区域的具体种植策略,以实现水稻产量的最大化。

此外,生育期对水稻产量也有显著影响。播种至齐穗期和齐穗至成熟期的持续天数对产量具有显著的正向影响,这表明较长的生长周期有利于干物质积累和最终产量的形成^[220-222,219]。然而,播期和齐穗期与产量的线性相关性较弱,但其非线性关系显著,表明结合特定区域和品种调整水稻播种时间对其产量有明显的提升。例如,Wang 等人^[223]的研究表明,单季稻和早稻提前播种、晚稻推迟播种,使得其各自的生育期长度增加,带来单产潜力增加。

在气候因素和发育期相互作用对水稻产量的影响方面,本研究发现不同生育阶段的气候条件对产量的作用存在显著差异。在播种至齐穗期(VGP),净太阳辐射量、平均日长、 $\geq 8^{\circ}\text{C}$ 有效积温和累积降雨量是影响产量的主要气候因素,表明这一阶段的光照和温度条件对水稻生长至关重要。而在齐穗至成熟期(RGP),日最低气温、日平均气温、日最高气温对产量的负影响更为显著,说明这一阶段的低温对水稻的灌浆和产量形成的影响更大。此外,全生育期内的湿热天数对产量具有一定的负向影响,极端温度事件(如高温热害和低温冷害)的发生频次和累积天数对产量的影响较小。这是由于本数据中该样本量少,但是,类似极端气候事件均属于发生频次低、影响大和危害性强的因素。根据中国气象局 27 日发布的《中国气候变化蓝皮书(2025)》显示,我国是全球气候变化的敏感区和影

响显著区，增暖速率高于同期全球平均水平，且极端天气气候事件趋多、趋强。因此，需要综合考虑多环境要素的交互作用，尤其是极端气候和复合型极端气候对农业生产的影响。另外，气候条件的时空异质性也提示我们在不同生态区应采取差异化的气候适应策略，以优化水稻产量。

水稻品种及其农艺性状对产量的影响同样不容忽视。本研究结果显示，水稻品种是影响产量的最关键因素，其遗传特性差异对产量具有决定性作用。此外，总粒数、实粒数、株高和穗长等农艺性状与产量显著正相关，且这些性状是产量形成的重要生理基础。品种与穗粒数和总籽粒数的正相关性进一步说明了品种遗传背景对产量的潜在影响。然而，千粒重、结实率和有效穗等性状相对其他形状对产量的贡献相对较小，这可能与这些性状在不同环境和品种间的变异有关。谷物产量由每单位面积的有效穗数、每穗的谷粒数、结实率和千粒重共同决定。以往的研究表明，单位面积穗数与每穗粒数之间存在显著的补偿机制，很难同时增加单位面积穗数和每穗粒数^[224-227]。在 20 世纪 60 年代，自交稻生产中曾采用高密度种植策略以增加单位面积穗数^[228,229]。然而，随着杂交水稻品种的发展，研究方向逐渐转向通过增大谷穗尺寸来提高产量。例如，Qian 等人（2016）^[230]提出培育大穗品种是实现超高产的有效途径，Shi 等人（2012）^[231]认为在合理穗数基础上增加每穗粒数是水稻高产的关键，Liang 等人（1996）^[232]认为每穗粒数对产量的贡献要大于单位面积穗数。然而，Huang 等人（2011）^[233]发现，尽管高产超级稻品种的每穗粒数多于普通杂交和自交品种，但在仅分析超级杂交品种时，单位面积穗数对籽粒产量的正贡献更为显著。综上，水稻品种的遗传特性及其农艺性状对产量的影响是复杂的。品种的遗传背景通过影响穗粒数和总籽粒数等关键性状，对产量产生显著影响。同时，单位面积穗数与每穗粒数之间的补偿机制限制了两者的同步增加，通过品种改良增加每穗总粒数是提升产量的关键途径。

4.4.2 预测产量的重要因素筛选和模型评价

本研究通过构建多个输入变量组合的随机森林回归模型，系统评估了地理位置（Loc）、物候（Phe）、环境（Env）以及水稻品种（Variety）对产量的贡献。100 次迭代计算的平均测试结果表明，单独使用 Loc 或 Phe 变量时模型模拟误差较大，决定系数（ R^2 ）较低，模拟能力有限。而随着 Env 变量的加入，模型误差显著降低， R^2 显著提升。尤其是在地理位置、物候和环境变量的组合下，模型已表现出较高的模拟精度（100 次迭代计算的平均测试结果：RMSE = 41.25 kg/mu， $R^2 = 0.75$ ）；进一步加入品种变量后，模型性能继续提升，在所有变量（All）组合中模型达到最优性能（100 次迭代计算的平均测试结果：RMSE = 40.52 kg/mu， $R^2 = 0.77$ ），模型具有较强的泛化能力和稳定性。

通过多变量重要性分析进一步揭示，水稻品种（Variety）、种植点地理特征（海拔和纬度）、营养生长期间的净太阳辐射（VGP_Rns）和日长（VGP_DL）、

播种日期 (DOY_Sow)、齐穗日期 (DOY_Fulpani) 是预测产量的关键特征。站点地理位置特征 (纬度和海拔) 对产量的相对重要性较高, 该发现与刘峻明等 (2019)^[139] (2019)、Wang 等 (2024)^[234] 的发现一致。本研究中的气候变量与水稻物候发育密切相关, 对水稻产量具有决定性作用。其中, 物候相关变量, 如播种日期 (DOY_Sow) 和齐穗日期 (DOY_Fulpani) 的重要性分别为 5.81% 和 6.55%, 营养生长期 (VGP) 和生殖生长期 (RGP) 的重要性分别为 5.61% 和 2.42%; 而在气候相关变量中, 除 VGP_DL 和 VGP_Rns 外, 其余单个气候相关变量的重要性均小于 5%, 这表明相对于其他气候变量而言, 物候变量对产量的重要性并不低。这一发现与 Guo 等 (2021)^[235] 的研究结果一致, 他的研究表明物候变量和气候变量对水稻产量估算都很重要, 并且综合物候、气候变量和地理信息是预测产量的最佳组合。此外, 本研究与 Zhao 等人 (2017)^[236] 和 Li 等人 (2023)^[237] 的研究存在一致性, 证实了不同生育阶段气候变量的重要性存在差异, 并且会因水稻种植地点、品种类型、气候条件的差异而有所不同。例如, 在营养生长期, 净太阳辐射 ($r=0.42$, $p<0.01$) 和日长 ($r=0.38$, $p<0.01$) 与产量的正相关关系最强; 而在齐穗至成熟期间, 日最低气温 ($r=-0.23$, $p<0.01$)、日平均气温 ($r=-0.20$, $p<0.01$) 和日最高气温 ($r=-0.18$, $p<0.01$) 都与产量呈现显著负相关。更重要的是, 品种作为遗传控制因子, 在本研究中被评估为最重要的单变量。程式华^[107] 的研究也证实了, 近百年来中国水稻育种实现了三次突破, 推进了全国水稻平均单产从 20 世纪 50 年代的 200 kg/mu 到当前的 470 kg/mu, 产量增长 2.35 倍。湿热天天数 (HWD) 对产量的重要性较弱, 这是由于与本研究湿热天的发生频率较低、样本量相对有限。

偏依赖图揭示了作物生长与环境因素之间的复杂相互作用。其中, 品种对产量有着显著的主导影响, 这凸显了通过育种进行遗传改良的重要性。海拔呈现出明显的梯度反应, 而纬度和经度则表现出明显的波动, 反映了气候适宜性在空间上的不均匀性。播种日期和齐穗日期显示出明显的最佳窗口期, 强调了精确选择种植时期的价值。营养生长期 (VGP) 和生殖生长期 (RGP) 与产量呈现出阶梯式的关系, 表明了物候持续时间方面的阈值效应——无论是过短还是持续时间过长都会对产量形成产生负面影响。与温度相关的变量, 包括 VGP 最高温度 (VGP_Tmax)、VGP 最低温度 (VGP_Tmin)、VGP 平均温度 (VGP_TS)、RGP 最低温度 (RGP_TMin) 和 RGP 平均温度 (RGP_TMean), 都显示出边际效应, 突出了关键温度阈值的存在以及在栽培管理中进行协调优化的必要性。总的来说, 随机森林模型能够有效地捕捉到多个农业生态驱动因素之间的非线性和交互作用, 为气候适应型水稻生产策略提供了理论见解和实用指导。

4.5 本章小结

本章基于中国水稻种植区 2007~2018 年品种试验观测数据,系统研究了地理位置、气候条件、物候、水稻品种及其农艺性状对水稻产量的影响,为优化水稻种植策略和提高产量提供了科学依据。下一步的研究可进一步探讨不同地理区域的具体种植策略,以实现水稻产量的最大化为目标,并兼顾了产量的稳定性。本章采用斯皮尔曼秩相关系数分析变量间关系,评估各因素与产量的相关性;构建随机森林回归模型,利用地理位置、气候条件、物候、水稻品种及其经济性状等不同变量及其组合评估模型对产量估算的表现,并量化各特征变量的重要性。主要结论如下:

(1) 地理位置通过影响气候条件和种植策略(播期)显著影响产量。纬度和海拔与产量显著正相关,经度与产量显著负相关。播种至齐穗期和齐穗至成熟期的持续天数对产量有显著正向影响,表明较长的生长周期有利于产量形成。但不同生育阶段的气候条件对产量的影响存在显著差异。播种至齐穗期,净太阳辐射量、平均日长、有效积温和累积降雨量是主要影响因素;齐穗至成熟期,净太阳辐射量、日最低气温、日平均气温更为重要。水稻品种也是影响产量的最关键因素,其遗传特性的差异对产量具有决定性作用。总粒数、实粒数、株高和穗长等农艺性状与产量有直接显著正相关关系。但产量构成要素之间存在相互制约,通过品种改良增加每穗总粒数是提升产量的关键途径。

(2) 随机森林模型性能方面,包含地理位置、物候发育、气候条件和水稻品种的全变量组合模型表现最优,均方根误差(RMSE)为 39.47 kg/mu,平均绝对误差(MAE)为 28.95 kg/mu,决定系数(R^2)为 0.77。变量重要性分析表明,站点地理位置特征(经纬度和海拔)在产量模型中的相对重要性较高,物候发育变量的重要性并不低于气候变量,水稻品种被评估为最重要的单影响变量。

第5章 基于播期和品种优化的水稻区域适宜性种植策略

5.1 概述

农作物的发育与产量形成受制于复杂且动态的环境因素与管理措施的交互作用。温度、降水、光照等环境要素在时空尺度上的变异性，与播期调整、品种选择等管理决策相互影响，共同决定作物的生长过程、资源利用效率及最终产量表现。在气候变异性增强、资源约束加剧与粮食安全压力提升的背景下，传统单一管理策略已难以应对日益复杂的农业生产环境，亟需发展基于多目标优化的区域适应性栽培体系。

基因型—环境—管理措施互作（ $G \times E \times M$ ）研究已成为提升作物生产潜力的核心方向。已有研究证实，环境因子与作物基因型之间存在显著交互作用，影响植物的表型可塑性^[238,239]、产量潜力和品质特性^[240]。在农业管理实践中，选择适宜基因型并匹配最佳播种窗口可在不增加投入的前提下显著提升资源利用率^[241]。然而，播期和品种选择往往相互依赖而非孤立存在，单一目标的优化已无法满足现代农业对高产、稳定与可持续性的多重要求。

前两章研究中，我们分别建立了基于聚类方法改进的过程物候模型和基于随机森林算法的水稻产量估算模型，为理解水稻生长发育过程和产量形成机制奠定了基础。本章在此基础上，进一步探索如何将这些模型应用于实际农业决策优化，通过调控播期和更替品种，实现水稻栽培策略的多目标优化配置，为区域适宜性种植提供理论支撑和技术路径。

本研究构建了融合作物模型与机器学习技术的多目标优化框架，旨在区域尺度上对水稻播期和品种选择进行同时优化。研究框架围绕四个相互关联的科学问题展开：

第一，创新性地整合了播期、作物品种特性与区域环境因子的调控机制，构建了多目标优化模型。与传统单一因素研究不同，本研究将前两章改进的物候模拟模型和构建的产量估算模型有机融合，形成从环境因子到物候发育，再到产量估算的完整分析过程。物候模型提供了不同播期和品种组合下的关键发育期模拟结果，而随机森林产量估算模型则提供了对应环境背景下的产量潜力评估，两者相互补充，共同支撑多目标优化的理论基础。

第二，基于大数据分析和田间试验验证，精确量化了不同决策变量对水稻生产的贡献权重，建立了包含产量水平、产量稳定性和气候适应性的综合目标函数。这一目标函数不仅考虑了平均产量最大化，还纳入了产量波动最小化和资源利用效率最优化等多维指标，突破了传统单一产量导向的优化思路。

第三，深入剖析了品种—环境—管理措施交互作用的内在机理，揭示了不同管理组合在区域尺度上的适宜性分异规律及其对环境变异的响应特征。研究发现，

最优播期与品种组合呈现明显的区域分异模式，主要受到光热资源匹配度的综合影响。这一发现与第三章物候模型研究中基于环境聚类的结果高度一致，进一步证实了环境异质性对农业管理决策的显著影响。同时，研究还发现品种类型与播期调整在应对环境变异性方面存在互补效应，即适当的播期调整可以增强特定品种的环境适应性，减轻气候变暖的负面影响。

第四，本研究将理论模型转化为实用决策工具，提供了区域适宜性水稻种植方案。该系统基于第四章高精度随机森林模型和重要性分析，结合多目标优化算法，能够针对特定区域和气候条件自动生成最优播期和品种组合推荐。验证结果表明，优化后的管理策略相比传统做法平均提高产量 5.04~10.57%，减少平均产量波动 3.41~6.06%。这一决策工具为精准农业提供了科学依据，也为应对气候变化的适应性管理提供了有效手段。

5.2 多目标优化策略

5.2.1 水稻生态类型区划分

本研究涉及的种植点共计 327 个（如图 4-1a 所示），广泛分布于中国的主要水稻种植区。不同生态类型区的水稻产量水平具有显著差异，结合本研究数据集的分布特性，以 36°N 纬度线为界，将整个水稻种植区划分为南方和北方两大生态类型区。其中，在南、北生态类型区内进一步依据各试验站点的经度、纬度、海拔高度和多年平均气温进行聚类分析，细分为七个子生态类型区域，以便开展更具地理特异性的品种选择、物候模拟和产量估算。南方生态类型区内包括华南地区（●）、云贵高原周边地区（■）、四川盆地及其周边地区（◀）、长江中下游和淮河地区（★），共计 4 个生态类型子区；北方生态类型区内包括京津冀平原和东北平原区（◆），宁夏平原区（▲），以及新疆绿洲农业区（▶），共计 3 个生态类型子区。

5.2.2 区域适应性播期优化

播期滑动窗口构建：本研究采用滑动窗口分析法进行播期优化研究。以田间观测试验记录的实际播期为基准点，在保持水稻品种不变的前提下，构建了基准播期前后各 15 天的滑动窗口。考虑到南北方稻区的气候条件差异及农业生产实际，对滑动窗口范围设定了区域特异性限制：南方稻区的播期日序范围为 30~223，北方稻区的播期日序范围为 80~150。上述参数设定基于长期观测数据分析，充分考虑了区域间气候特征与农业生产实际需求的差异性。

水稻物候模拟：针对各生态类型区，利用区域内观测数据校准物候模型参数。在播期滑动窗口中，采用基于三段式温度响应函数的物候模型对不同生态类型区内各水稻品种的物候发育过程进行模拟重构。三段式温度响应函数通过最低温度

(T_b)、最适发育温度下限 (T_l)、最适发育温度上限 (T_h) 和最高温度 (T_c) 定量描述了水稻发育速率对温度的响应特征, 如下式:

$$f_T(T, T_b, T_l, T_h, T_c) = \begin{cases} \frac{T - T_b}{T_l - T_b}, & \text{if } T_b \leq T \leq T_l, \\ 1, & \text{if } T_l < T < T_h \\ \frac{T_c - T}{T_c - T_h}, & \text{if } T_h \leq T \leq T_c \\ 0, & \text{if } T < T_b \text{ or } T > T_c \end{cases} \quad (5-1)$$

关键气象要素提取与胁迫指标计算: 通过播期滑动窗口分析, 系统量化了不同播期方案下水稻各生育期 (营养生长期VGP、生殖生长期RGP) 的时序变化特征。针对关键生育阶段, 提取并计算了一系列气象要素与胁迫指标, 包括平均温度、太阳辐射、有效积温、累积降水、日长等基础气象因子, 以及高温发生频次 (连续 3 天平均气温 $\geq 30^\circ\text{C}$, HN)、高温总天数 (HD)、冷害发生频次 (北方地区连续 3 天平均气温 $\leq 17^\circ\text{C}$ 或南方地区连续 3 天平均气温 $\leq 20^\circ\text{C}$, CN)、冷害总天数 (CD) 等胁迫指标。将种植点地理位置、水稻品种特性、播期、生育期时序以及上述关键气象要素作为特征变量, 输入随机森林产量估算模型得到产量结果, 构建出一个多变量特征数据集。

基于多目标进化算法的播期优化: 以站点为最小优化单元, 开展基于多目标进化算法的播期优化分析。优化流程包括以下步骤: 首先, 根据种植点位置与可行播期范围设定筛选条件, 对原始模拟结果进行样本筛选, 确保各生态区内样本的代表性与可靠性; 其次, 针对每一个站点—品种—年份组合, 构造播期范围内的种群个体, 个体以站点—品种—年份—播期四元组表示; 再次, 构建五目标加权优化函数, 综合考虑产量最大化与温度胁迫最小化目标, 优化权重分别设定为产量 (1.0000)、高温频次 (-0.2484)、高温天数 (-0.2484)、冷害频次 (-0.2500) 和冷害天数 (-0.2531)。优化算法基于NSGA-II框架实现, 采用均匀交叉 (交叉概率 0.5) 与整数变异 (变异概率 0.2) 操作, 经过 15 代演化迭代。种群规模根据播期范围动态确定, 最小不低于 15 个个体, 从最终种群中选取适应度最优个体作为该站点—品种—年份组合的最优播期方案。为提升计算效率, 优化过程采用并行计算方式对所有组合进行高效调度与处理。

5.2.3 区域适应性品种优化

品种综合评价与筛选: 本研究首先对各水稻生态类型区内的品种进行综合性能评价与排序。评价体系以品种的产量水平 (由高至低) 和稳定性 (由强至弱) 为核心指标, 从而筛选构建各生态类型区内具有代表性的候选品种集合。在品种高产性和稳产性的定量评价中, 采用温振民 (1994) [242] 提出的高稳系数 (HSC) 作为综合评价指标, 该系数能够有效反映作物品种的高产性与稳产性特征, 其值

越高表明品种的综合生产性能越佳。高稳系数的计算方法如下：

$$HSC_i = \frac{\bar{x}_i - S_i}{\bar{x}} \quad (5-2)$$

式中， $\bar{x}_i$ 表示品种*i*在的平均产量； S_i 为该品种产量的标准差； $\bar{x}$ 是整个南方研究区域内所有站点和所有品种产量的总体平均值。通过该指标的计算与排序，可以科学评估各品种在特定生态环境下的适应性表现。

品种替换情景下的物候模拟与产量估算：在品种评价与筛选的基础上，以各试验点的实际观测播期作为物候模拟的起始时间点，运用基于三段式温度响应函数的物候模拟模型，对每个生态类型区内的全部候选品种在该区域内所有试验点上的发育进程进行精确模拟重构。通过物候模拟，系统提取各候选品种在不同试验点的关键生育阶段时序数据，并计算特定生育阶段内的关键气象要素，包括平均温度、太阳辐射、有效积温、累积降水和日长等。综合考虑种植点的地理位置信息（包括经度、纬度和海拔高度）和品种参数，作为随机森林产量估算模型的输入变量，得到品种替换情景下的产量估算结果，构建出多维特征数据集。

基于多目标进化算法的品种选择：以站点为最小优化单元，开展基于多目标进化算法的品种分析。首先，针对每一个站点—播期—年份组合，构造候选品种的种群个体，个体以站点—年份—播期—品种四元组表示；然后，构建五目标加权优化函数，综合考虑产量最大化与温度胁迫最小化目标，优化权重分别设定为产量（1.0000）、高温频次（-0.2484）、高温天数（-0.2484）、冷害频次（-0.2500）和冷害天数（-0.2531）。优化算法基于NSGA-II框架实现，采用均匀交叉（交叉概率 0.5）与整数变异（变异概率 0.2）操作，经过 10 代演化迭代。种群规模根据候选品种数量动态确定，最小不低于 10 个个体，从最终种群中选取适应度最优个体作为该站点—年份—播期组合的最适宜种植品种。最后，量化不同品种优化策略的增产稳产潜力，并为各生态类型区筛选出最具适应性的代表性品种。

5.2.4 播期和品种共同优化

多变量特征数据集构建：本研究首先基于已构建的水稻品种地理分异数据库，结合基准播期±15 天的滑动窗口范围，采用基于三段式温度响应函数的物候模型对不同播期—品种组合的物候发育进程进行系统性重构。通过物候模拟，提取各关键生育阶段内的气象要素与胁迫指标，基础气象要素包括：平均温度、太阳辐射、有效积温、累积降水量和日长等；温度胁迫指标包括：高温发生频次（连续 3 天平均气温≥30℃，HN）、高温总天数（HD）、冷害发生频次（北方地区连续 3 天平均气温≤17℃或南方地区连续 3 天平均气温≤20℃，CN），冷害总天数（CD）。利用随机森林产量估算模型，对各试验点、播期和品种组合的产量水平进行预测估算，构建了一个涵盖不同时空尺度的品种与播期组合的多维特征数据集，为后续优化分析提供数据支撑。

基于多目标进化算法的播期—品种联合优化：在构建完整的特征数据集基础上，采用多目标进化算法（Multi-objective Evolutionary Algorithm, MOEA）对不同生态区内的水稻品种与播期组合进行联合优化。优化流程设计如下：首先，选择优化单元与准备数据。以站点为最小分析单元，针对每个站点—年份组合，首先筛选该站点在目标年份内的全部可用品种及其对应的播种日期范围，构建索引映射关系以便于后续编码处理。其次，生成个体编码与初始种群。定义优化个体编码方式为两个整数组成的序列，分别表示品种索引和播期索引。通过随机选取站点所属生态类型区内的品种及其对应播期窗口内的播期值，生成初始优化种群。再者，构建多目标适应度函数。针对每个优化个体，提取其对应的品种—播期组合在特征数据集中的相关指标，构建五目标优化问题：以产量最大化为主目标，同时最小化四项气象胁迫指标（HN、HD、CN、CD）。根据观测数据分析设定各目标权重为（1.000， -0.2484， -0.2484， -0.2500， -0.2531），其中产量权重为正值，胁迫指标权重均为负值，体现了提升产量的同时降低不利气象胁迫影响的优化策略。最后，基于NSGA-II选择算法框架实现优化过程。NSGA-II选择算法采用均匀交叉（交叉概率 0.5）和整数均匀变异（变异概率 0.2）操作，在每轮演化中，种群在保持多样性的基础上不断向更优解集合演进。演化迭代设置为 15 代，最终从种群中选取支配解集合中的最优个体，并返回其对应的品种、播期及相关评价指标。整个优化过程通过并行计算框架对所有站点-年份组合同时进行处理，提升了计算效率，最终形成基于多目标进化优化的区域适应性水稻品种与播期配置综合优化方案。

5.2 结果与分析

5.2.1 采用环境聚类方法模拟物候的模型性能表现

地点—气候—品种的组合差异导致了不同农业生态类型区内品种的热需求极具特异性。作物发育热需求分析结果如图 5-1 所示，从播种至齐穗阶段（VGP）的水稻发育热需求高于从齐穗至成熟阶段（RGP）的热需求，且两者均呈现出一定的变异性。从播种至齐穗阶段，水稻发育的热需求变动范围为 668.65 °C d ~ 2110.98 °C d，平均值为 1492.26 °C d (± 194.06 °C d)，变异系数为 13.00%。从齐穗至成熟阶段，水稻发育热需求的变动范围为 296.64 °C d ~ 1406.97 °C d，平均值为 683.85 °C d (± 105.83 °C d)，变异系数为 15.48%。

为了检验物候模型的模拟性能，我们选取了七个农业生态类型区内的所有供试品种的观测资料。我们把齐穗期和成熟期作为主要生育时期，采用均方根误差（RMSE）、平均绝对误差（MAE）以及决定系数（ R^2 ）作为评价指标。结果如图 5-2 显示，齐穗期的 RMSE、MAE 和 R^2 分别为 7.01 天、4.87 天和 0.94，成熟期的 RMSE、MAE 和 R^2 分别为 8.87 天、5.80 天和 0.92。图 5-3 显示，在齐

穗期时,模拟误差 ≤ 7 天的情况占比为 80.5%,模拟误差 >7 天的情况占比为 19.5%;在模拟误差 >7 天的情况中,早稻占到了 81.0%,一季稻(1.3%)和晚稻(17.7%)大偏差的情况较少。在成熟期时,模拟误差 ≤ 9 天的情况占比为 83.4%,模拟误差 >9 天的情况占比为 16.6%;在模拟误差 >9 天的情况中,早稻占到了 82.4%,一季稻(1.3%)和晚稻(16.3%)大偏差的情况较少。整体来看,模型的模拟精度较好,能够为预测作物产量提供准确的物候发育特征。




图 5-1 两个发育阶段水稻发育所需热求观测值的箱线图。箱形图和须线分别代表播种—齐穗期和齐穗—成熟期,热需求积累值的第 25 到第 75 百分位和第 10 到第 90 百分位范围。红色的点表示平均值,箱型中的竖线表示中位数。

Figure 5-1 Boxplot of thermal requirement observations in two developmental periods for Rice. Boxes and whiskers represent the 25th–to–75th and the 10th–to–90th percentile ranges, respectively, of the thermal requirements from sowing date to full heading date and from full heading date to maturation date. The red dots represent the average values, and the vertical lines within the box represent the median.




图 5-2 综合不同农业生态类型区和品种的水稻物候模拟值与观测值对比

Figure 5-2 Comparison of rice phenological simulation values and observed values from different agroecological regions and varieties




图 5-3 齐穗期和成熟期物候模拟误差分布情况

Figure 5-3 Distribution of phenological simulation errors during the full-heading stage and maturity stage

5.2.2 播期调整对水稻产量和生育期的影响

为探究播种期调整对水稻产量及生育期的综合影响,本研究在维持田间试验原有品种不变的前提下,以原播期为基准设置 ± 15 天活动窗口期进行播期优化,并系统评估了不同生态区域下播期调整对水稻生育期长度、产量水平及其稳定性的综合影响。研究表明,如图 5-4,播期优化后,总体的平均产量水平从品种试验阶段的 577.60 kg/mu 提升至 606.69 kg/mu,产量增幅达 5.04%,产量标准差由 86.02 kg/mu 降至 69.68 kg/mu,变异系数从 14.89%降低至 11.48%,产量稳定性显著提升。

对不同稻季和生态区域而言,产量提升幅度和稳定性变化各有差异。通过播期调整,早稻产量达到 609.54 kg/mu,增产 4.82%,产量变异性降低 3.22%;晚稻产量达到 565.00 kg/mu,增产 6.45%,产量变异性降低 4.32%;一季稻产量达




图 5-4 播期调整对不同生态类型区内的水稻产量、全生育期天数 (GP)、营养生长期天数 (VGP) 和生殖生长期天数 (RGP) 的影响。SC 表示华南地区 (●), YGP 表示云贵高原周边地区 (■), MLYZ-HHP 表示长江中下游和淮河地区 (★), SBSA 表示四川盆地及其周边地区 (◀), BTH-NEP 表示京津冀平原和东北平原区 (◆), NXP 表示宁夏平原区 (▲), XJOA 表示新疆绿洲农业区 (▶), 见图 4-1a。红色的点表示平均值, 箱型中的横线表示中位数。

Figure 5-4 Effects of adjusting sowing date on rice yield, days of entire growth period (GP), days of vegetative growth period (VGP), and days of reproductive growth period (RGP) in different ecological regions. SC represents the Southern China (●), YGP represents the Yunnan-Guizhou Plateau and surrounding areas (■), MLYZ-HHP represents the middle and lower reaches of the Yangtze River and Huaihe River areas (★), SBSA represents the Sichuan Basin and its surrounding areas (◀), BTH-NEP represents the Beijing-Tianjin-Hebei Plain and Northeast Plain regions (◆), NXP represents the Ningxia Plain region (▲), and XJOA represents the Xinjiang Oasis Agricultural region (▶). The red dots represent the average values, and the horizontal lines within the box represent the median.

到 681.57 kg/mu, 增产 4.19%, 产量变异性降低 3.70%。华南地区增产 5.72%, 产量变异性降低 3.60%; 云贵高原周边地区增产 4.00%, 产量变异性降低 3.69%; 长江中下游和淮河平原地区增产 5.06%, 产量变异性降低 3.60%; 四川盆地及其周边地区增产 4.93%, 产量变异性降低 3.93%; 京津冀和东北平原区增产 5.75%, 产量变异性降低 5.44%; 宁夏平原区增产 2.76%, 产量变异性降低 2.79%; 新疆绿洲农业区增产 4.39%, 产量变异性降低 6.31%。

在播期和生育期变化方面, 早稻播期平均推迟 1.1 天, 全生育期平均长度缩短了 0.6 天; 一季稻播期平均提前 0.2 天, 一季稻的全生育期平均长度缩短 0.4 天; 晚稻播期平均提前 3.7 天, 晚稻全生育期平均长度略缩短 0.1 天。具体到各生态区域, 在华南地区, 早稻播期推迟 0.4 天, 全生育期平均长度缩短 0.9 天, 主要是由于其生殖生长期平均长度缩短了 1.2 天; 晚稻播期提前 5.7 天, 全生育期平均长度缩短 0.7 天, 这是由于生殖生长期平均长度缩短 1.5 天, 抵消了营养生长期平均长度延长的 0.8 天。在云贵高原周边地区, 一季稻播期提前 0.6 天, 全生育期平均长度缩短了 0.5 天, 主要是由于生殖生长期平均长度缩短了 0.9 天。在长江中下游和淮河平原地区, 早稻播期推迟 0.7 天, 全生育期平均长度缩短了 0.5 天, 主要是由于生殖生长期平均长度缩短了 0.7 天; 晚稻播期提前 2.7 天, 全生育期平均长度延长了 0.4 天, 主要是由于营养生长期延长了 1.2 天, 抵消了生殖生长期缩短的 0.8 天。在四川盆地及其周边地区, 早稻播期推迟 1.7 天, 全生育期平均长度缩短 0.8 天, 主要是由于早稻生殖生长期缩短引起的; 晚稻播期提前 5.5 天, 全生育期平均长度缩短 8.3 天, 主要是由于晚稻生殖生长期缩短 6.9 天而导致的。在京津冀和东北平原区, 一季稻播期推迟 1.9 天, 全生育期平均长度延长 0.3 天, 营养生长期平均延长了 0.1 天, 生殖生长期长度延长了 0.3 天。在宁夏平原区, 一季稻播期推迟 1.7 天, 全生育期平均长度缩短 0.7 天, 这主要是由于生殖生长期长度缩短引起的。在新疆绿洲农业区, 一季稻播期推迟 2.2 天, 全生育期平均长度缩短了 0.8 天, 这主要是由于营养生长期长度缩短引起的。

5.2.3 品种更替对水稻产量和生育期的影响

本研究在保持田间试验原有播期不变的条件下, 对各生态类型区内的水稻品种进行了更替, 并系统评估了品种更替对水稻生长期、产量水平及其稳定性的综合影响。研究结果(图 5-5)揭示了品种更替在不同生态类型区引起的生育期和产量变化具有显著的空间差异性, 但新品种在多种生态环境中均展现出较强的适应性和稳产性。总体而言, 品种更替后整体产量水平显著提升, 总体产量增幅为 9.83%, 产量的波动性也明显降低, 标准差由 86.02 kg/mu 降至 61.06 kg/mu, 变异系数降低 5.26%。

进一步从不同稻季和生态类型区分析, 品种更替带来的产量提升幅度和稳定性变化各有差异, 但变异系数均明显降低。通过品种优化策略, 早稻产量达到




图 5-5 品种更替对不同生态类型区内的水稻产量、全生育期天数（GP）、营养生长期天数（VGP）和生殖生长期天数（RGP）的影响。SC 表示华南地区（●），YGP 表示云贵高原周边地区（■），MLYZ-HHP 表示长江中下游和淮河地区（★），SBSA 表示四川盆地及其周边地区（◄），BTH-NEP 表示京津冀平原和东北平原区（◆），NXP 表示宁夏平原区（▲），XJOA 表示新疆绿洲农业区（◆）。红色的点表示平均值，箱型中的横线表示中位数。

Figure 5-5 Effects of variety replacement on rice yield, days of entire growth period (GP), days of vegetative growth period (VGP), and days of reproductive growth period (RGP) in different ecological regions. SC represents the Southern China (●), YGP represents the Yunnan-Guizhou Plateau and surrounding areas (■), MLYZ-HHP represents the middle and lower reaches of the Yangtze River and Huaihe River areas (★), SBSA represents the Sichuan Basin and its surrounding areas (◄), BTH-NEP represents the Beijing-Tianjin-Hebei Plain and Northeast Plain regions (◆), NXP represents the Ningxia Plain region (▲), and XJOA represents the Xinjiang Oasis Agricultural region (◆). The red dots represent the average values, and the horizontal lines within the box represent the median.

637.17 kg/mu, 增产 9.58%, 产量变异性降低 5.40%; 晚稻产量达到 597.73 kg/mu, 增产 12.62%, 产量变异性降低 5.08%; 一季稻产量达到 696.59 kg/mu, 增产 6.49%, 产量变异性降低 7.03%。在华南地区, 品种更替实现产量增加 10.11%, 变异系数降低 5.40%; 在云贵高原周边地区, 实现增产 6.42%, 产量变异性降低 5.08%; 在长江中下游和淮河平原地区, 增产 11.82%, 产量变异性降低 7.03%; 在四川盆地及其周边地区, 增产 6.98%, 产量变异性降低 4.53%; 在京津冀和东北平原区增产 7.70%, 产量变异性降低 6.46%; 在宁夏平原区, 增产 2.48%, 产量变异性降低 2.72%; 在新疆绿洲农业区, 增产 4.58%, 产量变异性降低 6.95%。

从不同稻季的生育期长度变化来看, 品种更替使得早稻全生育期长度平均延长了 11.34 天, 晚稻全生育期长度平均延长了 21.31 天, 一季稻全生育期长度平均延长了 3.1 天。其中, 早稻营养生长期平均延长了 6.8 天, 生殖生长期平均延长了 4.6 天; 晚稻全生育期延长主要源于生殖生长期延长了 15.5 天, 营养生长期平均延长了 5.8 天; 一季稻全生育期平均长度延长, 主要是由于生殖生长期平均延长了 2.5 天。具体到各生态类型区域, 在华南地区, 早稻和晚稻的全生育期平均长度分别延长了 7.8 天和 15.7 天, 早稻全生育期延长主要是由于营养生长期平均长度延长了 5.3 天, 晚稻全生育期延长主要是由于生殖生长期平均长度延长了 11.8 天。在云贵高原周边地区, 一季稻全生育期长度平均延长了 0.9 天, 其中营养生长期平均长度缩短了 2.1 天, 生殖生长期平均长度延长了 3.0 天。在长江中下游和淮河平原地区, 早稻全生育期长度平均延长了 20.6 天, 晚稻全生育期长度平均延长 24.0 天, 其中早稻全生育期延长是由于营养生长期平均长度延长了 11.5 天, 晚稻全生育期延长主要是由生殖生长期平均长度 17.5 天。在四川盆地及其周边地区, 早稻全生育期平均长度缩短 1.2 天, 晚稻全生育期平均长度延长了 42.6 天, 早稻营养生长期长度缩短是由生殖生长期长度平均缩短 1.4 天引起的, 而晚稻全生育期平均长度延长是由于营养生长期和生殖生长期平均长度分别延长了 27.5 天和 15.1 天。在京津冀和东北平原区, 一季稻全生育期平均长度延长 17.5 天, 主要是由于营养生长期平均长度延长引起的, 生殖生长期平均长度未发生显著变化。在宁夏平原区, 一季稻全生育期平均长度缩短了 0.4 天, 这主要是由于生殖生长期长度缩短引起的。在新疆绿洲农业区, 一季稻全生育期平均长度缩短了 3.1 天, 主要是由于营养生长期平均长度缩短引起的。

5.3.4 品种更替结合播期调整对水稻产量和生育期的影响

为探究品种更替同时进行播期调整对水稻产量及生育期的综合影响, 本研究以原播期为基准设置 ± 15 天活动窗口期, 对各生态类型区内的水稻品种进行了更替, 系统评估了不同生态区域下品种更替结合播期调整对水稻生育期、产量水平及其稳定性的综合影响。研究结果显示(图 5-6), 通过播期调整和品种更替不仅提高了产量, 还增强了产量的稳定性, 减少了因环境因素导致的产量波动。水

稻产量显著提升,平均产量从品种试验阶段的 577.60 kg/mu 提升至 638.66 kg/mu,产量增幅为 10.57%,产量标准差由 86.02 kg/mu 降至 56.40 kg/mu,变异系数也从 14.89%降低至 8.83%。

多目标优化策略对产量的影响在不同稻季和生态类型区间存在差异,但均带来产量水平的提升和产量稳定性的增强。同时采取播期调整和品种更替,使早稻产量达到 638.06 kg/mu,增产 9.73%,产量变异性降低 5.78%;晚稻产量达到 616.04 kg/mu,增产 16.07%,产量变异性降低 5.09%;一季稻产量达到 694.85 kg/mu,增产 6.22%,产量变异性降低 5.48%。对各个生态类型区而言,华南地区增产 10.19%,变异性降低 5.12%;云贵高原周边地区增产 5.82%,变异性降低 5.49%;长江中下游和淮河平原地区增产 13.15%,变异性降低 8.97%;四川盆地及其周边地区增产 7.25%,变异性降低 5.57%;京津冀和东北平原区增产 9.48%,变异性低 7.23%;宁夏平原区增产 3.54%,变异性降低 3.35%;新疆绿洲农业区增产 5.73%,变异性降低 7.78%。

通过多目标优化,不同稻季和生态类型区的播期和生育期长度均发生了显著变化。从不同稻季的播期变化来看,早稻和一季稻播期普遍推迟,分别推迟 6.4 天和 0.3 天,而晚稻播期则有所提前,平均提前 11.8 天。在生育期变化方面,早稻、晚稻和一季稻的全生育期平均长度均显著延长,分别延长了 12.2 天、30.4 天和 1.9 天。具体到各生态类型区,在华南地区,早稻播期平均推迟了 3.1 天,早稻全生育期平均长度延长 13.3 天,其中营养生长期平均长度延长了 7.2 天,生殖生长期平均长度缩短了 6.0 天;晚稻播期平均提前 4.8 天,晚稻的全生育期平均长度延长 16.8 天,其中营养生长期平均长度延长了 6.2 天,生殖生长期平均长度缩短了 10.6 天。在云贵高原周边地区,一季稻播期提前 0.6 天,全生育期平均长度延长了 0.5 天,主要是由于生殖生长期平均长度延长引起的。在长江中下游和淮河平原地区,早稻播期推迟 9.9 天,早稻全生育期平均长度延长了 21.0 天,营养生长期和生殖生长期平均长度分别延长了 7.6 天和 13.3 天;晚稻播期提前 13.6 天,晚稻全生育期平均长度延长了 35.9 天,营养生长期和生殖生长期均显著延长,平均长度分别延长了 16.8 天和 19.1 天。在四川盆地及其周边地区,早稻播期推迟 4.1 天,全生育期平均长度缩短 0.6 天,这是由于早稻营养生长期和生殖生长期均略有缩短;晚稻播期提前 4.8 天,全生育期平均长度延长 17.1 天,营养生长期和生殖生长期平均长度分别延长了 11.4 天和 5.7 天。在京津冀和东北平原区,一季稻播期推迟 5.0 天,全生育期平均长度延长 12 天,这主要是由于营养生长期平均延长了 10.6 天导致的。在宁夏平原区,一季稻播期推迟 2.5 天,全生育期平均长度缩短 2.3 天,营养生长期和生殖生长期平均长度均分别缩短了 1.6 天和 0.8 天。在新疆绿洲农业区,一季稻播期推迟 6.0 天,全生育期平均长度缩短了 6.4 天,这主要是由于营养生长期长度缩短引起的。




图 5-6 播期和品种共同优化对不同生态类型区内的水稻产量、全生育期天数（GP）、营养生长期天数（VGP）和生殖生长期天数（RGP）的影响。SC 表示华南地区（●），YGP 表示云贵高原周边地区（■），MLYZ-HHP 表示长江中下游和淮河地区（★），SBSA 表示四川盆地及其周边地区（◀），BTH-NEP 表示京津冀平原和东北平原区（◆），NXP 表示宁夏平原区（▲），XJOA 表示新疆绿洲农业区（◆）。红色的点表示平均值，箱型中的横线表示中位数。

Figure 5-6 Effects of combined optimization of sowing date and variety on rice yield, days of entire growth period (GP), days of vegetative growth period (VGP), and days of reproductive growth period (RGP) in different ecological regions. SC represents the Southern China (●), YGP represents the Yunnan-Guizhou Plateau and surrounding areas (■), MLYZ-HHP represents the middle and lower reaches of the Yangtze River and Huaihe River areas (★), SBSA represents the Sichuan Basin and its surrounding areas (◀), BTH-NEP represents the Beijing-Tianjin-Hebei Plain and Northeast Plain regions (◆), NXP represents the Ningxia Plain region (▲), and XJOA represents the Xinjiang Oasis Agricultural region (◆). The red dots represent the average values, and the horizontal lines within the box represent the median.

5.4 讨论

5.4.1 播期调整和品种更替对水稻生产的影响

(1) 播期调整对水稻生育期和产量的影响

调整播期已成为增强作物适应气候变化的重要作物管理策略^[243]。本研究表明确明,播期调整是一种有效的种植优化策略,能显著提升水稻产量水平并增强产量稳定性,全国范围内平均增产幅度达 5.04%,产量变异系数从 14.89%降低至 11.48%。这一结果与 Wang 等(2025)^[223]的研究具有一致性,他们发现在中国南方水稻区域,通过播期调整可使单季稻产量提高 7.4%,早稻产量提高 1.7%,晚稻产量提高 4.4%。

从全国尺度来看,早稻和一季稻的播期优化趋势存在明显差异,早稻平均推迟播期 1.1 天而一季稻则提前播期 0.2 天,晚稻平均提前播期 3.7 天。这种播期调整模式与 Hu 等(2017)^[243]和 Wang 等(2025)^[223]的研究发现部分一致—他们指出单季稻适宜提前播种。然而,本研究与这些已有研究也存在部分差异,我们的研究发现,早稻在华南地区和长江中下游地区适宜推迟播种,Wang 等(2025)^[223]指出单季稻适宜提前播种。这可能是由于数据来源和结构、研究目的等差异。Wang 等(2025)的研究基于 1961~2020 年的气象数据和 20 世纪 80 年代的 6 个代表性品种数据,评估长期气候变化的影响;而我们的数据集包含了 2007~2018 年中国 327 个品种试验站点共 2175 个作物品种的区试和生产试验数据。由于我们的研究时间跨度较短(12 年),气候波动和变化并不如六十年间显著,这可能影响了播期优化策略的结论。此外,我们在早稻和晚稻的稻季划分上并不一致,这也可能导致了结果的差异。Wang 等人(2025)^[223]的研究旨在评估气候变化对水稻生育期和潜在产量的长期影响,而我们的研究更侧重于短期(12 年)内不同生态区的播期优化策略,以应对当前的气候波动和变化。

播期调整对水稻生育期长度的影响存在明显的生态区域分异特征。总体而言,早稻、晚稻和一季稻的全生育期长度在播期优化后分别缩短了 0.6 天、0.1 天和 0.4 天,与 Zhao 等(2016)^[244]研究中播期变化导致水稻生育期延长的结论不同。这一差异可能源于本研究采用了更加多样化的品种数据,并且研究区域和时间尺度不同。进一步分析发现,播期调整对生育期的影响在不同区域间存在差异,例如长江中下游地区晚稻全生育期平均延长 0.4 天,而四川盆地晚稻全生育期平均缩短 8.3 天,这与 Zhang 等(2022)^[245]的研究结果相符,他们指出播期调整对生育期的影响存在明显的区域分异特征。播期调整对不同生育阶段的影响更为复杂,生殖生长期(RGP)和营养生长期(VGP)对播期变化的响应存在差异。在南方大部分地区,播期调整后 RGP 普遍缩短,而 VGP 的变化则因区域而异。这与 Zhang 等(2023)^[246]的研究结果相吻合,他们发现气候变暖条件下,播期调整主要通过改变不同生育阶段的温度和光照条件,进而影响水稻的生育期结构和产量

形成。这一差异化响应表明,播期优化不仅影响全生育期长度,更显著地调整了生育期结构,使关键生育阶段能够避开高温或低温等不利环境条件,从而提高产量水平并增强稳定性。值得注意的是,京津冀和东北平原区的一季稻通过播期优化后全生育期平均延长 0.3 天,增产幅度达 5.75%,产量变异性降低 5.44%,是全国增产和稳产效应最为显著的区域之一。这与 Chen 等(2021)^[247]的研究结果相符,他们发现适当调整播期能有效缓解华北地区水稻生产面临的温度胁迫,延长有效灌浆期,提高产量水平。这一结果也支持了前人研究中提出的观点,即适当的播期调整能够优化水稻生长发育过程与气候资源的匹配度^[248]。

对比不同稻作区域,我们发现播期优化对各生态区的增产效应存在明显差异:华南地区增产 5.72%,长江中下游地区增产 5.06%,京津冀和东北平原区增产 5.75%,而宁夏平原区仅增产 2.76%。这种差异与各区域的气候特征和温度胁迫类型密切相关。在南方稻区,高温胁迫是影响产量的主要限制因素,而在北方稻区,低温胁迫则更为突出。通过播期优化,可以使水稻关键生育阶段避开这些不利胁迫条件,但在不同区域的效果存在差异。这一发现与 Zhang 等(2022)^[249]的研究结果一致,他们指出播期调整的效果取决于当地的气候条件和胁迫特征。

(2) 品种更替对水稻生育期和产量的影响

培育耐寒、耐旱和更具适应性的高产稳产水稻品种,是有效适应和减缓气候变化的对产量负面影响的另一重要措施^[250,251,223]。本研究结果表明,品种更替策略对水稻产量和生育期的影响超过了单纯的播期调整。通过品种更替,全国水稻平均产量提高了 9.83%,产量变异系数降低了 5.26%,远高于播期调整所带来的 5.04%增产和 3.41%稳产效果。这一结果与 Liu 等(2013)^[252]的研究结论部分一致,他们发现品种更替能有效补偿气候变化对单季稻生育期长度的负面影响,但对双季稻的补偿效果有限。

从生育期的变化来看,品种更替导致早稻、晚稻和一季稻的全生育期平均分别延长了 11.34 天、21.31 天和 3.1 天,这一变化幅度远超播期调整所带来的生育期变化。值得注意的是,本研究发现品种更替对晚稻生育期的延长效应尤为显著,平均延长 21.31 天,这与 Zhang 等(2016)^[220]的研究存在差异,他们认为品种更替使单季稻和早稻生育期延长而晚稻生育期缩短。这一差异可能源于本研究采用了更新的高产稳产品种数据库,反映了近年来晚稻育种方向的变化,即更加注重延长生殖生长期以提高产量和品质。在不同生育阶段方面,品种更替对营养生长期和生殖生长期均产生了显著影响,但影响程度各有差异。早稻的营养生长期和生殖生长期分别延长了 6.8 天和 4.6 天,晚稻则分别延长了 5.8 天和 15.5 天,一季稻的生殖生长期延长 2.5 天。这表明新品种主要通过延长生育期特别是生殖生长期来提高产量潜力,这与 Wang 等(2021)^[218]的研究结果一致,他们发现延长灌浆期是提高水稻产量的关键途径之一。

从区域差异来看,品种更替的影响在不同生态区间存在显著差异。长江中下游和淮河平原地区通过品种更替增产 11.82%, 华南地区增产 10.11%, 而宁夏平原区仅增产 2.48%。这种区域差异与各区域选用的品种特性和环境资源条件有关。Wang 等 (2021) [218] 指出, 品种更替策略的效果取决于新品种与当地生态环境的适应性匹配程度, 本研究的结果支持了这一观点。

对比品种更替与播期调整的影响, 我们发现在所有生态区, 品种更替对产量的提升效果均高于播期调整, 特别是在长江中下游和淮河平原地区, 品种更替带来的增产效应 (11.82%) 是播期调整 (5.06%) 的两倍多。同时, 品种更替对产量稳定性的提升效果也普遍高于播期调整。这一结果表明, 在资源有限的情况下, 优先考虑品种优化策略可能比播期调整更为有效。然而, 两种策略对生育期的影响模式存在差异: 播期调整主要通过微调生育期结构使关键发育阶段避开不利环境条件, 而品种更替则通过显著延长全生育期特别是生殖生长期来提高产量潜力。这与 Qiu 等 (2022) [253] 的研究结果一致, 他们发现新品种主要通过优化生长发育过程和生物量分配来提高产量。值得注意的是, 品种更替与播期调整对水稻产量影响的区域差异存在一定的一致性, 即在南方稻区特别是长江中下游地区, 两种策略的效果均较为显著; 而在西北干旱区如宁夏平原区, 两种策略的效果均相对有限。这表明区域气候条件是决定农业管理措施效果的关键因素, 这一结论与 Peng 等 (2009) [254] 的研究结果相符, 他们指出农业管理措施的效果受到区域气候条件的显著影响。

5.4.2 区域适宜性组合策略对水稻生产的影响

(1) 播期调整和品种更替组合策略对区域产量的差异影响

本研究结果表明, 组合策略较单一策略具有更显著的增产稳产效果, 全国范围内平均增产幅度达 10.57%, 产量变异系数从 14.89% 降低至 8.83%, 效果优于单独采用播期调整 (增产 5.04%) 或品种更替 (增产 9.83%) 策略。这表明两种策略之间存在表互补性, 组合策略通过结合播期调整和品种更替, 能够更全面地优化水稻生产条件, 从而实现比单一策略更显著的增产和稳产效果。这一结果支持了 Song 等 (2022) [255] 的研究结论, 他们指出综合采用播期调整和品种选择策略能够有效提高水稻对气候变化的适应性。

从区域差异角度分析, 组合策略的增产效应在不同生态区域间存在显著差异: 长江中下游和淮河平原地区增产 13.15%, 华南地区增产 10.19%, 京津冀和东北平原区增产 9.48%, 而宁夏平原区仅增产 3.54%。这种区域差异可能与各区域的气候资源条件、水稻种植制度以及现有品种和播期水平有关。在长江中下游和淮河平原地区, 水稻生产具有较高的基础水平和技术条件, 对管理措施优化的响应更为敏感; 而在宁夏等西北干旱区, 水资源短缺成为限制水稻产量提升的主要因

素,单纯的播期调整和品种更替难以突破这一限制。这与 Chen 等 (2021)^[247]的研究结果一致,他们发现水稻对管理措施的响应受到区域资源环境条件的显著影响。组合策略对产量稳定性的提升效果也存在明显的区域差异:长江中下游和淮河平原地区产量变异性降低 8.97%,新疆绿洲农业区降低 7.78%,京津冀和东北平原区降低 7.23%,而宁夏平原区仅降低 3.35%。这表明在资源条件较好或气候变异性较大的区域,组合策略对提高产量稳定性的效果更为显著。这与 Vogel 等 (2019)^[256]的研究结果相符,他们指出适当的管理措施能够有效降低极端气候事件对作物产量的不利影响。

从生育期变化看,组合策略下早稻、晚稻和一季稻的全生育期平均分别延长了 12.2 天、30.4 天和 1.9 天。这一结果表明,组合策略下生育期的变化主要受品种更替的影响,而播期调整则在此基础上进行了微调。播期提前与新品种特性的协同作用,共同延长了晚稻的生育期。这一发现与 Zhang 等 (2022)^[249]的研究结论一致,他们指出播期调整和品种选择的协同作用能够显著改变水稻的生育期结构。值得注意的是,组合策略对播期的调整方向与单纯的播期优化策略存在一定差异。在组合策略下,早稻和一季稻播期分别推迟 6.4 天和 0.3 天,晚稻播期提前 11.8 天;而在单纯的播期优化策略下,早稻播期推迟 1.1 天,一季稻播期提前 0.2 天,晚稻播期提前 3.7 天。这表明在考虑品种特性的情况下,最优播期策略发生了显著变化,这与 Ji 等 (2024)^[257]的研究结果一致,他们指出最优播期与品种特性密切相关,应根据品种特性进行针对性调整。

(2) 区域适宜性种植策略调整建议

基于本研究的模拟分析结果与多目标优化算法,结合各生态类型区域的气候特征、栽培制度和水稻生产实际,我们提出针对性的区域适宜性种植策略调整方案,旨在助力提升我国水稻产量,增强水稻生产的整体韧性。

华南地区是我国重要的双季稻产区,气候特点为高温多雨,全年光热资源丰富,但夏季极端高温和台风等灾害性天气频发。早稻建议选用 II 优 838、建两优 117、天优 998、天优华占、两优 2388、深两优 136、丰两优 4 号等品种,这些品种具有较强的抗逆性和稳产性。早播期为 2 月上旬至 5 月下旬,适当推迟早播期有助于避开早春低温,提高出苗率和秧苗素质。晚稻播期范围为 6 月上旬至 7 月下旬。晚稻建议选用天优华占、博优 998、建两优 117、两优 2388、两优 688、五优 308、永丰优 9802 等品种,晚播期为 6 月上旬至 7 月下旬,提前晚播期有助于避开晚秋低温和台风季节,降低灾害风险,保证晚稻安全成熟。

云贵高原周边地区以单季稻为主,气候特点为冬春干旱,夏秋多雨,气温年较差和日较差较大,光热资源相对不足。种植品种建议选赣 73 优明占、F 优 498、旺两优 959、宣香优 1577、神农优 422、垦优 259 等品种,这些品种对云贵高原气候条件有较强适应性。该区域一季稻播期为 3 月中旬至 4 月下旬,播期不宜过

早以避免春季低温，也不宜过晚以避免生育后期遭遇低温。

长江中下游和淮河平原地区可以种植双季稻或一季稻，气候特点为四季分明，雨热同期。早稻建议选用春优 927、嘉优 9 号、秀优 4913、中嘉优 6 号、甬优 540、浙优 1121、丰两优 4 号、II 优 838 等品种，播期为 3 月中旬至 5 月下旬，适当推迟播期有助于避开早春低温，提高出苗率和分蘖成穗率。晚稻建议选用秀优 4913、甬优 1540、甬优 1140、春优 927、嘉优 9 号、中嘉优 6 号、中嘉优 3 号等品种，播期为 6 月上旬至 6 月下旬，提前播期有助于延长有效生长期，增加生物量积累。

四川盆地及其周边地区气候特点为夏热冬暖，雨量充沛但光照不足。早稻建议选用鹏两优 3437、盘两优 1618、信优满 721、至优 08 等耐寡照品种，播期为 3 月上旬至 5 月下旬，播期应避开春季低温多雨期。晚稻建议选用泰优 50、湘优华占、和两优 633、天优华占等品种，播期为 6 月中下旬，提前播期有助于避开秋季低温，保证安全成熟。

京津冀和东北平原区、宁夏平原区 and 新疆绿洲农业区在气候特征上存在显著差异，但均表现出冬冷夏热、无霜期短、昼夜温差大等相似性。宁夏平原区和新疆绿洲农业区的大陆性气候尤为显著，干旱少雨，而新疆绿洲农业区则拥有更为充足的日照条件。三个生态类型区均种植单季稻，并且研究过程中发现这些区域的水稻品种可以进行轮换种植，种植品种建议选用津原 58、滨稻 9 号、皇香 48、北恢 1、津粳 253、吉洋 46、吉粳 821、吉粳 811、吉粳 823、吉农大 538、沈农稻 346、京粳 7 号等耐旱、耐寒、高光效品种。播期为 4 月初至 5 月末，播期范围相对宽松，可根据当年春季气温回升情况灵活调整，京津冀和东北平原区的播期调整需考虑春季气温回升的稳定性和晚霜期的结束时间，宁夏平原区的播期调整需考虑干旱条件下的水资源利用效率，新疆绿洲农业区的播期调整则需考虑日照充足条件下的光合作用效率和水资源的合理分配。

本研究主要聚焦于水稻产量提升，尚未充分考虑病害和米质等其他重要方面。科学的种植策略调整，还应考虑其他栽培措施的优化，如水肥管理、病虫害防治、土壤改良等，以增强水稻生产韧性。此外，农业政策和社会经济条件等因素也会显著影响水稻生产。未来的研究应进一步深入探讨具有区域特异性的综合优化策略，结合物联网和大数据技术，实现精准种植和管理，为我国水稻种植提供更加科学、高效的指导。

5.5 本章小结

本章基于前文开发的物候模型和随机森林产量估算模型，构建了水稻播期—品种多目标优化框架，探究了区域适应性种植策略的优化路径。研究首先将全国水稻种植区划分为七个生态类型区，随后通过滑动窗口方法模拟不同播期下的水

稻生育期变化及其对应的气象要素,进而采用 NSGA-II 多目标进化算法分别评估了播期调整、品种更替及两者组合策略对水稻产量和生育期的影响。结果表明,单纯播期调整可增产 5.04%,降低产量变异 3.41%;品种更替可增产 9.83%,降低产量变异 5.26%;而二者组合策略效果最佳,平均增产 10.57%,产量变异降低 6.06%。各策略效应存在显著的区域分异特征,长江中下游和淮河平原地区组合策略增产效应最显著(13.15%),而宁夏平原区效应最低(3.54%)。品种更替主要通过延长生育期特别是生殖生长期提高产量潜力,播期调整则通过微调生育期结构使关键发育阶段避开不利环境条件,两者协同作用下形成了明显的区域特异性优化模式。基于此,研究构建了区域适应性种植策略调整方案,针对七个生态类型区推荐了适宜品种组合和播期范围,为水稻精准种植和应对气候变化提供了科学依据。

第6章 结论与展望

6.1 结论

本研究以水稻生长发育与产量形成的综合优化为核心,构建了从物候模型升尺度、产量估算到区域气候适应性种植策略调整的完整技术体系。通过三个相互关联的研究部分,形成了从基础理论到应用实践的理论闭环,为精准农业管理和应对气候变化提供了理论基础和技术支撑。

6.1.1 基于环境聚类的物候模型升尺度

本研究首次系统量化了作物发育热需求(TR)参数在时空尺度的变异特征,揭示了基于常数积温假设的物候模型理论局限性。结果表明,即使对同一水稻品种汕优 63, 其在不同环境条件下的热需求也存在显著系统性差异。本研究提出的环境聚类参数化方法,将纬度和生长季平均温度作为关键聚类变量,有效降低了环境异质性对模型精度的干扰。通过聚类优化,五个发育阶段的模拟误差显著降低,成熟期平均误差从 6.6 天降至 3.7 天,降幅达 44%。研究表明,基于三段分段线性温度响应函数的模型性能最佳,而包含光周期效应的模型较仅考虑温度驱动力的模型具有更高的准确性,特别是在大尺度应用中。

6.1.2 基于随机森林算法的水稻产量模型

本研究系统整合了地理位置、气候条件、物候特征、水稻品种及其农艺性状等多维度影响因素,构建了具有高精度的随机森林产量模型。结果表明,基于所有特征变量的随机森林模型具有最佳模拟性能,解释方差达 77%,均方根误差为 39.47 kg/mu, 平均绝对误差为 29.85 kg/mu。特征重要性分析揭示,水稻品种是影响产量的最关键因素(8.82%),其次是 VGP 期间日长(8.07%)、种植点的海拔高度(7.65%)、VGP 期间净太阳辐射量(6.69%)和齐穗日期(6.55%)。

6.1.3 基于播期和品种优化的水稻区域气候适应性种植策略

本研究构建了融合作物模型与机器学习的多目标优化框架,实现了水稻播期和品种选择的区域适应性优化。结果表明,仅调整播期可使亩产从 577.60 kg/mu 提升至 606.69 kg/mu, 产量增幅达 5.04%, 产量标准差由 86.02 kg/mu 降至 69.68 kg/mu, 变异系数从 14.89%降低至 11.48%; 仅进行品种更替可使平均产量提高至 634.39 kg/mu, 增幅为 9.83%, 标准差降至 61.06 kg/mu, 变异系数降低 5.26%; 而播期调整结合品种更替可使得亩产提高 10.57%, 产量标准差降至 56.40 kg/mu, 变异系数降低至 8.83%。不同区域和稻季的最优播期和品种组合存在显著差异, 组合策略可显著提高水稻生产系统的适应性和稳定性。

6.2 创新点

本研究在理论层面实现了三项关键突破：首次系统量化了作物发育热需求（TR）在时空尺度的变异规律及其环境驱动机制，从根本上挑战了传统物候模型基于常数积温的理论假设，为理解作物适应性发育提供了全新视角；构建了从环境因子到物候发育再到产量形成的完整机理链，系统阐明了地理位置、气候条件、物候特征和水稻品种对产量的非线性影响路径，建立了多维变量交互作用的定量解释框架；精确量化了作物品种对产量的影响，品种更替可使亩产平均提高 9.83%，减少产量波动 5.26%，为缓解气候变化背景下水稻产量波动提供了定量科学依据。这些理论创新不仅丰富了作物物候学和产量形成的基础理论，也为后续适应性策略的制定奠定了坚实基础。

此外，本研究提出了基于环境相似性的聚类参数化方法并开发了参数自适应优化算法，使物候模型参数能够对环境条件做出动态响应，有效克服了传统物候模型在异质环境中参数固定的机理性限制，使成熟期模拟误差降低 44%；构建了包含产量水平、产量稳定性和气候适应性的多目标优化框架，实现了水稻播期调整和品种选择组合策略，将品种—环境—管理措施交互作用（G×E×M）理论转化为可操作的决策工具。这些方法突破了传统作物模型的技术瓶颈，为精准农业研究提供了新的分析范式。

6.3 问题与展望

本研究虽然构建了从物候模拟到产量估算再到管理决策的完整技术体系，但在研究过程中仍存在一些局限性。这些局限主要体现在四个方面：研究所基于的物候模型主要依赖单一品种数据，可能影响结论的普适性；随机森林产量估算模型主要基于试验站数据构建，与实际农业生产条件存在差距；优化策略主要基于历史气候数据，对长期气候变化的适应性考量不足；以及研究主要聚焦于产量优化，对资源利用效率、环境影响和经济效益等多维目标的协同考量有待加强。具体问题如下。

1. 物候模型品种多样性问题：本研究中物候模型改进时，采用环境聚类方法探索物候模型升尺度应用的可行性，侧重方法论构建，主要基于汕优 63 单一品种的长期观测数据，未涵盖更多品种水稻的长期观测数据。考虑到气候变化背景下，不同基因型对气候变化的响应机制存在显著差异，单一品种难以揭示作物适应性的遗传基础。尽管后续试验引入了大量水稻新品种，但每个品种的区试时间仅为 2~3 年，仍难以充分反映水稻这一类作物不同品种对环境变化的长期适应能力。水稻作为具有丰富品种多样性的作物，其早稻、中稻和晚稻品种在对温度和光周期的敏感性上存在显著差异，而不同类型的杂交稻和常规稻品种间的发育模式也各具特点。这种单一品种研究策略虽然提供了清晰的方法论框架，但其结论

的普适性受到限制。尤其在广泛的生态环境条件下,品种与环境的交互作用更为复杂,本研究提出的环境聚类方法在应用于其他品种时可能需要重新校准参数或调整聚类变量,增加了方法推广的复杂性。这种局限性在气候变化背景下尤为突出,因为不同基因型的品种对气候胁迫的适应能力和响应机制存在较大差异,单一品种研究难以全面把握作物适应性的遗传基础。

2. 数据来源与代表性局限:本研究的随机森林产量估算模型主要依赖农业试验站的品种试验数据,而试验站通常采用较高的管理水平和标准化的栽培措施,与农户实际大田生产条件存在显著差距。试验站数据虽然质量高、变量控制精确,但难以完全反映真实生产环境中的复杂变异性,如土壤条件的空间异质性、水肥管理的差异、病虫害发生的随机性等因素。此外,品种试验数据来源于固定试验点,其空间分布并非完全随机或系统抽样,北方生态区内代表性试验点不足。模型在训练数据分布之外的适用性有待验证,特别是在极端气候条件或管理水平较低的地区。这种数据代表性的局限性可能导致模型模拟结果与实际生产情况存在偏差,影响决策支持系统的实用性和可靠性。

3. 气候变化适应性考量不足:本研究的播期和品种优化策略主要基于历史气候数据构建,虽然考虑了年际气候变异性,但未能充分评估在长期气候变化情景下的适应性。随着全球变暖加剧,未来气候条件将越来越偏离历史气候范围,本研究提出的优化策略是否仍然有效存在不确定性。特别是极端气候事件(如热浪、干旱、强降水)频率和强度增加的趋势下,基于历史数据的模型可能低估这些极端事件的影响。此外,气候变化还会改变病虫害的发生规律、水资源可用性和土壤条件,这些因素在当前优化框架中未被充分考虑。长期来看,气候变化还将改变适宜水稻种植的地理分布,而当前的区域适应性策略缺乏对这种大尺度空间变化的响应机制,可能导致长期适应性差距。

4. 多目标优化视角局限:尽管本研究融合了作物模型与机器学习方法,构建了包含产量水平、产量稳定性和气候适应性的优化框架,但仍主要围绕产量这一核心目标展开,对水资源利用效率、养分利用效率、温室气体排放和经济效益等多维目标的协同优化研究不足。现代农业面临资源约束加剧和环境压力增大的双重挑战,单纯追求产量最大化的策略已不能满足可持续发展的需求。本研究中水稻生产系统的环境足迹和资源效率未被充分量化,难以评估优化策略对生态环境的潜在影响。此外,经济可行性分析缺失也限制了研究成果的实际应用价值,因为农民决策不仅考虑产量,更关注成本效益比和风险管理。这种多目标视角的局限使得研究成果在转化为实际生产决策时面临一定障碍。

6.4 未来研究方向

基于本研究的成果和面临的挑战，未来的研究工作将沿着五个主要方向展开。这些研究方向包括：深入探索作物适应性机制，构建新型物候模型；开发集成多源数据的农业产量预测估算大模型，实现跨尺度无缝预测；构建多维度协同优化框架，实现产量、品质、资源利用和经济效益的综合优化；开发智能农业决策支持系统，促进研究成果向生产实践转化；以及深化气候变化适应性研究，提高农业系统应对未来气候变化的韧性。具体内容如下。

1. 作物适应性机制的深入探索：未来研究将深入探索作物发育热需求的环境响应机制，从生理生态和分子水平阐明植物对环境变异的适应性反应机制。具体而言，将整合高通量表型平台与多组学技术，系统研究不同生态型水稻品种在多样化环境条件下的生理响应和基因表达模式，识别控制环境适应性的关键基因网络和调控路径。基于这些基础研究，构建考虑作物适应性机制的新型物候模型，突破传统模型仅描述响应而忽视适应的理论局限。这类新型模型将物候可塑性参数化，能够模拟作物对环境变化的适应性反应，显著提高模型在气候变化背景下的预测能力。同时，将基于环境聚类的参数化方法拓展应用于其他主要粮食作物（如小麦、玉米和大豆）和不同生态区域，验证方法的普适性，构建覆盖中国主要农业区域的作物物候预测系统，为国家粮食安全监测预警提供技术支撑。

2. 农业大模型的开发与应用：未来研究将致力于开发集成多源数据、跨尺度预测和实时更新功能的农业产量预测估算大模型。该大模型将整合卫星遥感、地面监测、农业统计和气象数据等多源异构数据，利用深度学习和大规模预训练技术构建能够处理高维时空数据的框架。不同于传统模型，农业大模型将具备三大关键特性：首先，实现从像素到区域的跨尺度无缝预测，解决农业预测中的尺度转换难题；其次，具备少样本学习和迁移学习能力，能够适应数据稀缺区域的预测需求；第三，融合物理知识约束和数据驱动学习，保证预测结果符合作物生长的生物物理规律。该大模型将不仅关注产量水平，还将扩展至品质、病虫害风险和资源需求的综合预测，形成农业生产全方位的数字孪生系统。通过与气象预报系统结合，实现滚动预测和动态更新，为农业生产提供从季节尺度到旬尺度的多层次决策支持，显著提升农业生产的信息化和精准化水平。

3. 多维度协同优化框架构建：未来研究将突破当前以产量为核心的单一优化思路，构建同时考虑产量、品质、资源利用效率、环境影响和经济效益的多维协同优化框架。该框架将整合作物生长模型、水资源模型、养分循环模型和农业经济模型，建立系统层面的综合评价体系。具体而言，将定量评估不同管理策略下的水足迹、碳足迹和氮足迹，将资源环境约束显性纳入优化目标；同时，将产量与品质指标（如蛋白质含量、直链淀粉含量、胶稠度）协同考虑，满足不同市场需求；进一步引入成本效益分析和风险评估，使优化结果更符合农户决策逻辑。

通过多目标演化算法和帕累托最优解析,识别不同维度目标间的权衡关系和协同增效机会,提供一系列适应不同资源禀赋和发展目标的优化方案。这一多维度协同优化框架将为农业可持续集约发展提供系统解决方案,特别是在资源约束加剧和环境压力增大的背景下,对转变农业发展方式具有重要指导意义。

4. 智能农业决策支持系统开发:未来研究将致力于将理论成果与现代信息技术深度融合,开发智能化、个性化的水稻生产决策支持系统。该系统将整合物联网、人工智能、区块链和移动互联等技术,构建“云—边—端”三层架构的农业智能服务平台。在数据采集层面,通过多源传感器网络 and 智能农机实现田间环境和作物生长状态的实时监测;在分析处理层面,部署本研究开发的物候模拟、产量预测和优化决策模型,并通过增量学习机制不断优化算法性能;在服务应用层面,基于用户画像和场景识别,提供个性化、可视化的决策建议,包括最优播期推荐、品种选择、水肥管理和病虫害防控等。系统将采用多级空间尺度设计,从国家、省级到县域、农场、地块实现无缝连接,满足不同层级用户的决策需求。特别是针对小农户,开发简易版移动应用,通过直观的图像和语音交互,降低技术应用门槛。这一智能决策系统将成为连接农业科研与生产实践的桥梁,推动农业生产方式向数字化、精准化和智能化转型。

5. 气候变化适应性研究深化:未来研究将聚焦气候变化背景下的长期适应性策略研究,构建不同气候情景下的水稻生产脆弱性评估和适应性提升框架。基于CMIP6气候模式集合预估数据和共享社会经济路径(SSP)情景,系统评估未来气候变化对中国水稻生产的潜在影响,识别高脆弱性区域和关键限制因素。在此基础上,开发适应性管理策略组合,包括短期战术调整(如播期优化、品种轮换)和长期战略变革(如种植制度重构、品种改良方向)。特别关注极端气候事件的频率、强度变化及其对水稻生产的冲击,开发基于概率风险分析的适应性决策框架,提高农业系统应对气候不确定性的韧性。同时,结合农业政策和社会经济因素,评估不同适应策略的可行性、成本效益和潜在障碍,提出差异化的适应路径。通过建立长期适应性监测评估体系,实现适应策略的动态调整和持续优化,为国家层面制定农业气候变化适应战略提供科学依据,提升我国粮食安全保障能力和农业可持续发展水平。

参考文献

- [1] 联合国粮食及农业组织统计数据库[EB/OL]. (2024). <https://www.fao.org>.
- [2] Rusty C. Bautista, Paul Allen Counce. An Overview of Rice and Rice Quality[J]. *Cereal Foods World*, 2020, 65(5).
- [3] 国家统计局全国农业年度普查数据[EB/OL]//国家统计局国家数据. (2025). <https://data.stats.gov.cn>.
- [4] Wallach D, Palosuo T, Thorburn P, et al. How well do crop modeling groups predict wheat phenology, given calibration data from the target population?[J]. *European Journal of Agronomy*, 2021, 124: 126195.
- [5] He D, Wang E, Wang J, et al. Data requirement for effective calibration of process-based crop models[J]. *Agricultural and Forest Meteorology*, 2017, 234-235: 136-148.
- [6] Gao Y, Wallach D, Liu B, et al. Comparison of three calibration methods for modeling rice phenology[J]. *Agricultural and Forest Meteorology*, 2020, 280: 107785.
- [7] Wallach D, Palosuo T, Thorburn P, et al. The chaos in calibrating crop models: Lessons learned from a multi-model calibration exercise[J]. *Environmental Modelling & Software*, 2021, 145: 105206.
- [8] Wang N, Wang J, Wang E, et al. Increased uncertainty in simulated maize phenology with more frequent supra-optimal temperature under climate warming[J]. *European Journal of Agronomy*, 2015, 71: 19-33.
- [9] Soualiou S, Wang Z, Sun W, et al. Functional–Structural Plant Models Mission in Advancing Crop Science: Opportunities and Prospects[J]. *Frontiers in Plant Science*, 2021, 12: 747142.
- [10] Mukhtar Ahmed. *Systems Modeling*[M]. Sweden: Springer Nature Singapore Pte Ltd., 2020.
- [11] Zhao G, Bryan B A, King D, et al. Large-scale, high-resolution agricultural systems modeling using a hybrid approach combining grid computing and parallel processing[J]. *Environmental Modelling & Software*, 2013, 41: 231-238.
- [12] Yin X. A nonlinear model for crop development as a function of temperature[J]. *Agricultural and Forest Meteorology*, 1995, 77(1-2): 1-16.
- [13] Zhang S, Tao F. Modeling the response of rice phenology to climate change and variability in different climatic zones: Comparisons of five models[J]. *European Journal of Agronomy*, 2013, 45: 165-176.
- [14] Zhang T, Zhu J, Yang X. Non-stationary thermal time accumulation reduces the predictability of climate change effects on agriculture[J]. *Agricultural and Forest Meteorology*, 2008, 148(10): 1412-1418.
- [15] Wu D, Wang P, Jiang C, et al. Measured Phenology Response of Unchanged Crop Varieties to Long-Term Historical Climate Change[J]. *International*

Journal of Plant Production, 2019, 13(1): 47-58.

[16] Wu D, Wang P, Jiang C, et al. Use of a plastic temperature response function reduces simulation error of crop maturity date by half[J]. Agricultural and Forest Meteorology, 2020, 280: 107770.

[17] 粮食产量的统计调查和计算方法 - 国家统计局[EB/OL]. [2025-07-04]. https://www.stats.gov.cn/zs/tjws/zytjzbqs/lsc1/202410/t20241029_1957203.html.

[18] 史东红. 农产量抽样调查方法研究[J]. 辽宁师专学报, 2017, 2(19): 98-101.

[19] Sultānī A, Sinclair T R. Modeling physiology of crop development, growth and yield[M]. Wallingford: CABI, 2012.

[20] J. T. Ritchie, E. C. Alocilja, U. S. Singh, 等. IBSNAT and the CERES Model[C]//Proceedings of the International Workshop on the Impact of Weather Parameters on Growth and Yield of Rice. Manila: IRRI, 1986: 271-281.

[21] Jones J W, Hoogenboom G, Porter C H, et al. The DSSAT cropping system model[J]. European Journal of Agronomy, 2003, 18(3-4): 235-265.

[22] Iizumi T, Yokozawa M, Nishimori M. Parameter estimation and uncertainty analysis of a large-scale crop model for paddy rice: Application of a Bayesian approach[J]. Agricultural and Forest Meteorology, 2009, 149(2): 333-348.

[23] Li T, Hasegawa T, Yin X, et al. Uncertainties in predicting rice yield by current crop models under a wide range of climatic conditions[J]. Global Change Biology, 2015, 21(3): 1328-1341.

[24] Kawakita S, Takahashi H, Moriya K. Prediction and parameter uncertainty for winter wheat phenology models depend on model and parameterization method differences[J]. Agricultural and Forest Meteorology, 2020, 290: 107998.

[25] Li Y, Wang J, Chen R, et al. Climate-smart planting for potato to balance economic return and environmental impact across China[J]. Science of The Total Environment, 2022, 850: 158013.

[26] Luo Z, Zhang S, Zhao Z, et al. Soil-smart cropping for climate-smart production[J]. Geoderma, 2024, 451: 117061.

[27] FAO. Climate-smart agriculture case studies 2021—Projects from around the world[M]. Rome, Italy: FAO, 2021.

[28] Karimi Y, Prasher S O, Patel R M, et al. Application of support vector machine technology for weed and nitrogen stress detection in corn[J]. Computers and Electronics in Agriculture, 2006, 51(1-2): 99-109.

[29] Yoon H, Jun S C, Hyun Y, et al. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer[J]. Journal of Hydrology, 2011, 396(1-2): 128-138.

[30] Zhou W, Liu Y, Ata-Ul-Karim S T, et al. Integrating climate and satellite remote sensing data for predicting county-level wheat yield in China using machine learning methods[J]. International Journal of Applied Earth Observation and

Geoinformation, 2022, 111: 102861.

[31] Hossein Dehghanisanij, Hojjat Emami, Somayeh Emami, et al. A hybrid machine learning approach for estimating the water-use efficiency and yield in agriculture[J]. Scientific Reports, 2022, 12.

[32] Deokule N, Kale G. Explainable AI Models for Blueberry Yield Prediction: A Step Towards Trustworthy Precision Agriculture[J]. 2025, 52(7).

[33] Brown M E, Funk C C. Food Security Under Climate Change[J]. Science, 2008, 319(5863): 580-581.

[34] Lesk C, Anderson W, Rigden A, et al. Compound heat and moisture extreme impacts on global crop yields under climate change[J]. Nature Reviews Earth & Environment, 2022, 3(12): 872-889.

[35] Hultgren A, Carleton T, Delgado M, et al. Impacts of climate change on global agriculture accounting for adaptation[J]. Nature, 2025, 642(8068): 644-652.

[36] Hazeu G, Elbersen B, Andersen E, 等. A biophysical typology in agri-environmental modelling[M]//Environmental and Agricultural Modelling. 2010: 159-188.

[37] Wit, C.T. de. Photosynthesis of leaf canopies[R]. Wageningen University, 1965: 56.

[38] W. G. Duncan, R. S. Loomis, W. A. Williams, 等. A model for simulating photosynthesis in plant communities: 卷 4[M]. California, USA: Hilgardia, 1967.

[39] F. W. T. Penning de Vries, H. H. Laar Vaneditors. Simulation of plant growth and crop production[M]. Netherlands, Wageningen: Centre for Agricultural Publishing and Documentation, 1983.

[40] Spitters C J T, Keulen H V, Kraalingen D W G V. A simple and universal crop growth simulator: SUCROS87[J]. Simulation & Systems Management in Crop Protection, 1989.

[41] Jarvis N, Larsbo M. MACRO (v5. 2): Model use, calibration, and validation[J]. Transactions of the ASABE, 2012, 55(4): 1413-1423.

[42] Boogaard H L, De Wit A J W, te Roller J A, 等. User's guide for the WOFOST Control Centre 2.1 and WOFOST 7.1.7 crop growth simulation model[Z]. Alterra, Wageningen University & Research Centre, Wageningen., 2014.

[43] Bouman B A M, Kropff M J, Tuong T P, et al. ORYZA2000: modeling lowland rice[M]. Manila, Philippines: IRRI, 2001.

[44] Proceedings of the International Workshop on the Impact of Weather Parameters on Growth and Yields of Rice[C]//International Rice Research Institute. IBSNAT and the CERES-Rice Model. Los Baños: Int. Rice Research Inst, 1987.

[45] Keating B A, Carberry P S, Hammer G L, et al. An overview of APSIM, a model designed for farming systems simulation[J]. European Journal of Agronomy, 2003, 18(3-4): 267-288.

[46] 黄策, 王天铎. 水稻群体物质生产过程的计算机模拟[J]. 作物学报,

1986, 12(1): 1-8.

[47] 高亮之, 金之庆. RCSODS—水稻栽培计算机模拟优化决策系统[J]. 计算机农业应用, 1993(3): 14-20.

[48] 蔡昆争, 骆世明. 水稻模拟模型的适用性研究[J]. 华南农业大学学报, 1995, 17(3): 12-18.

[49] Yin X, Qi C. Studies on the Rice Growth Calendar Simulation Model (RICAM) and It's Application[J]. The Crop Journal, 1994, 20(3): 339-346.

[50] 戚昌翰, 殷新佑, 刘桃菊, 等. RICAM1.3 的结构与功能的改进及其应用[J]. 江西农业大学学报, 1996, 18(4).

[51] 熊范纶, 郭霖, 吴文荣. 砂僵黑土小麦施肥计算机专家咨询系统[J]. 信息与控制, 1987, 16(2): 7-11.

[52] 赵春江. 一个基于模型的小麦管理专家系统(ESWCM)[C]//第一届全国青年作物栽培作物生理学术会文集. 1993: 7.

[53] 赵春江, 杨信廷, 李斌, 等. 中国农业信息技术发展回顾及展望[J]. 农学学报, 2018, 8(1): 180-186.

[54] 骆世明, 陈春焕, 刘振宇. 水稻高产栽培的计算机模拟研究[J]. 山东农业大学学报(增刊), 1992, 9(23): 87-94.

[55] Tang L, Zhu Y, Hannaway D, et al. RiceGrow: A rice growth and productivity model[J]. NJAS: Wageningen Journal of Life Sciences, 2009, 57(1): 83-92.

[56] Fukui S, Ishigooka Y, Kuwagata T, et al. A methodology for estimating phenological parameters of rice cultivars utilizing data from common variety trials[J]. Journal of Agricultural Meteorology, 2015, 71(2): 77-89.

[57] Vergara B S, Chang T T. The flowering response of the rice plant to photoperiod: a review of the literature[M]. 4 版. International Rice Research Institute, 1985.

[58] 贾明忠. 汕优 63 的光温反应特性研究[J]. 耕作与栽培, 1989(1): 49-53.

[59] 何迷, 李小波, 黄静, 等. 水稻叶面积指数与产量关系研究进展[J]. 农学学报, 2022, 12(8): 1-5.

[60] 王俊江, 尹媛红, 陆楚盛, 等. 水稻关键生育期灌溉对干旱胁迫下稻谷产量和水分利用效率的影响[J]. 中国农学通报, 2025, 41(8): 1-10.

[61] Reaumur R D. Observation du thermomètre, faites à Paris pendant l'année 1735, comparées avec celles qui ont été faites sous la ligne, à l'Isle de France, à Alger et en quelques-unes de nos îles de l'Amérique.[M]. Paris, 1735.

[62] Cannell M G R, Smith R I. Thermal Time, Chill Days and Prediction of Budburst in *Picea sitchensis*[J]. The Journal of Applied Ecology, 1983, 20(3): 951.

[63] Yin X, Kropff M J, Horie T, et al. A model for photothermal responses of flowering in rice I. Model description and parameterization[J]. Field Crops Research,

1997, 51(3): 189-200.

[64] Caffarra A, Donnelly A, Chuine I. Modelling the timing of *Betula pubescens* budburst. II. Integrating complex effects of photoperiod into process-based models[J]. *Climate Research*, 2011, 46(2): 159-170.

[65] Ahmad S, Ahmad A, Soler C M T, et al. Application of the CSM-CERES-Rice model for evaluation of plant density and nitrogen management of fine transplanted rice for an irrigated semiarid environment[J]. *Precision Agriculture*, 2012, 13(2): 200-218.

[66] Basso B, Liu L, Ritchie J T. A Comprehensive Review of the CERES-Wheat, -Maize and -Rice Models' Performances[M]//*Advances in Agronomy*: Vol. 136. Elsevier, 2016: 27-132.

[67] Brisson N, Mary B, Ripoche D, et al. STICS: a generic model for the simulation of crops and their water and nitrogen balances. I. Theory and parameterization applied to wheat and corn[J]. *Agronomie*, 1998, 18(5-6): 311-346.

[68] 高亮之, 金之庆, 黄耀, 等. 水稻计算机模拟模型及其应用之水稻钟模型[J]. *中国农业气象*, 1989, 10(3): 3-10.

[69] 梁光商, 蔡善信. 水稻品种出穗临界日长的研究[J]. *华南农学院学报*, 1980(3): 54-66.

[70] 贾明忠. 汕优 63 的光温反应特性研究[J]. *作物研究*, 1989(4): 10-12.

[71] Thomas B, Vince-Prue D. Photoperiodism in Plants[M]. London: Academic Press, 1997.

[72] Yano M, Kojima S, Takahashi Y, et al. Genetic Control of Flowering Time in Rice, a Short-Day Plant[J]. *Plant Physiology*, 2001, 127(4): 1425-1429.

[73] Grimm S S, Jones J W, Boote K J, et al. Parameter Estimation for Predicting Flowering Date of Soybean Cultivars[J]. *Crop Science*, 1993, 33(1): 137-144.

[74] Yin X, Kropff M J. Use of the Beta function to quantify effects of photoperiod on flowering and leaf number in rice[J]. *Agricultural and Forest Meteorology*, 1996, 81(3-4): 217-228.

[75] 邬定荣, 于强, 王培娟, 等. 一种基于作物对环境的响应与适应机制的发育期模拟方法: CN 110245444 A[P]. 2019-09-17.

[76] Seyoum S, Rachaputi R, Chauhan Y, et al. Application of the APSIM model to exploit $G \times E \times M$ interactions for maize improvement in Ethiopia[J]. *Field Crops Research*, 2018, 217: 113-124.

[77] Piao S, Liu Q, Chen A, et al. Plant phenology and global climate change: Current progresses and challenges[J]. *Global Change Biology*, 2019, 25(6): 1922-1940.

[78] Porker K, Straight M, Hunt J R. Evaluation of $G \times E \times M$ Interactions to Increase Harvest Index and Yield of Early Sown Wheat[J]. *Frontiers in Plant Science*, 2020, 11: 994.

- [79] Mahmood T, Ahmed T, Trethowan R. Genotype x Environment x Management (GEM) Reciprocity and Crop Productivity[J]. *Frontiers in Agronomy*, 2022, 4: 800365.
- [80] Olsson C, Jönsson A M. A model framework for tree leaf colouring in Europe[J]. *Ecological Modelling*, 2015, 316: 41-51.
- [81] Cai L, Benyuan Hao, Zhuang Xu, et al. ELD1 mediates photoperiodic flowering via OsCCA1 alternative splicing and interacts with phytochrome signaling in rice[J]. *Nature Communications*, 2025, 16.
- [82] 程志强, 蒙继华. 作物单产估算模型研究进展与展望[J]. *农业工程学报*, 2015, 23(4): 402-415.
- [83] Nandram B, Berg E, Barboza W. A hierarchical Bayesian model for forecasting state-level corn yield[J]. *Environmental and Ecological Statistics*, 2014, 21(3): 507-530.
- [84] Lobell D B, Asseng S. Comparing estimates of climate change impacts from process-based and statistical crop models[J]. *Environmental Research Letters*, 2017, 12(1).
- [85] Mathieu J A, Aires F. Assessment of the agro-climatic indices to improve crop yield forecasting[J]. *Agricultural and Forest Meteorology*, 2018, 253-254: 15-30.
- [86] 刘良云, 王纪华, 黄文江, 等. 利用新型光谱指数改善冬小麦估产精度[J]. *农业工程学报*, 2004, 20(1): 172-175.
- [87] Yang X, Li J, Yu Q, et al. Impacts of diffuse radiation fraction on light use efficiency and gross primary production of winter wheat in the North China Plain[J]. *Agricultural and Forest Meteorology*, 2019, 275: 233-242.
- [88] Stratonovitch P, Semenov M A. Heat tolerance around flowering in wheat identified as a key trait for increased yield potential in Europe under climate change[J]. *Journal of Experimental Botany*, 2015, 66(12): 3599-3609.
- [89] 史培华. 花后高温对水稻生长发育及产量形成影响的研究[D]. 南京农业大学, 2014.
- [90] Nielsen D C, Vigil M F, Benjamin J G. The variable response of dryland corn yield to soil water content at planting[J]. *Agricultural Water Management*, 2009, 96(2): 330-336.
- [91] Challinor A J, Watson J, Lobell D B, et al. A meta-analysis of crop yield under climate change and adaptation[J]. *Nature Climate Change*, 2014, 4(2153): 287-291.
- [92] 刘文丰, 白亚玮, 杜太生, 等. 区域尺度作物生长及伴生过程模型研究进展[J]. *中国科学: 地球科学*, 2025, 55(3): 669-685.
- [93] Steduto P, C. Hsiao T, Fereres E, et al. Crop yield response to water[M]. Rome: Food and Agriculture Organization of the United Nations, 2012.
- [94] 焦江华, 张旭博, 梁硕, 等. 引入水稻“移栽时间效应”和光敏感性算

法改进 ORYZA 模型并验证[J]. 植物营养与肥料学报, 2020, 26(7): 1251-1261.

[95] Luo Y, Schuur E A G. Model parameterization to represent processes at unresolved scales and changing properties of evolving systems[J]. *Global Change Biology*, 2020, 26(3): 1109-1117.

[96] Wang E, He D, Wang J, et al. How reliable are current crop models for simulating growth and seed yield of canola across global sites and under future climate change?[J]. *Climatic Change*, 2022, 172(1-2): 20.

[97] Kasampalis D, Alexandridis T, Deva C, et al. Contribution of Remote Sensing on Crop Models: A Review[J]. *Journal of Imaging*, 2018, 4(4): 52.

[98] Li L, Wang B, Feng P, et al. The optimization of model ensemble composition and size can enhance the robustness of crop yield projections[J]. *Communications Earth & Environment*, 2023, 4(1): 362.

[99] Joshi A, Pradhan B, Gite S, et al. Remote-Sensing Data and Deep-Learning Techniques in Crop Mapping and Yield Prediction: A Systematic Review[J]. *Remote Sensing*, 2023, 15(8): 2014.

[100] Ismael S F, Kayabol K, Aptoula E. Unsupervised Domain Adaptation for Semantic Segmentation using One-shot Image-to-Image Translation via Latent Representation Mixing[J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20: 1-5.

[101] Calvo Buendía E, Hans-Otto P, Skea J, et al. Climate change and land: an IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems[M]. Geneva: Intergovernmental Panel on Climate Change, 2020.

[102] Wood S A, Jina A S, Jain M, et al. Smallholder farmer cropping decisions related to climate variability across multiple regions[J]. *Global Environmental Change*, 2014, 25: 163-172.

[103] Xiao L, Wang G, Wang E, et al. Spatiotemporal co-optimization of agricultural management practices towards climate-smart crop production[J]. *Nature Food*, 2024, 5(1): 59-71.

[104] Brun F. Working with Dynamic Crop Models: Evaluation, Analysis, Parameterization, and Applications[M]. Amsterdam: Elsevier Science & Technology, 2006.

[105] C. Rosenzweig. Assessing agricultural risks of climate change in the 21st century in a global gridded crop model intercomparison. *Proceedings of the national academy of sciences of the United States of America*, 111(9): 3268-3273.[J].

[106] Asseng, S., Ewert, F., osenzweig, C., 等. Uncertainty in simulating wheat yields under climate change[J]. *Nature Climate Change*, 2013, 3: 827-832.

[107] 程式华. 中国水稻育种百年发展与展望[J]. *中国稻米*, 2021, 27(4): 1-6.

[108] 曾波. 近 30 年来我国水稻主要品种更新换代历程浅析[J]. *作物杂志*,

2018(3): 1-7.

[109] Rosenzweig C, Jones J W, Hatfield J L, et al. The Agricultural Model Intercomparison and Improvement Project (AgMIP): Protocols and pilot studies[J]. *Agricultural and Forest Meteorology*, 2013, 170: 166-182.

[110] Eitzinger J, Thaler S, Schmid E, et al. Sensitivities of crop models to extreme weather conditions during flowering period demonstrated for maize and winter wheat in Austria[J]. *The Journal of Agricultural Science*, 2013, 151(6): 813-835.

[111] Barlow K M, Christy B P, O'Leary G J, et al. Simulating the impact of extreme heat and frost events on wheat crop production: A review[J]. *Field Crops Research*, 2015, 171: 109-119.

[112] Feng P, Wang B, Liu D L, et al. Incorporating machine learning with biophysical model can improve the evaluation of climate extremes impacts on wheat yield in south-eastern Australia[J]. *Agricultural and Forest Meteorology*, 2019, 275: 100-113.

[113] 徐新刚, 吴炳方, 蒙继华, 等. 农作物单产遥感估算模型研究进展[J]. *农业工程学报*, 2008, 24(2): 290-298.

[114] Wu B, Zhang M, Zeng H, et al. Challenges and opportunities in remote sensing-based crop monitoring: a review[J]. *National Science Review*, 2023, 10(4): nwac290.

[115] Steven W. Running, Peter E. Thornton, Ramakrishna Nemani, 等. Global terrestrial gross and net primary productivity from the earth observing system[M]//Methods in ecosystem science. New York: NY: Springer New York, 2000: 44-57.

[116] Doraiswamy P C, Moulin S, Cook P W, et al. Crop Yield Assessment from Remote Sensing[J]. *Photogrammetric Engineering & Remote Sensing*, 2003, 69(6): 665-674.

[117] Wu B, Meng J, Li Q, et al. Remote sensing-based global crop monitoring: experiences with China's CropWatch system[J]. *International Journal of Digital Earth*, 2014, 7(2): 113-137.

[118] Filippi P. An approach to forecast grain crop yield using multi-layered, multi-farm data sets and machine learning[J]. *Precision Agriculture*, 2019.

[119] Shari A. Yield prediction with machine learning algorithms and satellite images[J]. *Journal of Agriculture and Food Research*, 2020, 101(3): 891-896.

[120] 杨晓华, 黄敬峰, 王秀珍, 等. 基于支持向量机的水稻叶面积指数高光谱估算模型研究[J]. *光谱学与光谱分析*, 2008(8): 1837-1841.

[121] Khanal S, Fulton J, Klopfenstein A, et al. Integration of high resolution remotely sensed data and machine learning techniques for spatial prediction of soil properties and corn yield[J]. *Computers and Electronics in Agriculture*, 2018, 153: 213-225.

[122] Jeong J H, Resop J P, Mueller N D, et al. Random Forests for Global and

Regional Crop Yield Predictions[J]. PLOS One, 2016, 11(6): 1-15.

[123] Everingham Y, Sexton J, Skocaj D, et al. Accurate prediction of sugarcane yield using a random forest algorithm[J]. Agronomy for Sustainable Development, 2016, 36(2): 27.

[124] Leng G, Hall J W. Predicting spatial and temporal variability in crop yields: an inter-comparison of machine learning, regression and process-based models[J]. Environmental Research Letters, 2020, 15(4): 044027.

[125] 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.

[126] Khanal S, Fulton J, Klopfenstein A, et al. Integration of high resolution remotely sensed data and machine learning techniques for spatial prediction of soil properties and corn yield[J]. Computers and Electronics in Agriculture, 2018, 153: 213-225.

[127] Khaki S, Wang L. Crop Yield Prediction Using Deep Neural Networks[J]. Frontiers in Plant Science, 2019, 10: 621.

[128] Soliman D M, Newlands N K, Lyubchich D V, et al. Multivariate Copula Modeling for Improving Agricultural Risk Assessment under Climate Variability[J].

[129] Lundberg S M, Lee S I. A Unified Approach to Interpreting Model Predictions[J].

[130] L Hoffman A, R Kemanian A, E Forest C. The response of maize, sorghum, and soybean yield to growing-phase climate revealed with machine learning[J]. Environmental Research Letters, 2020, 15(9): 094013.

[131] 李银胜, 柴洪峰. 基于知识图谱的农作物灾害损失及产量预测系统及方法: CN 115115126 A[P]. 2022-09-27.

[132] Zhao G, Siebert S, Enders A, et al. Demand for multi-scale weather data for regional crop modeling[J]. Agricultural and Forest Meteorology, 2015, 200: 156-171.

[133] Sun J, Di L, Sun Z, et al. County-Level Soybean Yield Prediction Using Deep CNN-LSTM Model[J]. Sensors, 2019, 19(20): 4363.

[134] Li X, Geng H, Zhang L, et al. Improving maize yield prediction at the county level from 2002 to 2015 in China using a novel deep learning approach[J]. Computers and Electronics in Agriculture, 2022, 202: 107356.

[135] Li X, Lyu Y, Zhu B, et al. Maize yield estimation in Northeast China's black soil region using a deep learning model with attention mechanism and remote sensing[J]. Scientific Reports, 2025, 15(1): 12927.

[136] Khaki S, Wang L, Archontoulis S V. A CNN-RNN Framework for Crop Yield Prediction[J]. Frontiers in Plant Science, 2020, 10: 1750.

[137] Shahhosseini M, Hu G, Huber I, et al. Coupling machine learning and crop modeling improves crop yield prediction in the US Corn Belt[J]. Scientific Reports,

2021, 11(1): 1606.

[138] Wang S, Guan K, Zhang C, et al. Airborne hyperspectral imaging of cover crops through radiative transfer process-guided machine learning[J]. Remote Sensing of Environment, 2023, 285: 113386.

[139] 刘峻明, 和晓彤, 王鹏新, 等. 长时间序列气象数据结合随机森林法早期预测冬小麦产量[J]. 农业工程学报, 2019, 35(6): 158-166.

[140] 李瑞杰, 王爱冬, 吴华星, 等. 水稻生育期遥感监测的研究进展、瓶颈问题与技术优化路径[J]. 智慧农业, 2025: 1-19.

[141] 陈晓玲, 张聪, 黄晓宇. 基于 Bayesian-LightGBM 模型的粮食产量预测研究[J]. 中国农机化学报, 2024, 45(6): 163-169.

[142] IPCC. AR6 Synthesis Report: Climate Change 2023[R]. Geneva, Switzerland: Intergovernmental Panel on Climate Change, 2023: 184.

[143] Ross S M, Tyree M T. Mason and Maskell's Diffusion Analogue Reconciled with a Translocation Theory[J]. Annals of Botany, 1979, 44(5): 637-640.

[144] 刘敬良, 杨润卓. 水稻高产品种株型设想与直化育种研究[J]. 广东农业科学, 1980(5): 14-16.

[145] 王复标, 杨小龙, 康华靖, 等. 不同环境条件下光合作用对光响应模型的研究进展[J]. 应用生态学报, 2023, 34(7): 1995-2005.

[146] 周竹青, 周广生. 作物库、源、流生理机理研究进展[J]. 中国农学通报, 2001(6): 45-48.

[147] 刘晓龙, 季平, 杨洪涛, 等. 高温胁迫对水稻内源脱落酸含量及其合成和分解基因表达的影响[J]. 分子植物育种, 2025, 23(14): 4583-4591.

[148] 杜思琪, 温育纶, 宁力兴, 等. 开花期高温对不同基因型籼稻开花授粉的影响[J]. 中国农业科学, 2025, 58(10): 1867-1877.

[149] 李霞, 严建民, 季本华, 等. 光氧化和遮荫条件下水稻的光合生理特性的品种差异[J]. 作物学报, 1999(3): 301-308.

[150] 徐强, 马晓鹏, 吕廷波, 等. 分蘖期干旱胁迫对水稻光合特性及产量的影响[J]. 干旱地区农业研究, 2020, 38(1): 133-139.

[151] 吴龙龙, 田仓, 张露, 等. 稻田水氮氧环境因子对水稻生长发育、光合作用和氮利用的调控研究进展[J]. 应用生态学报, 2021, 32(4): 1498-1508.

[152] Lawas L M F, Shi W, Yoshimoto M, 等. Combined drought and heat stress impact during flowering and grain filling in contrasting rice cultivars grown under field conditions[J]. Field Crops Research, 2018, 229: 66-77.

[153] 吴比, 胡伟, 邢永忠. 中国水稻遗传育种历程与展望[J]. 遗传, 2018, 40(10): 841-857.

[154] 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2007 年南方稻区国家水稻品种区试汇总报告[M]. 1 版. 北京: 中国农业科学

技术出版社, 2008.

[155] 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2008 年南方稻区国家水稻品种区试汇总报告[M]. 1 版. 北京: 中国农业科学技术出版社, 2009.

[156] 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2009 年南方稻区国家水稻品种区试汇总报告[M]. 1 版. 北京: 中国农业科学技术出版社, 2010.

[157] 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2010 年南方稻区国家水稻品种区试汇总报告[M]. 1 版. 北京: 中国农业科学技术出版社, 2011.

[158] 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2011 年南方稻区国家水稻品种区试汇总报告[M]. 1 版. 北京: 中国水稻新品种试验, 2012.

[159] 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2012 年南方稻区国家水稻品种区试汇总报告[M]. 1 版. 北京: 中国农业科学技术出版社, 2013.

[160] 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2013 年南方稻区国家水稻品种区试汇总报告[M]. 1 版. 北京: 中国农业科学技术出版社, 2014.

[161] 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2014 年南方稻区国家水稻品种区试汇总报告[M]. 1 版. 北京: 中国农业科学技术出版社, 2015.

[162] 农业部种子管理局, 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2015 年度南方稻区国家水稻区试品种报告[M]. 1 版. 北京: 中国农业科学技术出版社, 2016.

[163] 农业部种子管理局, 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2016 年度南方稻区国家水稻区试品种报告[M]. 1 版. 北京: 中国农业科学技术出版社, 2017.

[164] 农业部种子管理局, 全国农业技术推广服务中心, 中国水稻研究所. 中国水稻新品种试验: 2017 年度南方稻区国家水稻区试品种报告[M]. 1 版. 北京: 中国农业科学技术出版社, 2018.

[165] 农业农村部种业管理司, 全国农业技术推广服务中心, 中国水稻研究所, 等. 中国水稻新品种试验: 2018 年度国家水稻区试品种报告[M]. 1 版. 北京: 中国农业科学技术出版社, 2019.

[166] Keisling T C. Calculation of the Length of Day[J]. Agronomy Journal, 1982, 74(4): 758-759.

- [167] Lieth H. Phenology and seasonality modeling: 卷 8[M]. Springer Science & Business Media, 1974.
- [168] Wakatsuki H, Ju H, Nelson G C, et al. Research trends and gaps in climate change impacts and adaptation potentials in major crops[J]. Current Opinion in Environmental Sustainability, 2023, 60: 101249.
- [169] McMaster G. Growing degree-days: one equation, two interpretations[J]. Agricultural and Forest Meteorology, 1997, 87(4): 291-300.
- [170] Pan Y, Su Z. A review on the growth simulation of rice during its growth period[J]. Journal of Zhejiang Agricultural Sciences, 2011(2): 434-438.
- [171] van Oort P A J, Zhang T, de Vries M E, et al. Correlation between temperature and phenology prediction error in rice (*Oryza sativa* L.)[J]. Agricultural and Forest Meteorology, 2011, 151(12): 1545-1555.
- [172] Kang X, Wu D, Tan J, et al. Performance of nine maize phenology models in China under historical climate change conditions[J]. Agricultural and Forest Meteorology, 2024, 358: 110234.
- [173] Gannouni T A, Campoy J A, Quero-García J, et al. Dormancy related traits and adaptation of sweet cherry in Northern Africa: A case of study in two Tunisian areas[J]. Scientia Horticulturae, 2017, 219: 272-279.
- [174] Wu D, Wang P, Jiang C, et al. Measured Phenology Response of Unchanged Crop Varieties to Long-Term Historical Climate Change[J]. International Journal of Plant Production, 2019, 13(1): 47-58.
- [175] Zhang T, Zhu J, Yang X. Non-stationary thermal time accumulation reduces the predictability of climate change effects on agriculture[J]. Agricultural and Forest Meteorology, 2008, 148(10): 1412-1418.
- [176] 姚凤梅, 张佳华, 孙白妮, 等. 气候变化对中国南方稻区水稻产量影响的模拟和分析[J]. 气候与环境研究, 2007(5): 659-666.
- [177] Wang E, Engel T. Simulation of phenological development of wheat crops[J]. Agricultural Systems, 1998, 58(1): 1-24.
- [178] Gao L, Jin Z, Huang Y, et al. Rice clock model—a computer model to simulate rice development[J]. Agricultural and Forest Meteorology, 1992, 60(1-2): 1-16.
- [179] Meng Y, Cao W, Zhou Z, 等. A Process based Model for Simulating Phasic Development and Phenology in Rice[J]. Scientia Agricultura Sinica, 2003(11): 1362-1367.
- [180] Sultānī A, Sinclair T R. Modeling physiology of crop development, growth and yield[M]. Wallingford: CABI, 2012.
- [181] van Oort P A J, Zhang T, de Vries M E, et al. Correlation between temperature and phenology prediction error in rice (*Oryza sativa* L.)[J]. Agricultural and Forest Meteorology, 2011, 151(12): 1545-1555.
- [182] Wang L, Ning Z, Wang H, et al. Impact of Climate Variability on

Flowering Phenology and Its Implications for the Schedule of Blossom Festivals[J]. Sustainability, 2017, 9(7): 1127.

[183] Jia Z. Study on photothermal reaction characteristics of Shanyou63[J]. Tillage and cultivation, 1989, 16(01): 49-53.

[184] Yin X. Quantifying the effects of temperature and photoperiod on phenological development to flowering in rice.[M]. Wageningen: publisher not identified, 1996.

[185] Liang G, Cai S. Study on the critical day length of panicle emergence in rice varieties[J]. Journal of South China Agricultural College, 1980, 1(3): 54-66.

[186] Afrin S, Khan A T, Mahia M, et al. Analysis of Soil Properties and Climatic Data to Predict Crop Yields and Cluster Different Agricultural Regions of Bangladesh[C]//2018 IEEE/ACIS 17th International Conference on Computer and Information Science (ICIS). Singapore: IEEE, 2018: 80-85.

[187] Wallach D, Palosuo T, Thorburn P, et al. Multi-model evaluation of phenology prediction for wheat in Australia[J]. Agricultural and Forest Meteorology, 2021, 298-299: 108289.

[188] Jia Z. Study on photothermal reaction characteristics of Shanyou63[J]. Tillage and cultivation, 1989, 16(01): 49-53.

[189] Tao F, Zhang S, Zhang Z. Spatiotemporal changes of wheat phenology in China under the effects of temperature, day length and cultivar thermal characteristics[J]. European Journal of Agronomy, 2012, 43: 201-212.

[190] Cleland E, Chuine I, Menzel A, et al. Shifting plant phenology in response to global change[J]. Trends in Ecology & Evolution, 2007, 22(7): 357-365.

[191] Siebert S, Ewert F. Spatio-temporal patterns of phenological development in Germany in relation to temperature and day length[J]. Agricultural and Forest Meteorology, 2012, 152: 44-57.

[192] Liu Y, Xie R, Hou P, et al. Phenological responses of maize to changes in environment when grown at different latitudes in China[J]. Field Crops Research, 2013, 144: 192-199.

[193] Hill C B, Li C. Genetic Improvement of Heat Stress Tolerance in Cereal Crops[J]. Agronomy, 2022, 12(5): 1205.

[194] Dingkuhn M, Luquet D, Quilot B, et al. Environmental and genetic control of morphogenesis in crops: towards models simulating phenotypic plasticity[J]. Australian Journal of Agricultural Research, 2005, 56(11): 1289.

[195] Pigliucci M. Evolution of phenotypic plasticity: where are we going now?[J]. Trends in Ecology & Evolution, 2005, 20(9): 481-486.

[196] Hinsinger P, Bengough A G, Vetterlein D, et al. Rhizosphere: biophysics, biogeochemistry and ecological relevance[J]. Plant and Soil, 2009, 321(1-2): 117-152.

[197] Kumarathunge D P, Medlyn B E, Drake J E, et al. Acclimation and adaptation components of the temperature dependence of plant photosynthesis at the

global scale[J]. *New Phytologist*, 2019, 222(2): 768-784.

[198] Campoy J A, Ruiz D, Allderman L, et al. The fulfilment of chilling requirements and the adaptation of apricot (*Prunus armeniaca* L.) in warm winter climates: An approach in Murcia (Spain) and the Western Cape (South Africa)[J]. *European Journal of Agronomy*, 2012, 37(1): 43-55.

[199] Viti R, Andreini L, Ruiz D, et al. Effect of climatic conditions on the overcoming of dormancy in apricot flower buds in two Mediterranean areas: Murcia (Spain) and Tuscany (Italy)[J]. *Scientia Horticulturae*, 2010, 124(2): 217-224.

[200] Iizumi T, Yokozawa M, Nishimori M. Parameter estimation and uncertainty analysis of a large-scale crop model for paddy rice: Application of a Bayesian approach[J]. *Agricultural and Forest Meteorology*, 2009, 149(2): 333-348.

[201] Manivasagam V S, Rozenstein O. Practices for upscaling crop simulation models from field scale to large regions[J]. *Computers and Electronics in Agriculture*, 2020, 175: 105554.

[202] Pasquel D, Roux S, Richetti J, et al. A review of methods to evaluate crop model performance at multiple and changing spatial scales[J]. *Precision Agriculture*, 2022, 23(4): 1489-1513.

[203] Roberts E H, Summerfield R J. Chapter 2-Measurement and prediction of flowering in annual crop[M]//*Manipulation of Flowering*. UK: Elsevier, 1987: 17-50.

[204] Wong M T F, Nortcliff S. Seasonal fluctuations of native available N and soil management implications[J]. *Fertilizer Research*, 1995, 42(1-3): 13-26.

[205] Shu Z, Li W, Zhang J, 等. Historical Changes and Future Trends of Extreme Precipitation and High Temperature in China[J]. *Chinese Journal of Engineering Science*, 2022, 24(5): 116.

[206] Smith W N, Grant B B, Desjardins R L, et al. Assessing the effects of climate change on crop production and GHG emissions in Canada[J]. *Agriculture, Ecosystems & Environment*, 2013, 179: 139-150.

[207] Hansen J, Sato M, Ruedy R, et al. Global Temperature Change[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2006, 103(39): 14288-14293.

[208] Tao F, Hayashi Y, Zhang Z, et al. Global warming, rice production, and water use in China: Developing a probabilistic assessment[J]. *Agricultural and Forest Meteorology*, 2008, 148(1): 94-110.

[209] Zhao J, Liu Z, Lv S, et al. Changing maize hybrids helps adapt to climate change in Northeast China: revealed by field experiment and crop modelling[J]. *Agricultural and Forest Meteorology*, 2023, 342: 109693.

[210] Zhao Y, Xiao D, Bai H, et al. The Prediction of Wheat Yield in the North China Plain by Coupling Crop Model with Machine Learning Algorithms[J]. *Agriculture*, 2022, 13(1): 99.

[211] Wu D, Wang P, Jiang C, et al. Use of a plastic temperature response

function reduces simulation error of crop maturity date by half[J]. *Agricultural and Forest Meteorology*, 2019, 280: 107770.

[212] Fu J, Jian Y, Wang X, et al. Extreme rainfall reduces one-twelfth of China's rice yield over the last two decades[J]. *Nature Food*, 2023, 4(5): 416-426.

[213] Hossain A, Teixeira Da Silva J A. Phenology, Growth and Yield of Three Wheat (*Triticum aestivum* L.) Varieties as Affected by High Temperature Stress[J]. *Notulae Scientia Biologicae*, 2012, 4(3): 97-109.

[214] Ihsan M Z, El-Nakhlawy F S, Ismail S M, et al. Wheat Phenological Development and Growth Studies As Affected by Drought and Late Season High Temperature Stress under Arid Environment[J]. *Frontiers in Plant Science*, 2016, 7.

[215] Sharma L, Priya M, Bindumadhava H, et al. Influence of high temperature stress on growth, phenology and yield performance of mungbean [*Vigna radiata* (L.) Wilczek] under managed growth conditions[J]. *Scientia Horticulturae*, 2016, 213: 379-391.

[216] Zhao G, Bryan B A, King D, et al. Large-scale, high-resolution agricultural systems modeling using a hybrid approach combining grid computing and parallel processing[J]. *Environmental Modelling & Software*, 2013, 41: 231-238.

[217] Wang C, Zhang Z, Zhang J, et al. The effect of terrain factors on rice production: A case study in Hunan Province[J]. *Journal of Geographical Sciences*, 2019, 29(2): 287-305.

[218] Wang D ying, Li X yi, Ye C, et al. Geographic variation in the yield formation of single-season high-yielding hybrid rice in southern China[J]. *Journal of Integrative Agriculture*, 2021, 20(2): 438-449.

[219] Li T, Hasegawa T, Yin X, et al. Uncertainties in predicting rice yield by current crop models under a wide range of climatic conditions[J]. *Global Change Biology*, 2015, 21(3): 1328-1341.

[220] Zhang S, Tao F, Zhang Z. Changes in extreme temperatures and their impacts on rice yields in southern China from 1981 to 2009[J]. *Field Crops Research*, 2016, 189: 43-50.

[221] Fukushima A, Shiratsuchi H, Yamaguchi H, et al. Varietal Differences in Morphological Traits, Dry Matter Production and Yield of High-Yielding Rice in the Tohoku Region of Japan[J]. *Plant Production Science*, 2011, 14(1): 47-55.

[222] Kumar N, Mathpal B, Sharma A, et al. Physiological evaluation of nitrogen use efficiency and yield attributes in rice (*Oryza sativa* L.) genotypes under different nitrogen levels[J]. *Cereal Research Communications*, 2015, 43(1): 166-177.

[223] Wang Y, Li S, Zhao J, et al. Planting date adjustment and varietal replacement can effectively adapt to climate warming in China southern rice area[J]. *Agricultural Systems*, 2025, 226: 104330.

[224] Miller B C, Hill J E, Roberts S R. Plant Population Effects on Growth and Yield in Water-Seeded Rice[J]. *Agronomy Journal*, 1991, 83(2): 291-297.

- [225] Gravois K A, Helms R S. Path Analysis of Rice Yield and Yield Components as Affected by Seeding Rate[J]. *Agronomy Journal*, 1992, 84(1): 1-4.
- [226] Ottis B V, Talbert R E. Rice Yield Components as Affected by Cultivar and Seeding Rate[J]. *Agronomy Journal*, 2005, 97(6): 1622-1625.
- [227] Li G, Xue L, Gu W, et al. Comparison of yield components and plant type characteristics of high-yield rice between Taoyuan, a ‘special eco-site’ and Nanjing, China[J]. *Field Crops Research*, 2009, 112(2-3): 214-221.
- [228] Fagade S O, De Datta S K. Leaf Area Index, Tillering Capacity, and Grain Yield of Tropical Rice as Affected by Plant Density and Nitrogen Level¹[J]. *Agronomy Journal*, 1971, 63(3): 503-506.
- [229] Wu G, Wilson L T, McClung A M. Contribution of Rice Tillers to Dry Matter Accumulation and Yield[J]. *Agronomy Journal*, 1998, 90(3): 317-323.
- [230] Qian Q, Guo L, Smith S M, et al. Breeding high-yield superior quality hybrid super rice by rational design[J]. *National Science Review*, 2016, 3(3): 283-294.
- [231] Shi Z, Li D, Jing Q, et al. Effects of nitrogen applications on soil nitrogen balance and nitrogen utilization of winter wheat in a rice–wheat rotation[J]. *Field Crops Research*, 2012, 127: 241-247.
- [232] Liang J, Zhang J, Cao X. Grain sink strength may be related to the poor grain filling of *indica-japonica* rice (*Oryza sativa*) hybrids[J]. *Physiologia Plantarum*, 2001, 112(4): 470-477.
- [233] Huang M, Zou Y bin, Jiang P, et al. Relationship Between Grain Yield and Yield Components in Super Hybrid Rice[J]. *Agricultural Sciences in China*, 2011, 10(10): 1537-1544.
- [234] Wang Q, Sun L, Yang X. Identifying Spatial Determinants of Rice Yields in Main Producing Areas of China Using Geospatial Machine Learning[J]. *ISPRS International Journal of Geo-Information*, 2024, 13(3): 76.
- [235] Guo Y, Fu Y, Hao F, et al. Integrated phenology and climate in rice yields prediction using machine learning methods[J]. *Ecological Indicators*, 2021, 120: 106935.
- [236] Zhao C, Liu B, Piao S, et al. Temperature increase reduces global yields of major crops in four independent estimates[J]. *Proceedings of the National Academy of Sciences*, 2017, 114(35): 9326-9331.
- [237] Li Y, Tao F. Rice yield response to climate variability diverges strongly among climate zones across China and is sensitive to trait variation[J]. *Field Crops Research*, 2023, 301: 109034.
- [238] Via S, Lande R. GENOTYPE-ENVIRONMENT INTERACTION AND THE EVOLUTION OF PHENOTYPIC PLASTICITY[J]. *Evolution*, 1985, 39(3): 505-522.
- [239] Romero Navarro J A, Willcox M, Burgueño J, et al. A study of allelic diversity underlying flowering-time adaptation in maize landraces[J]. *Nature Genetics*,

2017, 49(3): 476-480.

[240] Zhang S, Hu J, Yang C, et al. Genotype by environment interactions for grain yield of perennial rice derivatives (*Oryza sativa* L./ *Oryza longistaminata*) in southern China and Laos[J]. Field Crops Research, 2017, 207: 62-70.

[241] Zhang L, Zhang Z, Luo Y, et al. Optimizing genotype-environment-management interactions for maize farmers to adapt to climate change in different agro-ecological zones across China[J]. Science of The Total Environment, 2020, 728: 138614.

[242] 温振民, 张永科. 用高稳系数法估算玉米杂交种高产稳产性的探讨[J]. 作物学报, 1994(4): 508-512.

[243] Hu X, Huang Y, Sun W, et al. Shifts in cultivar and planting date have regulated rice growth duration under climate warming in China since the early 1980s[J]. Agricultural and Forest Meteorology, 2017, 247: 34-41.

[244] Zhao H, Fu Y H, Wang X, et al. Timing of rice maturity in China is affected more by transplanting date than by climate change[J]. Agricultural and Forest Meteorology, 2016, 216: 215-220.

[245] Zhang Q, Zhang G, Zhu D, 等. Spatiotemporal patterns of paddy rice production change in China during 1980-2018[J]. 资源科学, 2022, 44(4): 687-700.

[246] Zhang Z, Li Y, Chen X, et al. Impact of climate change and planting date shifts on growth and yields of double cropping rice in southeastern China in future[J]. Agricultural Systems, 2023, 205: 103581.

[247] Chen J, Liu Y, Zhou W, et al. Effects of climate change and crop management on changes in rice phenology in China from 1981 to 2010[J]. Journal of the Science of Food and Agriculture, 2021, 101(15): 6311-6319.

[248] Liu Y, Zhou W, Ge Q. Spatiotemporal changes of rice phenology in China under climate change from 1981 to 2010[J]. Climatic Change, 2019, 157(2): 261-277.

[249] Zhang J, Liu Y. Decoupling of impact factors reveals the response of cash crops phenology to climate change and adaptive management practice[J]. Agricultural and Forest Meteorology, 2022, 322: 109010.

[250] Challinor A J, Watson J, Lobell D B, et al. A meta-analysis of crop yield under climate change and adaptation[J]. NATURE CLIMATE CHANGE, 2014, 4(2153): 287-291.

[251] Zhang T, Zhu J, Wassmann R. Responses of rice yields to recent climate change in China: An empirical assessment based on long-term observations at different spatial scales (1981–2005)[J]. Agricultural and Forest Meteorology, 2010, 150(7-8): 1128-1137.

[252] Liu Y, Wang E, Yang X, et al. Contributions of climatic and crop varietal changes to crop production in the North China Plain, since 1980s[J]. Global Change Biology, 2010, 16(8): 2287-2299.

[253] Qiu J, Liu Z, Xie J, et al. Dual impact of ambient humidity on the virulence

of *Magnaporthe oryzae* and basal resistance in rice[J]. *Plant, Cell & Environment*, 2022, 45(12): 3399-3411.

[254] Peng S, Tang Q, Zou Y. Current Status and Challenges of Rice Production in China[J]. *Plant Production Science*, 2009, 12(1): 3-8.

[255] Song B, Sun L, Barrett S C H, et al. Global analysis of floral longevity reveals latitudinal gradients and biotic and abiotic correlates[J]. *New Phytologist*, 2022, 235(5): 2054-2065.

[256] Vogel E, Donat M G, Alexander L V, 等. The effects of climate extremes on global agricultural yields[J]. *Environmental Research Letters*, 2019, 14(5): 054010.

[257] Ji Y, Xu Y, Sun X, et al. Optimization of sowing dates for enhanced rice yield: insights from field experiments in the middle and lower reaches of the Yangtze River, China[J]. *BMC Plant Biology*, 2024, 24(1): 1011.

致 谢

时光荏苒，岁月如梭。当笔尖在纸上落下最后一行字，我的博士研究生生涯也即将画上句号。回首往昔，这一路走来，满是恩师的悉心教导、同门的热心帮助、亲朋的默默支持，还有自己一路的坚持与成长。此刻，心中满是感激与不舍，千言万语，不知从何说起。

感恩我的导师于强教授，您是我学术道路上的引路人，更是我人生路上的明灯。感谢您给予我直接攻读博士的宝贵机会，让我有幸加入生态模拟团队。在求学路上，您给予我的信任与包容，是我坚持完成学业的不竭动力。您为我们营造了宽松的学习环境，搭建了优越的科研平台，让我得以在团队中自由探索，向各位老师和同学请教学习。每当我遇到难题，向您咨询求助时，您总能及时且细致地为我答疑解惑。我曾在博士选题上摇摆不定，经历了多次失败尝试，是您因材施教，建议我从物候研究入手开展课题。在科研工作上，您总是鼓励我不要气馁，哪怕我只取得了一点小小的进步，您也给予我充分的肯定，让我重新树立信心。您治学严谨、严以律己、宽以待人、以身作则，您为人处事的方式深深感染着我，在潜移默化中塑造着我的品格。能成为您的学生，是我莫大的荣幸，未来我会以您为榜样，砥砺前行。

衷心感谢我的合作指导老师赵刚教授，赵老师，您不仅在学业上给予我诸多帮助，在生活中也对我关怀备至。是您的谆谆教导，让我看到毕业的曙光；是您对同学们的关怀，让师门关系融洽和谐；是您的奖惩措施，让我们组内纪律严明。您也是一位松弛有度的好老师，您教导我们在核心工作时间内高效专注，在业余时间充分放松身心。您总是能和学生打成一片，亦师亦友，您的教诲如春风化雨，对我们的影响潜移默化。您不仅仅是传道受业解惑，还有立德树人，您对我的影响将让我在成长的道路上始终怀着对知识的敬畏与对品德的追求。

感谢中国气象科学研究院的邬定荣研究员，您给予我细致地指导，让我受益匪浅；感谢国家气象中心的何亮老师，在日常学习中给予的帮助，为我答疑解惑；感谢西北农林科技大学的何建强教授和姚宁副教授，何建强教授会细致地纠正我们在论文写作过程中的问题，让我在学术写作中受益匪浅，姚宁副教授在日常学习和生活中的指导和帮助，让我感激不尽；感谢西北农林科技大学的胡振宏教授，很抱歉年少时的我曾辜负您的期许，但您的教诲我始终铭记于心。感谢韩锁昌书记对我生活学习上的帮助，当我陷入困境，满心沮丧，不知所措时，是您耐心地开导我，用坚定的话语驱散我心中的阴霾，让我在迷茫中找到方向。您的每一次鼓励和帮助，都给予我无尽的力量。感谢岳超老师和刘准桥老师，你们严以律己、宽以待人，勤奋且严谨的科研态度一直都是我学习的榜样。在我与你们相识的六

年里，你们几乎一直都是早上来得最早，晚上下班最晚的优秀科研者，越是优秀的人就越是拼了命的勤奋，在你们的影响下，我有了更多坚持和奋斗的意义。也非常感谢周高祥老师在毕业论文撰写时给与建议。在这些老师的身上我看到了师者风范，更是让我明白，一个人的优秀不仅在于才华，更在于品德与修养。你们所给予我的，不仅仅是知识的滋养，更是心智的塑造，这份影响将伴随我一生，成为我不断前行的力量源泉。

感恩我的舍友刘逸滨、邵晓亚和薛利，我们一起走过了六年时光，共同经历了无数艰难坎坷，也将携手奔向美好未来。你们成绩优异，品德优良，能与你们成为挚友，是我此生之幸。未来的路，也许我们会各自踏上不同的征程，但无论身在何方，心中那份对彼此的牵挂永远不会改变。感谢何沁锬师姐、毋冰艳师姐、贾倩兰师姐、李林超师兄、施宇师兄、赵杰师兄、梁楚涛师兄、戎亮秉师兄、闫雨杏师妹，你们是一群优秀且温暖的人，是你们的卓越激励着我，也是你们的帮助支持着我；感谢同门田琪、康晓凤、王雪彤、李鹏、魏英楠、陈彬和范馨逸，尤其是田琪同学，我们曾在学业上经历巨大的挫败，也是我们彼此扶持，走过了学业最艰难的一段时间，这份情谊我将永远铭记于心。

感谢我的妈妈，是您给予我力量 and 爱，让我坚持完成学业。曾经，我以为读书上学都是为了实现父母的期望，为了完成他们未曾实现的梦想。经历了这几年后我才明白，妈妈对我的爱，从未因我成绩的优劣而改变。即使我平凡普通，您也依然为我的快乐成长感到骄傲。您给予我初生，而后又不断赋予我新生的力量，让我在困境中重拾信心，继续前行。妈妈，以前的我虽然任性且幼稚，但我很爱你，以后的我会以更加美好的状态更爱你。

感谢我的男朋友王玉玺，你的出现为我的生活带来了无尽的温暖和力量。曾经，我无法理解，为何会有这样一个人，与我毫无血缘之亲，却能毫无保留地爱我、包容我。如今，我终于明白，你便是命运赠予我的最珍贵的礼物。你情绪稳定，技能出众，你会耐心地教我做科研，训练我的思维方式和行为习惯；也会包容我的小情绪，接纳我的不完美，让我感受到无条件的爱与支持。你既能在我最艰难时给予我雪中送炭般的帮助，又会在在我取得成绩时为我锦上添花，你是我最坚实的底气和最大的王牌。

感谢我的表姐卫晶晶，多年来我的状态时好时坏，是你一直不离不弃地陪伴着我。在我沮丧时开导我，在我难过时安慰我，在我情绪不稳定时包容我，给予我源源不断的关爱和竭尽全力的帮助。你曾说，家人的意义在于竭尽全力的托举，让我明白，我可以放下那些不必要的担忧与不安，勇敢地依靠你。感谢你的陪伴，感谢你一直以来的付出。我希望在之后漫长的岁月里，我能给予你更多的回馈，让你感受到我更多的爱与感恩。

最后，要感谢这个平凡却又不甘平庸的自己。这一路走来，有过迷茫，有过挫折，经历过黑暗，遭受过伤害，但从未放弃。愿过往所有的经历，都成为我奔

赴未来的动力，让我在未来的道路上，更加坚定地追逐梦想，书写属于自己的精彩篇章。

再次向所有帮助和包容过我的所有人，致以最诚挚的感谢！

谭姣姣

2025 年 7 月于杨凌

作者简历及攻读学位期间发表的学术论文与其他相关学术成果

作者简历:

2015 年 9 月——2019 年 6 月, 在山西农业大学 资源环境学院 获得学士学位。
2019 年 9 月——2025 年 9 月, 在中国科学院大学 水土保持研究所 攻读博士学位。

工作经历:

无。

已发表的学术论文:

1. **Tan, J.J.**, Zhao, G.*, Tian, Q., Zheng, L., Kang, X.F., He, Q.S., Shi, Y., Chen, B., Wu, D.R., Yao, N., He, L., Srivastava, A.K., Li, Y., He, J.Q., Feng, H., Yu. Q.*, 2024. Overcoming mechanistic limitations of process-based phenological models: a data clustering method for large-scale applications. *Agricultural and Forest Meteorology*, 356: 110167.

2. **Tan, J.J.**, Zhang, H.W., Yao, N., Yu, Q.*, 2025. One-shot adaptation for cross-domain semantic segmentation in remote sensing images. *Pattern Recognition*, 162: 111390.

3. Kang, X.F., Wu, D.R.*, **Tan, J.J.**, Wang, P.J., Ma, Y.P., Yang, J.Y., Wang, C.Y., Huo, Z.G., Tian, Q., Yu, Q.*, 2024. Performance of nine maize phenology models in China under historical climate change conditions. *Agricultural and Forest Meteorology*, 358: 110234.

4. 康晓凤, 邬定荣*, 田琪, **谭蛟蛟**, 马玉平, 于强*. 玉米发育模式在我国主要产区的适用性比较研究. *中国生态农业学报*, 2022, 30 (9): 1477-1489.

参加的研究项目及获奖情况:

1. 中国科学院大学三好学生, 2023 年
2. 生态学会生态科学作品竞赛全国三等奖, 2023 年
3. 2023-2024 学年西北农林科技大学“优秀志愿者”称号, 2024 年
4. 水土保持与生态环境研究中心第十一届研究生学术论坛三等奖, 2025 年