



西北农林科技大学

博士学位论文

极端天气事件对粮食生产的影响及其缓解途径
——不同经济发展水平国家的案例分析

学科专业 土地资源与空间信息技术

研究方向 气候变化与粮食安全

论文作者 施宇

指导教师 于强教授

合作指导教师 田汉勤教授

论文提交时间 2023年11月

Dissertation Submitted to Northwest A&F University
in Partial Fulfillment of the Requirements
for Degree of
Doctor of Philosophy

Impact of Extreme Weather Events on Food
Production and Their Mitigation Pathways: Case
Studies from Countries with Varied Economic
Development Levels

Major: Land Resources and Spatial Information Technology

Research Field: Climate Change and Food Security

Candidate: Yu Shi

Supervisor: Qiang Yu

Co- Supervisor: Hanqin Tian

Date of submission: 2023.11

College of Natural Resources and Environment

Northwest A&F University

分类号：S127

UDC：631

密级：公开

学校代码：10712

研究生学号：2020060325

西北农林科技大学博士学位论文

极端天气事件对粮食生产的影响及其缓解途径 ——不同经济发展水平国家的案例分析

论文作者：施宇

指导教师：于强

答辩委员会：

西北农林科技大学水利与建筑工程学院何建强教授（主席）

西北农林科技大学资源环境学院刘梦云教授（委员）

西北农林科技大学水土保持研究所吕肖良研究员（委员）

西北农林科技大学机械与电子工程学院张东彦教授（委员）

中国农业大学资源环境学院冯璞玉副教授（委员）


答辩日期：2023年11月25日

本研究得到国家自然科学基金（编号：41961124006）资助。

研究生学位论文的独创性声明

本人声明：所呈交的学位论文是我个人在导师指导下独立进行的研究工作及取得的研究结果；论文中的研究数据及结果的获得完全符合学校《关于规范西北农林科技大学研究生学术道德的暂行规定》，如果违反此规定，一切后果与法律责任均由本人承担。

尽我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究结果，也不包含其他人和自己本人已获得西北农林科技大学或其它教育机构的学位或证书而使用过的材料。与我一同工作的同事对本研究所做的任何贡献均已在论文的致谢中作了明确的说明并表示了谢意。

研究生签名：

时间：2023年11月25日

导师指导研究生学位论文的承诺

本人承诺：我的研究生施宇所呈交的学位论文是在我指导下独立开展研究工作及取得的研究结果，属于我现岗职务工作的结果，并严格按照学校《关于规范西北农林科技大学研究生学术道德的暂行规定》而获得的研究结果。如果违反学校《关于规范西北农林科技大学研究生学术道德的暂行规定》，我愿接受按学校有关规定的处罚处理并承担相应导师连带责任。

导师签名：

时间：2023年11月25日


关于研究生学位论文使用授权的说明

本学位论文的知识产权归属西北农林科技大学。本人同意西北农林科技大学保存或向国家有关部门或机构送交论文的纸质版和电子版，允许论文被查阅和借阅；同意西北农林科技大学将本学位论文的全部或部分授权汇编录入《中国博士/硕士学位论文全文数据库》和《中国学位论文全文数据库》进行出版，并享受相关权益。


本人保证，在毕业离开（或者工作调离）西北农林科技大学后，发表或者使用本学位论文及其相关的工作成果时，将以西北农林科技大学为第一署名单位，否则，愿意按《中华人民共和国著作权法》等有关规定接受处理并承担法律责任。

任何收存和保管本论文各种版本的其他单位和个人(包括研究生本人)未经本论文作者的导师同意，不得有对本论文进行复制、修改、发行、出租、改编等侵犯著作权的行为，否则，按违背《中华人民共和国著作权法》等有关规定处理并追究法律责任。

（保密的学位论文在保密期限内，不得以任何方式发表、借阅、复印、缩印或扫描复制手段保存、汇编论文）

研究生签名：

时间：2023年11月25日

导师签名：

时间：2023年11月25日

摘要

自工业革命以来，人为排放二氧化碳使全球地表温度持续增加并显著地改变了陆地降水格局。这种变暖效提高了极端天气事件发生的频率和强度，进而损害了作物生产力、增加了作物气候敏感性并降低了作物恢复能力，为粮食生产带来严峻挑战。以往研究重点关注了气候变暖与作物生产力之间的响应关系，但对于极端天气事件对作物生产力的影响（直接损害、敏感性变化）以及人为活动缓解气候变化负面效应的潜力刻画较为模糊。此外，不同发展水平地区的适应性行为也存在巨大差异，例如欠发达地区通常以自然资源的直接利用作为潜在的农业缓解措施、发展中地区更多倾向于社会经济对农业生产的补偿，而发达地区需要寻求更精细化的因环境制宜的人为管理活动并尽可能地减少农业生产的气候代价（即单位粮食生产导致的温室气体排放）。然而由于人为活动的高度可变性，量化不同社会经济差异下的缓解潜力仍存在研究空白。随着未来变暖加剧，亟待建立一个准确估算极端天气事件与作物产量损失和敏感性动态变化的综合框架，并探究不同社会经济差异下国家缓解气候变化负面影响的区别路径。

针对上述科学问题，本文以全球极端天气频发且涵盖不同经济发展水平的代表性区域为例（朝鲜及其周边地区、美国）采取了证实研究。整合可用的环境数据和多源模型探究极端天气事件对区域粮食生产的影响以及缓解方案的可行性与潜力。基于经验模型、半经验模型和机理模型结合多源环境数据，复现了站点尺度、生态系统尺度和区域尺度的作物生产力。在此基础上，探究了多尺度下作物生产力与环境因素的响应关系并归因其贡献。从作物生产力损失和敏感性动态变化的角度，揭示了极端天气事件对研究区内作物生产的长期影响，进一步量化了不同经济发展地区社会恢复力缓解极端天气事件导致粮食减产的潜在效应，并探讨了发达地区气候智慧型耕作实践缓解作物气候敏感性并减少气候代价（单位粮食生产所排放的温室气体）的潜力。本论文的主要结论如下：

（1）基于多源环境数据和模型模拟站点粮食生产力。本研究采用逐像元模拟法结合多种遥感指数以及物候信息，模拟了朝鲜及其周边地区水稻种植分布的历史动态演变。随机森林模型在水稻单产和总产年际变化的预测方面表现出色，其预测准确性超过 80%，显著优于其他经验模型。同时，证实了水稻产量提前一个物候期预测的可行性。此外，随机森林模型还能够实现对农田生态系统光能利用效率的精确模拟。最后，通过对生态系统模型（DLEM v4.0）进行参数调优并与实测数据对比，研究精确模拟了美国小麦区站点尺度的产量变化，同时还精确捕捉到了小麦生产过程中温室气体排放和土壤有机碳的变化，为气候代价评估和粮食安全监测提供了可靠的工具。

(2) 区域粮食生产力模拟及其与环境因子的响应关系。本研究提出一种基于气候相似性的可迁移框架，用于稀缺数据地区的水稻产量预测。与联合国粮农组织的统计数据相比，预测结果在全生育期和播种-抽穗期情景下分别解释了总产变异的 78.72%和 76.89%，以及单产变异的 69.42%和 71.15%。其中，日光诱导叶绿素荧光在水稻产量预测中扮演了主要角色，其解释超过 15%，其次是最高温度和蒸散发，共同解释了超过 20%的水稻产量变化。此外，本研究还通过改进的生态系统光能利用率模型对区域生物量进行了预测，发现高温热浪是影响朝鲜水稻生物量变化最关键的环境因子。基于过程模型和遥感衍生数据模拟了美国小麦区作物生产力和温室气体排放的历史变化，发现气候变化和氮肥施用和单位小麦产量和温室气体排放变化中起着主导作用，但土地利用、气候变化和氮肥施用则对总产量和总排放的变化产生了更大的影响。

(3) 典型区域粮食生产对极端天气事件的响应特征。研究发现极端高温和极端降水事件分别导致了 2000 年和 2007 年朝鲜水稻产量的剧烈波动。随着未来气候变暖，朝鲜将面临更高的极端热浪和降水风险，如果不采取相关适应策略，朝鲜水稻生物量到 2080s 在中、高二氧化碳排放情景下将分别减少 18.9%和 20.2%，届时水稻总产量将分别下降 13%和 14.4%。此外，美国小麦种植区在过去六十年经历了加剧的干热事件，尤其在小麦生长季期间，超过 75%的地区面临干旱风险，这导致了美国超过 70%的冬小麦种植区和 90%的春小麦种植区单位粮食生产所排放的温室气体增加，显著提高了小麦生产的气候代价。其中春小麦的温室气体排放强度敏感性增加了 2.2 倍，而冬小麦的敏感性则自 2008 年以来增加了 5.4 倍。在大多数小麦实验站中观测到了负面的干热气候冲击，显著增加了 29.9%的冬小麦站点和 27.5%的春小麦站点的产量敏感性。

(4) 极端气候下不同发展水平地区的优势性缓解措施。基于朝鲜及其周边地区不同经济发展水平的对比研究发现，现阶段社会恢复力对朝鲜水稻生产贡献较低，而对韩国和中国的水稻生产有显著解释能力，分别增加了超过 26%和 100%模型解释度。韩国地区的高温 and 热浪对水稻生产构成威胁，但区域氮肥投入、农村人口和 0-14 岁人口的增加逆转了气候冲击的影响，甚至促进了更高的水稻产量。同样，中国的资源利用缓解了降雨极端事件带来的负面影响。非线性模型同样证明在欠发达地区 (15.2%)，社会恢复力对粮食生产的贡献远远低于发达地区和发展中地区 (分别为 83.0%和 86.1%)。此历史动态模拟显示，传统耕作和免耕的交叉应用显著降低了美国中部地区冬小麦对高温的敏感性，特别是免耕在北部地区的冬小麦和春小麦种植区表现出更为显著的效果，减轻了极端干热事件对温室气体排放强度负面影响。实施气候智慧型耕作策略可以在全美 31%的小麦区内有效降低温室气体排放强度的干热气候敏感性，从而使全美小麦生产区的温室气体排放强度敏感性降低约 9%，有效降低了作物生产的气候代价。

该研究有助于加深极端天气事件与粮食生产关系的理解，同时为不同经济发展地区提供了可行的适应策略。未来研究需要建立更为准确的作物产量损失和敏感性动态

变化的综合框架，以应对气候变化带来的挑战。此外，还需要充分考虑不同社会经济差异下国家和地区缓解气候变化负面影响的^{区别}路径，更好地保障全球粮食安全，实现农业的可持续发展。

关键词：极端天气事件；生产力模拟；产量损失；气候敏感性；缓解途径

ABSTRACT

Since the advent of the Industrial Revolution, anthropogenic emissions of carbon dioxide have engendered a relentless elevation in global surface temperatures. This has led to a pronounced transformation in terrestrial precipitation patterns. The ramifications of this warming effect have been far-reaching, notably amplifying the frequency and intensity of extreme climatic events—ranging from droughts and heatwaves to intense rainfall. These phenomena have exerted a direct deleterious influence on crop productivity, exacerbating the crops' climate sensitivity, while concurrently diminishing their capacity for resilience. The collective outcome has placed formidable challenges on the realm of food production. While antecedent investigations have predominantly focused on the interplay between climate change and the corresponding responses in crop productivity, there remains an appreciable gap in understanding the intricate influence of extreme weather events on crop productivity, encompassing both the direct damages incurred and the associated shifts in sensitivity. Additionally, the potential role of anthropogenic interventions in ameliorating the adverse repercussions of climate change remains relatively nebulous. Furthermore, there exists a marked diversity in adaptive strategies across regions characterized by varying levels of economic development. Less developed regions are oftentimes reliant on direct harnessing of natural resources as a prospective avenue for mitigating the impact on agriculture. Conversely, regions that are in a state of developmental transition have exhibited a proclivity toward socioeconomic compensation as a mechanism to safeguard agricultural productivity. In contrast, regions that have achieved a high level of development necessitate a more nuanced approach in the form of environmentally tailored anthropogenic interventions, while simultaneously endeavoring to minimize the ecological costs incurred in the pursuit of agricultural production. Given the escalating trajectory of future warming, there is an exigent need to establish a comprehensive framework that can accurately estimate the dynamic alterations in the occurrence of extreme weather events, the concomitant losses in crop yields, and the underlying fluctuations in crop sensitivity. Concurrently, a concerted exploration is warranted to delineate distinct pathways that are commensurate with the socioeconomic disparities among nations, in a concerted effort to mitigate the adverse ramifications of climate change.

In addressing the aforementioned scientific inquiries, this study conducts a corroborative investigation within representative regions covering a spectrum of economic development levels, namely North Korea and its surrounding areas, as well as the United States, which are

prone to recurrent extreme weather events on a global scale. Leveraging available environmental data and multiple-source models, we examine the impact of extreme weather events on regional food production and the feasibility and potential of mitigation strategies. By integrating empirical models, semi-empirical models, and mechanistic models with a wealth of environmental data, we replicate crop productivity at the site-specific, ecosystem-wide, and regional scales. Building upon this foundation, we investigate the responsiveness of crop productivity to environmental factors across multiple scales, attributing their contributions. We unveil the enduring consequences of extreme weather events on crop production within the study regions, elucidating the long-term implications from the perspective of crop productivity losses and sensitivity dynamics. Furthermore, we quantify the potential effects of varying levels of economic development on societal resilience in mitigating food production reductions resulting from extreme weather events. Additionally, we explore the prospects for climate-smart agricultural practices in developed regions to alleviate crop climate sensitivity and curtail climate costs, as measured by greenhouse gas emissions per unit of food production. The main findings are as follows:

(1) Simulations of situ crop productivity based on multi-dimensional environmental data and model. The research employed a pixel-wise modeling approach and various remote sensing indices, as well as phenological information, accurately portraying the dynamic evolution of rice cultivation distribution in historical North Korea and its surrounding regions. The Random Forest model performed admirably in predicting rice yield and total production interannual variability, with a high prediction accuracy of $R^2 = 0.83-0.87$, significantly outperforming other empirical models. Furthermore, our study supported the feasibility of predicting rice yield one phenological stage in advance. The Random Forest model also successfully simulated ecosystem light use efficiency in croplands, exhibiting high accuracy. Finally, through parameter tuning of the Ecosystem Model (DLEM v4.0), we successfully captured changes in wheat yield, maintaining a high level of productivity simulation performance at the national scale. The DLEM model also reliably simulated greenhouse gas emissions and soil organic carbon, providing a dependable tool for climate cost assessment and national-scale food security monitoring.

(2) Regional crop productivity prediction and its relationship with environmental factors. This study proposed a climate-similarity-based transferable framework for rice yield prediction in data-scarce regions. Compared to statistics from the Food and Agriculture Organization of the United Nations, the predictive results explained 78.72% and 76.89% of total production variability and 69.42% and 71.15% of yield variability in the WGP and SHP

scenarios, respectively. In this process, we found that SIF played a primary role in rice yield prediction, contributing more than 15%, followed by maximum temperature and evapotranspiration, explaining over 20% of rice yield variation. Additionally, we predicted regional biomass using an improved ecosystem light use efficiency model, identifying high temperature and heatwaves as the most critical environmental factors influencing rice biomass variation in North Korea. Finally, based on process models and remote sensing data, we successfully simulated historical changes in wheat productivity and greenhouse gas emissions, and conducted an in-depth analysis of influencing factors. Climate change and nitrogen fertilizer application played dominant roles in greenhouse gas emissions and yield change per unit greenhouse gas emissions, while land use, climate, and nitrogen fertilizer application had a greater impact on total greenhouse gas emissions and total production.

(3) Characterizing the Response of Typical Regional Grain Production to Extreme Weather Events. Extreme heat events and extreme precipitation events in 2000 and 2007 respectively led to significant fluctuations in North Korean rice production. With future climate warming, North Korea faces a higher risk of extreme heat and rainfall events. Without adaptation strategies, rice biomass in North Korea is projected to decrease by 18.9% and 20.2% by the 2080s under SSP245 and SSP585 scenarios, respectively, and rice total production is expected to decline by 13% and 14.4%, respectively. This will further strain an already fragile food production system, exacerbating future food insecurity. Additionally, the U.S. wheat belt has experienced an intensification of hot and dry events over the past sixty years, particularly during the wheat growing season, with over 75% of the region at risk of drought. These hot and dry events have led to an increase in greenhouse gas emissions intensity in over 70% of winter wheat planting areas and 90% of spring wheat planting areas in the United States. The sensitivity of greenhouse gas emissions intensity for spring wheat has increased 2.2 times, while for winter wheat, it has increased 5.4 times since 2008. In most experimental sites, wheat yields have experienced negative impacts from hot and dry climatic shocks, increasing the sensitivity of 29.9% of winter wheat sites and 27.5% of spring wheat sites.

(4) Dominant Mitigation Measures for Different Development Levels in Regions Under Extreme Climate. Based on a comparative study of different economic development levels in North Korea and its surrounding areas, it was found that, at the present stage, social resilience contributes less to rice production in North Korea but significantly explains rice production in South Korea and China, increasing model explanatory power by over 26% and 100%, respectively. High temperatures and heatwaves pose a threat to rice production in South Korea, but resource utilization such as regional nitrogen input, rural population, and population aged

0-14 have reversed the impact of these climate shocks, even promoting higher rice yields. Similarly, resource utilization in China mitigates the adverse effects of extreme rainfall events. Non-linear models also demonstrate that in less developed regions (15.2%), social resilience contributes much less to grain production than in developed regions and developing regions (83.0% and 86.1%, respectively). Historical dynamic simulations show that conventional tillage (CT) and no-tillage (NT) significantly reduce the sensitivity of winter wheat to high temperatures in the U.S. Midwest. Particularly, CT has a more significant effect in northern regions' winter wheat and spring wheat planting areas, alleviating the negative impact of hot and dry climate events on production. Implementing climate-smart farming strategies can effectively reduce the sensitivity of GHGI to hot and dry climate in 31% of wheat areas in the United States, reducing the sensitivity of GHGI nationwide by approximately 9%.

This study contributes to a deeper understanding of the relationship between extreme weather events and crop production, offering viable adaptation strategies for diverse economic development regions. Future research endeavors should strive to establish a more precise comprehensive framework for crop yield losses and dynamic sensitivities to effectively address the challenges posed by climate change. Moreover, it is imperative to thoroughly consider distinct pathways for mitigating the adverse impacts of climate change, taking into full account the socio-economic variations among nations and regions. This holistic approach aims to better safeguard global food security and achieve sustainability in agriculture.

KEY WORDS: Extreme weather events; Productivity simulation; Yield losses; Climate sensitivity; Mitigation pathways

目 录

摘要.....	I
ABSTRACT.....	IV
第一章 绪论	1
1.1 研究背景、目的和意义.....	1
1.2 国内外研究进展.....	4
1.2.1 气候变化对区域粮食安全的影响概况.....	4
1.2.2 极端天气事件对粮食生产的影响机制.....	6
1.2.3 基于多源模型和数据模拟作物生产力.....	8
1.2.4 缓解气候变化对作物生产的负面影响.....	10
1.3 研究内容.....	11
1.4 技术路线.....	12
第二章 材料与方法	14
2.1 研究区域概况.....	14
2.2 数据来源及预处理.....	17
2.2.1 气象数据.....	17
2.2.2 观测数据.....	21
2.2.3 遥感数据及其分析.....	23
2.2.4 统计数据.....	28
2.2.5 其他数据.....	29
2.3 研究方法.....	31
2.3.1 多源模型模拟.....	31
2.3.2 归因分析.....	36
2.3.3 可迁移的产量预测框架.....	39
2.3.4 粮食生产的气候风险.....	39
2.3.5 作物生产对极端天气事件的响应及其敏感性变化.....	41
2.3.6 社会恢复力缓解气候变化.....	41
2.3.7 气候智慧型耕作方案缓解气候变化.....	45
2.4 精度评估.....	46
第三章 基于多源环境数据和模型模拟站点粮食生产力	48
3.1 引言.....	48
3.2 基于经验模型和统计数据模拟站点水稻生产力.....	49
3.2.1 识别水稻物候期并制图水稻空间分布.....	49
3.2.2 水稻生产力模拟与验证.....	52
3.3 基于半经验模型和通量观测数据模拟站点生物量.....	57
3.4 基于过程模型和田间试验模拟站点小麦生产力和温室气体排放.....	58
3.5 小结.....	60
第四章 区域粮食生产力预测及其与环境因子的响应关系	61
4.1 引言.....	61
4.2 基于经验模型和统计数据预测区域水稻产量.....	62

4.2.1 基于可迁移框架预报近五年朝鲜水稻生产力	62
4.2.2 多环境因子对水稻生产力预测的解释性	66
4.3 基于半经验模型和通量观测数据模拟区域作物生物量	67
4.3.1 区域水稻生物量模拟	67
4.3.2 水稻生物量与环境因子之间的响应关系	69
4.4 基于过程模型和空间遥感数据模拟小麦产量及温室气体排放	70
4.4.1 模拟区域小麦产量和温室气体排放的量级和趋势	70
4.4.2 1960 年至 2018 年美国小麦产量和温室气体排放变化的归因分析	72
4.5 讨论	74
4.5.1 迁移框架的可预测性	74
4.5.2 基于迁移框架预测水稻单产和总产	75
4.5.3 气候变化和施肥主导小麦产量和温室气体排放的变化	76
4.6 小结	77
第五章 典型区域粮食生产对极端天气事件的响应特征	78
5.1 引言	78
5.2 极端天气事件对水稻生产的历史影响以及未来的潜在损失风险	79
5.2.1 极端天气事件对朝鲜水稻生产的历史影响	79
5.2.2 朝鲜未来气候变化	81
5.2.3 未来气候变化下朝鲜的粮食损失风险	84
5.3 小麦生产对极端天气事件敏感性的响应及其动态变化	88
5.3.1 小麦生产对极端干热事件的响应	88
5.3.2 小麦生产对极端干热事件的敏感性长期动态变化	91
5.4 讨论	95
5.4.1 极端气候事件对朝鲜粮食生产的影响	95
5.4.2 干热事件造成产量损失和温室气体排放	95
5.4.3 小麦产量和温室气体排放的敏感性变化	96
5.5 小结	97
第六章 极端气候下不同发展水平地区的优势缓解措施	98
6.1 引言	98
6.2 欠发达地区粮食安全的缓解途径—以朝鲜社会恢复能力为例	100
6.2.1 社会恢复力的构成及其对气候变化的缓解作用	100
6.2.2 粮食生产对社会恢复力的动态响应	102
6.3 发达地区粮食安全的缓解途径—以美国气候智慧型耕作为例	103
6.3.1 基于特定气候背景下的最优耕作方案	103
6.3.2 最优耕作方案缓解小麦生产敏感的表现	106
6.4 讨论	109
6.4.1 社会恢复力对朝鲜粮食安全的影响	109
6.4.2 气候智慧型耕作对美国小麦产量和温室气体排放的影响	111
6.5 小结	111
第七章 结论与展望	113
7.1 主要结论	113
7.2 论文创新点	114
7.3 研究不足和展望	115

目 录

参考文献.....	117
附录.....	138
致谢.....	148
作者简介.....	149

第一章 绪论

1.1 研究背景、目的和意义

人类的持续活动改变了地表分布和大气组成，直接或间接地影响地球的能量平衡，从而导致全球气候系统的变暖。根据政府间气候变化专门委员会（IPCC）第六次评估报告，21 世纪的全球地表温度比工业革命前期上升了约 1°C （IPCC 2021），且陆地增幅（ 1.59°C ）高于海洋（ 0.88°C ）。全球气象记录显示，在过去几十年中，最热的 20 个年份均集中在这一时期。除增温效应变强以外，气候变化还改变了全球陆地的降水格局和频率。已经观察到极端天气事件的频率和强度增加（包括高温热浪、强降水、干旱和野火）对生态系统、人类社会以及基础设施产生了广泛而深刻的影响。根据 IPCC 第六次报告估计，在全球变暖 1.5°C 的情况下，非洲、亚洲、北美和欧洲大部分地区预计会出现更加强烈且更频繁的暴雨和洪涝。大多数地区的极端气候事件在频率和强度上都将变得更加频繁和严重，其中人为气候变化是变暖的主要驱动因素（姜彤等 2022）。此外人为活动不仅增加了单一极端天气的发生频率和强度，同时也增加了复合极端事件发生的概率。包括全球范围内同时发生的热浪和干旱，以及在全球特定地区同时出现的火灾天气和洪涝灾害。

气候变化和极端天气事件通常会直接损害作物生产力、增加作物气候敏感性和降低作物恢复能力进而影响最终的粮食产出（图 1-1）。对于气候变暖的直接损害，可以解释为作物生长期内由于变暖加剧导致的干热胁迫抑制了其光合能力、碳的分配与积累（Eyshi Rezaei et al. 2015），并促进蒸腾作用和呼吸速率，加速水分耗竭（Innes et al. 2015），从而限制产量形成（Chaves et al. 2002）。如果不考虑二氧化碳（ CO_2 ）的施肥作用和人为适应性措施，每升高 1°C 的气温将导致全球小麦产量平均减少约 5.7%（Liu et al. 2016）。此外，关键生育期内的其他极端天气事件也会直接抑制作物的生长发育。例如，小麦苗期的极端低温可能会导致幼苗发育迟缓甚至枯萎，而花期的霜冻事件也会造成花朵不育，加剧减产风险（Fuller et al. 2007; Barlow et al. 2015）。气候变化不仅会直接引发产量损失，还会通过改变作物的敏感性进一步加剧未来减产风险。作物产量对未来气候变化的敏感性因作物类型、灌溉条件以及其他生物物理和社会经济因素而异（Mondal et al. 2015），并且作物不同的生育期对气候变化的敏感性也存在巨大差异。Trnka et al. (2016) 的跨区域分析表明欧洲作物产量与气候的关系发生了显著变化，并且在某些地区气候环境因素在最几十年对产量的影响比过去更大。尽管随着作物品种改良和二氧化碳的施肥效应增强，在特定地区观察到了持续增加的作物产量，但是在变暖的气候影响下，农艺的改变往往会将作物耐旱性的提高转化为更高的平均产量，

不会降低田间作物的干旱敏感性 (Lobell et al. 2014)。因此, 在未来极端干热事件增多的背景下, 作物生产的敏感性以及敏感性的动态变化在很大程度上是未知的。

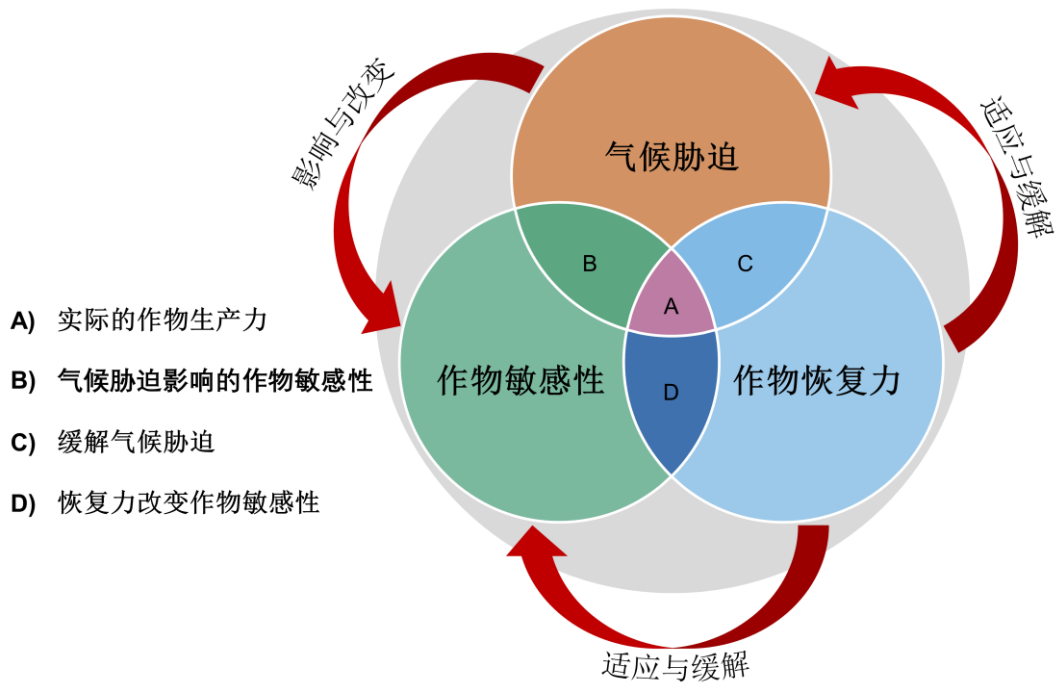


图 1-1 作物生产力脆弱性关系示意图

Fig. 1-1 Conceptual relationships of crop productivity vulnerability

当作物生长不可避免受到气候变化和极端天气的扰动时, 其生长发育从不良状态恢复到正常水平的能力也决定最终的产量形成, 这称之为作物的气候恢复力。恢复力的概念源于生态学, 描述了系统在外部扰动下仍能维持性状的能力 (Holling 1973)。虽然农业生态系统中不存在这种被广泛接受的恢复力的明确定义, 但衡量农业恢复力的目标是确定农业系统在受到扰动的情况下仍能蓬勃发展并确保其可持续性, 以及恢复力能在多大程度上支持粮食生产 (O'Connell et al. 2015)。农业生产系统的恢复力可以通过提高适应力和管理水平来增强, 即应对生长胁迫的农业实践, 如选择抗性作物品种、调整作物种植日期、对土壤、水、养分、病虫害进行适当调控 (Peltonen-Sainio et al. 2009; Olesen et al. 2011; Zhang et al. 2015b; Macholdt et al. 2019)。然而, 由于农业生态系统的复杂性, 且随着时间、空间和下垫面环境的变化而变化, 衡量其恢复力仍然具有挑战性 (Darnhofer et al. 2010)。此外, 几乎很少的研究能够将社会经济环境下的人为活动纳入到恢复力评价框架内。过去的研究大多基于定性的方式 (包括案例归纳、访谈和相关人员咨询) 结合若干可变的恢复力指标评价了多个方面的农业生态系统的恢复力。例如: Mahmood et al. (2023) 使用主成分分析权重法和综合环境指标探究了孟加拉国的社会生态恢复力。随着未来气候变暖, 热浪和干旱等极端事件在生长季节可能变得更加频繁和严重。相比于过去, 当前气候条件下的农业系统受到扰动后可能更难恢复到

此前的水平，无论农业管理水平如何，最极端的气候事件依然严重损害作物生产（Schlenker and Roberts 2009; Gourджи et al. 2013; Toreti et al. 2019）。因此，亟待一个综合的、定量的评价框架以估算气候变化下（极端天气）基于社会经济的恢复能力对于农业生产的贡献，特别是不同经济发展水平下的对比研究。

评价气候变化和极端天气事件对作物生产力的一个重要科学问题是现有的模型方法和多源数据能在多大程度上跨尺度复现作物生产力。当前生产力评价方法可大致分为三类：基于传统的回归模型、基于黑箱的机器学习模型、基于生长过程的机理模型。机理模型可进一步细化为基于田间尺度的作物模型和面向区域尺度的生态系统模型。与传统回归不同，机器学习模型大多是非参数的。它们可以拟合复杂的函数并具有卓越的预测精度（Crane-Droesch 2018; Liu et al. 2018）。然而，机器学习经常因其黑箱性质而受到质疑。黑箱模型专注于结果预测，而不推断产生这些结果的性质、动态和过程。因此，机理模型虽然受限于参数校验和模型结构差异，但是其强大的解释性是统计模型不可替代的。作物生产力的模拟与预测通常基于某一特定数据源，例如田间试验观测、中尺度通量塔和近地卫星监测。随着模型技术的发展和用户需求，包含更多数据源的产量模拟框架也被进一步开发。例如将田间试验、小型无人机和大尺度卫星观测纳入同一个监测网络，以实时判断作物生长过程中的光合信息、结构信息和其他生理生态信息（Zhou et al. 2017; Schut et al. 2018; Mateo-Sanchis et al. 2019）。然而，多样的模型和数据源在跨尺度的研究中复现作物生产力的能力仍然未知。

朝鲜作为全球社会经济欠发达地区的代表，自 20 世纪 90 年代以来，频繁遭遇极端气候事件以及衍生的自然灾害，导致粮食生产急剧下降，使其不得不依赖国际援助和进口以填补国内的粮食缺口。例如 1993 年的冻灾、1994 年的冰雹、1995 至 1996 年的严重洪水、1997 年的台风和干旱，以及 1998 年的霜冻等（Bhatia and Thorne-Lyman 2002）。此外，朝鲜封闭的国界限制了其粮食生产数据的获取，并导致已有的公开数据连续性和系统性不足，这限制了机理模型在该地区的应用。然而，与朝鲜毗邻的中国东北地区和韩国却具有相似的气候特征和不同的经济发展水平，这为探究社会恢复力减轻极端气候事件的负面影响并促进国家粮食安全提供了天然案例（Shi et al. 2022）。相比之下，美国是全球经济发达地区和大型农业集约化的代表，其在全球小麦生产中占有举足轻重的地位，贡献了超过 10% 的全球小麦总产量，且占据着 30% 的出口份额。然而，过去四十年来，严重的干旱和高温热浪对美国小麦生产造成了显著的冲击，可能导致冬季小麦产量减少 10%-40%。在美国中部地区，极端的干热气候使得受影响县区的小麦年均产量损失高达 9 千克/公顷，相当于国内冬小麦产量减少了约 190 万吨，这些挑战对美国小麦产业及全球粮食供应链带来了重要而深远的影响。该地区小麦生产依赖先进的农业技术和现代化农机设备，包括精细的播种、施肥、灌溉以及病虫害管理等诸多环节。高效的生产模式和科学的农业管理手段保障了小麦产量的持续性高水平。

此外，发达国家的农业生产不仅需要保障国家粮食安全，还需要关注生产中的气候成本，尽可能地减少单位生产中释放的温室气体。并且充足的数据资料为使用机理模型模拟作物产量和温室气体排放敏感性以及量化因环境制宜的人为环境方案提供了重要基础。

因此，针对以上科学问题，本研究以全球极端天气频发的典型气候区（朝鲜和美国）为研究对象，试图（1）基于不同的模型和多源数据复现站点尺度、生态系统尺度和区域尺度的作物生产力；（2）分析多尺度下作物生产力与环境因素的响应关系；（3）从作物生产力损失和敏感性动态变化的角度，揭示极端天气事件对作物生产和粮食安全的长期影响；（4）量化典型气候区优势性缓解措施减少极端天气负面影响的潜力。上述分析对于我们理清气候脆弱区极端天气发生特征与粮食生产之间的动态关系以及人为活动如何影响气候变化与粮食生产的发展进程具有重要作用。通过探究优势性缓解措施的潜力，为政府部门在全球气候变化下制定合理的粮食生产规划和科学有效的气候风险应对策略提供了重要依据。该研究有助于提高全球粮食安全意识、调整粮食战略和社会经济政策，以确保可持续的粮食生产与供应。

1.2 国内外研究进展

1.2.1 气候变化对区域粮食安全的影响概况

近年来，全球气候变化以气温升高为主要特征，已经成为全球范围内备受关注的议题，也是当今各国学者研究的前沿热点。政府间气候变化专门委员会第六次评估报告指出，21世纪全球地表温度比工业革命期间高出约 1°C ，且陆地增幅高于海洋。世界气象组织统计资料显示，自有气象记录以来，20个最热的年份都出现在过去几十年中。气候变暖及其影响超出了研究人员的预期，这种变暖趋势预计将在未来相当长的时间内持续存在（Huang et al. 2017）。自20世纪中叶以来，全球范围内极端气候灾害事件的发生频次和强度都呈现明显上升趋势。西欧国家近些年遭受连续的高温热浪，对当地居民的生产和生活造成了严重影响，形成前所未有的气候变化挑战。与此同时非洲大陆由于高蒸发和低降水，其干旱也日趋严重。根据联合国减灾风险办公室的数据，1998年至2017年期间，全球发生了七千多起重大自然灾害事件，其中超过90%与气候变化密切相关。洪水和风暴是发生频率最高的灾害类型，占比约为43%和28%。

农业对气象条件极为敏感，自古以来“靠天吃饭”是农牧生活的主旋律，这种脆弱性使得农业成为受气候变化影响最为显著的领域之一。国内外学者已广泛研究了气候变化对主要作物（例如水稻、小麦、玉米）的多方面影响，包括生长过程、品质、产量、生产成本以及种植制度等。然而，不论气候因素如何演变或者种植环境如何变化，作物产量一直是研究关注的核心问题。气候变化背景下的温度上升和水资源供应不足直接导致了干热胁迫的发生（许迪等 2019），进而改变作物的光合能力、生长周期和病

虫害环境，显著降低农作物的田间生产力。试验研究表明，夜间最低温度每升高 1°C，早稻产量降低 5.42-9.48%，而晚稻产量提高 8.99-11.28%。夜温升高有利于早、晚稻的分蘖，但不利于颖花分化，使得早稻结实率下降（魏金连等 2014）。Liu et al. (2016) 利用历史观测和多源回归模型在站点尺度进行了模拟研究，结果显示全球气温每升高 1°C，小麦单产将减少~4-6%。他们同时指出寒冷地区对温度升高的响应比在温暖地带更为强烈。农业生产系统模拟的研究结果发现当气温升高 1°C 和降水减少 10%时，全球玉米平均产量将分别减少 6.5%和 2.8%（Lobell and Asseng 2017）。尽管气候变化的负面影响在全球不同地区被广泛报道，然而气候变化对粮食生产的实际影响因地制宜，这取决于地理分布、下垫面环境和作物品种的差异。Shaw et al. (2022) 发现气候变化普遍损害亚洲的粮食生产，区域差距预计将不断扩大，特别是在高排放的情景下。Chandio et al. (2023) 利用最小二乘法和统计数据探究了气候变化对南亚作物生产的影响，他们发现温度和碳排放对该地区的长期作物生产造成了不利影响，而降雨有利于该地区的作物生产。Chaudhary and Hanif (2022) 认为虽然气候变化对尼泊尔、孟加拉国和缅甸等国家的粮食安全产生不利影响，但也能让巴基斯坦受益。

现有的间接证据表明，目前观察到的粮食不安全人数中至少有一些是由于极端天气事件造成的（FAO et al. 2021）。例如，Verschuur et al. (2021) 研究了 2007 年莱索托的干旱，强有力的证据表明人类引起的气候变化加剧了干旱，导致粮食短缺加剧、价格上涨和严重的粮食不安全。随着未来 CO₂ 浓度和气温持续攀升，由此产生的粮食生产风险也在持续增加，特别是对于低收入的气候脆弱国家。农业模型比较和改进项目基于最新一代全球网格作物模型和气候情景的集合（AGMIP，第 6 阶段）预测表明，在 SSP126 情境下，玉米生产力下降了~5%；而在 SSP585 情境下，玉米生产力下降了~23%（Jägermeyr et al. 2021）。随着气温从 1.5°C 上升至 2-4°C，全球主产区的玉米单产损失预计将大幅增加（Tigchelaar et al. 2018; Gaupp et al. 2019）。此外，极端天气事件导致储存和分配的基础设施损坏以及粮食供应中断也将影响粮食生产和多样性（Bezner Kerr et al. 2022），进而导致粮食贸易下降。在中等脆弱性-高变暖情景（SSP260）中考虑到 CO₂ 施肥效应，Hasegawa et al. (2018) 预计与没有气候变化的情景相比，到 2050 年面临饥饿风险的人数将增加 2400 万。在 CO₂ 施肥效应较小的低变暖情景（RCP2.6）下，这一数字会增加约 7800 万。同时考虑到气候变化和缓解政策的影响，在高脆弱性-高变暖情景下（SSP370），预计到 2050 年低收入国家将有多达 1.83 亿人因气候变化而营养不良（Mbow et al. 2019）。即使大气中 CO₂ 含量的增加具有无可争议的施肥作用，然而这种施肥效应通常假设 CO₂ 浓度对应于气候变暖超过 3°C 的情景（胡根华和鲁向晖 2017）。此外，只有考虑其他限制因素（例如水或氮气）的协同作用下才能实现未来产量增加。一项模型研究结果表明，假设到 2100 年气温将上升 6°C（RCP8.5），尽管 CO₂ 施肥作用可能对小麦、大豆和水稻产生积极影响，但这些积极效

应将会被水资源等不利因素所抵消 (Lombardozzi et al. 2018)。

综上所述, 极端天气事件对全球主要粮食作物的生产力造成了严重破坏, 特别是对于低收入的气候脆弱性地区。随着未来变暖加剧, 由此产生的负面效应将会进一步威胁全球粮食安全, 造成数以万计的人口面临饥饿。即使部分地区的作物生产力会受益于温度变暖和 CO₂ 浓度升高, 但不足以扭转全球愈演愈烈的粮食不安全状况。

1.2.2 极端天气事件对粮食生产的影响机制

气候变暖和降水变异性的上升导致了极端气候事件发生频率和强度的增加 (Frich et al. 2002; Sui et al. 2018)。作物生长周期中, 发生的极端天气事件可能会造成严重的产量损失。特别是极端干旱、高温、霜冻、强降水事件, 这几种极端天气事件被广泛认为对作物生长发育具有重大影响 (Guarin et al. 2020)。

干旱被认为是全球粮食安全面临的最严重威胁之一, 其对作物生产力的影响可能超过其他极端天气事件造成的影响总和 (刘宪锋和傅伯杰 2021)。面对有限的水资源, 迅速增加的人口压力将会进一步扩大未来粮食需求, 加剧干旱的负面影响。干旱的首要影响是抑制了种子萌发以及植物建立健康种群的能力 (Kaya et al. 2006)。例如, 在一项豌豆试验中, 干旱胁迫影响了 5 个豌豆品种的发芽和幼苗生长 (Okçu et al. 2005)。由于渗透压降低, 细胞生长是对干旱最敏感的生理过程之一。具体而言, 作物通过木质部从根部吸收水分, 并将其运输到植物的各个部分。如果遭遇严重缺水, 水分在木质部和伸长细胞之间的流动可能会受阻或中断, 这阻碍了伸长细胞的正常伸展, 从而限制了植物的生长 (Nonami 1998)。此外在干旱条件下, 有丝分裂、细胞伸长和扩展会受到损害, 导致作物株高减小、叶面积下降 (Nonami 1998; Kaya et al. 2006; Hussain et al. 2008)。干旱还会对作物不同物候期的发育过程产生影响, 进而阻碍产量形成。例如, 在花期遭受干旱的情况下, 作物无法获得足够的养分和水分来支持穗的正常发育, 从而影响了谷物产量 (Yadav et al. 2004)。此外, 干旱胁迫还会影响灌浆期蔗糖合成酶、腺苷二磷酸葡萄糖焦磷酸化酶、淀粉合成酶和淀粉分支酶的活性, 抑制了从简单碳水化合物合成淀粉的过程 (Ahmadi and Baker 2001; Taiz et al. 2015)。对于特定作物来讲, 水分胁迫会导致黑麦的花期和籽粒灌浆期缩短 (Estrada-Campuzano et al. 2008)。此外, 水分胁迫还会延缓玉米植株进入吐丝期, 导致开花到吐丝的时间间隔延长, 从而对玉米产量产生不利影响 (Cattivelli et al. 2008)。在小麦抽穗后, 尽管干旱对籽粒灌浆速率的影响较为有限, 但抽穗期的缩短依然影响了小麦成熟期的干重 (Wardlaw and Willenbrink 2000)。总之, 干旱降低了植物的生长和发育水平, 进而抑制开花和灌浆过程, 最终导致作物减产甚至绝收。

热胁迫通常被定义指植物所遭受的高温环境条件, 超出其正常耐受范围, 并对其生长、发育产生不利影响的现象, 它在特定气候带发生的程度取决于白天/夜间发生高

温的概率和持续时间。热胁迫和产量损失之间的关系也在许多研究中得到确认 (Semenov and Shewry 2011; Innes et al. 2015; Pagani et al. 2017), 这种关系可以用一系列的机制解释, 包括缩短作物的发育时间、引发器官发育不良以及降低光感知和碳同化过程 (光合作用、呼吸作用和蒸腾作用) (Eyshi Rezaei et al. 2015; Innes et al. 2015; Stratonovitch and Semenov 2015)。高温可能直接改变作物现有的生理过程, 也可能间接改变发育模式, 这些反应可能因物候阶段而异。例如, 在种子灌浆过程中, 作物暴露于高温会加速衰老, 减少结实率和种子重量, 并降低产量 (Siddique et al. 1999)。这是因为在高温下, 植物通常会转移水、氮和其他营养元素以应对热胁迫, 因此可用于生殖发育的光合产物受到限制。热胁迫对发育中的种子的长期影响包括延迟发芽和种子活性丧失, 从而导致出苗减少。随着温度持续上升, 玉米胚芽鞘在 40 °C 时生长减缓, 在 45 °C 时生长停止 (Weaich et al. 1996)。高温导致玉米和甘蔗芽的干物质量、相对生长率和净同化率显著下降, 但叶片生长受到的影响很小 (Ashraf and Hafeez 2004)。例如, 在高温下的甘蔗表现出节间变小、分蘖增加、衰老提前以及总生物量减少等特征 (Ebrahim et al. 1998)。在小麦中, 籽粒重量和数量都对热胁迫十分敏感, Ferris et al. (1998) 发现成熟时每穗的籽粒数量随着温度的升高而下降。高温对番茄雌雄器官减数分裂、花粉萌发和花粉管生长、胚珠活力、花柱位置、花粉粒数、受精过程、原胚生长等生殖过程均有不利影响。热胁迫对许多植物的另一个影响是在开花前或花期施加高温时诱导不育现象。豆类在花期对热胁迫同样敏感, 仅暴露在高温数天就可能因落花或荚果败育而导致严重的产量损失 (Siddique et al. 1999)。总之, 根据现有研究, 植物对高温的反应因植物种类和物候阶段而异。大多数植物的生殖过程显著受到高温的负面影响, 进而影响受精过程, 最终导致作物产量下降。

特定温度的组合对某种作物的生长发育来讲可能是最佳温度范围, 但是对另一种作物可能会产生胁迫。过去的研究普遍观察到, 原生于热带或亚热带的作物暴露在非冰点温度时, 会表现出冻伤的症状。例如, 玉米、大豆、棉花、番茄等作物暴露在低于 10-15°C 的温度下会出现损伤迹象 (Guy 1990; Lynch 1990)。这种低温损伤现象因作物而异, 取决于作物对低温的敏感性。暴露于低温胁迫下的作物表现出各种表型症状, 包括叶片减少、枯萎和黄化, 并可能导致坏死影响产量的形成。低温胁迫通常导致发芽不良、幼苗发育迟缓、叶片变黄、枯萎以及分蘖减少。作物生殖生长阶段的低温胁迫会导致抽穗延缓和花粉不育, 这被认为是导致作物减产的关键因素之一 (Suzuki et al. 2008)。冻害对作物的主要不利影响主要表现为低温胁迫引起脱水导致的细胞质膜损伤 (Steponkus 1984; Steponkus 1993)。过去的研究已经注意到, 低温致冰是造成作物损害的真正原因。在低温胁迫条件下, 作物组织的细胞外间隙中的水分会形成冰结晶, 这一区域的溶质浓度相对较低。因此, 在细胞外间隙中的冰晶将在该区域与周围细胞之间形成压力梯度。由于这个梯度的存在, 胞质内的水分子将沿着梯度从细胞质向细胞外

间隙迁移。这一过程导致细胞外间隙中现有的冰晶增多，从而对细胞壁和质膜施加机械压力，最终导致细胞破裂 (McKersie and Bowley 1997; Uemura and Steponkus 1997)。总之，低温胁迫损害了细胞器和生物膜的完整性，进而导致溶质泄漏和分区性丧失。此外，冻害还会损害作物光合作用、蛋白质合成和其他代谢过程。

随着气候变化加剧，在全球各地已经观察到了降水增加和极端降水事件增多的趋势，因此洪水发生的可能性更高 (Palmer and Räisänen 2002)。然而，确定降水增加与洪水之间的因果关系十分困难，但不可否认的是在当前气候条件下，强降水事件可能会对农业生产造成巨大损害。例如，1993 年美国中西部洪水给农民造成约 80 亿美元的损失，这一数字约占洪水总损失的 50% (Floods 1995)。1997 年美国北达科他州红河洪水也对农业生产造成了负面影响，总损失约 10 亿美元。2001 年，红河和密西西比河的发生洪水泛滥导致大范围农作物播种推迟。除了洪水的直接损害之外，土壤湿度过高也是极端降水事件造成农作物损失的一个主要因素 (菅艺伟等 2021)。过度潮湿的土壤由于缺氧可能会损害作物的地上和地下部分 (Kozdrój and van Elsas 2000)，间接增加植物病虫害的风险 (Ashraf and Habib ur 1999)。此外，极端潮湿的土壤由于无法进行机械操作而导致播种或收获延迟，进一步损耗作物可收获的产量。例如，1993 年密西西比州洪水期间，由于持续大雨导致土壤水分饱和，大约造成 70% 的农作物损失。作物保险数据显示 (<http://www.rainhail.com>)，过去的二十年里，爱荷华州农民因土壤湿度过高而遭受的损失是直接洪水损失的五倍。因此，在估计极端天气事件对粮食生产影响的时，由极端降水可能导致的作物减产风险需要被进一步考虑纳入到相关评估框架中去。

1.2.3 基于多源模型和数据模拟作物生产力

作物产量模拟与预测通常基于某一特定数据源，例如田间试验观测、中尺度通量观测塔和近地卫星监测。随着模型技术的发展和用户需求，包含更多数据源的产量模拟框架也被进一步开发，例如将田间试验、小型无人机和大尺度卫星观测纳入同一个监测网络，以实时判断作物生长过程中的光合信息、结构信息和其他生理生态信息 (Zhou et al. 2017; Schut et al. 2018; Mateo-Sanchis et al. 2019)。过去几十年，基于单一数据源或多数据源组合的作物产量预测获得了极大的进步。然而，由于作物生产与环境之间的复杂动态关系以及作物内部基因差异，现有的模型难以全面刻画作物发育和最终的产量形成。

估算作物产量的方法可以是经验、半经验或者是机理模型。经验模型通常使用实测的作物产量或者区域统计产量与相关遥感的植被指数 (VIs) 建立关系，这种关系可以是线性或非线性的。线性模型通常是建立 VIs 与产量的一次、二次甚至更复杂的数学关系，这种模型在全球范围内不同地区也得到了很好的验证，但它们通常缺乏严格

的生理生态学理论基础并且往往不能扩展到其他地区，面对复杂的自然环境不能很好的解释产量形成。相比于线性模型，以机器学习为代表的非线性模型应运而生，在解决复杂环境因子之间的共线性问题以及多因子与产量的关系方面有着突出的表现。此外，为解决实际产量的模拟误差，更多的研究倾向于提升产量模拟精度而忽略产量形成时复杂关系，因此经验黑箱模型被大量应用于产量预测以满足利益相关者的需求。随着样本量的增加，机器学习模型更加适应复杂自然环境，预测的结果不断逼近真实的产量水平。

机理模型通常是基于过程的作物模型或者生态系统模型，使用生态生理过程的定量描述来模拟环境变化和管理措施影响下的作物生长发育。因此，基于过程的作物模型可以用于了解作物基因型、管理和环境之间的相互影响 (Messina et al. 2009)。作物模型被广泛用于研究气候变化对农业生产力的潜在影响 (Rosenzweig et al. 2014; Asseng et al. 2015) 并探讨在当前形势下的管理选择 (Hochman et al. 2009; Kassie et al. 2016)。然而，基于过程的作物模型通常为小规模农场的适应决策提供信息 (Chenu et al. 2017; Jones et al. 2017)。由于作物模型最初旨在支持农民决策，因此其侧重于同质条件下的田间尺度的产量模拟。此外，这些模型通常采用简化的水文、能量和生物地球化学循环过程。这些特性限制了它们在模拟区域作物生产、评估缓解潜力以及农业管理对环境影响的能力。包含农业模块的陆地生物圈模型为更广泛的农业气候变化减缓和适应提供了新的见解 (Bondeau et al. 2007; McDermid et al. 2017; Lombardozzi et al. 2020)。大多数陆地生物圈模型都涵盖了详细的水文、生物物理和生物地球化学过程，并且可以进一步与大气环流模型和海洋模式相耦合，以预测未来的气候变化对地球生态系统的影响 (Alo and Wang 2008; Fisher et al. 2014)。因此，它们可用于模拟历史和未来气候情景下的区域作物生产力，评估农业管理方案的缓解潜力，并量化农业-气候-环境系统内碳、水、养分和能量的交换。耦合作物生长过程和农业管理实践的生态系统模型不仅能够提供精细的生产力模拟，还能够捕捉农业过程中的温室气体交换和土壤有机碳动态变化。这一方案系统地刻画了环境变化和人为管理对农业生产的影响，以及农业活动对气候的反馈机制。因此，它为解决粮食安全和气候变暖的减缓效应提供了可行性方案。然而，无论是面向田间的作物模型还是面向区域的陆地生物圈模型，都需要许多强迫数据和参数驱动模型运转，包括土壤理化特征、管理措施和农业气象数据、作物遗传信息、生理生态参数和模拟设置等系数 (Li et al. 2015; Masutomi et al. 2016)。因此这种模型的区域应用是复杂的，并受到输入数据和参数不确定性因素的阻碍。

半经验模型包含经验模型与机理模型优点，既不需要大量的强迫数据和参数，也能从植物碳同化与分配的角度解释其生长发育。半经验模型为代表的是光能利用模型，将生产力估算为植物吸收的能量乘以光合作用过程中将能量转化为固定碳的实际光能利用率 (Monteith 1972b)，再通过环境胁迫因子和经验参数计算净初级生产力和产量。

近期的研究表明，利用卫星反演的作物生产力结合作物特定收获指数可以可靠地估计收获产量 (Xin et al. 2013; Guan et al. 2016; Yuan et al. 2016)。光能利用率模型有两个基本假设：(1) 总初级生产力 (GPP) 与吸收的光合有效辐射 (APAR) 线性相关；(2) 实际光能利用率 (LUE_m) 源自于环境条件影响下的理论最大光利用效率 (LUE_0)，例如温度或水分胁迫。光能利用率模型的一般形式可以表示为：

$$GPP = APAR \times LUE_m \quad (1-1)$$

$$APAR = PAR \times FPAR \quad (1-2)$$

$$LUE_m = LUE_0 \times f(T, P, \dots) \quad (1-3)$$

其中 PAR 是光合有效辐射, FPAR 是 PAR 被吸收的比例, $f(T, W, \dots)$ 表示环境条件, 例如气温 $f(T)$ 和降水 $f(P)$ 。Yuan et al. (2016) 基于卫星的光利用效率模型结合收获指数和碳分配系数, 模拟了欧洲和北美 12 个站点的不同类型的作物产量。结果表明, 部分试验点的产量被低估了 32-61%, 而在其他站点高估了 34-55%。

1.2.4 缓解气候变化对作物生产的负面影响

根据 IPCC 的气候脆弱性框架, 可将特定地区的气候脆弱性划分为三个层面, 即暴露度、敏感性和适应力。对于农业生产来讲, 暴露度被归纳为作物生长发育阶段所面临的自然环境变化, 包括气候、土壤、生物等多方面的影响。而敏感性更多的是面向作物本身, 由自身的基因型所调控, 敏感性会随着环境的变化而不断改变, 朝着更适应当前环境的方向发展 (图 1-1)。当环境变化足够稳定时, 当地的作物依靠自身的耐受性和调控机制足以应对复杂的环境变化。然而随着气候变暖加剧, 环境变化的稳定状态被打破, 导致极端环境事件超过了作物本身的适应机制, 且基因的演化速度远远低于环境改变的速度。因此, 需要人为干预以提高作物对气候变化的适应能力。一般而言, 提升作物适应力的人为活动可分为直接和间接两种。直接适应措施包括培育抗性品种、基因编辑技术、肥料和营养管理、水资源管理和农药化学保护 (房世波等 2011), 间接适应措施包括土壤管理、生态系统保护、经济补偿、农业教育和培训、人口意识和政策支持。

过去的研究主要集中在人为活动下的直接适应措施, 以探讨它们对作物在抵抗气候变化方面的影响。对全球 1700 多个已发布模拟的新数据集进行的荟萃分析表明, 作物层面的适应性措施使模拟产量平均提高 7-15%, 这种适应包括品种、种植时间、灌溉和作物残茬管理的变化 (Challinor et al. 2014)。品种调整是作物适应性提高的关键措施。在北欧地区, 引入了抗旱、耐病虫害和耐热的小麦和大豆品种, 以增加产量并提高作物的抗性 (Peltonen-Sainio et al. 2018; Zhao et al. 2022b)。同样, 在南欧和中欧, 耐旱品种的使用有助于缓解蒸散发增加和降雨量变异性大引发的负面效应 (Zhao et al. 2022b)。

其次，水资源管理和灌溉策略在气候变化适应中发挥了关键作用。Lychuk et al. (2017) 改进的灌溉系统提高了美国东南部农田的水资源利用效率，预计使未来玉米产量增加 29-33%，并减轻干旱对农业的不利影响。此外，作物保护和风险管理措施（如作物保险和气象预警系统）在全球范围内的广泛应用也成功地帮助农民减少极端天气事件造成粮食产量损失（Yin et al. 2016; Pertot et al. 2017; Gobin 2018）。种植日期调整是另一个适应气候变化挑战的关键措施，Laux et al. (2010) 在撒哈拉以南通过筛选最佳的播种日期，使得花生和玉米产量相比于基准期分别增加 30% 和 15%。由播期和品种调整（种植晚熟品种）带来的生产收益也在全球其他地方被观察到（Woo et al. 2022）。近年来混合生产系统也越来越受到关注，这些系统将多年生和一年生的作物、牲畜和渔业相结合，提高了农业的生态系统恢复力、粮食安全和生计多样性（Baker et al. 2023）。

随着气候变化的负面影响加剧，间接适应措施也被逐步纳入到气候缓解方案中，并在特定地区发挥了重要作用。一项基于尼日利亚的研究发现气候适应受到资金不足等障碍的制约，其中资金、物质和人力资源的缺乏占据了主要障碍的 70%（Oluwatimilehin and Ayanlade 2023）。资金不足可能是经济薄弱地区提高适应能力的主要限制，经济限制不仅体现在农业，还通过限制其他行业间接影响农业投入（Oluwatimilehin and Ayanlade 2023）。此外，Mase et al. (2017) 证实农民的风险认知和态度对于应对气候变化的挑战至关重要。农民对自己农场的风险的看法、对创新的理解以及适应态度是决定适应行为的最重要因素。在埃塞俄比亚，性别差异对适应策略选择产生显著影响，特别是妇女为主的家庭更受到严重的气候变化的影响，因为她们缺乏资源获取和控制的能力（Assefa and Gebrehiwot 2023）。此外，多源概率分析表明气候适应策略还受到家庭财富和人口特征的影响，农民适应选择的主要决定因素来源于性别、年龄、教育程度、家庭规模、农场规模、非农业收入、牲畜、信息获取、推广服务以及距市场中心的距离（Adamseged and Kebede 2023; Assefa and Gebrehiwot 2023）。总的来说，这些研究强调了全球范围内的间接气候适应策略的多样性。深入的研究和实践有助于更好地理解 and 改善适应策略，以提高农业对气候变化的适应能力，为农业的可持续性和粮食安全提供更全面的解决方案。

1.3 研究内容

（1）基于多源模型和数据模拟典型区域站点尺度粮食生产力

以全球典型的极端气候敏感区为例（朝鲜，韩国，中国辽宁、吉林省和美国小麦区），采用机器学习模型（经验模型）、改进的生态系统光能利用模型（半经验模型）和基于过程的陆地生态系统模型（机理模型）模拟站点尺度粮食生产力。充分考虑可用的环境因素，包括气象因子、物候信息、多种植被指数、遥感光谱信息和极端气候指数，探究现阶段主流模型模拟气候敏感区作物生产力的潜力。

(2) 区域粮食生产力的预测及其与环境因素的响应关系

将多源模型和数据从站点尺度扩展到区域尺度，模拟典型区域作物生产力长期的时空变化趋势。基于气候相似性原理，提出一种基于机器学习和可扩展数据的可迁移模型，预测数据稀疏地区（朝鲜）水稻生产力。采用站点升尺度的方法结合空间环境信息，将生态系统光能利用率模型用于区域生产力预测，并分析长期的生物量变化特征。基于多源格网驱动因子的生态系统模型，模拟美国小麦区过去 60 年作物生产力以及温室气体排放并分析其作物生产的气候代价。基于相关性分析、变量重要性分析和多情景模拟控制试验，探究不同模型模拟的作物生产力对环境因素的响应关系，并归因影响作物历史生产力动态变化的关键环境因素。

(3) 典型区域粮食生产对极端天气事件的响应特征

从作物生产损失和敏感性的角度，揭示极端天气事件对典型区域粮食生产的影响。使用 27 个全球气候模式和两种未来气候情景，计算朝鲜气候变化下极端天气的发生风险（2021-2100 年），并定量化估算未来气候变化下朝鲜水稻产量损失。此外，基于滑动窗口结合相关系数法分析美国小麦生产中作物产量、温室气体排放及其气候代价对极端干热事件的响应关系，并探究小麦生产中气候代价敏感性的长期变化趋势。

(4) 探究典型气候区优势性缓解措施的效果

基于相似的气候敏感性但是不同的社会经济发展水平的典型气候区（朝鲜、韩国以及中国辽宁和吉林省），采用社会恢复力框架和调节模型，探究社会恢复力对于缓解极端气候对区域粮食生产负面影响的能力。通过随机森林模型和部分依赖分析（PDP）定量化评估社会恢复力对粮食生产影响的非线性变化和阈值。气候智慧型耕作方案被用于探究缓解小麦生产对极端干热事件敏感性的潜力。定量化估算气候智慧型耕作实践缓解小麦产量、温室气体排放及其气候代价敏感性的能力以及时空动态特征。

1.4 技术路线

本研究基于多源环境数据和多过程模型模拟典型气候敏感区多尺度粮食生产力。在此基础上探究气候敏感区粮食生产力与环境因素的动态响应关系。分析气候变化下极端天气事件对区域粮食生产的影响（产量损失和敏感性变化）。最后根据环境特征和经济发展水平提出基于社会恢复力和气候智慧型管理的缓解方案，并进一步量化了该方案缓解潜力。具体技术路线如图 1-2 所示：

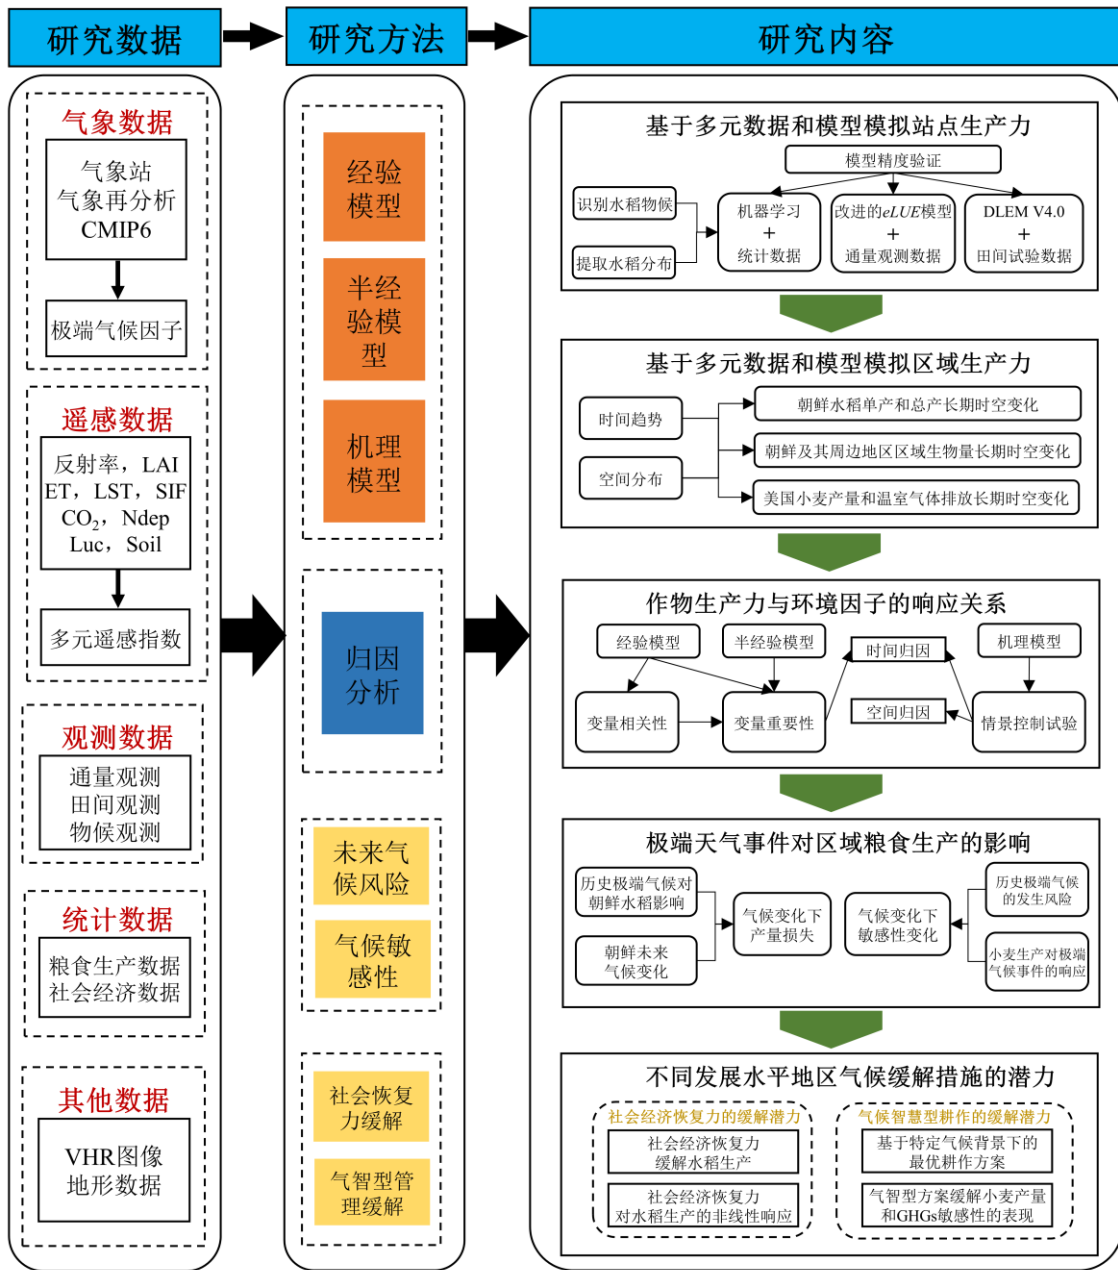


图 1-2 本研究技术路线图

Fig. 1-2 The framework of this study

第二章 材料与方法

2.1 研究区域概况

本论文以朝鲜和美国小麦区为例探究极端天气事件对粮食生产的影响以及不同发展水平下优势性缓解措施的潜力。朝鲜和美国是全球极端天气事件频发地区，展示了极高的气候暴露度和不同的极端气候特征。此外，这两个地区代表了多样的发展水平，为我们探究社会恢复力的缓解效应和气候智慧型管理减少粮食生产的气候代价提供了模板案例。

朝鲜位于东亚，东临日本海，西濒黄海，北界与中国接壤，南隔朝鲜湾与韩国相望。水稻在朝鲜的粮食生产中占据了超过 60% 的份额，为该国 2500 万人口的生活提供主要口粮 (Dill et al. 2021)。由于其独特的气候条件 (如高纬度位置和季风气候影响)，极端天气事件对朝鲜农业和生态系统的影响较为显著。在过去的二十年里，由于低生产率、政治孤立以及极端天气等因素，朝鲜频繁遭受饥饿和营养不良的困扰 (Dill et al. 2021)。尤其是自 20 世纪 90 年代以来，频繁的自然灾害导致朝鲜的粮食生产急剧下降，使其不得不依赖粮食援助和进口以填补粮食缺口，如 1993 年的冻灾、1994 年的冰雹、1995 至 1996 年的严重洪水、1997 年的台风和干旱，以及 1998 年的霜冻等 (Bhatia and Thorne-Lyman 2002)。即使进入 21 世纪，朝鲜的粮食产量仍然无法满足人口需求，粮食赤字问题依然严重甚至呈现增加趋势 (McCurry 2012; Crespo Cuaresma et al. 2020)。此外，封闭的国界限制了朝鲜的统计数据获取，导致公开数据的连续性和系统性不足。难以获取的大量数据和参数，使得机理模型在该地区的应用受到了极大挑战。然而，与朝鲜毗邻的中国东北地区 and 韩国却具有相似的气候特征 (图 2-1)，且能够获得完整的、公开可用的统计数据。尽管朝鲜 (根据世界银行的分类，朝鲜被归类为欠发达地区) 与其邻国 (韩国，发达地区；中国，发展中地区) 在气候条件上有相似之处，但社会经济发展水平却存在巨大差异，这为本研究模拟数据稀疏地区作物生产力并量化社会恢复力的缓解潜力提供了有力支持 (Shi et al. 2022)。

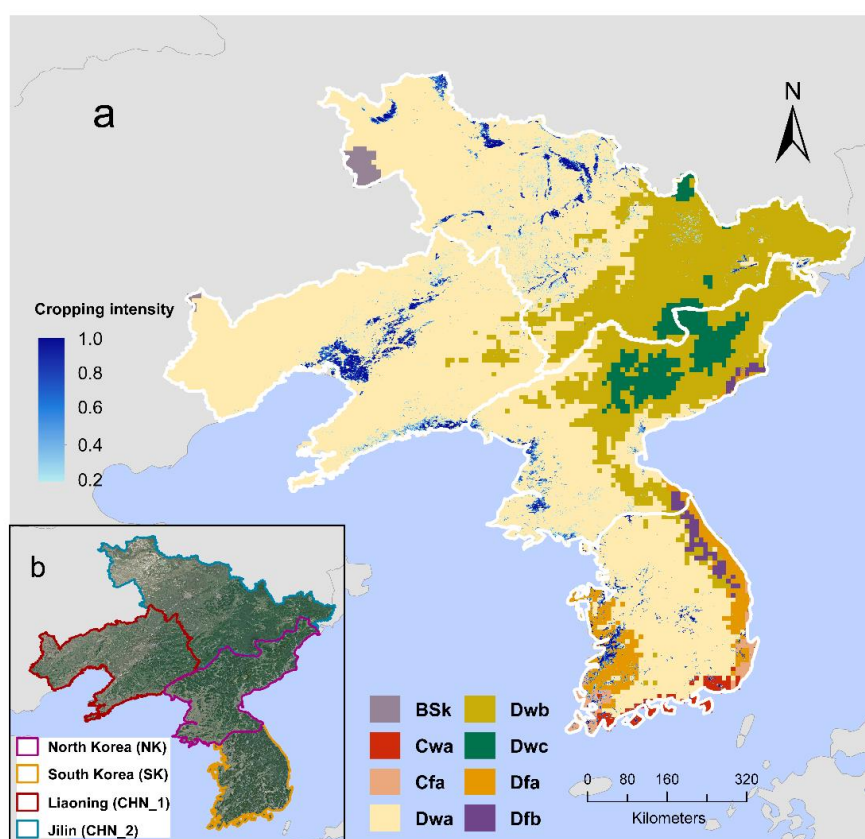


图 2-1 朝鲜，韩国，中国辽宁、吉林地理气候与水稻种植分布的空间格局。种植强度 0.2~0.4 为水稻低频种植区，0.4~0.6 为中频种植区，0.6~0.8 为高频种植区，大于 0.8 为多年种植区。图中缩写代表了具体的气候分区，详情参见 Beck et al. (2018)

Fig. 2-1 Spatial patterns of geographical and climatic distribution across North Korea, South Korea, and Liaoning and Jilin province of China. Cropping intensity values of 0.2–0.4 are considered as low-frequency rice planting areas, 0.4–0.6 are medium-frequency areas, 0.6–0.8 are high-frequency areas, and greater than 0.8 as the perennial planting areas.

美国是全球社会经济发达和大型农业集约化的代表国家，其小麦种植在全球小麦生产中占有举足轻重的地位。据统计，美国小麦产量贡献了超过全球小麦总产量的 10%，且占据着 30% 的出口份额。美国的小麦种植范围广泛分布于各州，涵盖多样的气候和土壤条件，为多元的小麦品种提供了适宜的生长环境（图 2-2）。美国小麦生产依赖先进的农业技术和现代化农机设备，包括精细的播种、施肥、灌溉以及病虫害管理等诸多环节。高效的生产模式和科学的农业管理手段保障了美国小麦产量的持续性高水平，这取决于发达社会经济水平。然而，过去四十年来，严重的极端天气事件（干旱和高温热浪）对美国小麦生产造成了显著的冲击，导致冬小麦年际产量损失 10%-40%，并释放大量的温室气体。在美国中部地区，极端的干热气候使得受影响县区的小麦年均产量损失高达 9 千克/公顷，相当于国内冬季小麦产量减少了约 190 万吨。这些挑战对美

国小麦产业及全球粮食供应链带来了重要而深远的影响。此外，发达国家的粮食生产不仅要保障国家粮食安全和全球供应链的稳定，还要尽可能地减少作物生产中的温室气体排放，以满足雄心勃勃的气候承诺。因此，其丰富的、可获取的多源数据为机理模型的模拟提供了必要支持，在模拟作物生产力的基础上，有助于进一步探究生产过程中气候代价的敏感性以及因环境制宜的人为管理活动的缓解潜力。

总而言之，以上的案例有助于本研究分析多源模型模拟作物生产力的性能以及极端天气事件对粮食生产的影响（产量损失和敏感性变化），并在此基础上量化不同发展水平地区优势性缓解措施的缓解潜力。

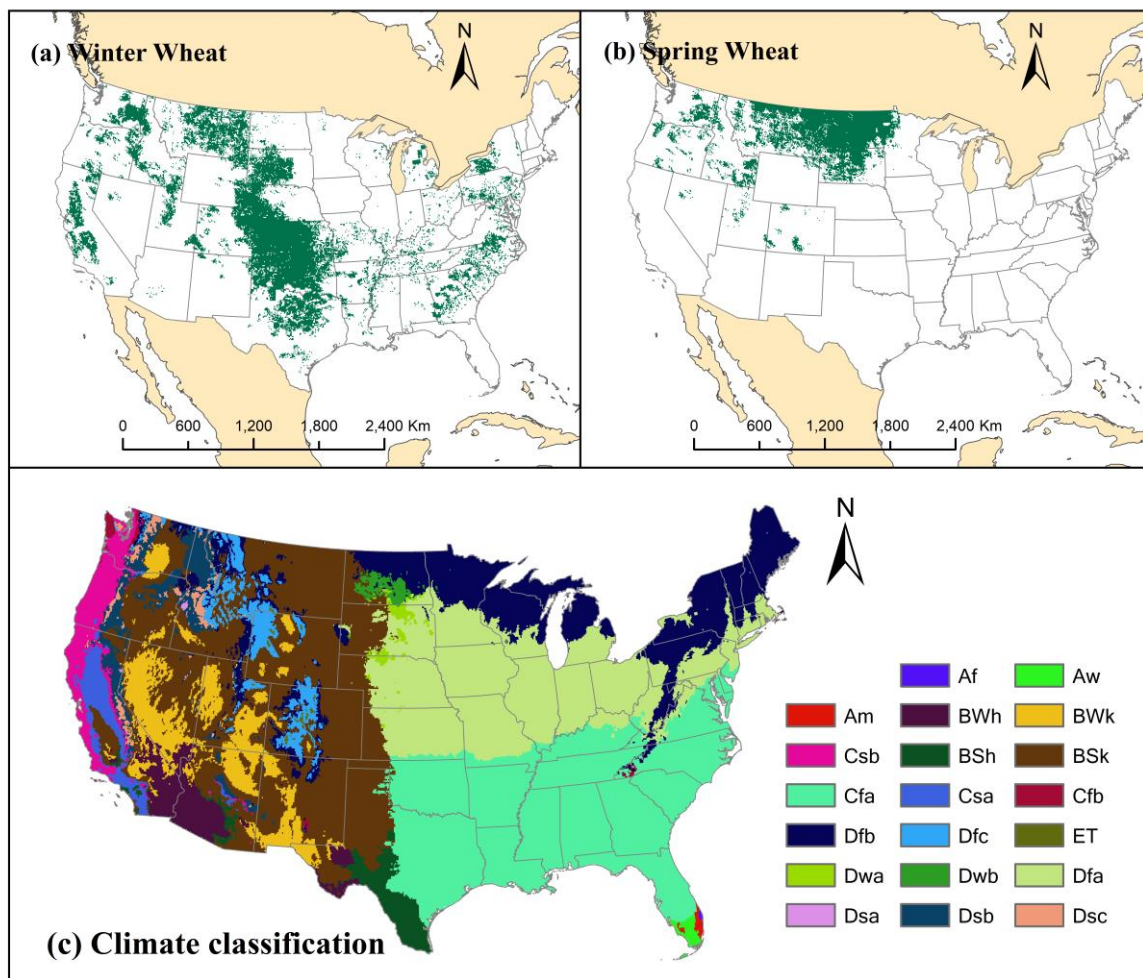


图 2-2 美国本土地理气候与小麦种植分布的空间格局。图中缩写代表了具体的气候分区，详情参见 Beck et al. (2018)

Fig. 2-2 Spatial patterns of geographical and climatic distribution in the United States

2.2 数据来源及预处理

2.2.1 气象数据

2.2.1.1 数据介绍

(1) 站点数据:

原始气象数据是从中国气象局国家气象中心 (<http://data.cma.cn>) 获取, 包括 1960 年至 2020 年期间的 2419 个站点的日均、最高和最低气温、降水、风速、相对湿度和日照时数等。这些数据经过一致的质量控制和标准处理。在进行计算之前, 排除了缺失值超过总天数的 5% 的数据。此外, 我们还使用了特定站点的历史数据通过计算不同年份对应日期的平均值来估算缺失的气象要素。

(2) 气象再分析数据:

本研究使用逐日的再分析气象数据数据分析了朝鲜及其周边地区的气候因子。这些逐日的再分析数据来源于欧洲中期天气预报中心 (European Centre for Medium-Range Weather Forecasts, ECMWF) 的格网数据集, 空间分辨率为 0.1 度。该数据集包括了 1979 年至 2018 年逐日的 2 米气温 (24 小时最高、最低和平均温度)、降水和太阳辐射 (详见表 2-1)。本研究选择了 ECMWF 的第五代再分析数据集 (ERA-5), 有两个原因: 1) 朝鲜地面数据稀少且不易获得; 2) 通过使用全球数据集, 可以将本研究的方法应用于其他数据稀疏的地区。

本研究进一步分析计算了 1979 至 2017 年 (历史时期) 和 2021 至 2100 年 (未来时期) 两个时期的三种平均气候指数和九种极端气候指数 (表 2-2)。此外, 本研究基于 2000 年至 2017 年的气候变量归因极端天气、建模回归并对朝鲜的区域水稻生物量进行重建预测。具体而言, 本研究基于 1979 至 2018 年的 ERA-5 数据进行降尺度分析, 并将未来气候因子应用于已进行校正的模型, 以预测 2021 至 2100 年间未来的气候风险和粮食生产损失, 这一过程涵盖了两种不同的气候情景和 27 个全球气候模式 (GCM)。

表 2-1 本研究涉及的数据来源

Table 2-1 Data sources used in this study

数据类型	数据源	时间分辨率	空间分辨率	单位	描述
EVI	MOD09A1	8d	500 m	-	Enhanced vegetation index
LSWI	MOD09A1	8d	500 m	-	Land Surface Water Index
NDVI	MOD09A1	8d	500 m	-	Normalized difference vegetation index
LAI	MOD15A2H	8d	500 m	m ² m ⁻²	Leaf index area
LST _{night}	MYD11A2	8d	1000 m	K	Land surface temperature
LULC	MCD12Q1	Yearly	500 m	-	Land use and land cover
ET	MOD16A2	8d	500 m	Kg m ⁻² 8day ⁻¹	Total evapotranspiration
Precipitation	ERA-5	Daily	0.1°	mm day ⁻¹	Precipitation
Maximum TEMP	ERA-5	Daily	0.1°	K	2-m temperature
Minimum TEMP	ERA-5	Daily	0.1°	K	2-m temperature
Solar radiation	ERA-5	Daily	0.1°	J m ⁻² day ⁻¹	Solar radiation
DEM	SRTM	-	90 m	meter	Digital Elevation Model
Biomass observation	EC towers	Daily	site	g C day ⁻¹	-
Phenological stages	Weather station	10 day	site	-	-
Production statistics	FAO	Annual	National	tone	-
Population	FAO	Annual	National	1000 Person	-
GDP	UNSD	Annual	National	US\$	Gross Domestic Product
Population ages 0-14	World Bank	Annual	National	% of total population	-
Population ages 15-64	World Bank	Annual	National	% of total population	-
Rural population	World Bank	Annual	National	% of total population	-
Energy use	World Bank	Annual	National	kg of oil equivalent per capita	-
Access to electricity	World Bank	Annual	National	% of population	-
School enrollment	World Bank	Annual	National	% gross	-
Patent applications	World Bank	Annual	National	-	-
Net ODA received	World Bank	Annual	National	% of GNI	-
Nitrogen application	-	Annual	0.5°X0.5°	g N m ⁻² yr ⁻¹	Lu and Tian
Phosphorus application	-	Annual	0.5°X0.5°	g P m ⁻² yr ⁻¹	Lu and Tian

注：UNSD 和 GNI 分别是联合国统计司和人均国民总收入。FAO、EC 和 TEMP 分别代表联合国粮农组织、涡动相关方差和温度。

表 2-2 平均和极端气候变量的详细描述

Table 2-2 Average and extreme meteorological variables.

	描述	缩写	类型	单位
平均气候变量	Total solar radiation during GS	TS	I	MJ m ⁻² day ⁻¹
	Average air temperature during GS	AAT	I	K
	Total precipitation during GS	TP	I	mm
极端气候变量	Minimum value of daily minimum temperature during GS	TNn	I	K
	Maximum value of daily maximum temperature during GS	TXx	I	K
	Count of days when TN > 20°C during GS	TR20	F	Day
	Count of days when TX > 30°C during GS	SU30	F	Day
	Count of days when TN < 0°C during GS	FD0	F	Day
	Count of days when R ≥ 50 mm during GS	R50	F	Day
	Count of days when R ≥ 25 mm during GS	R25	F	Day
	Count of days when R ≥ 10 mm during GS	R10	F	Day
	Count of days when R ≥ 1 mm during GS	R1	F	Day

注：I、F、GS 分别表示强度、频率和生长季。TN、TX 分别为日最低气温、日最高气温。R 为日降水量（详见 http://etccdi.pacificclimate.org/list_27_indices.shtml）。

基于统计降尺度（SD）方法将 CMIP6 的 27 个全球气候模式（表 2-3）进行降尺度分析，得到了两种未来气候情景（SSPs，共享社会经济途径的组合），其中 SSP245 代表中等发展途径 SSP2 + RCP4.5，SSP585 代表高发展途径 SSP5 + RCP8.5。SD 模型（NWAI-WG58）将全球气候模式的逐月格点数据降尺度到朝鲜（NK）的 1299 个格点，生成了逐日气候数据。统计降尺度包括三个主要组成部分：空间降尺度、偏差校正和时间降尺度。空间降尺度采用了基于 GCM 最近四个格点中心的逆距离加权（IDW）插值方法来提高模拟精度（Liu and Zuo 2012）。然后基于历史时期的观测和 GCM 数据之间的关系来生成 GCM 的月尺度数据。最后，通过改进的随机天气发生器（Richardson et al. 1984），基于偏差校正的月尺度 GCM，对每个像元的最高温度、最低温度、降水和太阳辐射的逐日时间序列进行降尺度。有关 SD 的更详细描述，请参阅（Liu and Zuo 2012）。

表 2-3 本研究所用的 CMIP6 全球气候模式

Table 2-3 Information for the 27 selected GCMs from CMIP6.

顺序	名称	缩写	国家	空间分辨率 (°×°)
1	ACCESS-CM2	ACC1	Australia	1.2 × 1.8
2	ACCESS-ESM1-5	ACC2	Australia	1.2 × 1.8
3	BCC-CSM2-MR	BCCC	China	1.1 × 1.1
4	CanESM5	Can1	Canada	2.8 × 2.8
5	CanESM5-CanOE	Can2	Canada	2.8 × 2.8
6	CIESM	CIES	China	0.9 × 1.3
7	CMCC-CM2-SR5	CMCS	Italy	0.9 × 1.3
8	CNRM-ESM2-1	CNR1	France	1.4 × 1.4
9	CNRM-CM6-1	CNR2	France	1.4 × 1.4
10	CNRM-CM6-1-HR	CNR3	France	1.4 × 1.4
11	EC-Earth3	ECE1	Europe	0.7 × 0.7
12	EC-Earth3-Veg	ECE2	Europe	0.7 × 0.7
13	FGOALS-g3	FGOA	China	5.2 × 2.0
14	GFDL-CM4	GFD1	USA	1.0 × 1.3
15	GFDL-ESM4	GFD2	USA	1.0 × 1.3
16	GISS-E2-1-G	GISS	USA	2.0 × 2.5
17	HadGEM3-GC31-LL	HadG	England	1.3 × 1.9
18	INM-CM4-8	INM1	Russia	1.5 × 2.0
19	INM-CM5-0	INM2	Russia	1.5 × 2.0
20	IPSL-CM6A-LR	IPSL	France	1.3 × 2.5
21	MIROC6	MIR1	Japan	1.4 × 1.4
22	MIROC-ES2L	MIR2	Japan	2.7 × 2.8
23	MPI-ESM1-2-HR	MPI1	Germany	0.9 × 0.9
24	MPI-ESM1-2-LR	MPI2	Germany	1.8 × 1.9
25	MRI-ESM2-0	MTIE	Japan	1.1 × 1.1
26	NESM3	NESM	China	1.9 × 1.9
27	UKESM1-0-LL	UKES	England	1.3 × 1.9

2.2.1.2 计算极端气候因子

本研究使用干旱指数 (AI) 来表征干旱的严重程度, 其中 AI 定义为降水量 (P , mm yr^{-1}) 与潜在蒸散发量 (ET_P , mm yr^{-1}) 的比值, ET_P 是在气候变暖条件下控制地表水平衡函数的重要变量。如果 $AI < 0.2$, 在特定的时间和地点被认为是干旱条件的发生, 这常用于识别全球范围内的干旱环境或干旱条件 (Middleton and Thomas 1992; Berg and McColl 2021; Shi et al. 2021)。 ET_P 采用了广泛使用的 Hargreaves 模型进行计算, 该模型受到太阳辐射和温度的约束 (Hargreaves and Samani 1982; Shi et al. 2020a)。之前的研究表明, 气温和太阳辐射可以捕捉超过 80% 的 ET_P 变化 (Almorox et al. 2015; Shi et al. 2020a)。具体公式参数化如下:

$$ET_p = 0.0023 \times 0.408 R_a \times (T_{\max} - T_{\min})^{0.5} \times (T - 17.8) \quad (2-1)$$

$$AI = \frac{P}{ET_p} \quad (2-2)$$

其中 R_a , T_{\max} , 和 T_{\min} 分别表示太阳辐射 ($\text{MJ m}^{-2} \text{d}^{-1}$)、最高气温 ($^{\circ}\text{C}$) 和最低气温 ($^{\circ}\text{C}$)，而 T ($^{\circ}\text{C}$) 则是 2 米高度的日平均空气温度。在小麦生长季 (3 月至 9 月期间，通常在这段时间内会出现高温现象)，每日最高温度超过 30°C 被定义为小麦遭受了高温事件，这远远超出了无灌溉情况下光合作用的最适温度上限。本研究还计算了复合干热事件，即在特定位置和时间同时发生的高温与干旱事件，并进一步将全年复合干热事件的数量 (极端干热事件的频率) 作为导致小麦碳变化的环境因素。

本研究将十二个气候变量 (原始分辨率为 0.1°) 降尺度到 500 米分辨率，并计算 2000 至 2017 年间朝鲜地面总初级生产力 (GPP) (表 2-2)。具体而言，基于双线性插值法将所有分辨率为 0.1° 的气候变量栅格重新采样到 500 米，以匹配生物量的空间分辨率，而后计算了 2000-2017 年朝鲜的特定年份气候因子与其他年份平均值之间的偏差，并基于该偏差其他年份气候因子的标准差进一步计算比率来确定特定年份的气候异常。其中，对于气候异常的朴素理解是表示特定年份的气候因子偏离往年平均状态的程度。因此，如果异常值大于 1 或小于 -1，则认为这些值显著高于或低于其他年份 (Tian et al. 2012)，需要说明的是，本研究使用一个标准差作为阈值，假设在正常情况下，气候因子通常在多年均值的一个标准差范围内波动 (Ren et al. 2012)。

2.2.2 观测数据

(1) 通量观测

为了在没有气象因子输入的情况下，校准和模拟研究区域的水稻生物量，本研究从中国通量观测研究网络 (ChinaFLUX) 中获取了两个涡度相关 (EC) 塔的逐日净生态系统交换 (NEP) 和生态系统呼吸量的观测数据，时间跨度为 2003 年至 2010 年。这两个 EC 塔位于中国山东省禹城 ($116^{\circ}34'12.72''\text{E}$, $36^{\circ}49'44.4''\text{N}$) 和吉林省长白山 ($128^{\circ}05'45''\text{E}$, $42^{\circ}24'9''\text{N}$) 附近，分别代表农田和森林生态系统。因此，本研究基于 EC 通量塔的净生态系统交换和异养呼吸计算了逐日的总生态系统 CO_2 交换量，并将其近似看作生态系统总初级生产力。

(2) 物候观测

为了确定朝鲜及其周边地区水稻生长季和移栽期的开始和结束时间，我们从中国气象数据共享服务系统 (<http://cdc.cma.gov.cn/home.do>) 中获取了中国辽宁省盘锦平原的主要农作物的物候数据。并根据 Zhou et al. (2016) 重新绘制了作物物候历 (表 2-4)。

表 2-4 朝鲜及其周边地区作物物候历

Table 2-4 The crop calendar in Korea and neighbors.

月份	四月			五月			六月			七月			八月			九月			十月		
	F	M	L	F	M	L	F	M	L	F	M	L	F	M	L	F	M	L	F	M	L
水稻		1	2	2	2	3	4	5	5	5	5	6	7	7	8	8	8	9	10	10	10
大豆					1	2	3	3	4	4	4	5	6	6	6	6	6	7			
玉米					1	2	3	4	4	5	5	5	6	6	7	7	7	7	8		

注：表格参照在中国辽宁省盘锦平原重新绘制（Zhou et al. 2016）。F、M 和 L 分别代表上旬、中旬和下旬。

水稻：1-播种，2-移栽/淹水，3-移栽/淹水，4-返青，5-分蘖，6-孕穗期，7-抽穗期，8-乳熟期，9-成熟期，10-收获期；

大豆：1-播种，2-发芽，3-三叶期，4-分枝，5-花期，6-结荚 7-成熟；

玉米：1-播种，2 发芽，3-三叶期，4-七叶期，5 拔节期，6 抽穗，7 乳熟，8 成熟。

（3）田间试验观测

本研究收集了田间试验数据以校准并验证 DLEM v4.0 模型在小麦产量和温室气体模拟方面的精度，包括三个主要步骤：平衡运行、自旋运行和瞬态运行。共计使用了 74 个站点年份的单产观测数据、33 个温室气体排放观测数据以及 36 个土壤有机碳储量观测数据进行了模拟验证，这些站点覆盖了主要的小麦类型和常见品种（图 2-3）。此外，本研究还利用美国农业部（USDA）1960-2018 年的小麦总产统计数据，进一步验证了模型在模拟国家尺度小麦产量空间变化方面的准确性和可靠性（图 2-3）。

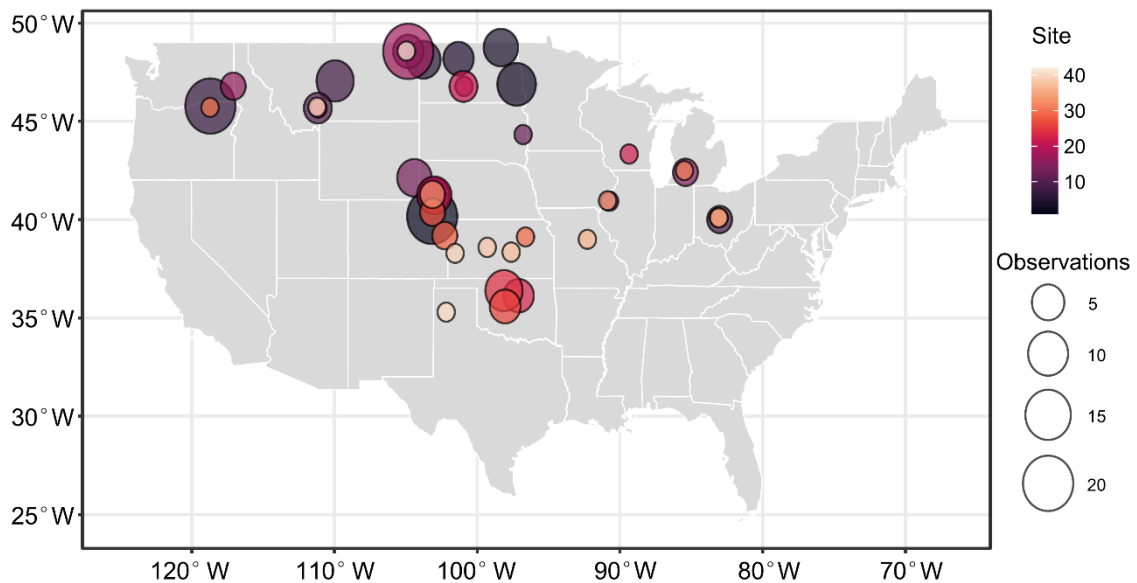


图 2-3 美国小麦站点观测的空间分布

Fig. 2-3 Spatial distribution of situ observations in the US wheat-planting regions

最后，基于 1960 年至 2018 年的小麦产量观测报告以探究，本研究拟对小麦生产的干热敏感性进行探究，其中观测报告来自南部苗圃试验田、北部苗圃试验田以及硬质春小麦苗圃试验田，总计包括 29 个冬小麦试验田和 23 个春小麦试验田，所有试验田均分布于美国大平原地区，其中灌溉试验田的比例低于 5% (Zhu and Burney 2021; Zhang et al. 2022a)，“Kharkof”用于冬小麦品种，“Matquis”用于春小麦品种。

2.2.3 遥感数据及其分析

2.2.3.1 数据介绍

(1) MODIS 遥感数据及其衍生产品

本研究收集了与植被生长相关的格网数据，包括叶面积指数 (LAI)、增强型植被指数 (EVI)、蒸散发 (ET)、日光诱导叶绿素荧光 (SIF)、地表温度 (LST) 以及气象再分析数据，以上所有数据均在县级尺度上进行了平均。

叶面积指数 (LAI): 本研究使用 LAI 作为重要驱动因子，用于评估粮食产量，因为 LAI 与粮食产量之间存在显著的相关性 (Parker 2020)。LAI 数据 (MOD15A2H Version 6) 来自于美国国家航空航天局 (NASA) 的种分辨率成像光谱仪 (MODIS) 遥感产品。MOD15A2H Version 6 是一个四级格网产品，其空间分辨率为 500 米，时间步长为 8 天。该产品提供了变量的质量评级和标准差 (Myneni and Knyazikhin 2015)。

增强型植被指数 (EVI): EVI 可以减少植被冠层背景信号和大气干扰，以弥补由于光谱饱和效应导致的背景噪声，并提高对作物产量的估计准确性 (Huete et al. 2002)。因此，本研究使用了 MODIS 的 MOD13A1 Version 6 产品来计算 EVI 和水稻空间分布图，其空间分辨率为 500 米，时间步长为 16 天 (Didan 2015)。我们使用最大值合成 (MVC) 法计算不同的物候期的 EVI 最大值，以有效地捕捉水稻产量变化。

蒸散发 (ET): NASA 的 MODIS 产品中的 MOD16A2 Version 6 提供了空间分辨率为 500 米、时间步长为 8 天的 ET 数据 (Running et al. 2017)。该产品基于 Penman-Monteith 方程生成，用于计算植被蒸散发和蒸腾的水分通量 (Monteith 1972a)。本研究使用 MVC 方法生成了年尺度 ET 栅格。

日光诱导叶绿素荧光 (SIF): SIF 是一种基于植物光合作用过程中近红外范围 (650-850 nm) 荧光的新信号 (Meroni et al. 2009; Guanter et al. 2014)。本研究的 SIF 数据来自 Eumetsat MetOp-A/B 卫星平台上的 GOME-2 (Global Ozone Monitoring Experiment-2) 传感器中第 734-758 nm 波段的 SIF 值 (Joiner et al. 2016)。GOME-2 的格网化逐月 SIF 数据作为预测模型的输入变量。

地表温度 (LST): 本研究从 MYD11A2 Version 6 获取了夜间地表温度 (LST_{night})，该版本提供了 1200 米空间分辨率的 8 天平均地表温度，其中每个像元是在 8 天窗口内 MOD11A1 LST 像元的平均值。本研究将 LST_{night} 的开尔文单位转换为摄氏度，并基于

特定的地表温度和测定的物候参数提取了水稻生长季节和各个物候阶段的开始和结束时间。

本研究中使用的 MODIS 格网化遥感数据在 Google Earth Engine (GEE) 上进行了数据预处理、最大值合成以及本地下载, 并进一步基于 MODIS 地表反射率数据计算归一化植被指数 (NDVI)、增强植被指数 (EVI)、地表水指数 (LSWI) 以及植被近红外反射率 (NIR_v)。具体的计算公式如下:

$$EVI = G \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + C_1 \times \rho_{Red} - C_2 \times \rho_{Blue} + L} \quad (2-3)$$

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad (2-4)$$

$$LSWI = \frac{\rho_{NIR} - \rho_{SWIR}}{\rho_{NIR} + \rho_{SWIR}} \quad (2-5)$$

$$NIR_v = NDVI \times \rho_{NIR} \quad (2-6)$$

其中 ρ_{Red} , ρ_{NIR} , ρ_{SWIR} , and ρ_{Blue} 分别代表红波段、近红外波段、短波红外波段和蓝波段的地表反射率值。 L 表示冠层背景系数, 用于解决冠层内非线性、不同近红外和红外辐射的传递问题。而 C_1 和 C_2 则是气溶胶抗性系数, 通过蓝波段对红波段进行校正, 以消除气溶胶在红波段的影响 (Huete et al. 2002)。EVI 公式中的参数分别设置为: $L = 1$, $C_1 = 6$, $C_2 = 7.5$, and $G = 2.5$ 。在数据处理过程中, 本研究使用 MODIS 的质量控制波段移除了质量较差的观测数据 (置信水平为 67-100%), 包括云层、卷云、雪和冰。最终, 本研究保留了质量较高的像元, 以建立模型并制作水稻分布地图。

为了更深入地分析非气候因素的影响, 本研究额外考虑了灌溉对水稻生长的影响。由于在朝鲜及其周边地区缺乏公开可用的灌溉数据, 并且灌溉的时间、量和方法存在较大的不确定性, 因此本研究选择使用水耗用系数 (WCE) 即地表蒸散发 (来自 MOD16A2, 表 2-1) 与降水的比率以代替灌溉活动, 对应的灌溉期为 2001 年至 2017 年。此外, 我们对朝鲜及其周边地区的水稻 WCE 进行了掩膜提取和平均计算。

(2) 陆地生态系统模型输入数据

本研究同样构建了长期的空间数据集, 以 5 分的空间分辨率来驱动 DLEM v4.0 模型, 包括大气 CO₂ 浓度、氮沉降、土壤类型、土地覆盖变化、作物轮作、氮肥和粪肥施用、灌溉活动、耕作强度和作物物候期等 (表 2-5)。1860 年到 2018 年的历史逐日气象数据集 (降水、太阳辐射、最高、最低和平均温度) 是基于北美陆地数据同化系统产品 (Mitchell et al. 2004; Xia et al. 2012)、气候研究—国家环境预测中心数据集 (Mitchell

and Jones 2005) 和 IPSL 气候模型数据集 (Boucher et al. 2020) 中使用校正的降尺度方法重建的 (Liu et al. 2013)。从 1860 年到 2018 年的月平均大气 CO₂ 浓度数据来自于 NOAA GLOBALVIEW-CO₂ 数据集, 该数据集基于大气和冰芯测量获得 (www.esrl.noaa.gov)。从 1860 年到 2018 年的月平均大气氮沉降数据来自于国际全球大气化学 (IGAC) /平流层过程及其在气候中的作用 (化学—气候模型倡议, CCMI) (Eyring et al. 2013)。土壤物理和化学性质来自 ISRIC - WISE 全球土壤剖面数据集 (Batjes 2008)。从 1960 至 2018 年的年度土地利用和覆盖变化数据集 (包括耕地覆盖比例) 来自 Yu and Lu (2018)。1910 年到 2018 年的年度作物轮作数据集是通过整合美国农业部 (USDA) 的作物数据层产品和 USDA 国家农业统计服务 (NASS) 的县级作物种植面积调查数据而开发的, 并采用了 Yu et al. (2018) 中的空间化方法。从 1910 年到 2018 年的年度作物特定氮肥施用数据是使用 USDA-NASS 的州级氮肥施用率 (Mehring et al. 1957) 和 USDA - ERS (2019) 的国家级商业氮肥消费数据重建的 (Cao et al. 2018)。从 1860 年到 2018 年的年度粪肥施用数据集来自于 Bian et al. (2021)。从 1950 年到 2018 年的年度作物特定灌溉数据集是基于县级灌溉再分析数据集 (McManamay et al. 2021) 和 USDA-NASS 县级灌溉农田面积进行空间降尺度处理得到的, 并且使用 MODIS 灌溉农业数据集 (MIrAD) 作为基础地图 (Pervez and Brown 2010; Brown and Pervez 2014)。1960 年到 2018 年的年度耕作强度数据集是来自于保护技术信息中心 (<https://www.ctic.org/CRM>) 的国家作物残留管理调查 (CRM) 数据 (1989 年至 2011 年) 中的县级耕作实践调查数据。其中缺失年份的耕作分布图与最近年份保持一致。CRM 数据集中原始的五种耕作方式被重新组织成四种类型, 通过将 CRM 中的垄耕和覆盖耕作类型合并为 DLEM v4.0 中的保护耕作类型。县级 CRM 数据集与 CDL 导出的作物轮作地图和 USDA-NASS 的作物种植面积相结合, 估算了历史时期耕作实践的空间分布。州尺度最早和最晚的作物种植日期是从 USDA-NASS 的调查报告 (Nass 2010) 中获得的, 该报告提供了大多数历史年份的种植和收获窗口。其他辅助数据, 包括地形和河网数据, 均源自之前的研究成果 (Tian et al. 2010a; Tian et al. 2012; Xu et al. 2019; Tian et al. 2020)。

表 2-5 陆地生态系统模型所用的驱动数据

Table 2-5 Input datasets to drive DLEM v4.0

数据类型	时间跨度	空间分辨率	时间分辨率	数据源
Climate (precipitation, solar radiation, maximum, minimum and mean temperatures)	1860–2018	5 arc-min	Daily	North American Land Data Assimilation System product; the Climate Research Unit-National Centers for Environmental Prediction dataset; and the IPSL Climate Model dataset
CO ₂ concentration	1860–2018	5 arc-min	Monthly	NOAA GLOBALVIEW-CO2 dataset
Nitrogen deposition	1860–2018	5 arc-min	Yearly	International Global Atmospheric Chemistry (IGAC)/Stratospheric Processes and Their Role in Climate (SPARC) Chemistry–Climate Model Initiative (CCMI)
Soil physical and chemical properties	One time	5 arc-min	One time	ISRIC-WISE Harmonized Global Soil Profile dataset
LULC (e. g., cropland fraction)	1860-2016	5 arc-min	Yearly	Yu and Lu (2018)
Crop rotation maps	1910–2018	5 arc-min	Yearly	the United States Department of Agriculture (USDA) Cropland Data Layer (CDL) product, the USDA-National Agricultural Statistics Service (NASS) survey data of county-scale crop planting area Yu et al. (2018)
Crop-specific nitrogen fertilizer use rate	1910–2018	State-level	Yearly	state-level N fertilizer use rates from USDA-NASS and the national-level commercial N fertilizer consumption data
Manure nitrogen application	1960–2018	5 arc-min	Yearly	Bian et al. (2021)
Crop-specific irrigation map	1950–2018	5 arc-min	Yearly	MODIS Irrigated Agriculture Dataset (MIrAD); county-scale irrigation reanalysis dataset derived from the United States Geological Survey (USGS); the USDA-NASS county-scale irrigated cropland area
Tillage map	1960–2018	5 arc-min	Yearly	county-scale tillage practices survey data obtained from the National Crop Residue Management Survey (CRM) of the Conservation Technology Information Center
The earliest and latest crop planting dates	One time	State-level	One time	USDA-NASS survey report (NASS, 2010)
Auxiliary data (e.g., topography and river network)	One time	5 arc-min	One time	Obtained from previous DLEM studies (Tian et al., 2010, 2012b, 2020b; Xu et al., 2019)

注：该表格根据 You et al. (2022) 重新绘制

2.2.3.2 划分水稻物候期

本研究将朝鲜水稻生长季划分为多个物候阶段，旨在实现以下两个目标：（1）计算移栽期并以提取年际水稻种植分布；（2）确定不同物候阶段的植被指数，以预测水稻生产力。水稻的生长季通常包括播种、移栽、分蘖、拔节、抽穗和成熟阶段。由于朝鲜纬度较高，在所有年份种水稻均为一年一熟。水稻通常于4月底灌溉，5月底移栽。在6月和7月，秧苗迅速生长，覆盖整个稻田（表 2-4），并最终在9月底成熟收获（Zhou et al. 2016）。

水稻播种日期受温度限制，尤其在中高纬度的寒冷低温地区。考虑朝鲜及其周边地区地理范围广泛，不同纬度的水稻播种开始生长的时间不同。因此，本研究采用了遥感和气象观测数据，以分析地表温度的变化情况并验证地表温度数据用以替代站点气温数据的可行性。并将这一方法扩展应用到其他地区。此外，本研究利用 MODIS 的夜间地表温度（LST）数据来确定水稻生长季的起始和结束时间（Zhou et al. 2016）。具体而言，本研究将 0°C 开始出现的时间作为水稻生长季的开始时间，然后依次定义不同物候阶段的开始时间。同时，根据物候日历（表 2-4），本研究将水稻生长季划分为四个阶段，即播种-移栽、移栽-分蘖、分蘖-抽穗、抽穗-成熟。因此，四个物候期的持续时间分别设置为 50 天、50 天、40 天和 40 天，以匹配物候日历和遥感图像（表 2-4）。

2.2.3.3 水稻分布制图

水稻的分布和面积信息是产量评估的重要因素。尽管存在许多全球水稻分布图，但高空间分辨率的年度水稻分布图却相对稀缺。因此，本研究采用了基于物候和像元的水稻制图（PPPM）方法（Xiao et al. 2005; Xiao et al. 2006; Dong et al. 2016）生成了 2000 至 2017 年的水稻分布地图，文中以 2015 年的为例展示了水稻的空间分布以及验证精度，PPPM 方法的主要步骤和参数见图 2-4。

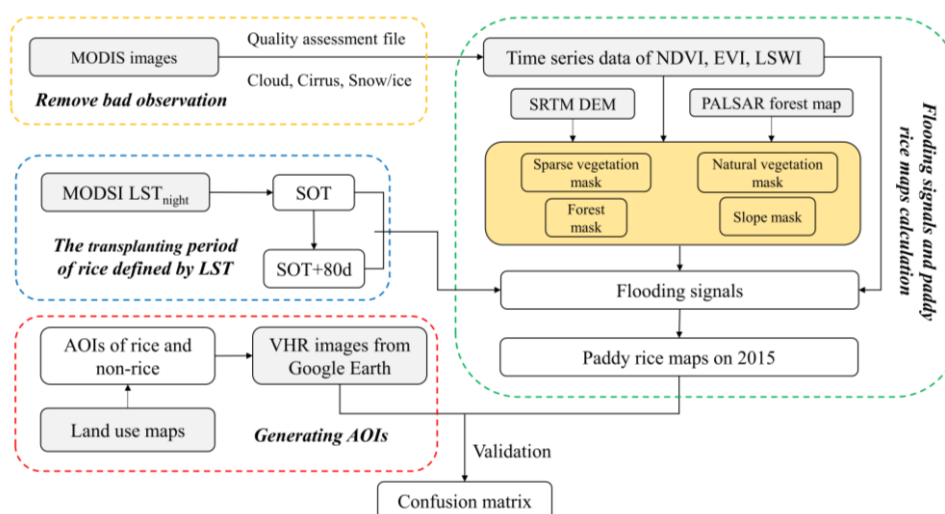


图 2-4 区域水稻分布提取的工作流

Fig. 2-4 The flowchart of rice paddy map using the PPPM method

PPPM 基于陆地表面水体指数 (LSWI)、归一化植被指数 (NDVI) 和增强型植被指数 (EVI) 的时间序列, 以检测从移栽到早期生长阶段的水稻的淹水特征 (Xiao et al. 2005; Xiao et al. 2006)。LSWI 的有效性已被证明适用于陆地表面的水分含量 (Qin et al. 2015)。尽管在移栽阶段的淹水信号是特定于水稻的, 但湖泊、河流和湿地也可能影响淹水信号。为了去除非水稻区域, 本研究根据过去研究提出的定义, 生成了一系列的掩膜, 有关掩膜规则的详细信息, 请参阅 (Dong et al. 2015; Zhang et al. 2015a)。先前的研究表明, LSWI 与 NDVI (或 EVI) 之间的关系可以有效地识别出淹水信号。因此, 本研究根据以下规则确定了淹水信号: $LSWI > EVI$ 或 $LSWI > NDVI$ 。鉴于 MODIS 影像的时间间隔较长且可用影像较少, 本研究将水稻移栽的持续时间从 50 天延长到 80 天, 以更有效地检测淹水信号 (Dong et al. 2016)。关于淹水信号的规则如下所示:

$$Flood = \begin{cases} 0 & (LSWI_T \leq EVI \text{ and } LSWI_T \leq NDVI) \\ 1 & (LSWI_T > EVI \text{ or } LSWI_T > NDVI) \end{cases} (SOT < T < EOT) \quad (2-7)$$

其中 $Flood$ 表示淹水状态, 移栽阶段的开始 (SOT) 和结束 (EOT) 是基于上述规则定义的, T 则表示观测的时间段。然后, 本研究采用了淹水频率来排除不良的淹水信号。在具有良好质量观测数据的单个像元基础上, 计算淹水频率 (FF), 具体公式如下:

$$FF = \frac{N_{flood}}{N_{good}} \quad (2-8)$$

其中 N_{flood} 是在移栽阶段在良好质量观测基础上被确定为水稻的格点数量, N_{good} 是移栽期内良好质量观测的格点数量。最后, 当格点的 FF 值大于 10% 时, 被定义为水稻种植 (Dong et al. 2016)。

2.2.4 统计数据

水稻产量的统计数据来自中国辽宁省和吉林省统计局在 2007 年至 2016 年期间发布的公开可用的统计年鉴, 包括县级水稻单产和总产。本研究进一步移除了每个县缺失的产量观测和总产低于 1 万吨的情况, 因为这被视为小农户的水稻种植, 难以被大尺度卫星观测到。因此, 本研究从统计年鉴中获得了 602 个县级单产观测和 537 个总产观测。需要说明的是研究区的农民并不直接向政府机构提交生产力报告, 这意味着该数据可能存在无法评估的不确定性。尽管存在这种不确定性, 但这仍然是最可靠和最容易获取的产量统计数据。本研究还使用了联合国粮食及农业组织 (FAO) 提供的全国水稻产量数据以评估最终的预测结果 (<http://www.fao.org/faostat/en/>)。此外, 本研究从联合国世界粮食计划署 (WFP) 的报告中收集并平均了 2018 年和 2019 年朝鲜的省级水稻产量数据 (<https://www.wfp.org/publications/>) 以验证被预测水稻生产力的空间分布。鉴于每个省份的产量比率在短期内变化不大, 基于临近时间段的空间验证是可以

接受的。

本研究额外搜集了公开的统计数据用于社会经济恢复力的分析，包括 FAO 统计的水稻产量、水稻进出口量和人口规模；联合国统计司的国内生产总值（GDP）以及世界银行的 0-14 岁人口、15-64 岁人口、农村人口、能源利用、电力接入、学校入学率、专利申请和人均净官方发展援助数据等（表 2-6 和表 2-7）。数据类型均为 2000 年至 2019 年的国家尺度统计。FAO 的数据质量通常分为十个类别：“Unofficial figure, Symbol for indigenous or liveweight meat, Official data, Aggregate (may include official; semi-official; estimated or calculated data), Calculated, FAO estimate, Calculated data, FAO data based on imputation methodology, Data not available, and Trend”。本研究使用的数据中，超过 95% 来自“Official data”和“Aggregate”类别，以确保高质量的数据。此外，农业生产中的氮和磷肥施用数据由 Lu and Tian（2017）提供，他们在 $0.5^{\circ} \times 0.5^{\circ}$ 的空间分辨率下开发了 1961-2013 年全球网格数据，并免费发布。

表 2-6 社会恢复力相关的脆弱性指标

Table 2-6 The vulnerability indexes for social resilience

社会恢复力因素	脆弱性指标	缩写
Population development (S)	Population ages 0-14 (% of total population)	Pop. 0-14
	Population ages 15-64 (% of total population)	Pop. 15-64
	Rural population (% of total population)	RP
Resources use (H)	Energy use (kg of oil equivalent per capita)	EU
	Access to electricity (% of population)	AE
Science and education (S)	School enrollment, tertiary (% gross)	SE
	Patent applications	PA
Economic development (H)	Net ODA received per capita (current US\$)	NOR
	GDP per capita	GDP
Agricultural input (H)	Nitrogen fertilizer use	N
	Phosphorus fertilizer use	P
	Irrigation	Irrigation

注：S 和 H 分别代表软适应措施和硬适应措施。ODA 和 GDP 分别代表官方发展援助和国内生产总值。

2.2.5 其他数据

本研究基于 2015 年空间分辨率为 1 米的高分辨率（VHR）影像以及来自全球地理参考田野照片库（www.eomf.ou.edu/photos/）的田间照片，对水稻分布图的准确性进行了评估。有关田间照片的详细信息，请参见（Dong et al. 2016）。本研究从谷歌地球收集了历史 VHR 影像，并使用分层随机抽样方法，以确保合理的样本点分布（图 2-5）。具体而言，首先根据 2015 年 MCD12Q1 的土地利用数据集，将朝鲜以及周边地区划分

为若干分层（水稻、旱地作物、森林和其他天然植被、水体以及建设用地）。其次，在每个分层中生成了随机样本，进一步生成了矩形缓冲区（200 米×200 米）作为感兴趣区域（图 2-5b）。再次根据历史 VHR 影像和田间照片（如果有）检查并保留了具有纯净土地覆盖的感兴趣区域，那些没有清晰土地覆盖的 AOIs 被移除。最后，将水稻划分为水稻区域（992 个 AOIs/42,400 个像元），将其他作物、森林和其他天然植被、水体以及建设用地划分为非水稻区域（2691 个 AOIs/121,753 个像元）。

本研究还基于 GEE 平台中 SRTM 数字高程数据第 4 版的 90 米空间分辨率数字高程模型（DEM），计算每个栅格单元的高程和坡度。

表 2-7 基于社会经济水平的社会恢复力相关文献参考

Table 2-7 Reference for social-economic factors for social resilience

社会恢复力因素	参考文献
Population development	O'Neill et al. 2010; Wang 2020
Resources use	Riahi et al. 2017; Parikh et al. 2012; Fuso Nerini et al. 2018
Science and education	O'Neill et al. 2020; Crespo Cuaresma et al. 2014; Lutz et al. 2008, 2014;
Economic development	Nakhoda et al. 2013; Cinner and Barnes 2019; Smit and Wandel 2006
Agricultural input	Wang et al. 2021; Challinor et al. 2014

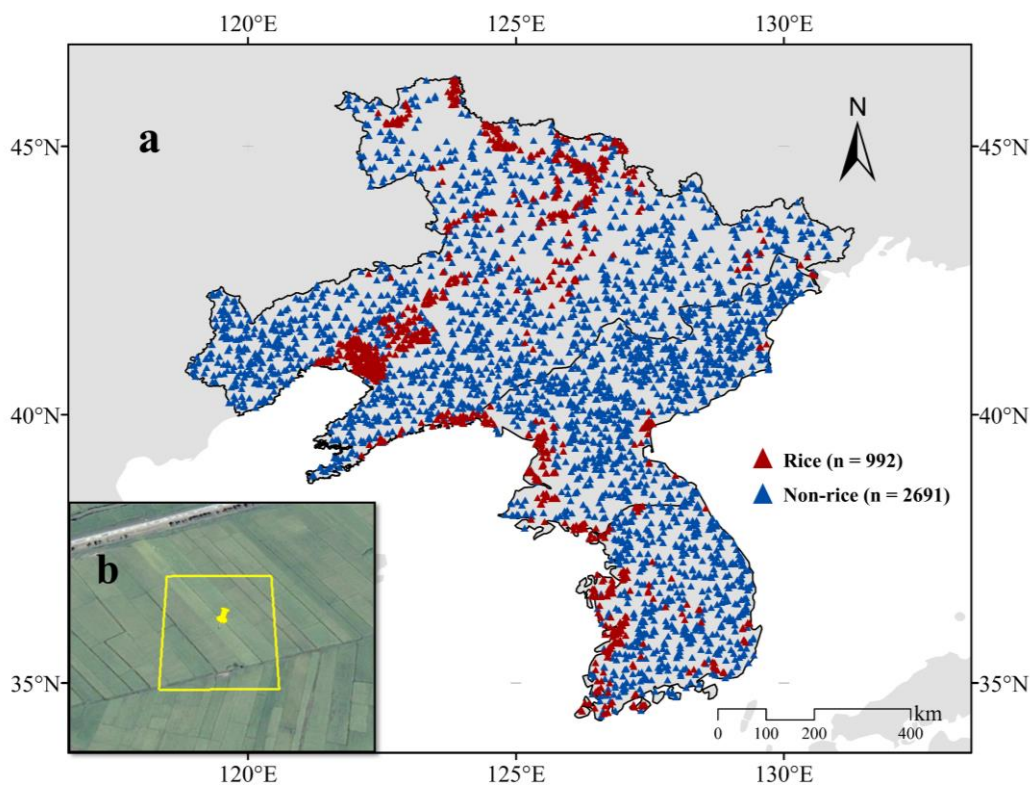


图 2-5 基于高分辨率遥感图像的 2015 年水稻验证点分布

Fig. 2-5 Distribution of rice validation points in 2015 based on VHR images (Shi et al. 2022)

2.3 研究方法

2.3.1 多源模型模拟

2.3.1.1 经验模型

(1) 统计模型

多源线性回归 (Multiple Linear Regression) 是统计学中一种用于建立和分析多个自变量与一个连续因变量之间关系的方法。它是简单线性回归的扩展, 适用于多个自变量对因变量的影响情况。多源线性回归旨在通过建立一个线性模型, 描述自变量和因变量之间的关系, 从而进行预测、解释和推断。多源线性回归的基本形式可以表示为:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon \quad (2-9)$$

其中 Y 是因变量 (被预测的值), β_0 是截距项, $\beta_1, \beta_2, \dots, \beta_p$ 是各个自变量的回归系数, 表示自变量对因变量的影响程度, X_1, X_2, \dots, X_p 是自变量的值, ε 是误差项, 表示模型无法解释的随机变化。

(2) 机器学习模型

与线性回归相比, 非线性模型解释了气候变量的非线性响应, 并揭示了相关变量的影响。本研究对比了三种非线性模型 (随机森林、支持向量机、人工神经网络) 的表现, 并筛选最优模型用于后续的水稻生产气候风险和缓解途径评估研究中。

随机森林模型 (RF): RF 是一种使用多个分类器的集成模型。RF 通过增加训练数据的复杂性来提高泛化精度, 并避免过拟合问题 (Breiman 2001)。RF 模型利用随机多个训练集和特征生成不同的回归树, 每个回归树独立抽样并分布相同 (Breiman 2001)。每个回归树通过分支产生不同的结果, 而随机森林回归模型的预测结果是基于所有树的平均值 (Breiman 2001)。本研究中使用 R 程序中的 “randomForest” 包构建了 RF 模型。先前的研究证明, 参数 “mtry” 作为变量数的平方根足以使模型表现优越, 并且参数 “ntree” 设置为大于 1000 时模型达到稳定状态。

支持向量机 (SVM): SVM 是一种基于结构风险最小化和统计理论的机器学习算法 (Zendehboudi et al. 2018)。本研究使用 R 程序中的 “e1071” 包构建了 SVM 模型。通过径向基核函数和网格搜索来确定最佳的惩罚系数和核参数以减少分类错误, 而其余参数设置为默认值。

人工神经网络 (ANN): ANN 能够自动地建立变量之间的非线性映射关系。无需建立主导关系, 样本也不需要满足独立或正态分布。本研究使用 R 程序中的 “nnet” 包构建了反向传播神经网络模型。该模型包括输入层、隐藏层和输出层, 分别设置为与输入变量数量相同的数值、10 (神经元) 和 1 (预测产量) 的节点数目。参数 “decay” 和

“maxit”分别设置为0.01和1000，而其余参数设置为默认值。此外，在构建ANN模型之前对所有数据进行了标准化处理。

(3) 多重共线性分析

多重共线性分析 (Multicollinearity Analysis) 是在多重线性回归模型中，用于识别和评估自变量之间共线性 (collinearity) 问题的一种统计方法。两个或多个自变量之间存在高度相关性，可能会造成回归系数估计的不稳定和难以解释的影响。共线性可能导致以下问题：(1) 系数不稳定性：高度相关的自变量可能导致回归系数估计值在不同样本中波动较大，使得模型的解释性降低；(2) 解释力下降：由于共线性问题，难以区分每个自变量对因变量的独立影响，从而降低了模型对因变量变化的解释能力；(3) 假设检验失效：共线性可能导致回归系数的显著性检验结果不准确，影响对模型的统计推断。

方差膨胀因子 (Variance Inflation Factor, VIF) 是多重共线性分析中常用的指标，用于评估多重线性回归模型中自变量之间共线性的程度。VIF 衡量了在模型中某个自变量的方差增加的程度，由于共线性而引起的方差膨胀。VIF 越大，表示自变量与其他自变量之间存在较强的相关性。VIF 的计算方式是基于回归模型的残差分析。假设我们正在考虑模型中的第 i 个自变量，剩余的自变量标记为 $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_p$ ，其中 p 是自变量的总数。VIF 的计算公式如下：

$$VIF_i = \frac{1}{1 - R_i^2} \quad (2-10)$$

其中 R_i^2 是仅使用剩余自变量来预测第 i 个自变量的决定系数，即将第 i 个自变量回归到其他自变量上所得到的拟合优度。此外，复杂的模型和公式使用了大量的栅格数据，导致了较重的计算负担和较长的计算时间。因此在建模之前，本研究通过方差膨胀因子测试了多重共线性，以减少在归因分析中的计算负荷和干扰。当 VIF 值超过 10 的变量通常被认为存在严重的多重共线性，应予以排除。本研究在 R 程序中使用“car”包的“vif”函数进行了 VIF 测试。通过 VIF 分析，本研究排除了平均温度变量，剩余变量保证了在后续分析中具有较低的多重共线性 (表 2-8)。

2.3.1.2 生态系统光能利用率模型 (半经验模型)

传统的光能利用率模型在计算 GPP 时需要分别估计 FAPAR 和 ε (图 2-6)。然而，大量气象强迫数据和经验参数的使用限制了传统模型的应用场景和表现。并且计算 GPP 的流程中本身包含了气象因子，因此不能用于环境因素的归因分析。本研究开发了一种基于机器学习改进的光能利用率模型以估算区域作物生产力。具体而言，利用 $VIs \times PAR_{TOC}$ 的来估计 GPP，意味着 VIs 可以更明确地用作生态系统用光利用效率 ($eLUE$) 的度量，因此对于特定通量站的生态系统光能利用率 ($eLUE$) 定义为 GPP 和

光合有效辐射 (PAR_{TOC}) 的比率:

$$eLUE_{TOC} = \frac{GPP}{PAR_{TOC}} = f(VIs) \quad (2-11)$$

表 2-8 去除多重共线性因素后环境变量的方差膨胀因子

Table 2-8 VIF of environmental variables after removing multicollinearity factors

情景	变量	方差膨胀指数	变量	方差膨胀指数
SHP scenarios	SIF	1.263465	EVI_heading	1.846721
	ET	1.766692	EVI_tillering	3.282167
	Precipitation	2.751896	EVI_transplant	4.463249
	solar	4.185720	LAI_heading	2.093355
	Maxt	3.436204	LAI_tillering	6.686988
	Mint	4.661015	LAI_transplant	5.500101
WGP scenarios	Rice area	1.551720	EVI_tillering	3.406763
	SIF	1.278514	EVI_transplant	4.606789
	ET	1.884019	EVI_mature	3.220474
	Precipitation	2.893356	LAI_heading	2.508496
	solar	4.445239	LAI_tillering	7.647277
	Maxt	4.074025	LAI_transplant	5.790485
	Mint	4.730382	LAI_mature	4.637721
	EVI_heading	1.951327		

使用 8 天平均 GPP ($g C m^{-2}d^{-1}$) 和 8 天平均 PAR_{TOC} ($MJ m^{-2}d^{-1}$) 计算每个站点的 $eLUE_{TOC}$ ($g C MJ^{-1}$)。EVI、LAI 和 NIRv 分别用于表征植被的综合绿度、结构和光和信息, 通过模拟 $eLUE_{TOC}$ 与 VIs 的非线性关系构建 $f(VIs)$ 。这里我们使用随机森林模型探究光能利用效率和多项植被指数之间的非线性关系。然后将校验后的站点尺度 $f(VIs)$ 和植被遥感观测相结合, 预测区域生态系统光能利用率 ($eLUE_{TOC}$)。因此区域 GPP 可被描述为区域 $eLUE_{TOC}$ 和区域 PAR_{TOC} 的乘积:

$$GPP = eLUE_{TOC} \times PAR_{TOC} \quad (2-12)$$

为了校准和验证 eLUE 和 VIs 之间的非线性关系, 我们对两个通量站的数据集 (共 397 个样本) 进行标准化, 根据年份将其平均分为 10 子集。通过 10 折交叉验证计算每个子模型的模拟精度和误差 (更多细节见 2.4 节), 并取其平均值作为改进的光能利用率模型的模拟精度。

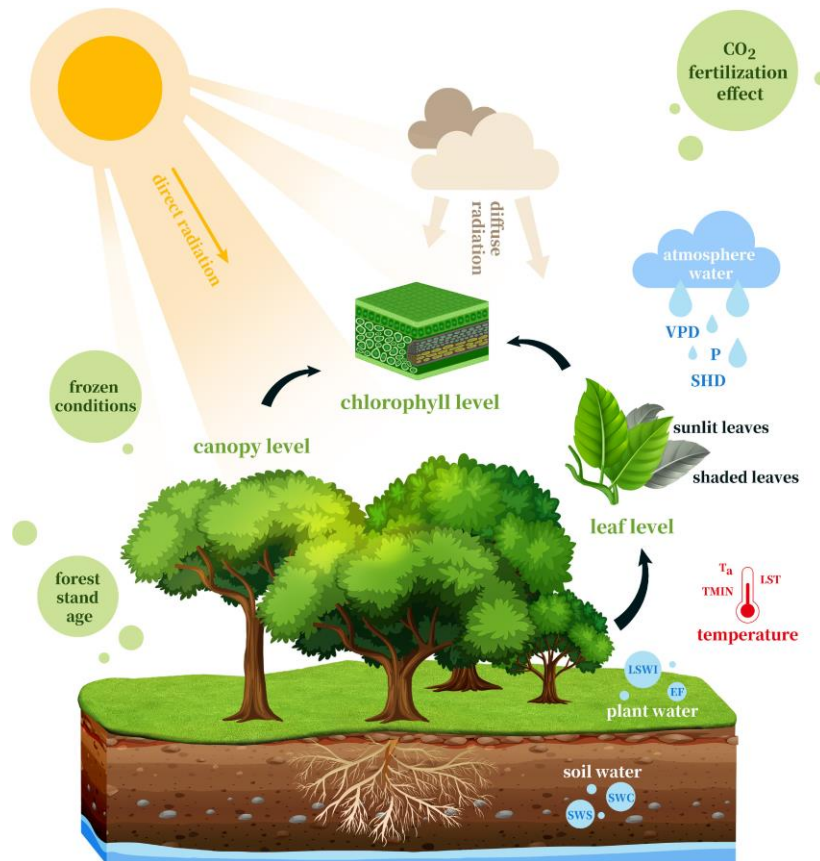


图 2-6 光能利用率模型的基本理论示意图 (Pei et al. 2022)

Fig. 2-6 The basic theory of the light use efficiency (LUE) models (Pei et al. 2022)

2.3.1.3 陆地生态系统模型（机理模型）

动态陆地生态系统模型（Dynamic Land Ecosystem Model, 简称 DLEM）是一个高度耦合的基于过程的生态系统模型，适用于多个时间尺度（从逐日到逐年）和空间尺度（从米到千米，从景观到区域到全球）以满足用户感兴趣的问题，其目标在于模拟自然和人为干扰对陆地生态系统结构和功能的影响，以及这些影响对地球陆地表面及相邻海洋区域的人类和自然系统的反馈。更具体地说，该模型整合了生物物理、水文、生物地球化学过程（碳、氮和磷循环）、植被动态、包括自然和人为压力在内的干扰（如气候变化、大气成分变化和土地利用/覆盖格局的变化、对农作物和森林的集约管理、野火、昆虫和疾病等），以及耦合的自然-人类系统中各个子系统之间的复杂相互作用。DLEM 模型能够对水、温室气体通量（包括 CO_2 、 CH_4 和 N_2O ）、陆地生态系统中碳、氮和水储存库的变化以及河流径流、从陆地向海洋的碳和氮输出等进行逐日的空间估计（Chen et al. 2007; Tian et al. 2010b; Xu et al. 2010）。

DLEM 包括五个核心组件：1) 生物物理学、2) 植物生理学、3) 土壤生物地球化学、4) 动态植被、5) 土地利用和管理，以及 6) 动物种群动态（图 2-7）。简言之，生

物物理组件模拟陆地生态系统内能量、水分和动量的瞬时通量以及与周围环境的交换，涉及微气象学、冠层生理学、土壤物理学、辐射传输、水分和能量流动以及动量运动。植物生理组件模拟主要生理过程，如植物物候、碳氮同化、呼吸、分配和周转等。土壤生物地球化学组件模拟养分组成的动态变化和基础微生物活动。该组件考虑了矿化、硝化/反硝化、分解、甲烷产生/氧化等生物地球化学过程，使 DLEM 能同时够估计多种痕量气体（ CO_2 、 CH_4 和 N_2O ）的排放。动态植被组件模拟由自然和人为干扰引起的植被结构动态，考虑了两个过程：气候变化时的生物地理的重新分布，以及干扰后植被的恢复和演替。土地利用和管理组件模拟耕地转换、造林（耕地弃耕）、森林管理（采伐、间伐、施肥和人工火灾）。动物种群动态组件模拟放牧对草地生产力、碳、营养和水动态的影响，以及植物对动物种群属性（如出生、死亡和种群大小等）的反馈作用。DLEM 强调对人类主导或管理的生态系统进行建模，包括农业生态系统、人工林和牧场。空间管理数据集，如灌溉、肥料使用、轮作和收获，可以用作调控生态系统动态的输入信息。它还模拟了城市化过程，并可以用于估计城市不透水地表和城市绿地管理对生态系统过程的影响。

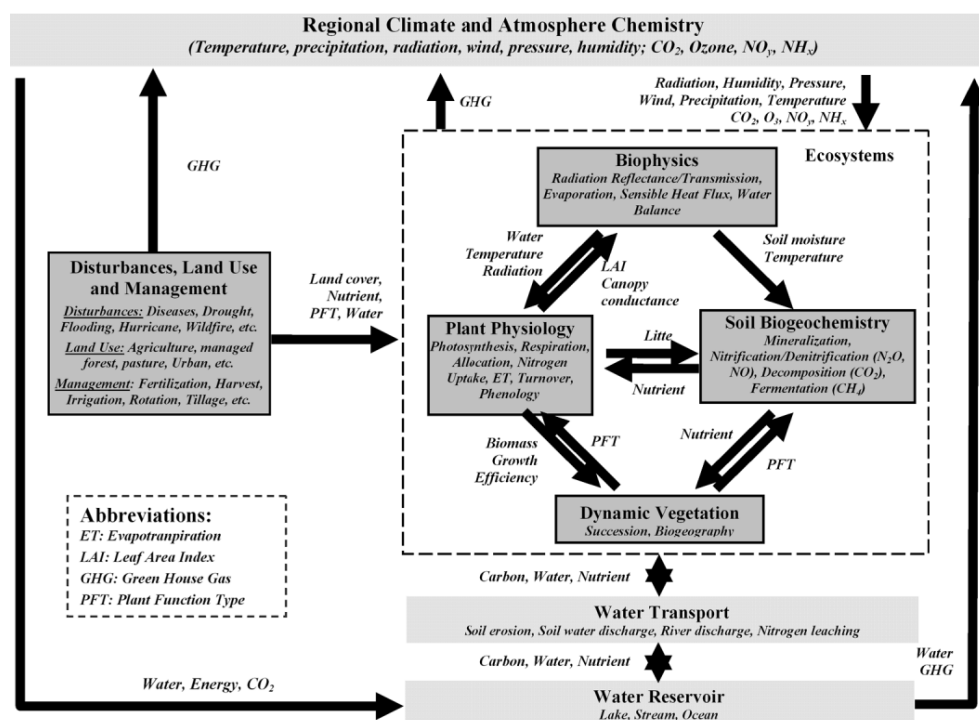


图 2-7 DLEM 模型框架

Fig. 2-7 Framework of DLEM (Tian et al. 2010c)

DLEM v4.0 模型的新农业模块是基于之前的版本（DLEM-Ag 和 DLEM-Ag2）进行开发的，包括了农作物动态生长模拟和主要管理实践（如施肥、灌溉和耕作）(Ren et

al. 2012; Tian et al. 2012; Zhang et al. 2018; You et al. 2022)。新模型在区域模拟精度和量化农业活动对生物圈-大气相互作用影响的能力方面取得了显著的改进，主要涉及作物物候发育、碳分配、产量形成、生物固氮和管理实践等方面。首先，本研究引入了特定农作物的物候发育过程，并考虑了与植物生长相关的环境压力。其次，本研究实施了一种新的动态碳分配方案，即以净同化物的分配比例为基础，根据不同植被库中的碳分配曲线进行调整，并根据水分、光照和氮素压力进行适应。第三，产量的形成被计算为生殖生长库中碳供应与籽粒充实所需的碳平衡。第四，本研究融合了一种新的生物固氮方案，其中固氮速率取决于土壤温度、湿度、氮利用效率、底物浓度和子物候期。最后，本研究将基本的管理实践纳入了 DLEM v4.0 中，即耕作、覆盖作物种植和作物基因改良，并使用实时轮作地图实现了动态轮作方案，以反映作物分布和类型的年度变化。

在 DLEM v4.0 模型中，净 CO_2 排放源于土壤碳库的周转，受到植被光合作用、凋落物积累、自养和异养呼吸以及生态系统内部的环境变化等机制的调控。 CH_4 交换是土壤孔隙水中产生、氧化和向大气的输送之间的平衡。 N_2O 模块设计用于捕捉生物硝化和反硝化过程，考虑到氮素供应、土壤特性以及热量和湿度状态。之前的研究详细介绍了新模型的产量形成和温室气体排放方式，碳变化与环境压力之间的相互作用，以及农业碳循环对人类管理的响应（Tian et al. 2010b; Ren et al. 2012; Lu et al. 2022b; You et al. 2022）。

DLEM v4.0 模型融入了四种耕作方式（免耕、少耕和传统耕作），这是基于耕作深度、混合效率以及耕作后覆盖土壤表面的残留物的比例而确定的（You et al. 2022）。耕作对农业生态系统的影响表现在三个方面：（1）由于耕作导致的表面残留物覆盖的变化，从而重新分布了土壤有机质和养分；（2）混合成分、容重、湿度和氮循环过程的变化（如硝化、反硝化和淋溶）；（3）土壤分解速率的变化。新模型在休耕期种植覆盖作物（例如冬季黑麦和豌豆），并将作物生物量留在下一季作物生长季节中（Huang et al. 2020）。作物基因改良对产量的影响通过两种机制实现：提高光合速率和增强作物对氮吸收的能力。

2.3.2 归因分析

（1）相关性分析

相关性分析是一种用于测量和评估两个或多个变量之间的关系程度的统计方法。相关性分析可以帮助我们了解变量之间的相互作用，以及它们之间是否存在线性关系。在相关性分析中，最常用的是皮尔逊相关系数（Pearson Correlation Coefficient）。皮尔逊相关系数衡量了两个连续变量之间的线性关系的强度和方向。它的取值范围在-1 到 1 之间，具体解释为：当相关系数为 1 时，表示两个变量完全正相关，即一个变量增加，

另一个变量也会增加，呈现出完全线性关系；当相关系数为-1 时，表示两个变量完全负相关，即一个变量增加，另一个变量会减少，呈现出完全线性反关系；当相关系数接近 0 时，表示两个变量之间没有线性关系或者关系非常弱。

(2) 变量重要性分析

本研究基于随机森林模型估算了多种环境因子对粮食生产的影响。在 R 语言软件中使用“importance”函数计算变量的贡献率。“Importance”的含义是增加或减少某一变量后模型准确性变化的程度，即基于未参与训练的样本进行计算得到的错误率，通常称为袋外误差（Out-of-Bag, OOB）。在本研究中，我们采用均方误差（MSE）百分比（%IncMSE）来衡量变量的重要性。具体而言，对一个变量进行排列，但保持 OOB 样本的其他变量不变。然后重新运行 RF 模型，从 OOB 中获得新的排列结果。变量的重要性是排列的 OOB 样本与原始 OOB 样本之间的平均差异（Liaw and Wiener 2002）。在数学上，解释变量的重要性定义为：

$$VI_x = \frac{1}{N_{tree}} \sum_{i=1}^N (y_{1,i} - y_{2,i}) \quad (2-13)$$

其中， $y_{2,i}$ 是由 RF 的原始 OOB 样本计算得出的； $y_{1,i}$ 是由排列后的 OOB 样本计算得出的； N_{tree} 是 RF 模型的树的数量。通常情况下，更高的变量重要性表示解释变量影响更大。

(3) 基于模拟试验的归因分析

本研究基于陆地生态模型进行了 11 个模拟控制试验，以归因于气候、CO₂、土地利用变化（包括作物轮作）、氮沉降、耕作、氮肥施用、粪肥、灌溉等因素对美国小麦（春小麦和冬小麦）产量和温室气体排放变化的影响，时间跨度从 1860 年到 2018 年（表 2-9）。具体而言，第一个模拟实验（S1）旨在使所有驱动因素保持在最早可用的年份。第二个模拟实验（S2）代表了美国小麦产量和温室气体排放的最佳估计，由历史数据输入驱动。由所有环境因素驱动的小麦净产量和温室气体排放变化被计算为 S1 和 S2 之间的差异。S3-S9 模拟试验都设置了一个不随时间变化的驱动因素（表 2-9）。并且单个驱动因素的贡献被计算为 S2 和 S3-S9 之间的差异。此外，本研究还基于 S10 和 S11 之间的差异来量化土地利用变化的影响，因为土地覆盖的变化可能也会影响到农业管理实践的输入（如氮肥和肥料）。因此，对于 S10 和 S11，我们保持所有管理措施在 1860 年水平，以区分没有管理措施影响下的土地利用变化的贡献。此外，本研究还设计了两种耕作情景，以模拟耕作对小麦产量和温室气体排放的潜在影响，这些耕作实践被固定为免耕（NT）和传统耕作（CT）（S12 和 S13）。

表 2-9 基于机理模型的情景控制试验

Table 2-9 Experiments design based on the mechanism model

序号	情景名称	Climate	CO ₂	Ndep	Tillage	Nfer	Manure	Irrigation	LULC
S1	Baseline	1860	1860	1860	1860	1860	1860	1860	1960
S2	With all drivers	1860-2018	1860-2018	1860-2018	1860-2018	1860-2018	1860-2018	1860-2018	1960-2018
S3	Without climate	1860	1860-2018	1860-2018	1860-2018	1860-2018	1860-2018	1860-2018	1960-2018
S4	Without CO ₂	1860-2018	1860	1860-2018	1860-2018	1860-2018	1860-2018	1860-2018	1960-2018
S5	Without N deposition	1860-2018	1860-2018	1860	1860-2018	1860-2018	1860-2018	1860-2018	1960-2018
S6	Without tillage	1860-2018	1860-2018	1860-2018	1860	1860-2018	1860-2018	1860-2018	1960-2018
S7	Without N fertilization	1860-2018	1860-2018	1860-2018	1860-2018	1860	1860-2018	1860-2018	1960-2018
S8	Without manure	1860-2018	1860-2018	1860-2018	1860-2018	1860-2018	1860	1860-2018	1960-2018
S9	Without irrigation	1860-2018	1860-2018	1860-2018	1860-2018	1860-2018	1860-2018	1860	1960-2018
S10	Climate+CO ₂ +Ndep	1860-2018	1860-2018	1860-2018	1860	1860	1860	1860	1960
S11	Climate+CO ₂ +Ndep+LULC	1860-2018	1860-2018	1860-2018	1860	1860	1860	1860	1960-2018
S12	No-tillage (NT)	1860-2018	1860-2018	1860-2018	ALL NT	1860-2018	1860-2018	1860-2018	1960-2018
S13	Conventional tillage (CT)	1860-2018	1860-2018	1860-2018	ALL CT	1860-2018	1860-2018	1860-2018	1960-2018

注: Climate 包括日平均、最低和最高气温、降水和太阳短波辐射。在利用 LULC 进行的模拟试验中, 由于资料有限, 假定 1960 年以前的小麦种植空间分布在 1960 年水平不变。此外, 由于模型模拟是基于单位面积进行, 因此土地利用变化的影响与小麦每年种植面积线性相关, 即: 年际 LULC 影响=模拟值₁₉₆₀ * (小麦逐年的面积变化) + 模拟值₁₉₆₀

本研究根据 100 年时间尺度内 CO₂、CH₄ 和 N₂O 的全球变暖潜势 (GWP), 以 g C (或者 g N) 为基础转化为当量 CO₂ 克数 (gram CO₂ equivalent) 的方式来计算净温室气体排放的总和 (IPCC 2021)。具体而言, GWP 表达为小麦耕地中 SOC 封存、N₂O 排放和 CH₄ 排放的 CO₂ 当量之和:

$$E_{CO_2} = (F_{CO_2} / 12) \times 44 \quad (2-14)$$

$$E_{N_2O} = (F_{N_2O} / 28 \times 44) \times 273 \quad (2-15)$$

$$E_{CH_4} = (F_{CH_4} / 12 \times 16) \times 27 \quad (2-16)$$

$$E_{GHG} = E_{CO_2} + E_{N_2O} + E_{CH_4} \quad (2-17)$$

$$GHGI = E_{GHG} / Y \quad (2-18)$$

其中 F_{CO_2} , F_{N_2O} , 和 F_{CH_4} 分别表示二氧化碳 (TgC yr⁻¹)、氧化亚氮 (TgN yr⁻¹) 和甲烷 (TgC yr⁻¹) 的通量。 E_{CO_2} , E_{N_2O} , 和 E_{CH_4} 则分别代表以 Tg CO₂ 当量为单位的二氧化碳、氧化亚氮和甲烷排放。 E_{GHG} , $GHGI$, 和 Y 分别表示净温室气体排放 (kg CO₂-eq ha⁻¹ yr⁻¹)、温室气体排放强度 (kg CO₂-eq kg⁻¹) 和小麦产量 (kg ha⁻¹ yr⁻¹)。

2.3.3 可迁移的产量预测框架

朝鲜是全球数据稀缺的代表性地区，预测其粮食生产力受限于可用的地面观测和统计。因此本研究以朝鲜及其周边地区（中国辽宁和吉林省）为例，提出了一个可迁移的框架，用于预测数据稀疏地区的水稻生产力。具体而言，基于气候相似性，使用中国辽宁和吉林省（源域）的预测因子来构建校准模型，然后将该模型转移到朝鲜（目标域）进行水稻生产力的预测和验证。本研究首先基于夜间地表温度数据（MODIS_LST）和物候观测数据（图 2-8 和表 2-4）计算水稻的物候期，并提取了 2007-2016 年间不同子物候期的植被指数作为预测因子，而后进一步采用 PPM 法绘制 2007-2016 年朝鲜和中国辽宁、吉林省的年际水稻分布图。上述步骤是通过 GEE 云平台上使用公开的遥感数据完成的。其次，基于源域的预测因子（即水稻分布和面积、不同子物候期的 EVI 和 LAI、气象变量、蒸散发和 SIF）以及公开可用统计数据（县级尺度水稻生产力）构建了四种生产力预测模型。本研究还比较了线性模型和机器学习模型（人工神经网络；支持向量机；随机森林）之间的模拟精度以获取最优的产量模拟，并进一步将最优模型迁移到朝鲜并预测两种不同生长情景下的水稻单产和总产。最后，使用 2012-2016 年联合国粮食农组织（FAO）的国家尺度数据验证了预报结果（图 2-8）。此外，本研究还收集了联合国世界粮食计划署（WFP）的朝鲜省级水稻生产力数据以验证其空间分布。可迁移的产量预测框架如图 2-8 所示，这一研究方法不仅有助于揭示气候极端事件对农业和社会经济系统的影响，还为解决粮食安全等问题提供了新的途径。

2.3.4 粮食生产的气候风险

本研究评估了未来 2040s（2021–2060）和 2080s（2061–2100）的气候变化和产量损失。未来的气温的相对变化（AAT、TXx 和 TNn）被计算为历史时期（1979-2017）与未来时期（2021–2060；2061–2100）温度均值的差异。对于生物量、TS、TP、TR20、SU30、FD0、R50、R25、R10 和 R1（表 2-2），相对变化被计算未来均值与历史均值之比。对于未来的产量损失，我们首先基于 FAO 的产量统计（productionF）和模拟的区域生物量计算了平均产量转换系数，即生物量与产量之比（记作为 α ，用以表示水稻生物量中有多少能够转化为实际产量）。公式如下：

$$P_{sta} = \sum B_{t1} \times \alpha_i \times A \quad (2-19)$$

$$\alpha_{mean} = \sum_{i=0}^n \alpha_i \div n \quad (2-20)$$

其中 P_{sta} 是 FAO 的水稻产量统计。 $\sum B_{t1}$ 表示由 RF_b 模型预测的每个格网生物量之和。 α_i 表示每年的转换系数， α_{mean} 是由 α_i 计算得出的历史时期平均的产量转换系数（2000-2017 年）。n 表示年数，A 表示像元面积（500 米 X 500 米）。

未来的水稻产量被计算为平均转换系数和 RF_b 模型预测的生物量的乘积：

$$P_{pre} = \sum B_{t2} \times a_{mean} \times A \quad (2-21)$$

其中, P_{pre} 代表未来的水稻产量。 $\sum B_{t2}$ 表示被预测的格网 GPP 的总和。最终, 本研究利用未来和历史的植被 GPP 以及产量数据, 计算出相对变化作为生产损失的度量。

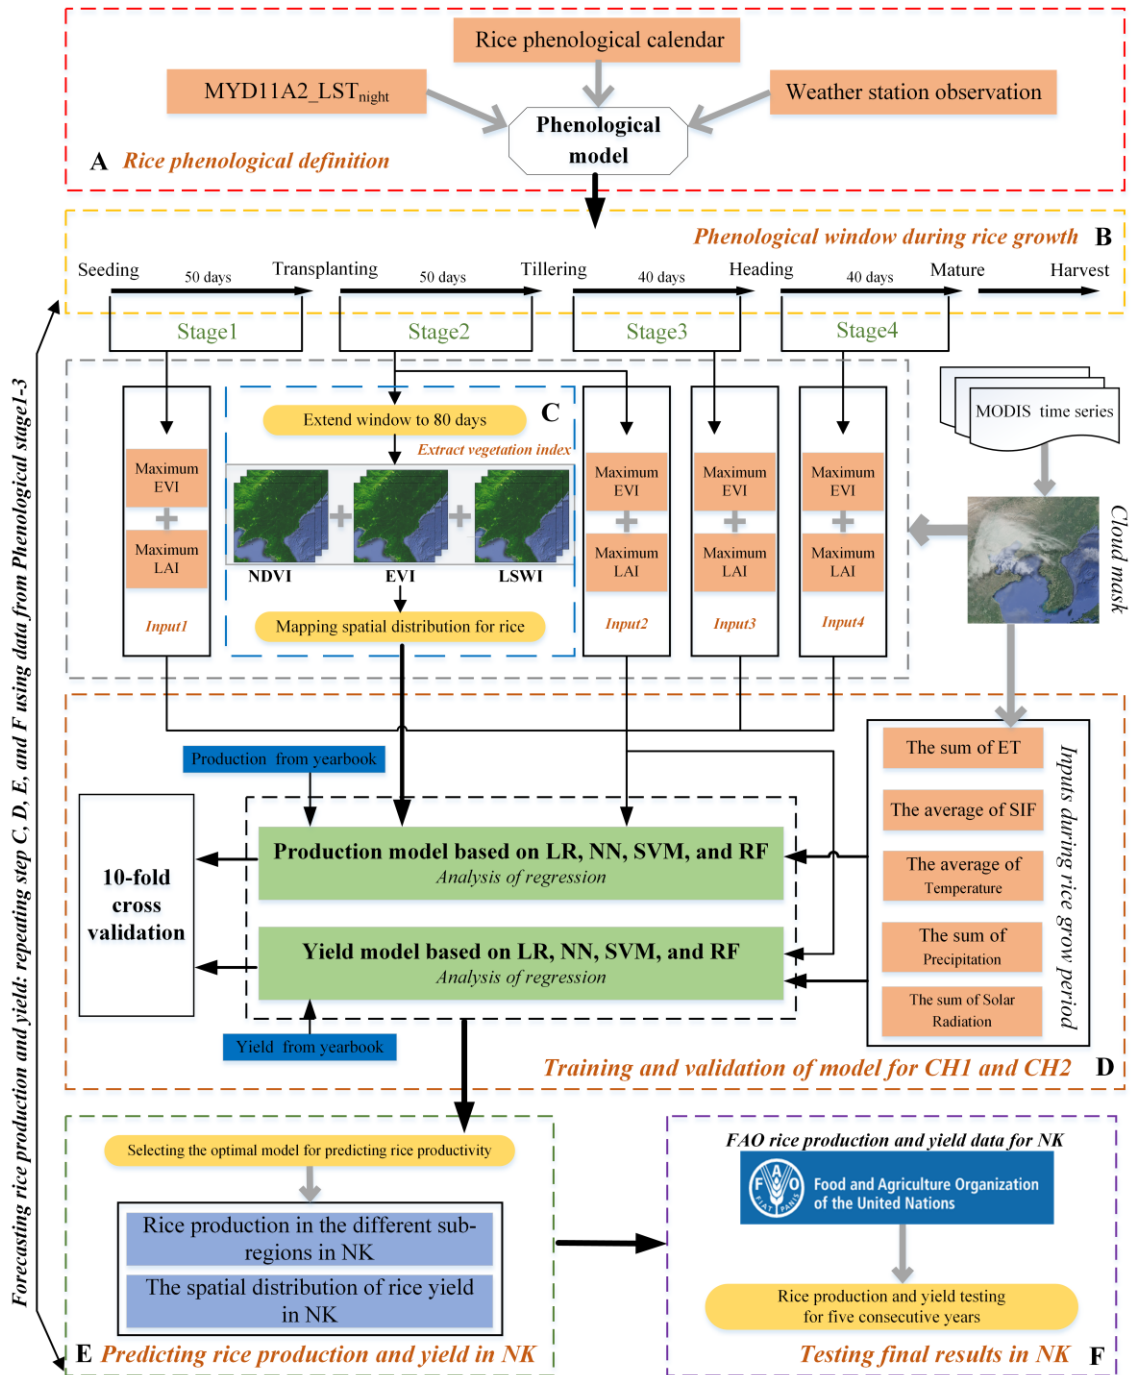


图 2-8 可迁移的生产力预测模型 workflow

Fig. 2-8 Workflow of the methodology for the transferable model of productivity prediction

2.3.5 作物生产对极端天气事件的响应及其敏感性变化

为了检测小麦产量和温室气体排放对极端干热事件（干旱、高温以及它们的复合事件）的响应以及敏感性动态变化，其中采用皮尔逊相关系数被用于表征长时间序列之间的响应关系，而 20 年滑动窗口法（从 1960-1979 年到 2009-2018 年）被用于分析窗口内极端干热事件与小麦碳变化（产量、温室气体排放以及温室气体排放强度）之间的响应变化（这里被称为敏感性变化）。具体而言，首先我们对研究时间段内的所有变量进行了线性去趋势处理。其次，在给定的时间窗口内，所有敏感性计算的结果都以时间窗口的最后一年作为标记，具体的处理细节可参考 Zhang et al. (2022b)。1979 年的 REDH-carbon 代表了从 1960 年到 1979 年间极端干热事件与小麦碳变化之间的线性关系（当 REDH-yield < 0, REDH-GHG > 0, REDH-GHGI > 0 时，表示为干热气候的负面影响；而当 REDH-yield > 0, REDH-GHG < 0, REDH-GHGI < 0 时，代表干热气候的正面影响）。最后，本研究使用一元线性回归方法计算了每个格点中的斜率和显著性（ P 值），以分析时间变化趋势（ $P < 0.05$ ）。此外，本研究使用 MK 检验来测试整个区域干热敏感性的总体趋势和显著性水平。

2.3.6 社会恢复力缓解气候变化

本研究提出的社会恢复力评估流程旨在评估气候变化（气候极端）和社会恢复力对区域粮食安全的贡献。本研究使用灵活的多源数据可以将该框架扩展到数据受限的全球其他地区（图 2-9）。首先，我们基于生态系统光利用效率模型结合中国辽宁省和吉林省通量塔观测和遥感指数（500 米空间分辨率和 8 天时间步长）模拟了区域生物量，并对预测生物量进行了交叉验证。此外，使用 ERA-5 再分析数据（原始 0.1° 的空间分辨率和逐日的时间步长）在 2000-2017 年的水稻生长季节内计算了朝鲜（NK）、韩国（SK）以及中国辽宁省和吉林省（CHN_1_2）的十二个极端气候因子，这些气象变量被用于构建随机森林模型。然后，我们通过 PPPM 和 MODIS 的卫星产品提取了年际水稻分布图，以掩膜非水稻区域。细节的工作流程如图 2-9 所示：

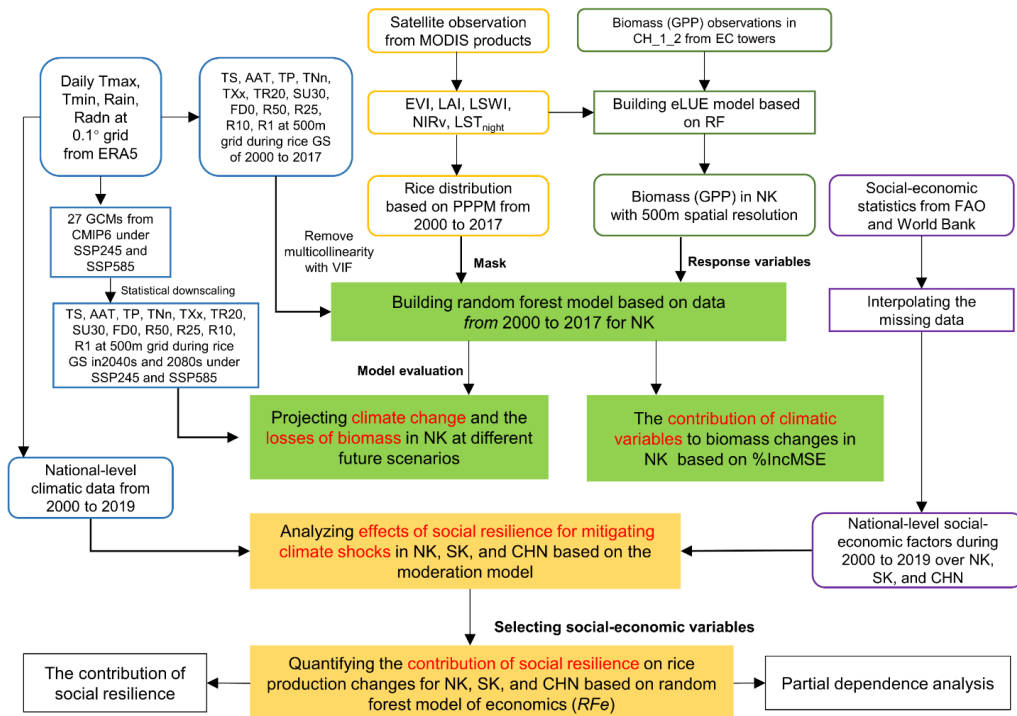


图 2-9 评估朝鲜粮食安全和社会恢复力效果的工作流程

Fig. 2-9 The workflow for assessing food security in North Korea and the effects of social resilience for NK and its neighbors

再次，对于气候冲击和未来的气候风险的评估，本研究采取了两个步骤。第一步：基于 2000-2017 年朝鲜水稻区域的格网气候变量和生物量构建了随机森林模型(RF_b)，同时还对该模型的稳定性进行了验证，并计算了各个变量的重要性。第二步：基于 RF_b 模型，结合 ERA-5 逐日的历史气候数据（1979-2017 年）以及 27 个全球气候模型在 SSP245 和 SSP585 情景下的未来气候数据，进行了统计降尺度。我们利用这些数据预测了朝鲜的气候风险和生物量损失，并评估了其在 2040s 和 2080s 的粮食安全状况。最后，对于朝鲜、韩国和中国，本研究基于 2000-2019 年的国家级气候变量（表 2-2）和社会经济变量（表 2-6，表 2-7），分析了社会恢复力减缓极端天气事件对水稻产量负面影响的潜力。同时，基于朝鲜、韩国和中国的部分依赖性分析，探究了影响水稻生产的四个关键社会经济因子的非线性响应变化，以定量化描述社会恢复力如何影响并调控水稻生产。

上述关键变量的选择基于先前研究的证据，该研究指出社会恢复力受这些经济和社会特征的影响。对于恢复力的关键理解在于，一旦系统超越某一临界点，它可能会转变到另一种状态，并且难以恢复到原始状态。因此，恢复力通常被定义为维持相同结构和功能的能力，并被描述为系统可以吸收或可能导致破坏的变化幅度。社会恢复力基于人类活动与生态系统之间的相互关系。当人们可以获得各种金融、技术和资源

以及资产时，他们通常更适应社会变化，因此以财富为基础的社会相对于贫穷社会更具适应环境变化的能力，而富裕人群比贫困人群有更强的恢复力。社会恢复力中教育是提高生产力和收入的关键，人口红利的很大一部分来自教育红利。此外，不断变化的人口结构是减缓和适应气候变化的一个直接社会经济挑战，其中老龄化和劳动力变化被认定为基本的社会经济问题（O'Neill et al. 2010; Wang et al. 2021c）。能源是社会经济发展的基本因素，也是消除贫困的重要支撑（Parikh et al. 2012; Riahi et al. 2017; Fuso Nerini et al. 2018），联合国千年发展目标强调了资源利用的重要性，提出了“实现人人都能获得经济适用、可靠和可持续的能源”以及“社会经济发展取决于对地球自然资源的可持续管理”这两个核心目标。值得说明的是，本研究还进一步考虑了农业生产中管理实践对于提升作物生产力以及抵抗气候变化负面影响的潜力。

鉴于社会恢复力变量中包含不连续性的社会经济数据，本研究使用了线性回归插值法来填补 2000 年至 2019 年间缺失的 FAO 和世界银行统计数据。缺失数据的范围、领域和插值结果如图 2-10 所示。具体而言，线性回归插值法很好地补缺了不连续地社会经济数据（包括能源利用、高等教育入学率、电力供应和专利申请），展示出较高的模拟精度和稳健的线性趋势，相应的 R^2 值分别为 0.70、0.99、0.99 和 0.92， P 值均小于 0.01（图 2-8）。因此，插值估算的结果可以被用于后续的模式构建和社会经济分析。

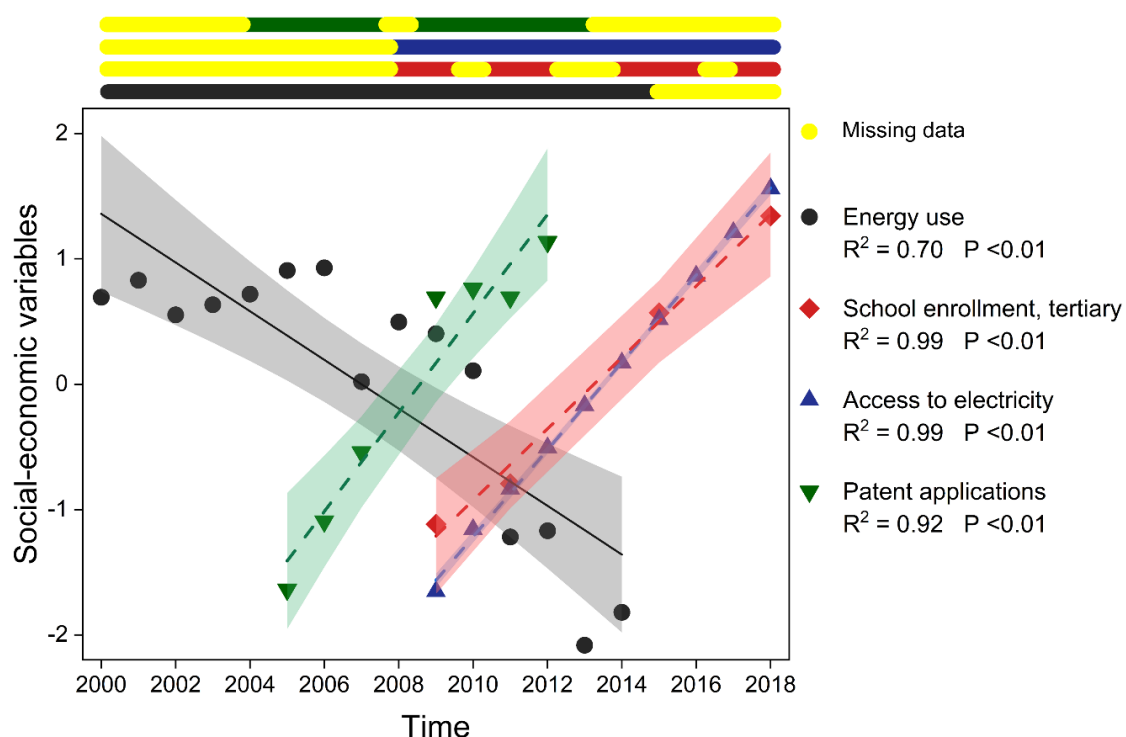


图 2-10 朝鲜社会恢复力缺失数据插补与验证

Fig. 2-10 Interpolation of missing data for social resilience and its performance in North Korea.

本研究采用调节模型来探究社会恢复力缓解气候冲击的潜力 (Hogan et al. 2020)。首先,我们对朝鲜、韩国和中国 (使用 CHN_1_2 中的气候数据替代) 的所有格点气候变量进行了区域尺度的平均计算,并与社会经济变量进行了匹配。其次,我们对所有变量进行了标准化,以便更有效地比较气候变化对水稻产量的积极和消极影响。再次,本研究基于多源线性回归模型筛选了对水稻产量变化影响的所有不利气候冲击和积极社会适应性因子。筛选后的消极气候冲击 (作为自变量) 和积极的社会适应性 (作为调节变量) 用于配对组合,构建潜在的产量调节模型。最后,本研究在潜在模型中引入了自变量和调节变量之间的交互作用,以初步探索社会适应性的缓解效应。具体而言,如果两个变量 (因变量 Y 和自变量 X) 之间的关系 (回归的斜率方向和大小) 依赖于第三个变量 (调节变量 Z), 则我们认为发生了调节作用。在这里,本研究考虑了一个简单的调节模型,即对于假设检验来说,存在以下关系:

$$Y = aX + bZ + cXZ + \varepsilon \quad (2-22)$$

其中 Y 、 X 、 Z 和 XZ 分别代表因变量 (水稻产量)、自变量 (负面气候冲击)、调节变量 (积极的社会适应性) 和调节项。其中 a 、 b 和 c 分别是每个回归项的系数, ε 表示误差。如果系数 c 显著 ($P < 0.1$), 则表示 Z 具有显著调节效应。方差分析被用于检验不同变量组合的显著性。

考虑到社会恢复力对水稻产量的影响通常是非线性的。由于随机森林回归模型在评估非线性关系方面表现出色,本研究基于 RF_e 模型 (表 2-10) 模拟社会经济变量与水稻产量之间复杂的响应关系,并使用 R 软件中的“ $A3$ ”包测试了每个变量以及模型的显著性水平。

表 2-10 本研究所用的基于随机森林的非线性模型

Table 2-10 List of non-linear models based on random forest used in this study

模型缩写	描述	数据	时间范围	应用
RF_b	Random forest model for baseline	Gridded rice biomass and climatic variables from remote sensing TS products	2000 to 2017	Building production model to project future rice losses with climate change.
RF_e	Random forest model for economics	Rice production and variables of social resilience from statistics	2000 to 2019	Quantifying the contribution of social resilience to rice production from 2000 to 2019.

RF_e 模型的参数 n_{tree} 和 m_{try} 分别设置为 500 和变量数量的平方根。此外,增加的均方误差 (MSE) 百分比和方差解释度被用作评估变量重要性和非线性模型的拟合优度 (细节见 2.4 节)。通过“random forest”包中的“ $partialPlot$ ”函数分析了输入变量的边

际效应，并评估水稻产量与最关键的四个影响因子之间的动态变化关系。对于 NK、SK 和 CHN，本研究采用了三折时间序列分割法的交叉验证，以检验 RF_e 模型的稳健性。与原始的交叉验证相比，本章研究将训练和验证集与时间序列一起划分，具体而言，我们以 2000 年至 2012 年的时间段作为第一折的测试数据，2013 年至 2014 年的时间段作为相应的验证数据，然后以每两年为一个时间间隔，以此方式循环遍历所有数据集。

2.3.7 气候智慧型耕作方案缓解气候变化

气候智慧型农业旨在增加作物产量、降低温室气体排放并且提升土壤质量，促进农业的可持续发展。在本研究中，GHGI 被计算为作物产量、非 CO_2 温室气体排放和土壤 SOC 的综合性指标，以检验极端干热环境下农业生产的可持续性。因此，气候智慧型耕作被定义为因气候和环境而异的能够在特定时间和地点降低 GHGI 干热敏感性（即 GHGI 对干热环境的敏感度）的耕作实践措施。本研究考虑了两种耕作情景（CT 和 NT，表 2-9）下小麦产量和温室气体排放的敏感性动态变化，通过与实际温室气体排放强度情景对比，探讨了气候智慧型耕作应对极端干热气候时的潜在收益。根据历史上特定地区的最优耕作措施（超过 75% 的概率降低干热敏感性），研究进一步制作了气候智慧型耕作方案的空间分布图，并以该地图为掩膜，分析量化了实施气候智慧型耕作的缓解效应。耕作实践的效应被定义为全因子驱动的实际情景下年际敏感性与耕作情景下敏感性的差异。具体的判断规则如下：

$$\left\{ \begin{array}{l}
 \text{if } SY_a < 0 \ \& \ DY_{a-t} > 0 \ , \ NE \\
 \text{if } SY_a > 0 \ \& \ DY_{a-t} > 0 \ , \ NE \\
 \text{if } SY_a < 0 \ \& \ DY_{a-t} < 0 \ , \ PE \\
 \text{if } SY_a > 0 \ \& \ DY_{a-t} < 0 \ , \ PE \\
 \\
 \text{if } SGHG_a < 0 \ \& \ DGHG_{a-t} > 0 \ , \ PE \\
 \text{if } SGHG_a > 0 \ \& \ DGHG_{a-t} > 0 \ , \ PE \\
 \text{if } SGHG_a < 0 \ \& \ DGHG_{a-t} < 0 \ , \ NE \\
 \text{if } SGHG_a > 0 \ \& \ DGHG_{a-t} < 0 \ , \ NE \\
 \\
 \text{if } SGHGI_a < 0 \ \& \ DGHGI_{a-t} > 0 \ , \ PE \\
 \text{if } SGHGI_a > 0 \ \& \ DGHGI_{a-t} > 0 \ , \ PE \\
 \text{if } SGHGI_a < 0 \ \& \ DGHGI_{a-t} < 0 \ , \ NE \\
 \text{if } SGHGI_a > 0 \ \& \ DGHGI_{a-t} < 0 \ , \ PE
 \end{array} \right. \quad (2-23)$$

其中 SY_a 、 $SGHG_a$ 和 $SGHGI_a$ 分别表示在实际情景下小麦的产量、温室气体排放和温室气体强度的敏感性。 SY_a 、 $SGHG_a$ 和 $SGHGI_a$ 表示在每个移动窗口内实际情景与耕作情景之间产量、温室气体排放和温室气体强度之间的敏感性差异。NE 和 PE 分别代表

由耕作实践产生的消极和积极影响。此外，在 60 年的时间窗口内，耕作效应（NE 和 PE）的频率被进一步统计以量化耕作对特定地区总体效应。如果年际积极效应出现的频率小于 50%，则该地区主要受到耕作的负面影响。

当积极的耕作效应发生频率超过 75%时，则定义为该地区耕作对历史小麦产量和温室气体排放造成了显著影响，表明特定的耕作实践在该地区有超过 75%的概率减缓小麦的干热敏感性。如果耕作效应在所有移动窗口期间保持为正，那么这些特定区域的耕作实践可以完全减缓由极端干热气候引起的敏感性。因此，气候智慧型耕作方案是通过叠加不同耕作实践下显著效应的空间分布生成的。

2.4 精度评估

我们基于决定系数（ R^2 ）和标准化均方根误差（nRMSE）评价模型模拟的精度，并且采用分层交叉验证方法来评估机器学习模型的精度。我们使用 R^2_{CV} （ R^2_{Cal} ）和 $nRMSE_{CV}$ （ $nRMSE_{Cal}$ ）来评估交叉验证结果，其中 CV 下标表示这些结果是基于测试集的交叉验证数据，而 Cal 下标表示结果是基于校准数据集的数据（Shi et al. 2020b; Wang et al. 2020）。交叉验证的具体步骤可以分为以下几个环节，首先将数据随机分成若干折（使用 R 的“caret”包中的 createFolds 函数）；然后以第一折作为测试集，剩余的数据作为校准集，运行机器学习模型并模拟作物生产力；最后，依次以相同方式历遍所有的测试集和验证集，并得到多组模拟精度。我们将这些模拟结果计算平均值，作为机器学习模型模拟精度的度量标准。本研究涉及的精度评估参数的计算公式如下：

$$R^2 = \frac{\left[\sum_{i=1}^n (x(i) - x_m) \cdot (y(i) - y_m) \right]^2}{\sum_{i=1}^n (x(i) - x_m)^2 \sum_{i=1}^n (y(i) - y_m)^2} \quad (2-24)$$

$$MSE = \frac{\sum_{i=1}^n (x(i) - y(i))^2}{n} \quad (2-25)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x(i) - y(i))^2}{n}} \quad (2-26)$$

$$nRMSE = \frac{RMSE}{\overline{pe}_i} \quad (2-27)$$

其中 $y(i)$ 和 $x(i)$ 分别代表模拟值和观测值； y_m 和 x_m 分别表示预测和观测序列的平均值； n 是样本数量； \overline{pe}_i 是观测值的平均值。

对于随机森林模型，本研究额外使用袋外误差（OOB）以测试该模型的无偏估计，这个结果与 k 折交叉验证类似。具体而言，对于朝鲜、韩国和中国，通过 RF 模型的

OOB 计算了方差解释百分比 ($\%Var$), 作为对生物量对气候变量响应的拟合优度的评估。具体公式如下:

$$\%Var = 1 - \frac{MSE_{OOB}}{\delta_y^2} \quad (2-28)$$

其中 δ_y^2 是使用 n 作为除数计算的, 而不是 $n - 1$ 。 MSE_{OOB} 是平均平方残差, 计算方法如下:

$$MSE_{OOB} = \frac{1}{N_{tree}} \sum_{i=1}^N \left(y_i - \bar{y}_i^{OOB} \right)^2 \quad (2-29)$$

其中 \bar{y}_i^{OOB} 是第 i 个观测值的平均袋外预测。

此外, 本研究基于 VHR 数据和田间照片的验证点来测试水稻分布图的准确性。我们使用了混淆矩阵中的生产者精度 (PA)、用户精度 (UA)、总体精度 (OA) 以及 Kappa 系数进行验证。具体的计算公式如下:

$$OA = \frac{\sum_{k=1}^q n_{kk}}{n} \quad (2-30)$$

$$Kappa_{coe} = \frac{n \sum_{k=1}^q n_{kk} - \sum_{k=1}^q n_{k+} n_{+k}}{n^2 - \sum_{k=1}^q n_{k+} n_{+k}} \quad (2-31)$$

$$UA = \frac{n_{kk}}{n_{k+}} \quad (2-32)$$

$$PA = \frac{n_{kk}}{n_{+k}} \quad (2-33)$$

其中 n_{k+} , n_{+k} , 和 n_{kk} 分别代表行求和值、列求和值以及主对角线值。而 n 和 q 分别代表验证样本数和分类的数量。

最后, 本研究基于联合国粮农业组织的水稻单产和总产统计数据来测试水稻预测结果的准确性, 并验证了从 2012 年到 2016 年连续五年的预测水稻产量, 以确保方法的有效性和结果的可靠性。验证公式如下所示:

$$A = \left(1 - \frac{|y_i - x_i|}{y_i} \right) \times 100 \quad (2-34)$$

其中 A 代表准确度; y_i 和 x_i 分别代表了联合国粮农业组织的统计值和模型的预测值; i 代表年份。

第三章 基于多源环境数据和模型模拟站点粮食生产力

3.1 引言

全球反复出现的干旱、冲突和极端天气导致严重的粮食短缺，并且对农作物生产力的可靠预测提出了重大挑战 (Jiang et al. 2020)。随着未来粮食需求的增加、农业技术进步带来的回报递减以及气候变化对农作物产量的影响，粮食安全问题也越来越紧迫 (Zhang and Zhang 2016)。作物产量是农业生产力和农民收益的直接指标，也是最基本、最广泛使用的粮食安全评估措施之一，对于农业可持续管理和调整粮食生产政策具有重要意义。因此，在确定潜在的生产风险并制定食品价格、进出口方面的决策时，提前预报作物产量对于决策者至关重要 (Jaafar and Mourad 2021)。可靠的作物产量预测有助于农民诊断作物生长状况并采取必要的措施应对风险，并帮助政策制定者有效调控当地粮食供应，确保及时进出口 (Lobell and Asner 2003)。

作物产量模拟与预测通常基于某一特定数据源，例如田间试验观测、中尺度通量观测塔和近地卫星监测。随着模型技术的发展和用户需求，包含更多数据源的产量模拟框架也被进一步开发。将田间试验、小型无人机和大尺度卫星观测纳入同一个监测网络，以实时判断作物生长过程中的光合信息、结构信息和其他生理生态信息 (Zhou et al. 2017; Schut et al. 2018; Mateo-Sanchis et al. 2019)。过去几十年，基于单一数据源或多数据源组合的作物产量预测获得了极大的进步。然而，由于作物生产与环境之间的复杂动态关系以及作物内部基因差异，现有的模型难以全面刻画作物发育和最终的产量形成。因此，一种只关注产量模拟结果而忽略中间复杂关系的经验黑箱模型被大量应用于产量预测以满足多方需求，例如机器学习和深度学习模型。

统计模型大致分为两类：传统回归分析和机器学习模型 (Kukal and Irmak 2018; Feng et al. 2021)。它们的相对优势和劣势是显而易见的，这在过去的研究和实际应用中得到了证明 (Wolanin et al. 2020; Sidhu et al. 2023)。多源线性回归是应用最广泛且最具解释性的传统方法，但其预测能力有限 (Leng et al. 2016)。为了建立具有高解释性的回归模型，许多研究仅关注单个环境变量的直接影响，而忽略了其他预测变量的交互作用 (Li and Troy 2018; Tebaldi and Lobell 2018)。此外，部分研究在多源回归中添加了二次项来解释非线性气候-产量关系，但“人工”添加的二次项以达到拟合目的受到了质疑和批评 (Blanc 2017)。与传统回归不同，机器学习模型大多是非参数的。它们可以拟合复杂的函数并具有卓越的预测精度 (Crane-Droesch 2018; Liu et al. 2018)。鉴于机器学习的优势，越来越多的研究将其应用于气候对作物产量的影响 (Hoffman et al. 2018; Feng et al. 2019; Leng and Hall 2020)。由于其对数据量要求较高，机器学习有时被称为数据密集型算法。机器学习经常因其低解释性，即所谓的黑盒性质，而受到批

评。黑盒模型专注于结果预测，而不推断产生这些结果的性质、动态和过程。因此，机理模型虽然受限于参数校验和模型结构差异，但是其强大的解释性是统计模型不可替代的。作物产量模拟研究中并不总是阐明两者之间的区别，可能是因为在使用线性模型分析环境对作物的影响时侧重可解释性；使用机器学习预测未来作物产量时强调预测准确性（Lobell and Asseng 2017）。总之，基于多种数据源和多源模型的产量预测需要权衡模型的预测精度与可解释性，并且慎重选择与数据源相配的模式以发挥模拟的最大潜力。

本章研究使用多源环境数据和模型复现不同生产力的观测结果。具体而言，数据来源包括县级尺度的统计数据、农田作物通量塔观测以及大尺度遥感衍生产品。考虑到作物生产力数据源的格式以及与模型的适配性，研究分为三个内容：（1）基于遥感衍生的多源环境因子，探究机器学习模型模拟县级统计资料的能力；（2）探究机器学习改进的光能利用率模型模拟通量塔观测的能力；（3）探究机理模型模拟田间试验观测的能力。

3.2 基于经验模型和统计数据模拟站点水稻生产力

3.2.1 识别水稻物候期并制图水稻空间分布

在高纬度地区，作物生长通常受到温度限制。图 3-1 展示了通化站全年的气象因素和地表温度（LST）的时间变化。每日最低温度和夜间 LST（例如冬季的最低温度和夏季的最高温度）展现了高度一致的趋势和量级。降水量和平均温度在观察时段初期显示出逐渐增加的趋势，然后逐渐趋于下降。全年 0°C 的温度出现时间大约分布在一年的第 100 天和第 300 天。通过进一步比较物候日历，发现 0°C 的起始和结束时间与水稻生长季节的起始和结束时间相吻合。结果表明，空气温度与夜间地表温度（LST）之间存在显著的正相关性（相关系数 $r = 0.94$ ），因此夜间 LST 能够有效地反映每日最低温度的变化情况（见图 3-1）。

图 3-2 展示了水稻生长季节和移栽期的起始和结束时间。在朝鲜及其周边地区内，水稻生长季节和移栽期开始的时间相差未超过 40 天。空间分布表明，由于纬度梯度引起的热量差异，水稻生长季节和移栽期的起始时间逐渐向北延迟，并进一步延后对应物候期的结束时间。

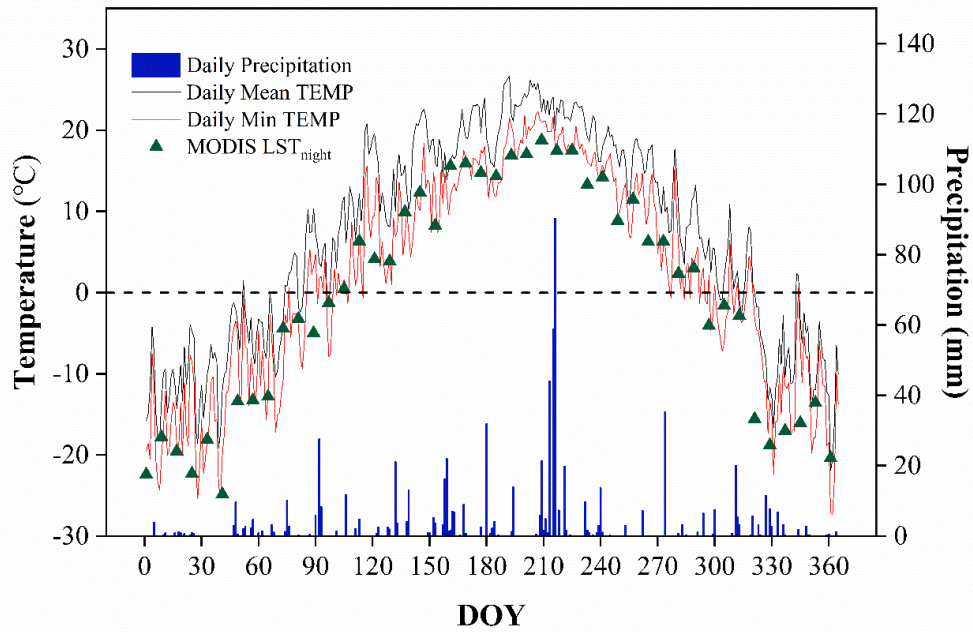


图 3-1 通化气象站气温、降水和地表温度的时间序列变化

Fig. 3-1 The changes of air temperature, precipitation, and land surface temperature (LST) in the Tonghua weather station (41.68N, 125.9E).

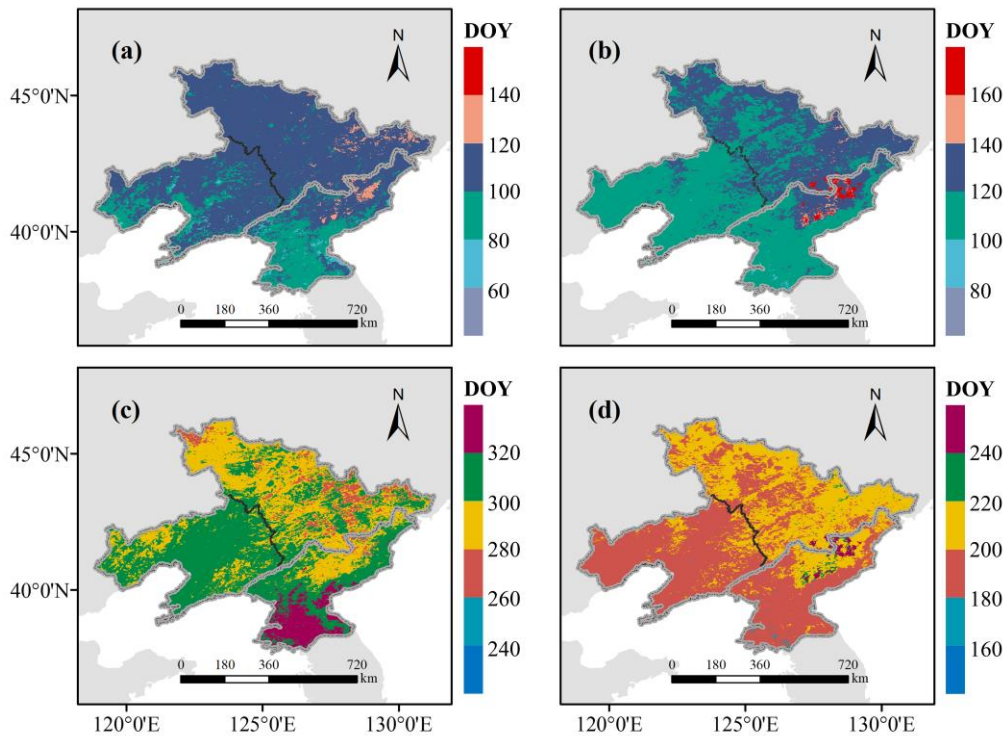


图 3-2 2015 年朝鲜及其周边地区水稻生长季和移栽期的起止时间

Fig. 3-2 The starting and ending times of rice growth and the transplanting period over North Korea and its neighbors in 2015.

遥感监测的水稻植被指数在一年中的变化如图 3-3 所示。研究发现基于遥感数据的物候方法能够捕捉到植被指数的年际变异，例如水稻分蘖期的 EVI 峰值以及寒冷低温冬季中由冰雪覆盖引起的 LSWI 峰值。LSWI 指数表明在移栽期前的灌溉水平达到最低，这可能是春季短暂干旱导致的。分布在不同地区的研究站一致地说明淹水信号在 5 月和 6 月之间出现，与水稻移栽期相对应。然而，本研究发现淹水信号也出现在水稻的非生长季节（图 3-3），这可能是因为在水稻成熟时，裸露的田地会被降雨、雪水以及其他人为活动导致的地表水覆盖。

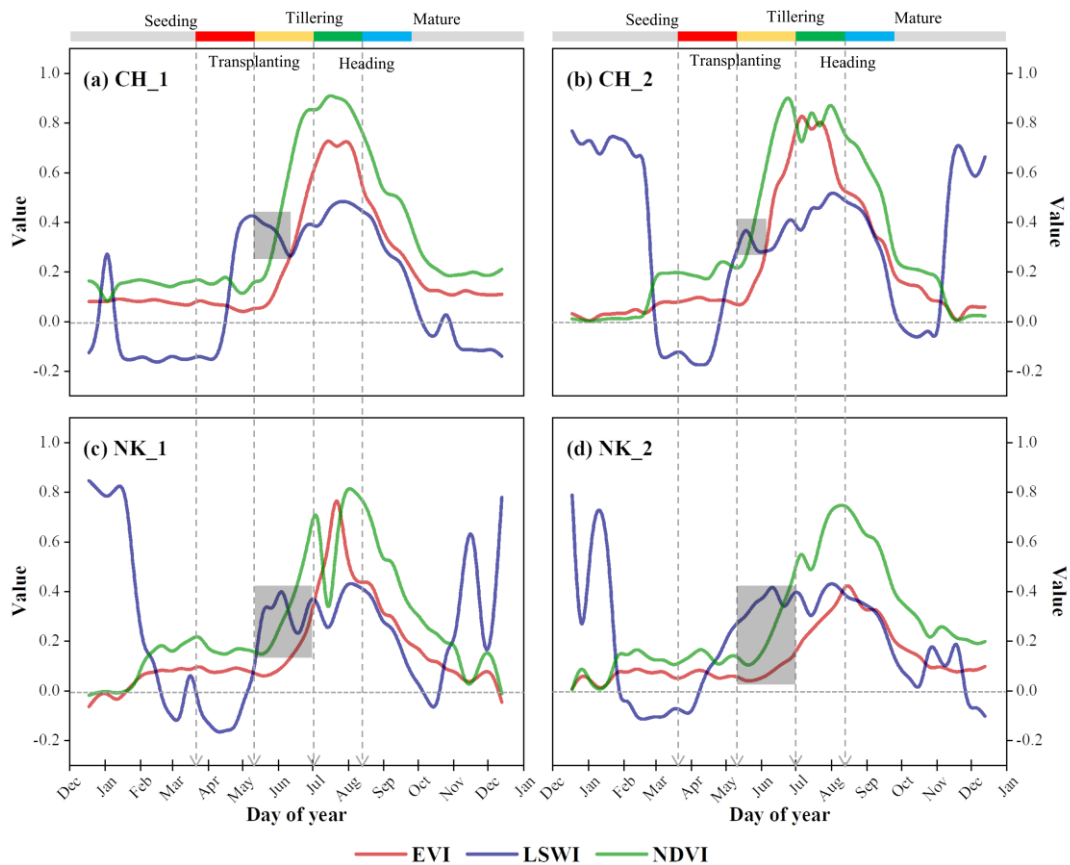


图 3-3 基于 MODIS 产品计算朝鲜及其周边地区植被指数的时间变化。灰色阴影表示在移植期间确定的洪水信号。

Fig. 3-3 The change of three vegetation indices calculated by the MODIS product over North Korea and its neighbors. The gray boxes represent the flood signal during the transplanting period determined by the method described in the text.

本文采用 PPM 方法对年际水稻分布进行了制图。图 3-4 展示了 2015 年水稻分布的详细情况。具体而言，CH_1 地区的水稻种植从盘锦平原一直延伸到内陆地区；CH_2 地区的水稻分布范围则从中国吉林省中部延伸至西北地区；而 NK 地区的水稻种植区域覆盖朝鲜西部和南部沿海地区。本研究进一步评估了水稻地图的准确性，并生成了混淆矩阵（见表 3-1）。结果显示，CH_1、CH_2 和 NK 地区的总体精度均超过 95%，

表明这些地区的水稻分类具有高度的可信度。就水稻区域而言，CH_1 的制图准确率达到到了 98%，明显高于 CH_2 (89%) 和 NK (71%)，而 CH_2 和 NK 的用户精度 (User's Accuracy, UA) 分别为 99%，明显高于 CH_2 (86%)。在非水稻区域，CH_1、CH_2 和 NK 的生产者准确率均高于 90%，而用户准确率均高于 95%。本研究产生的水稻地图精度与之前的研究结果类似，特别是 NK 地区的制图准确率 (PA) 为 71%，甚至优于 Dong et al. (2016) 的研究结果。因此，本研究制作的水稻分布图具备高度的可信度，可用于掩膜预测因子并作为估算水稻生产力的输入数据。

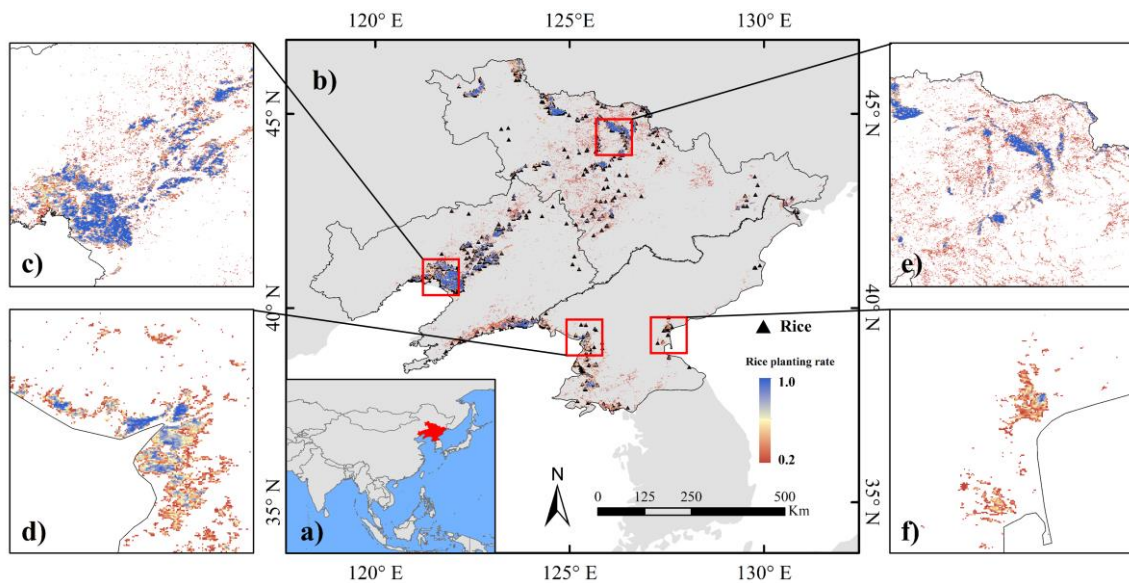


图 3-4 基于物候和像元的水稻制图法提取 2000 - 2017 年水稻种植分布

Fig. 3-4 Map of rice paddies from 2000 to 2017 based on phenology- and pixel-based paddy rice mapping (PPPM) on the Google Earth Engine platform.

3.2.2 水稻生产力模拟与验证

本研究建立了四种回归模型，用于预测 WGP 和 SHP 情景下的水稻生产力。为了评估这些模型的模拟精度，研究采用了 10 折交叉验证方法，并使用 R^2 (决定系数) 和 nRMSE (标准化均方根误差) 作为评估指标。在 WGP 情境下，水稻总产的随机森林回归模型表现最佳 ($R^2 = 0.86$)，优于线性回归 (LR, $R^2 = 0.68$)、神经网络 (NN, $R^2 = 0.68$) 和支持向量机 (SVM, $R^2 = 0.68$) 模型 (图 3-5)。此外，10 折交叉验证的结果表明 RF 模型的表现最佳 ($R^2_{cv} = 0.72$, $nRMSE_{cv} = 53.1\%$)，而 LR、NN 和 SVM 模型的 R^2_{cv} 值分别为 0.69、0.69 和 0.7 (表 3)。对于 SHP 情景，RF 模型在总产预测方面的表现也是最佳的 ($R^2 = 0.87$)，而 LR 模型的表现最差 ($R^2 = 0.46$) (图 3-6)。并且 10 折交叉验证的结果显示，RF 模型的准确性 ($R^2_{cv} = 0.66$, $nRMSE_{cv} = 60.6\%$) 优于 LR、NN 和 SVM 模型 (表 3-2)。然而，研究发现 RF 模型的结果表明存在过拟合现象 (校

准数据集的 $R^2_{Cal} = 0.95$ ；验证数据集的 $R^2_{CV} = 0.66$)。与 WGP 情景相比，在使用 SHP 数据时，所有模型的精度出现了不同程度的下降（表 3-2）。具体而言， R^2_{Cal} 和 R^2_{CV} 分别降低了 0.08 ± 0.08 和 0.13 ± 0.08 ，而 $nRMSE_{Cal}$ 和 $nRMSE_{CV}$ 分别增加了 $7.21 \pm 6.35\%$ 和 $11.50 \pm 4.48\%$ 。尽管如此，由 SHP 预测因子驱动模型仍然展现出令人满意的精度，满足了产量和产值预测的要求。

表 3-1 2015 年朝鲜和中国辽宁、吉林省水稻分布验证

区域	类型	水稻 (%)	非水稻 (%)	样点数 (%)	生产者精度	总体精度
吉林	水稻 (%)	29.1%	0.6%	29.7%	0.98	0.95
	非水稻 (%)	4.7%	65.6%	70.3%	0.93	
	分类总数 (%)	33.8%	66.2%	100%		
	用户精度	0.86	0.99			
辽宁	水稻 (%)	29.1%	3.3%	32.4%	0.89	0.96
	非水稻 (%)	0.1%	67.5%	67.6%	0.99	
	分类总数 (%)	29.3%	70.7%	100%		
	用户精度	0.99	0.95			
韩国	水稻 (%)	8.6%	3.6%	12.2%	0.71	0.96
	非水稻 (%)	0.0%	87.8%	87.8%	0.99	
	分类总数 (%)	8.6%	91.4%	100%		
	用户精度	0.99	0.96			

注：为了方便水稻和非水稻地区的比较，所有样本都以百分比计算。吉林、辽宁和韩国的样本总数分别为 41603，51811 和 39672。

四种模型对水稻单产的预测与总产的模拟结果类似。具体而言，基于 WGP 数据进行评估时，RF 模型表现 ($R^2 = 0.83$) 优于 LR ($R^2 = 0.49$)、NN ($R^2 = 0.59$) 和 SVM ($R^2 = 0.71$) (图 3-7)。基于 10 折交叉验证，研究进一步证实了 RF 模型的出色表现，其 R^2_{CV} 为 0.58， $nRMSE_{CV}$ 为 14.25%。相比之下，LR、NN 和 SVM 的 R^2_{CV} 分别为 0.45、0.55 和 0.53 (表 3-2)。

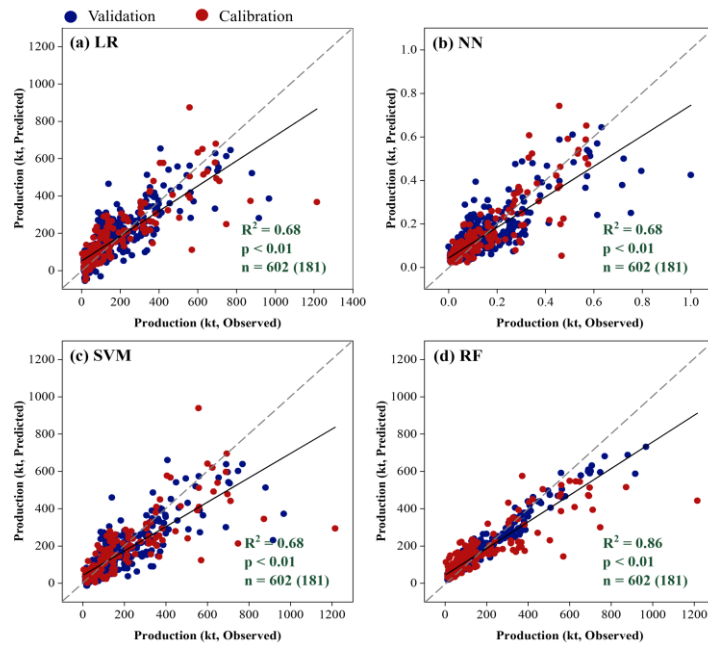


图 3-5 基于水稻全生育期统计总产的模型模拟与验证。红色和蓝色分别表示来自验证集和训练集的数据。

Fig. 3-5 Model validation for estimating rice production for CH1 and CH2 in China using four regression models with predictor variables during the whole growth period. The red and blue colors represent data from validation and training sets, respectively.

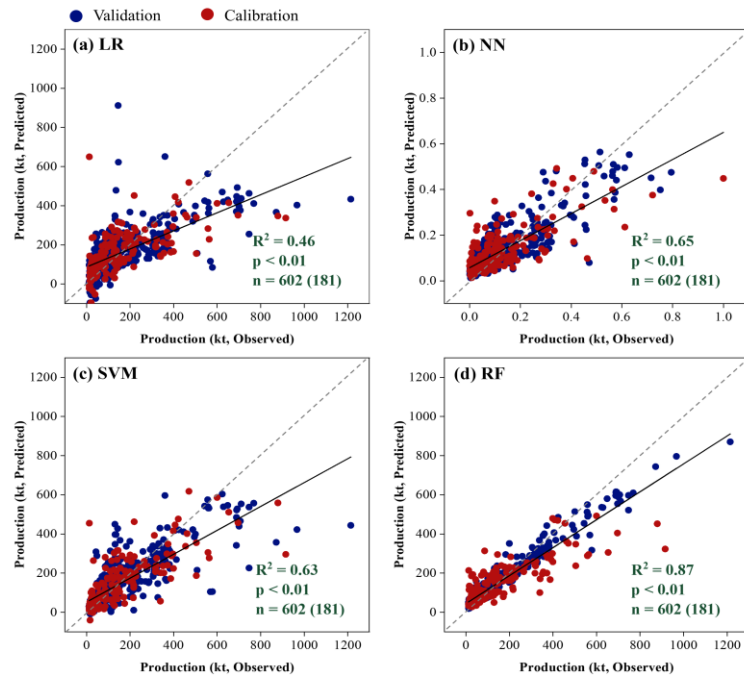


图 3-6 基于水稻发芽至抽穗期总产的模型模拟与验证

Fig. 3-6 Model validation for estimating rice production for CH1 and CH2 using regressive models with predictor variables during the seedling-heading period

表 3-2 WGP 和 SHP 情境下四种经验模型模拟水稻产量的十折交叉验证

Table 3-2 10-fold cross-validation using four regression models for rice productivity in the WGP and SHP for CH1 and CH2 in China

	情景	模型	R^2_{Cal}	R^2_{CV}	$nRMSE_{Cal}$ (%)	$nRMSE_{CV}$ (%)
总产	WGP	LR	0.68	0.69	59.66	58.04
		NN	0.73	0.69	56.23	58.15
		SVM	0.68	0.70	60.34	57.53
		RF	0.96	0.72	20.98	53.07
	SHP	LR	0.46	0.43	77.10	77.03
		NN	0.68	0.62	63.76	68.92
		SVM	0.64	0.59	62.80	66.26
		RF	0.95	0.66	22.38	60.56
单产	WGP	LR	0.50	0.45	15.87	16.14
		NN	0.62	0.55	20.03	21.47
		SVM	0.78	0.53	10.56	15.19
		RF	0.95	0.58	5.17	14.25
	SHP	LR	0.50	0.46	15.87	16.20
		NN	0.62	0.55	20.12	21.55
		SVM	0.62	0.50	13.75	15.49
		RF	0.94	0.58	5.26	14.40

对于 SHP 情景下的四种模型, RF 回归在水稻单产预测方面表现最佳($R^2 = 0.83$), 而 LR 在此方面表现最差 ($R^2 = 0.49$) (图 3-8)。通过 10 折交叉验证, 研究进一步验证了 RF 模型在使用 SHP 数据时的模拟精度 ($R^2_{CV} = 0.58$, $nRMSE_{CV} = 14.40\%$), 相较之下, LR、NN 和 SVM 模型的精度较低 (表 3-2)。相对于使用 WGP 数据, 研究观察到使用 SHP 数据的四种模型的精度略微下降 (表 3-2)。具体而言, R^2_{Cal} 和 R^2_{CV} 分别降低了 0.04 ± 0.07 和 0.01 ± 0.01 , 而 $nRMSE_{Cal}$ 和 $nRMSE_{CV}$ 分别增加了 $0.84 \pm 1.36\%$ 和 $0.15 \pm 0.09\%$ 。

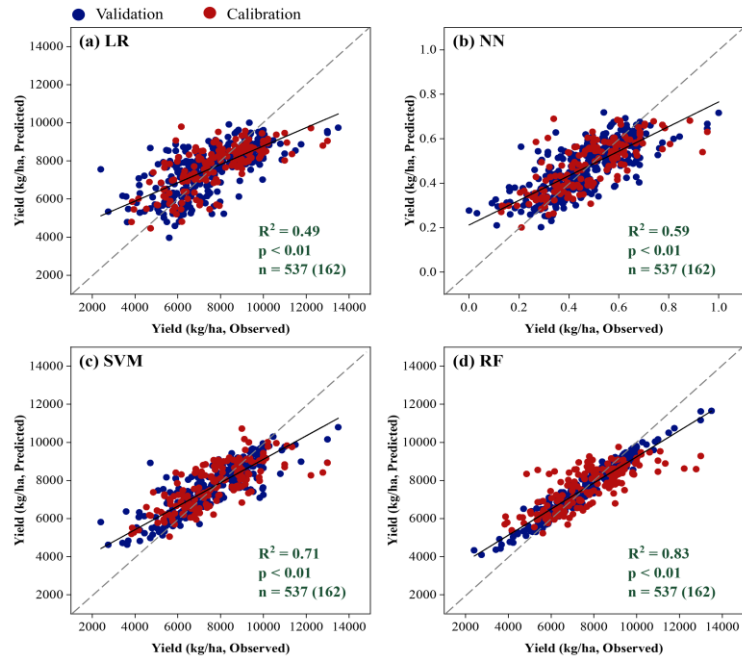


图 3-7 基于水稻全生育期单产的模型模拟与验证

Fig. 3-7 Yield modeling during the whole growth period for CH1 and CH2 in China using four regression models and statistical yearbook data.

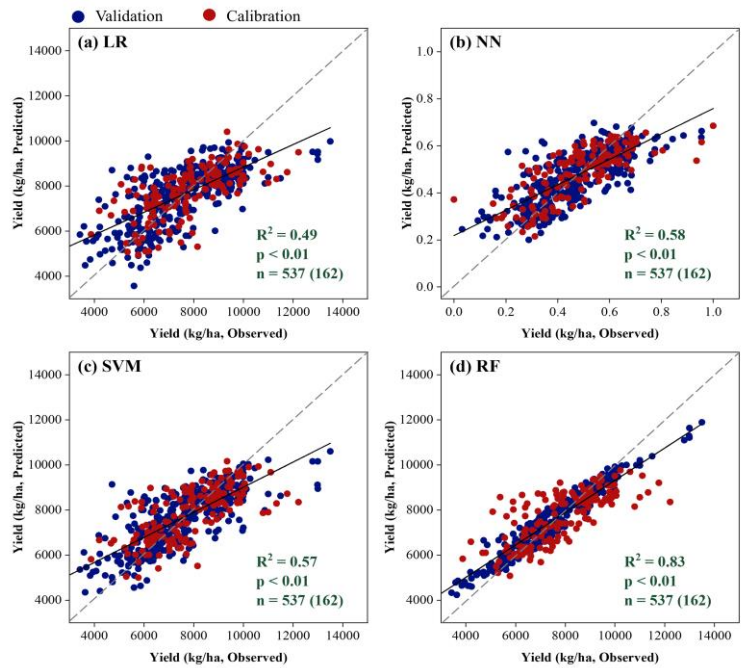


图 3-8 基于水稻发芽至抽穗期单产的模型模拟与验证

Fig. 3-8 Yield modeling during the seedling-heading period for CH1 and CH2 using regressive models and statistical yearbook data.

3.3 基于半经验模型和通量观测数据模拟站点生物量

本研究首先在 Google Earth Engine 云平台上应用了基于物候和像元的水稻制图 (PPPM) 算法 (图 3-9), 以提取参考用的水水稻地图, 该算法经过了 Dong et al. (2016) 的充分验证, 以确保在大尺度领域中的可靠应用。采用生态系统光能利用效率 (eLUE) 模型对朝鲜及其周边地区 2000 至 2017 年的水稻生物量进行了细致的模拟, 并对该模型进行了严格的校准。基于 MODIS (500 米空间分辨率和 8 天步长) 植被指数结合朝鲜的邻近地区 (中国辽宁省和吉林省) 的逐日 EC 通量塔观测数据, 用于估算朝鲜及其周边地区 8 天时间步长的总初级生产力。这种方法的优势在于无需额外考虑气候因素 (如温度和降水), 因为气候对植被的综合影响可以直接体现在生产力相关的植被指数上。具体的 eLUE 模型原理和数据处理细节见材料方法部分。

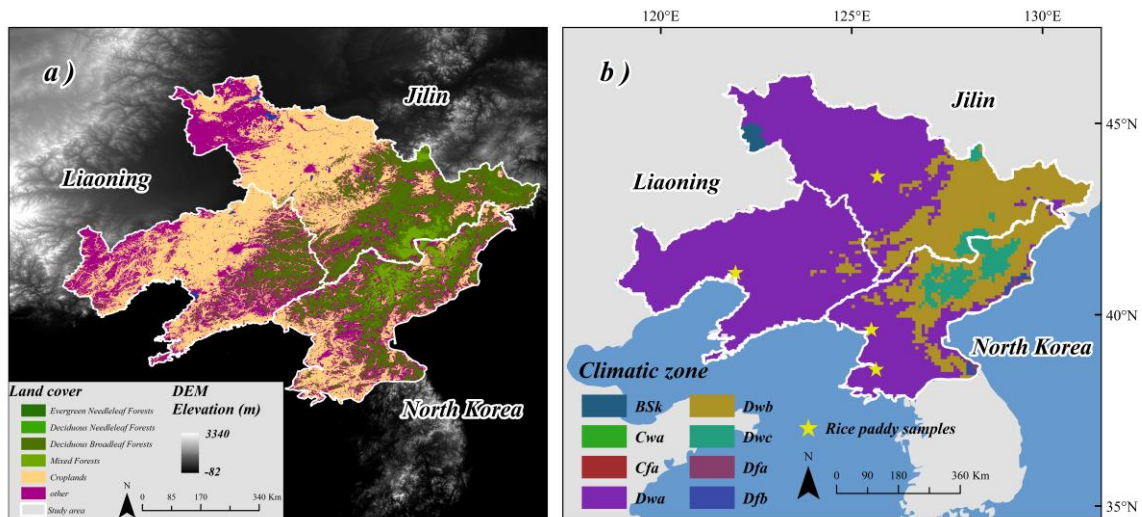


图 3-9 朝鲜及其邻国的土地覆盖类型和气候区

Fig. 3-9 Land cover and climatic zones of North Korea and its neighbors

图 3-10 展现了 eLUE 模型的预测性能, 结果表明该模型能够准确地再现涡度相关 (EC) 塔监测记录的生态系统光能利用效率。与观测数据的比较显示, 基于该模型模拟的光能利用效率捕捉了 90% 以上的站点观测变化 (图 3-10)。对于农业生态系统而言, 作物光能利用效率的整体分布范围为 0.1 至 0.5 之间。为了进一步验证 eLUE 模型的模拟精度, 研究进行了 10 折交叉验证。图 3-10b 展示了交叉验证的决定系数 (R^2) 以及模拟误差的概率密度分布范围。具体而言, 交叉验证的 R^2 值整体稳定在 0.75 左右, 并能够模拟部分观测值变异程度超过 80% 的情况, 这些结果在统计学上呈极显著 ($P < 0.01$)。综上所述, eLUE 模型展现出在模拟农田生态系统的生态光能利用效率方面具备出色的潜力, 可应用于区域农田生产力的预测研究。

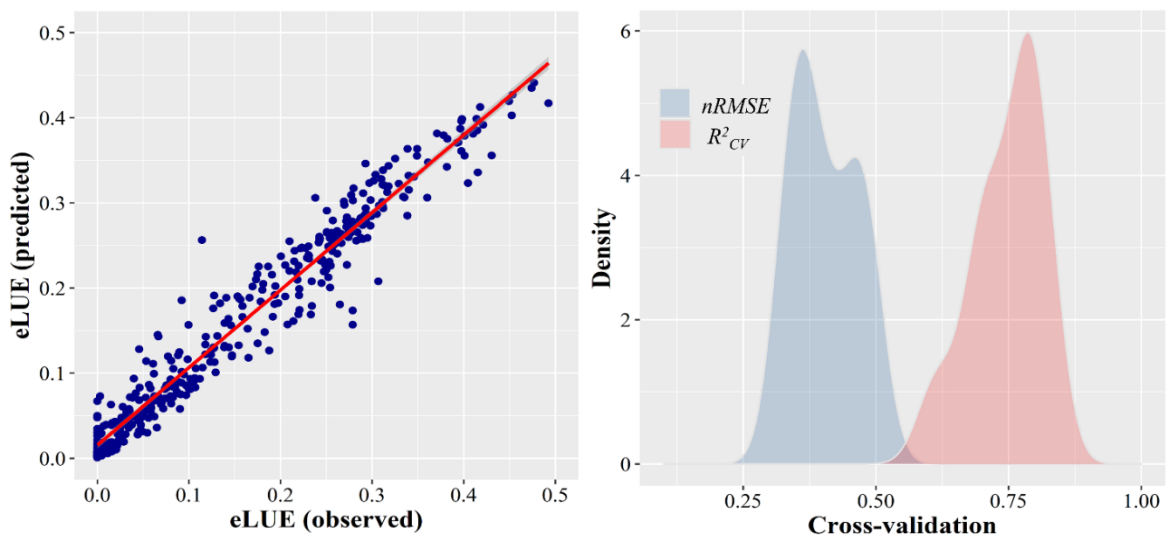


图 3-10 生态系统光能利用模型模拟水稻生物量的精度

Fig. 3-10 Performance of ecosystem light use model for modeling rice biomass

3.4 基于过程模型和田间试验模拟站点小麦生产力和温室气体排放

本研究通过对田间观测数据的详尽验证，验证了 DLEM v4.0 模型模拟小麦产量和温室气体排放结果的准确性。整个过程包含了平衡态、自旋态和瞬时态三个主要步骤。观测数据包括 74 个站点年份的产量观测、33 个温室气体观测以及 36 个土壤有机碳 (SOC) 储量观测数据，这些数据涵盖了主要的小麦类型和常见品种。此外，本研究还通过美国农业部 1960-2018 年的统计数据进一步验证了模型模拟小麦年际总产的时空变化的能力。在模型模拟之前，我们还进行了多项参数敏感性分析以及更加详尽的验证，包括叶面积指数、地上生物量、作物单产和作物总产的空间分布以及时间序列动态等，细节参考 You et al. (2022)。

经过严格参数校准后的模型 (DLEM) 精确地模拟了小麦生产力的时空变化，成功复现了分布在美国各个不同时间和站点的小麦单产情况 (图 3-11a)。具体而言，DLEM 模型捕捉到了站点尺度下 52% 的小麦单产变化，并且准确地捕捉到了国家尺度的小麦总产变化 ($R^2=0.64$)。虽然模型模拟存在一定的限制，但是面对复杂的气候变化和人为管理背景，大尺度范围下的产量模拟表现仍然稳健。

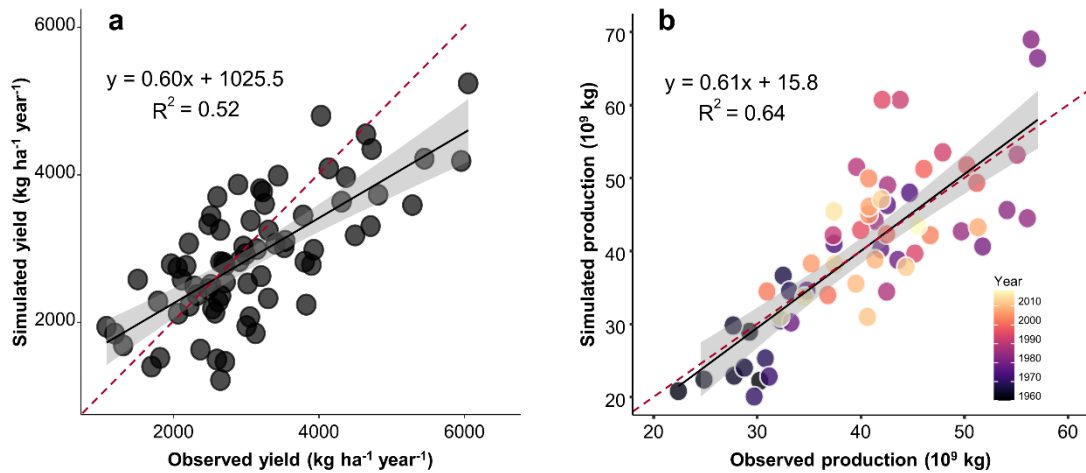


图 3-11 基于 DLEM 模型模拟美国小麦站点尺度生产力

Fig. 3-11 Simulation of situ wheat productivity based on DLEM in the US

此外，该模型还成功地复现了净温室气体排放（包括 N_2O 和 CH_4 ）以及土壤有机碳储量的变化，在站点层面表现出较高的模拟准确性。具体而言，通过对比观测值和模拟值的温室气体排放数据，发现了显著的相关性，其决定系数达到了 0.66（图 3-12a）。并且 DLEM 模型也很好地模拟了小麦生产过程中土壤有机碳储量的变化，其 R^2 为 0.64（图 3-12b）。综上所述，这一全面的验证为 DLEM 模型的区域应用提供了可靠的基础，有助于更准确地预测区域尺度小麦产量和温室气体排放情况。

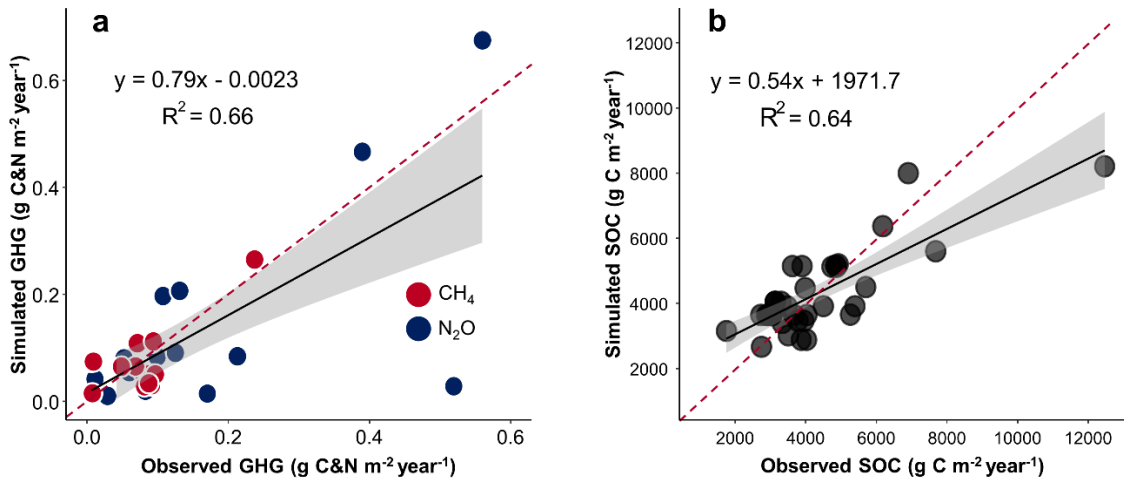


图 3-12 基于 DLEM 模型模拟小麦站点尺度温室气体排放和 SOC

Fig. 3-12 Simulation of situ wheat greenhouse gas and SOC based on DLEM in the US

3.5 小结

本章研究基于多源环境因子和观测数据探究了经验模型、半经验模型和机理模型模拟站点尺度作物生产力的表现。多源观测数据来自于统计数据、通量塔观测和田间站点试验,考虑到模型优势、研究区域和观测数据差异,以及模型解释力与预测精确性的权衡,研究分别将多源数据纳入到机器学习模型、生态系统光能利用率模型和陆地生态系统模型框架中,用以评价站点尺度作物生产力的模拟精度。

研究发现,基于多种遥感指数和物候的逐像元模拟法(PPPM)成功复现了历史朝鲜及其周边地区水稻种植分布的动态变化。基于水稻位置和可用的环境因子,随机森林模型更准确地捕捉到了水稻单产和总产的年际变化($R^2=0.83-0.87$),精度优于其他经验模型(LR, SVM 和 ANN)。通过与WGP情景下的预测结果进行对比,本研究进一步证明该模型可以提前一个物候期(一个到两个月)预测水稻生产力。此外,基于随机森林改进的生态系统光能利用率模型高精度地复现了基于通量塔衍生的农田生态系统光能利用效率(交叉验证的 $R^2 > 0.75$, $P < 0.01$)。最后,基于过程的生态系统模型(DLEM v4.0)在调参校准后也成功捕捉到了站点小麦绝大多数的产量变化($R^2=0.52$),并且保持了较高的国家尺度生产力模拟精度($R^2=0.64$)。除此之外,DLEM 仍然以稳健的性能模拟了站点尺度下多种温室气体排放(GHG 的 $R^2=0.66$; SOC 的 $R^2=0.64$),这为粮食生产过程中的气候代价评估以及国家尺度的粮食安全监测提供了可靠的方案。

第四章 区域粮食生产力预测及其与环境因子的响应关系

4.1 引言

由于全球气候变化、人口增长以及不可预测的灾难性事件，粮食不安全问题引起了广泛关注（Tilman et al. 2011; Wheeler and Von Braun 2013）。准确、及时、高效地预测作物产量对于政府、农民和其他利益相关者评估粮食安全至关重要（Whitcraft et al. 2015; Fritz et al. 2019）。

作物生长过程受到多源环境因素的影响（Guo et al. 2021）。Tao et al.（2003）指出降雨强度和分布以及气温升高，均能通过改变作物生长阶段的光合作用和呼吸速率，对水稻产量产生影响。极端降水引发的洪水不仅直接危害农田，还可能导致积水，从而严重削减产量。气候变化还会调整物候阶段的起止时间，进而控制水稻生殖生长时间以及光合产物在不同器官之间的分配（Tao et al. 2013）。例如，极端高温事件会在开花和灌浆阶段降低潜在颗粒数量或增加皱缩颗粒的比例，导致明显的产量损失（Fuller et al. 2007; Butler and Huybers 2013）。早期物候变化还可能导致水稻在开花期遭受冻害胁迫（Shimono 2011）。因此，在作物生产力的预测评估框架中，纳入气象条件与物候信息是至关重要的。此外，各类遥感监测还能提供全面多角度的农作物生长信息，如 EVI 反映植被绿度的整体变化，叶面积指数（LAI）反映植被冠层结构的变化，以及太阳诱导叶绿素荧光（SIF）反映光合能力。Zhang et al.（2021）研究证实，基于叶绿素与地表温度（LST）的绿度植被指数，在作物产量预测方面优于可见光和近红外植被指数。Peng et al.（2020）同样展示了基于卫星的 SIF 产品与植被指数相结合预测农作物产量方面具备巨大的潜力。

预测作物产量的模型可分为经验、半经验和机理模型。经验模型主要是一种简单的统计模型，其利用遥感植被指数（VIs）与产量之间的关系来建立回归方程（Shi et al. 2013）。然而，经验模型仅适用于局部地区，将此模型推广到其他时空尺度可能会造成额外的不确定性。此外，传统的统计模型难以捕捉作物产量与环境变量之间的非线性关系（Mahlein et al. 2012）。机器学习技术旨在从数据中学习规律、模式和关联，是解决作物产量与预测变量之间的非线性关系的重要方法，例如随机森林（RF）、支持向量回归（SVM）和神经网络（NN）（Everingham et al. 2016）。Thorp and Drajat（2021）利用递归神经网络和 Sentinel 卫星数据，预测了水稻生长阶段的时间变化。Cao et al.（2021）对比了最小绝对收缩算子回归、RF 和深度学习预测中国水稻产量的表现，结果显示深度学习模型优于其他模型。然而，经验模型的区域应用主要受限于地面观测和统计数据，这些数据通常由地区或国家的行政部门每年发布在统计报告中（Ji et al. 2017;

Lambert et al. 2017)。由于自身敏感性、国家政策或战争等外部因素，年度报告中提供的地面观测和统计数据通常不完整。即使这些数据定期收集，也可能需等到收获后六个月到一年后才能发布。因此，在地面数据稀缺的地区（如朝鲜和非洲），采用传统经验方法来预测作物产量和评估粮食不安全问题具有挑战性。

基于过程的作物模型通常为小规模农场的适应决策提供信息（Chenu et al. 2017; Jones et al. 2017）。然而，由于作物模型最初旨在支持农民决策，因此其侧重于同质条件下田间尺度的产量模拟。此外，这些模型通常采用简化的水文、能量和生物地球化学循环过程。上述特性限制了它们在模拟区域作物生产、评估农业部门缓解潜力以及农业管理对环境影响的能力。包含农业模块的陆地生物圈模型（TBM）为更广泛的农业气候变化缓解和适应提供了新的见解（Bondeau et al. 2007; McDermid et al. 2017; Lombardozzi et al. 2020）。大多数 TBM 都涵盖了详细的水文、生物物理和生物地球化学过程，并且可以进一步与大气环流模型相耦合，以预测未来气候变化的影响（Alo and Wang 2008; Fisher et al. 2014）。因此，它们可用于模拟历史和未来气候情景下的区域作物生产、评估农业管理方案的缓解潜力并量化农业-气候-环境系统内碳、水、养分和能量交换。耦合作物生长过程和农业管理实践的生态系统模型不仅能够提供精细的生产力模拟，还能够捕捉农业过程中的温室气体交换和土壤有机碳动态变化。这一方案系统地刻画了环境变化和人为管理对农业生产的影响，以及农业活动对气候的反馈机制。因此，它为解决粮食安全和气候变暖的减缓效应提供了可行性方案。

基于上述分析，本章研究充分利用多源环境因子和可迁移模型，提出了一种基于机器学习技术的可扩展的作物生产力框架，用于预测数据稀疏地区的作物生产力，并进一步耦合机器学习技术和光能利用率模型，结合通量观测数据预测区域作物总初级生产力。最后，在考虑明确的物理过程和大尺度产量预测的限制的基础上，利用新一代陆地生态系统模型（DLEM V4.0）探究区域尺度作物生产和温室气体排放模拟的表现。因此，本章以朝鲜（数据稀疏地区）和美国（拥有丰富的数据驱动机理模型）为例开展以下科学问题的探究：（1）可迁移的预测框架在多大的程度上能够捕捉朝鲜水稻生产力；（2）分析多源环境因子在作物产量预测中的主导作用；（3）探究新一代陆地生态系统模型模拟大尺度作物产量的表现；（4）量化作物生长过程中的释放的温室气体以及作物生产的气候代价。

4.2 基于经验模型和统计数据预测区域水稻产量

4.2.1 基于可迁移框架预报近五年朝鲜水稻生产力

WGP 情景下，2013 年的水稻总产预测准确率最低（65.78%），而 2015 年的预测准确率最高（91.09%），2012 年至 2016 年期间的平均准确率为 78.72%（图 4-1 和表 4-1）。在 SHP 情景下，2013 年的水稻总产预测准确率同样最低（66.10%），而 2014 年的

预测准确率最高 (85.92%), 2012 年至 2016 年的平均准确率为 76.89% (图 4-1 和表 4-1)。在 2012 年至 2016 年期间, SHP 情景下的水稻总产预测准确率略高于 WGP, 这一趋势在平均准确率上同样得以体现 (图 4-1 和表 4-1)。对于水稻单产的模拟, 研究发
 现到不论在 SHP 还是 WGP 情景下, 整体的预测产量明显高于实际的观测值 (图 4-1)。这种情况可能是因为在模型迁移的过程中未考虑到两个地区的农业技术差异所引起的。

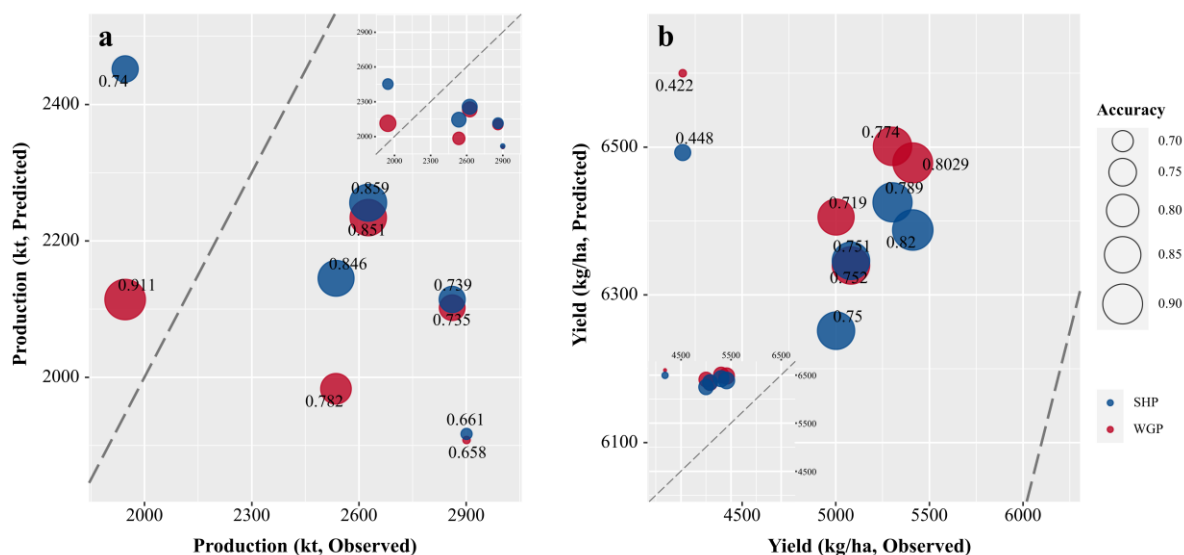


图 4-1 基于粮农组织统计数据预测水稻生产力的可扩展框架的验证

Fig. 4-1 The performance of the extendable framework for predicting rice productivity based on FAO statistics.

表 4-1 利用 2012 - 2016 年粮农组织数据验证朝鲜水稻产量预测

Table 4-1 Verification of predicted rice production for NK using FAO data during 2012 to 2016

情景	项目	2012	2013	2014	2015	2016	平均	
总产	WGP	FAO (kt)	2,861	2,901	2,626	1,946	2,536	2,574
		Forecast	2,102	1,908	2,234	2,114	1,983	2,069
		Accuracy (%)	73.49	65.78	85.07	91.09	78.16	78.72
	SHP	Forecast	2,114	1,917	2,256	2,452	2,145	2,177
		Accuracy (%)	73.89	66.10	85.92	74.02	84.55	76.89
		Forecast	2,114	1,917	2,256	2,452	2,145	2,177
单产	WGP	FAO (hg/ha)	50,817	53,035	50,019	41,831	54,119	49,964
		Forecast	63,398	65,009	64,052	65,999	64,786	64,649
		Accuracy (%)	75.24	77.42	71.94	42.22	80.29	69.42
	SHP	Forecast	63,461	64,251	62,514	64,924	63,877	63,805
		Accuracy (%)	75.12	78.85	75.02	44.79	81.97	71.15
		Forecast	63,461	64,251	62,514	64,924	63,877	63,805

关于水稻总产的空间分布, WGP 情景下的预测表明, 慈江道、两江道和江原道地区的产量明显低于其他地区, 而平安北道和平安南道的年产量变动较大 (图 4-2)。预

测的朝鲜水稻单产在空间分布上与 WGP 的预测一致，即高产水稻集中在朝鲜的西海岸，其中西部地区的水稻单产（约 7500 kg/ha）高于南部地区（约 5500 kg/ha）（图 4-3）。此外，高单产区域与高总产区域的分布呈现出一致性，例如在平安北道和平安南道（图 4-3）。然而，黄海南道的水稻总产量主要取决于广泛的水稻种植，而不是单产。

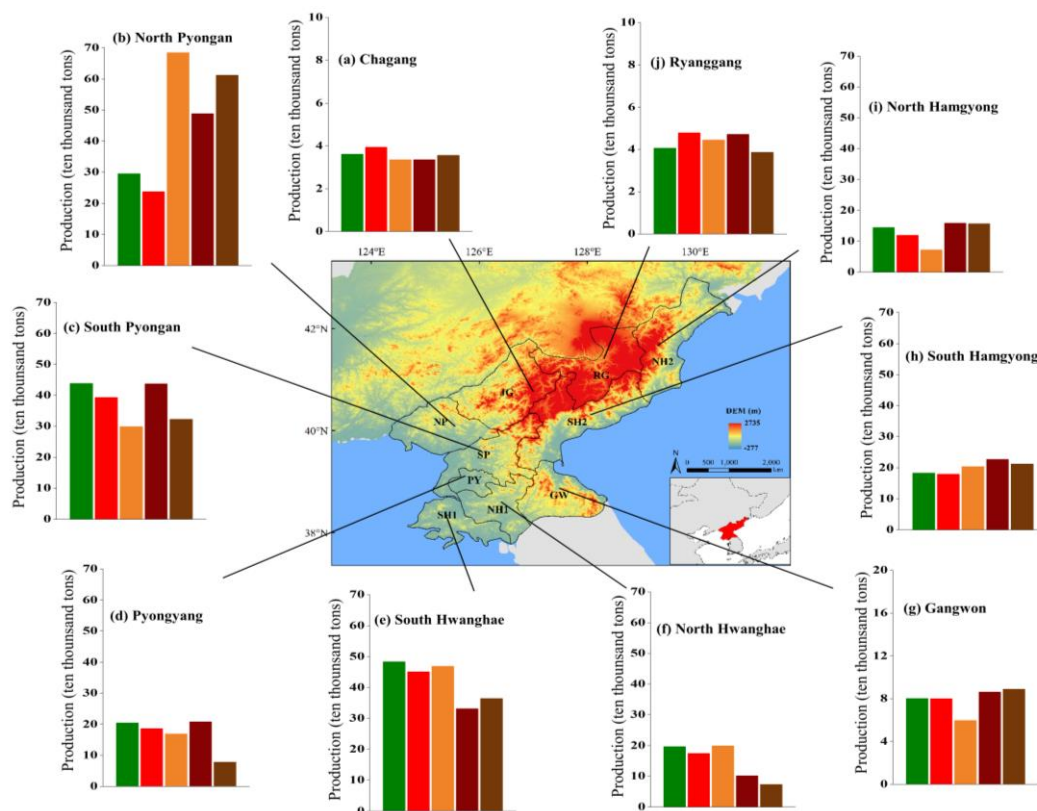


图 4-2 基于全生育期数据预测朝鲜不同省份的水稻总产。绿色、红色、橙色、暗红色和棕色条分别代表 2012 年至 2016 年。

Fig. 4-2 Projected rice production in different provinces of North Korea using whole growth period data.

The green, red, orange, dark red, and brown bars represent 2012 to 2016, respectively.

基于 SHP 情景的分析结果显示，慈江道、两江道和江原道的水稻总产低于其他地区，而平安北道和平安南道的年总产变化趋势与 WGP 情景下的产量变异趋势相近（附图 1）。根据卫星观测数据，朝鲜的水稻生产分布主要集中在西部和南部，这与本研究的结果一致。附图 2 显示了 2012 年至 2016 年的水稻单产分布情况。在 SHP 情景下，可迁移框架仍能够捕捉到水稻产量的空间变化，这结果表明在水稻收获之前，对水稻总产和单产的预测仍然具有较高的可行性。

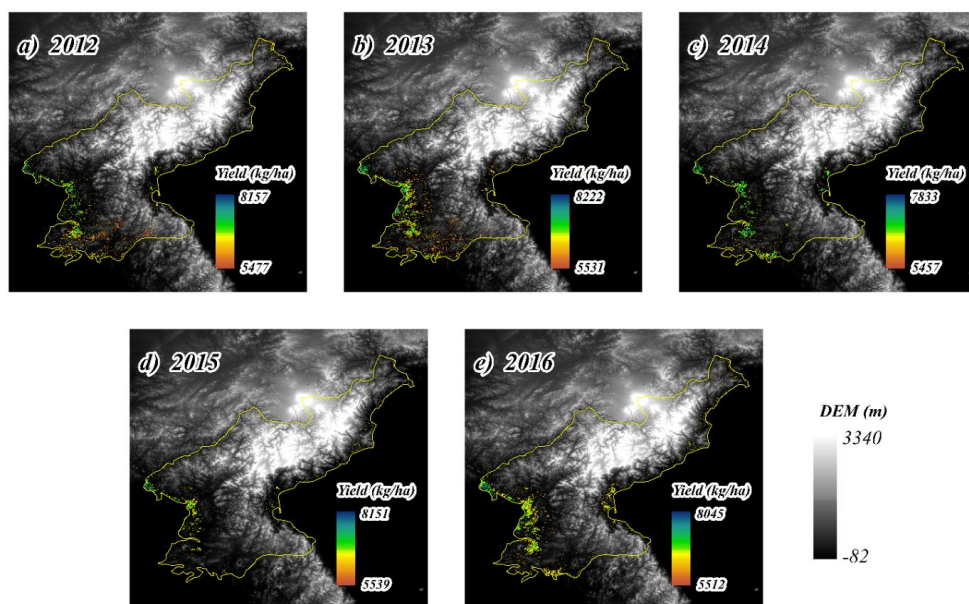


图 4-3 基于全生育期数据预测预测朝鲜 2012 年至 2016 年的水稻单产。

Fig. 4-3 Predicted rice yield at a resolution of 500 m in North Korea from 2012 to 2016 using predictor variables during the whole growth period.

本文进一步使用世界粮食计划署的统计数据验证了在 WGP 和 SHP 情景下可迁移框架对水稻产量空间分布的预测。结果显示，与 WFP 的估算结果相比，本研究的预测结构呈现出显著的一致性，并成功地识别出朝鲜的粮食主产区，且与 SHP 情景下相比，WGP 情景更为全面地反映了产量的变化（图 4-4）。预测值和统计值之间的数值差异可能源于时间步长不一致（统计产量为两年，预测产量为五年）和结果范围不同等因素（统计产量涵盖了 2018 年至 2019 年，而预测产量则涵盖了 2012 年至 2016 年）。

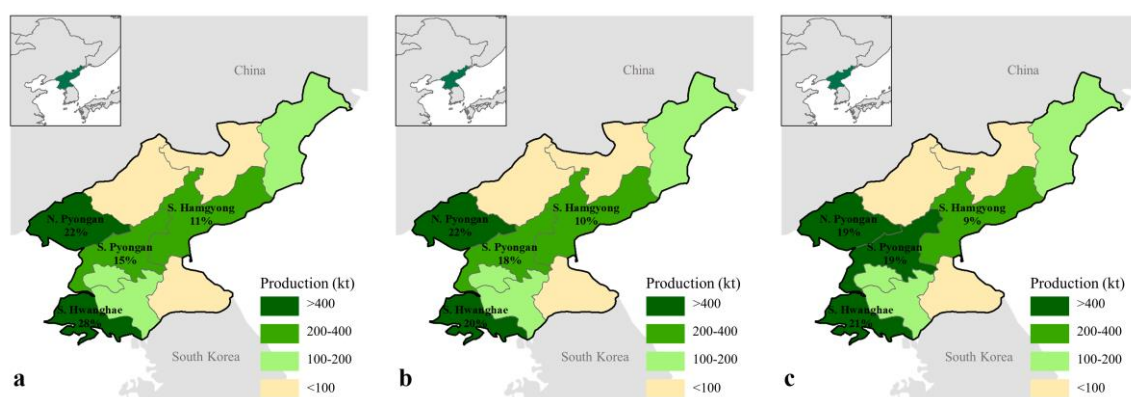


图 4-4 省级水稻产量和分布预测检验。图 a 是世界粮食计划署平均统计总产。图 b 和图 c 分别为 WGP 和 SHP 情境下预测的平均总产。

Fig. 4-4 Testing the predicted rice production and distribution at the provincial level. Panel a is the average statistic production from World Food Programme. Panels b and c are the predicted average production under the whole growth period and the seedling-heading period, respectively.

4.2.2 多环境因子对水稻生产力预测的解释性

根据 WGP 和 SHP 情景下的分析结果，发现 RF 模型表现出最佳的预测精度。因此，本研究使用 RF 模型预测了 2012 年至 2016 年的朝鲜水稻单产和总产，并使用联合国粮农组织的国家尺度数据和世界粮食计划署的省级数据对预测结果进行了时空验证。

本研究采用了随机森林（RF）模型，并通过变量重要性检验，在两种不同情景下分析了环境因素对水稻生产力变异的影响，结果如图 4-5 所示。研究发现 SIF 是影响水稻单产变化的主导因素，在 SHP 和 WGP 情景下的解释性超过 15%（图 4-5a, b）。其次是 Maxt 和 ET，共同解释了超过 20%的水稻单产变化（图 4-5a, b）。为了提高水稻总产预测的准确性，本研究在 RF 单产模型的基础上引入了水稻种植面积。正如研究预期，水稻种植面积被确定为对水稻总产变化最重要影响的因素，其贡献在 WGP 和 SHP 情景下分别为 42.37%和 46.97%。LAI_T2 和 SIF 分别是第二和第三重要因素，解释了约 15%的水稻总产变异性（图 4-5c, d）。

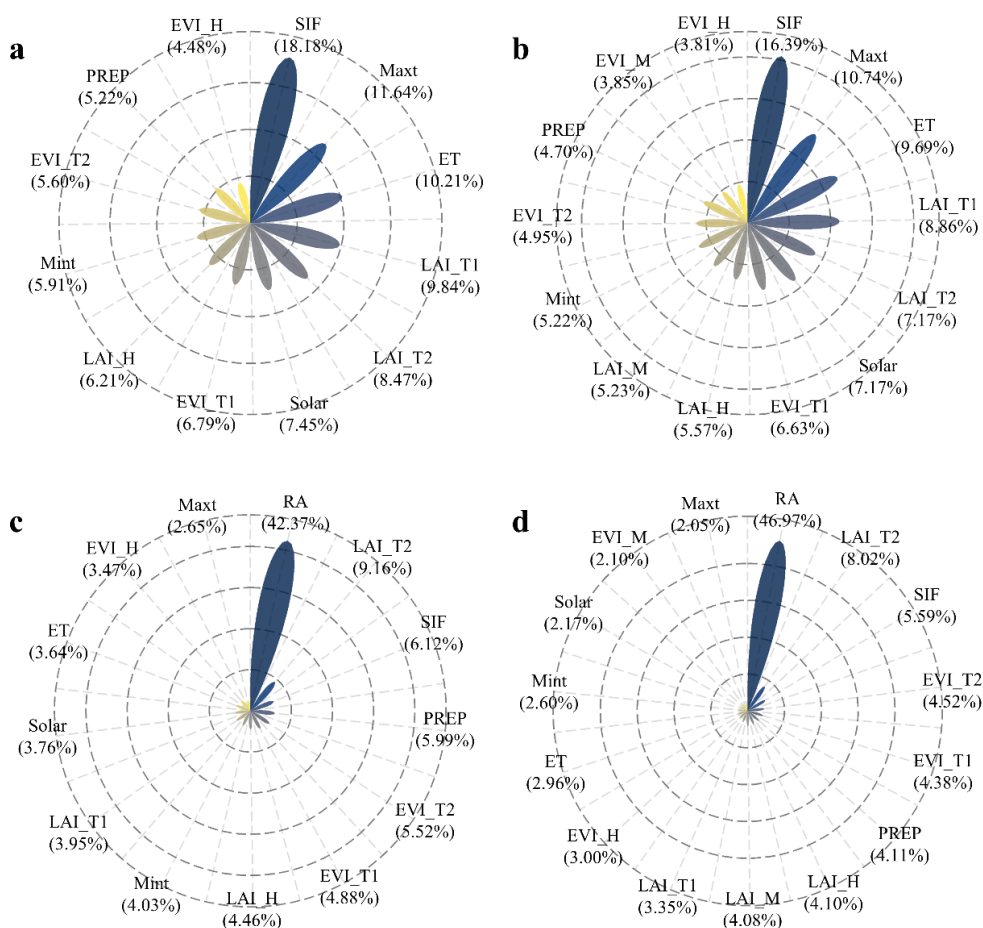


图 4-5 可用环境变量对随机森林模型预测水稻产量和产量的贡献。图 a 和图 b 分别是 WGP 和 SHP 情景的水稻单产数据。面板 c 和 d 分别是基于 WGP 和 SHP 情景水稻总产数据。

Fig. 4-1 The contribution of available environmental variables to predictions of rice production and yield from the random forest model. Panels a and b are based on rice yield data with WGP and SHP scenarios, respectively. Panels c and d are based on rice production data with WGP and SHP scenarios, respectively.

4.3 基于半经验模型和通量观测数据模拟区域作物生物量

4.3.1 区域水稻生物量模拟

本节基于机器学习模型和通量观测数据改进了生态系统光能利用模型，并用于预测 2000 至 2017 年间朝鲜、韩国和中国吉林辽宁省的区域生物量。下图展示了三个地区过去区域生物量的均值、线性变化趋势和显著水平。研究发现朝鲜区域生物量在空间上展示了较高的水平，只有少部分地区生物量较低，例如朝鲜中西部以及东部沿海地区。然而，生物量较低的区域集中分布在朝鲜粮食主产区，那里种植了朝鲜超过 70% 以上的主粮，如水稻和玉米（图 4-6）。生物量较高的地区更多分布在未开发的原始森林，难以改变朝鲜粮食紧迫的现状。过去 18 年朝鲜生物量在大多数地区呈现了上升趋势，并且这种生物量的增加趋势在统计学上为显著和极显著。这一变化可能是由于过去全球气候变暖和全球氮沉降增加对植被光合作用的促进效应，导致植被变绿和生物量增加。即使如此，在东西部沿海地区、中部和南部的零散作物种植区，并未观察到明显的生物量增加，甚至部分地区出现了显著的生物量下降。随着未来气候进一步变暖、极端天气增加，预计会进一步冲击朝鲜粮食生产，造成更大范围且显著的产量下降。

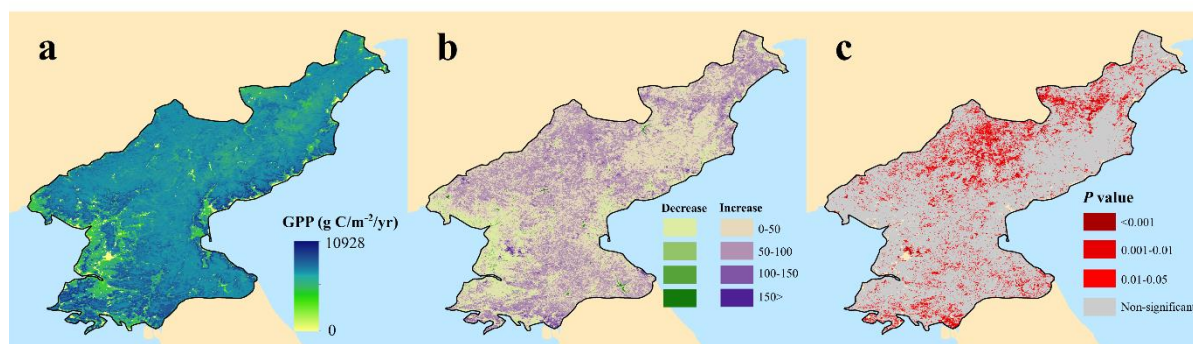


图 4-6 基于机器学习和生态系统光能力用模型估算朝鲜 2000-2017 年区域生物量

Fig. 4-6 Estimation of regional biomass in North Korea from 2000 to 2017 based on integration of machine learning and ecosystem light use model

韩国生物量的空间格局也展现了较高水平的生物量，只有零散的沿海地区生物量较低。韩国北部和西部地区生物量呈显著增长趋势 ($P < 0.05$)，而中部和南部的生物量变化趋势呈现轻微下降，并且这种效应并不显著。韩国的粮食生产区分布较为零散，遍布全国各个地区，且与森林城镇错落结合。因此根据图 4-7 大致可以判断在沿海地区的粮食生产受益于环境变化，而在中部南部的粮食生产能力较为稳定或者轻微下降。

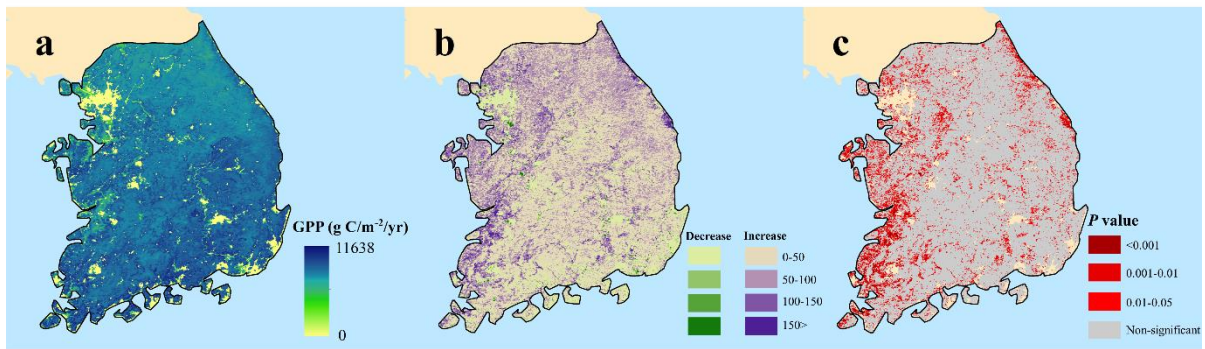


图 4-7 基于机器学习和生态系统光能力用模型估算韩国 2000-2017 年区域生物量
 Fig. 4-7 Estimation of regional biomass in South Korea from 2000 to 2017 based on integration of machine learning and ecosystem light use model

相比于朝鲜和韩国，中国辽宁和吉林两省的区域生物量变化更为显著（图 4-8）。具体而言，生物量空间格局以南部和东部的山区森林为最高，北部平原生物量相对较低。过去 18 年吉林、辽宁省西部和北部的生物量变化为最明显，呈现极显著的持续上升。相反，东部原始森林生物量变化相对较小，在空间上没有观察到显著的变化趋势。吉林省北部和辽宁省西部主要以平原地形为主，也是该地区重要的粮食生产基地，大面积的种植了玉米、水稻等重要主粮。过去环境变化极大地促进了区域粮食生产，保障了口粮自给自足，为地区和全国粮食安全贡献重要作用。

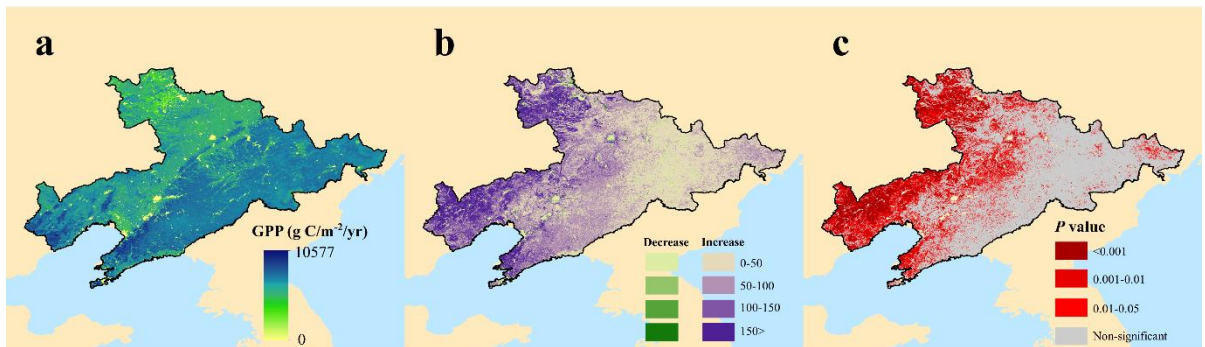


图 4-8 基于机器学习和生态系统光能力用模型估算中国吉林辽宁省 2000-2017 年区域生物量
 Fig. 4-8 Estimation of regional biomass in Jilin and Liaoning provinces of China from 2000 to 2017 based on integration of machine learning and ecosystem light use model

基于区域平均生物量的时间序列，我们依然可以观察到类似的结果（图 4-9）。即朝鲜和韩国的区域平均生物量高于中国辽宁和吉林省，但是结合空间分布来看这种高生物量多数分布于原始森林地区。从 2000 至 2017 年朝鲜和韩国的区域平均生物量并没有观察到显著的趋势变化，决定系数分别为 0.11 和 0.12。然而辽宁和吉林省的平均生物量却表现出显著的上升态势（ $R^2=0.34$ ），并且这种显著的生物量增加多数来自于农

田粮食生产力的提高（图 4-8）。综上所述，基于机器学习和通量观测数据改进的生态系统光能利用模型很好地捕捉了区域生物量的空间模式和时间动态演化，在时间和空间上较为准确地还原了三个地区生物量的时间变化特征，这为后续的未来气候变化下生物量损失的评估研究提供了一个稳定的基础。

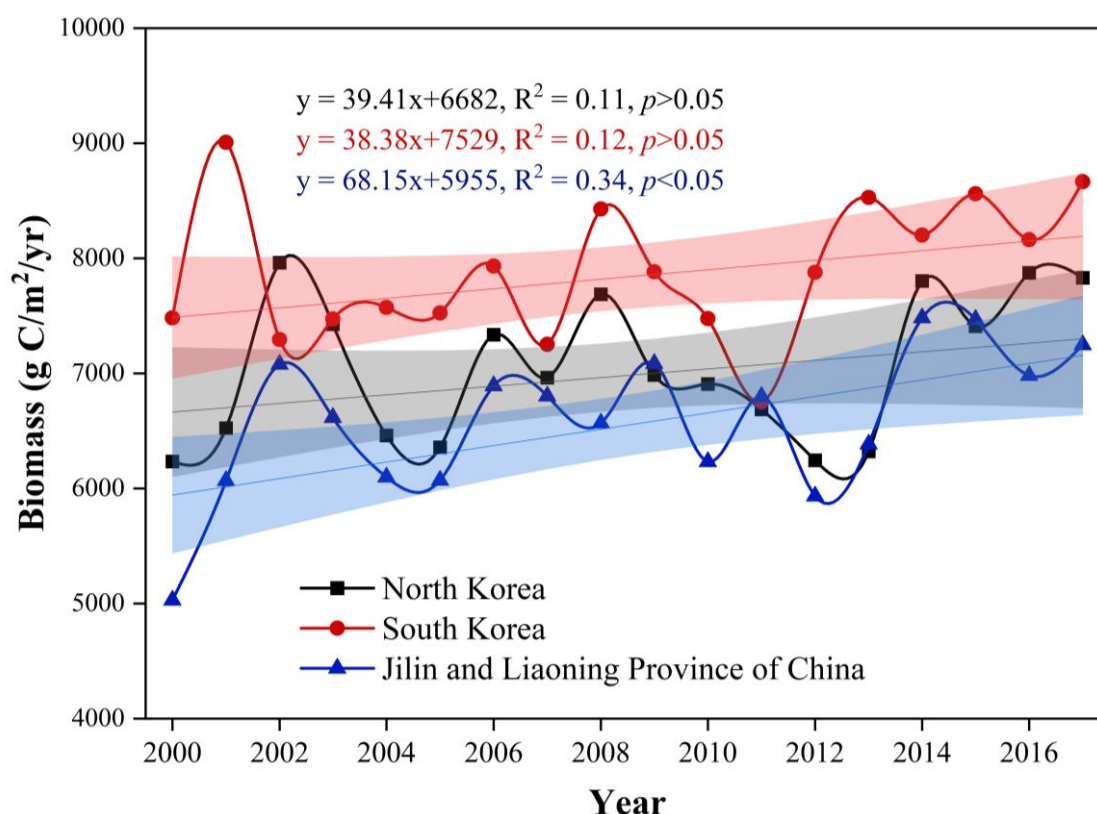


图 4-9 朝鲜，韩国和中国辽宁、吉林省 2000-2017 年区域平均生物量的时间动态变化
Fig. 4-9 Temporal dynamics of regional mean biomass in North Korea, South Korea and Liaoning and Jilin provinces of China during 2000-2017

4.3.2 水稻生物量与环境因子之间的响应关系

本文基于方差膨胀因子（VIF）排除了气候变量之间的共线性效应，并进一步将其纳入到归因分析中以确定影响过去 18 年（2000 年至 2017 年）朝鲜水稻总初级生产力（GPP）变化的缓环境因子。对于朝鲜而言，气候变量解释了 2000-2017 年间通量塔观测 GPP 变化的 80%（图 4-10a）。此外，重要性分析显示温度效应（尤其是温度极端值）在朝鲜 GPP 变化中占主导地位（解释了近 50%），这一现象可通过与温度相关的最重要的四个变量（TNn，最低气温的最小值；TR20，最低温度大于 20° C 的天数；FD0，最低温度小于 0° C 的天数；和 AAT，平均气温）来加以证实（图 4-10b）。研究进一步通过多种交叉验证的方法测试了模型的稳健性，结果表明气候因子是过去朝鲜水稻生

产力的主要驱动，交叉验证的 R^2 为 0.78（图 4-10a 和表 4-2）。

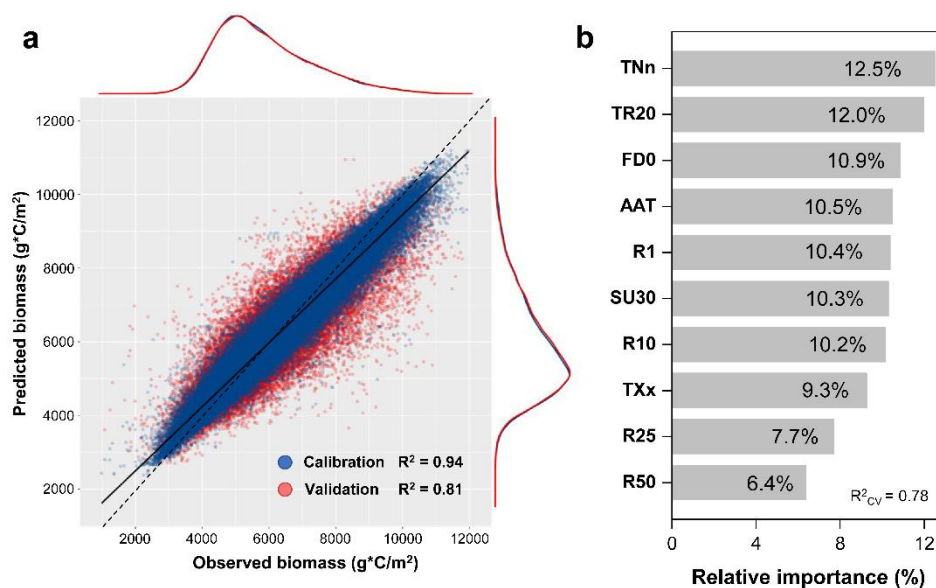


图 4-10 基于随机森林模型的朝鲜水稻生物量模拟及气候变量贡献归因。蓝色点和红色点分别代表校准和验证数据集。黑色虚线和实线分别为 1:1 线和线性趋势。图 a 中的边际密度表示预测生物量 (y 轴) 和观测生物量 (x 轴) 中校准和验证点的分布。

Fig. 4-10 Simulating rice biomass and attributing the contribution of climatic variables based on random forest model in North Korea. The blue and red points represent the calibration and validation data sets, respectively. The dashed and solid black lines are the 1:1 line and the linear trend, respectively. The marginal density in panel a represents the distribution of calibration and validation points in predicted biomass (y-axis) and observed biomass (x-axis).

表 4-2 2000 年至 2017 年朝鲜生物量随机森林模型的交叉验证结果

Table 4-2 Cross-validation of random forest model for baseline in North Korea from 2000 to 2017.

交叉验证	R^2	$nRMSE$ (%)
First fold	0.779	10.30
Second fold	0.779	10.32
Third fold	0.780	10.28
Fourth fold	0.783	10.24
Fifth fold	0.784	10.15
Average	0.781	10.26

4.4 基于过程模型和空间遥感数据模拟小麦产量及温室气体排放

4.4.1 模拟区域小麦产量和温室气体排放的量级和趋势

过去的研究已经深入探究了特定作物的生产力，但对于这些特定作物生产过程中

所释放的温室气体（例如 N_2O 、 CH_4 和 CO_2 ）仍然缺乏报道，而更多的是集中在农田尺度的总体土壤排放。本研究试图采用基于过程的陆地生态系统模型结合最先进的农业模块来弥补这一空白。图 4-11 展示了 DLEM 模型对小麦生产力的区域估计，与美国农业部（USDA）的调查数据相比，呈现出高度一致的空间分布和量级。具体而言，美国西北部（如华盛顿和蒙大拿）和中部大平原地区（如堪萨斯州和俄克拉荷马州）是全美小麦生产的热点区域。

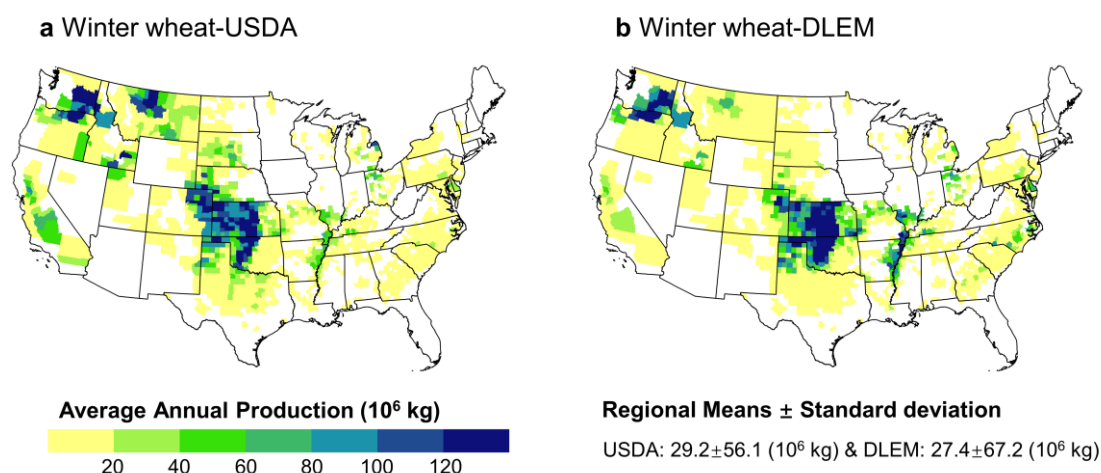


图 4-11 DLEM (a) 和统计 (b) 小麦产量估算的区域比较。DLEM 的模拟结果被平均到县级尺度以匹配美国农业部调查数据的格式

Fig. 4-11 Regional comparisons between DLEM-based (a) and survey-based (b) estimations for wheat production. The simulations from DLEM were averaged county level to match the format of survey data from United States Department of Agriculture (USDA, <https://quickstats.nass.usda.gov/>).

本研究的模拟结果显示，在过去的六十年中，美国小麦产量每年贡献了约 7.3 Tg 的温室气体排放（其中 85.6%来自冬小麦，15.4%来自春小麦）和 56 Tg 的产量（其中 72.3%来自冬小麦，27.7%来自春小麦）。从 1960 年到 1990 年，冬小麦的温室气体排放强度（GHGI）、净温室气体排放（GHG）和产量都大幅增加，但从 1990 年到 2018 年经历了显著下降（图 4-12 和附表 1）。与此同时，春小麦的 GHGI 显著上升，这是由于同期温室气体排放和产量的显著增加所致（图 4-13 和附表 1）。冬小麦的温室气体排放和产量的空间格局呈现出相当大的异质性，美国中南部的 GHGI 和净温室气体排放较高，与小麦产量较高的地区呈现一致的格局，而美国西北部地区的冬小麦在吸收温室气体方面发挥了关键作用，致使该地区 GHGI 降低（图 4-12）。此外，1990 年后春小麦的产量呈现负增长趋势，这与前三十年的显著增长形成了鲜明对比（图 4-13c）。总而言之，春小麦的温室气体排放和产量低于冬小麦，并且在空间格局中没有展示明显的冷点或者热点（图 4-13）。

值得额外说明的是，本研究模拟的美国小麦土壤 N_2O 排放总计为 $0.03 \text{ Tg N yr}^{-1}$ ，这以往研究的结果相符。例如，Tesfaye et al. (2021) 进行了全球小麦 N_2O 排放的估计，并报告了 2013 年全美国的 N_2O 排放约为 $0.02 \text{ Tg N yr}^{-1}$ 。此外，根据 Lu et al. (2022b) 报告的条形图，美国土壤中的小麦 N_2O 排放量在 0.01 至 $0.02 \text{ Tg N yr}^{-1}$ 范围内。

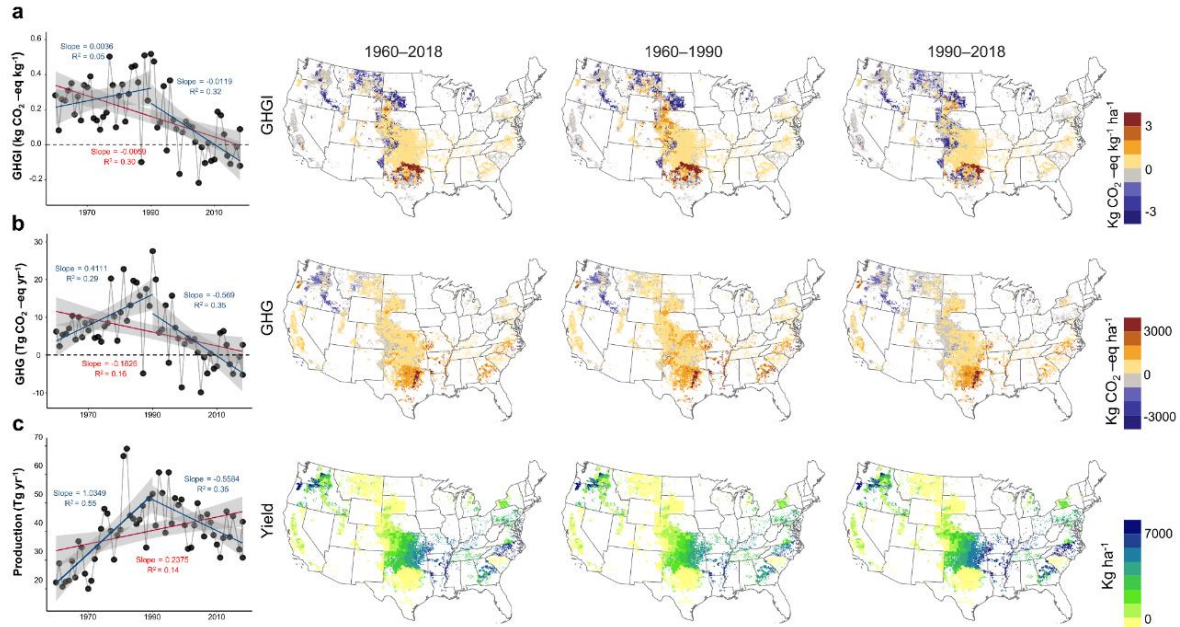


图 4-12 1960-2018 年美国冬小麦温室气体排放强度、净排放量与产量的时空变化。蓝色实线和红色实线显示了两个子时期（1960-1990 年和 1990-2018 年）和整个时期（1960-2018 年）的线性趋势。阴影带表示 95% 置信区间。各图中温室气体排放和温室气体排放强度的负值表示吸收量。

Fig. 4-12 Spatial-temporal variations in greenhouse gases (GHG) emission intensity, net GHG emission, and yield for winter wheat in the United States (1960-2018). The line graphs show trend lines for two sub-periods (1960-1990 and 1990-2018) and the entire period (1960-2018) represented by two blue solid lines and one red solid line, respectively. The shaded bands indicate the 95% confidence intervals. Negative values for GHG emission and GHG emission intensity in each graph indicate uptake.

4.4.2 1960 年至 2018 年美国小麦产量和温室气体排放变化的归因分析

本节研究进行了一项归因分析，以探究环境因素和农业管理对美国小麦种植区 1960 年至 2018 年温室气体排放和产量的影响（图 4-14）。结果表明气候变化和氮肥施用是区域温室气体排放和产量变化的主要驱动因素（区域估计未土地利用和覆盖变化对单产的影响）。人为耕作实践和大气 CO_2 施肥效应在小麦种植区的特定条件下发挥了更重要的作用（图 4-14）。此外，本研究还对 1960 年至 1990 年和 1990 年至 2018 年这两个不同时期进行了深入分析，结果发现氮肥施用、土地利用变化以及耕作管理是影响冬小麦温室气体排放和产量随时间变化的关键因素。具体而言，氮肥施用和土地利

用变化在 1990 年之前促进了冬小麦的温室气体排放和产量增加，而在随后的三十年中对排放和产量变化产生了抑制作用。在 1990 年至 2018 年期间，耕作方式的变化导致温室气体排放大幅增加，尽管对产量的影响相对较小，但这一变化抵消了由于氮肥减少而取得的减排努力（图 4-14a 和图 4-14c）。与冬小麦不同，土地利用变化并没有导致春小麦温室气体排放的增加，而氮肥施用和气候变化是温室气体排放和产量变化的主要影响因素。然而，土地利用变化对春小麦的产量变异造成了显著影响。具体而言，在 20 世纪 60 年代到 90 年代期间，气候变化、氮肥施用和土地利用主导了春小麦的产量增加（图 4-14b 和图 4-14d）。然而，自 1990 年以来，土地利变化对春小麦生产造成了抑制作用，导致了这一时期产量的显著下降（图 4-12c 和图 4-13c）。

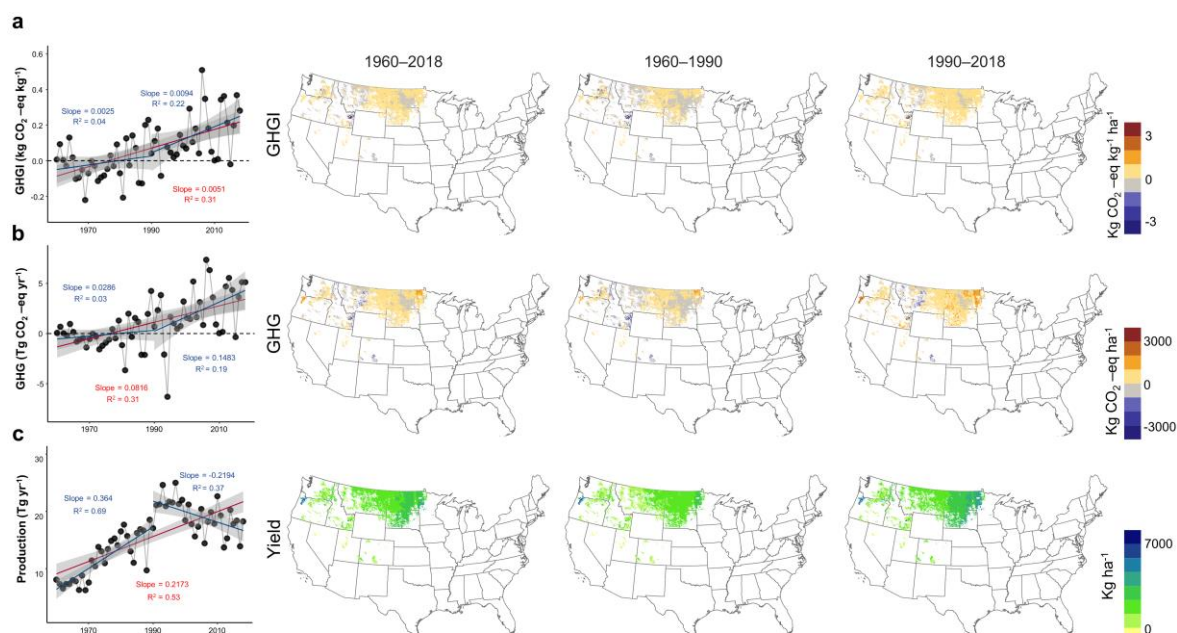


图 4-13 1960-2018 年美国春小麦温室气体排放强度、净排放量与产量的时空变化。蓝色实线和红色实线显示了两个子时期（1960-1990 年和 1990-2018 年）和整个时期（1960-2018 年）的线性趋势。阴影带表示 95%置信区间。各图中温室气体排放和温室气体排放强度的负值表示吸收量。

Fig. 4-13 Spatial-temporal variations of greenhouse gases (GHG) emission intensity, net GHG emission, and yield for spring wheat from 1960 to 2018 in the United States. Two blue solid lines are the trend line of the two periods (1960–1990 and 1990–2018) and the red solid line is the trend line of the whole period (1960–2018) in each line graph. The shaded bands denote the 95% confidence intervals. The negative value for GHG emission and GHG emission intensity represents the uptake.

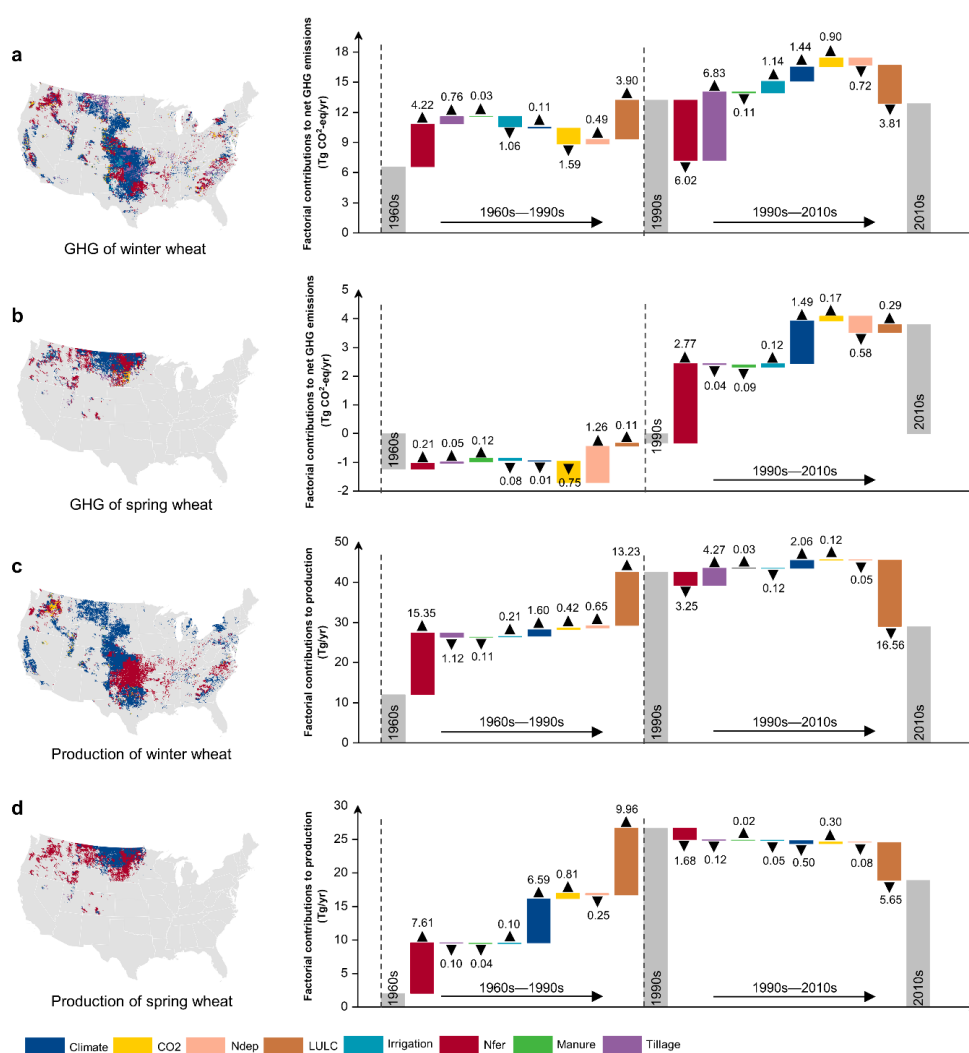


图 4-14 多环境因子对美国小麦净温室气体排放和产量的时空贡献。黑色三角形的方向表示环境因子对小麦净温室气体和产量造成的排放（朝上）或吸收（朝下）。

Fig. 4-14 Spatial-temporal importance of multi-environmental factors to net greenhouse gases (GHG) emissions and yield for wheat in United States. The direction of black triangle represents the emission (facing up) or uptake (facing down) resulting from environmental factors for net GHG and production of wheat.

4.5 讨论

4.5.1 迁移框架的可预测性

本研究提出了一个可迁移框架，用于评估数据稀疏地区的水稻生产力，即基于气候相似性原理，采用非线性模型和公开可用环境变量来预测水稻的单产和总产。该方法有两个主要优势：1) 能够扩展农业调查的时空尺度；2) 简化昂贵和耗时的调查和参数获取过程。

传统的农业生产调查大多集中在可控的田间或站点尺度上（使用气象站或通量站

的数据), 所得结果仅能反映单一的环境条件。由于区域尺度上环境因素的空间异质性, 传统方法不适用于大尺度的作物生产力评估。然而, 本研究提出的方法将为减小这些不足提供支持。具体而言, 该方法不仅能够扩展到大尺度空间估计, 还能基于输入变量的环境异质性保证连续的时间尺度。此外, 该方法还能有效降低人力和物力的消耗高成本。许多学者此前通过作物模型和遥感数据的同化方法 (Huang et al. 2019)、生态模型 (Tian et al. 2010a) 以及基于能量传输的光能利用率模型 (Waring et al. 1998) 扩展了作物生产力预测的尺度。然而, 这些方法受到大量强制数据和经验参数的限制, 对于区域模拟存在不确定性。相比之下, 本研究采用的框架潜在地避免了这些问题并获得了较高的准确性, 然而, 并未显著提升对作物生长机制和过程的理解。此外, 机器学习是一种“黑盒”模型, 能够有效处理数据异常值 (Rudin 2019), 特别是随机森林模型 (Breiman 2001; Shi et al. 2020b)。在实践中, 数据异常值可能来自与极端天气信号 (如极端降水和高温热浪), 导致植被生长异常 (Shew et al. 2020)。因此, 本研究无法评估机器学习模型能否在极端条件下精确预测水稻产量。如果训练数据中不包含大量的极端事件, 则在水稻产量预测方面机器学习模型存在一定程度的不确定性。

本研究通过交叉验证和联合国粮农组织数据验证了所提出框架的稳定性和结果的可靠性。然而, 该方法存在两个需要注意的问题。一是朝鲜和其邻国之间的气候相似性。气候条件决定了水稻生长季和不同物候期的持续时间 (Wang et al. 2021a)。如果使用相同的输入变量和模型参数确定物候期, 当气候条件存在较大差异时, 结果将引入更多不确定性。此外, 不同物候期的持续时间也会有所变化, 导致物候期的起止时间出现判断偏差, 进一步影响模型精度。二是种植强度也直接影响该方法的适用性 (Blanke et al. 2017)。朝鲜位于中纬度地区, 水稻一年一熟, 然而在低纬度地区, 作物通常每年可以进行两到三次的种植和收获。本研究强烈建议参考当地物候历来确定水稻生长季节的开始。值得注意的是, 物候日历通常可以轻松获得, 因此其获取不会影响该框架的广泛适用性。

4.5.2 基于迁移框架预测水稻单产和总产

本研究利用联合国粮农组织公开的统计数据对预测的单产和总产进行了验证。研究发现, 该框架很好地捕捉到了水稻总产的变化, 但高估了水稻单产 (图 4-2), 这可能是由于水稻总产由种植面积和单产组成, 本研究中的水稻种植面积主导了产量的变化 (图 4-1a, b)。而水稻单产受内部因素 (基因) 和外部因素 (环境和管理) 的联合调控, 如实际的光合能力 (图 4-1a, b), 中国和朝鲜经济社会差异可能解释了在类似气候条件下由于训练数据来自更好的管理环境而导致的产量高估 (Shi et al. 2022)。因此, 将模型扩展到其他地区时, 应进一步考虑作物管理差异的潜在影响。此外, 验证数据来源于 FAO 的朝鲜全国水稻生产力统计, 并且作为可靠的数据来源展示了稳健的验证结

果。然而，这些数据对于验证特定地区的预测精度并不具备足够的效力。特别是在某些地区，水稻产量的高估和低估可能会相互抵消，从而表现出更好的区域结果。未来研究的一个重要方向是开发高精度的时空数据，以进行独立验证。

水稻种植面积作为一个变量被纳入到可迁移模型中直接预测总产。本研究中，直接预测总产与根据单产和种植面积的乘积计算的总产相比，减少了由水稻分布图所引入的误差传播。对于该框架来说，水稻地图提供了县级水稻面积的动态比例，而不是绝对数值，并且预测结果受到特定变量的相对变化的影响。因此，本研究没有将总产计算为单产和面积的乘积。研究发现水稻种植面积主导了超过 40% 的水稻总产变化，这个结果是合理且可解释的，不论是采用区域分析还是年度时间序列的累积分析，都表明作物的种植面积在影响县级作物产量方面有着不可忽视的作用 (Rezaei et al. 2021)，特别是在欠发达地区，作物总产的变化是由种植面积而不是单产所驱动的 (Rezaei et al. 2021; Zhu et al. 2022)。总之，将种植面积纳入产量评估系统是必要的。

本研究初步探索了提前一个物候期预测水稻生产力的可行性。研究选择 SHP 情境下的水稻生产力进行估计有两个主要原因：1) 先前发表的研究结果表明，水稻在拔节期对环境变化的敏感性高于其他物候期 (Ji et al. 2017)。Chang et al. (2005) 利用敏感物候期的反射率数据成功了预测水稻产量。因此，拔节期可能是预测水稻产量的关键时期。2) 本研究更关注该框架在收获前预测生产力的潜力。"本研究发现，基于 SHP 数据驱动的模式在评估水稻产量方面表现比 WGP 情景下更可靠。这可能是因为水稻成熟和收获阶段叶片衰老导致光合能力下降，进而降低了预测精度 (Fang et al. 2014)。对于国家而言，作物产量的早期预测可能直接影响进口、出口和食品价格的稳定性。本研究建议未来的研究考虑引入多个物候期，并将该模型应用于其他农作物，以满足更大尺度产量预测的需求。

4.5.3 气候变化和施肥主导小麦产量和温室气体排放的变化

本章研究发现气候和人为氮输入对整个美国的小麦产量和温室气体排放具有显著影响 (图 4-14)。然而，增加氮肥的施用以提高小麦产量和品质可能会导致严重的环境污染和大量 N_2O 排放 (Liu et al. 2012; Mueller et al. 2012; Zhao et al. 2015)。近几十年来， N_2O 排放量与小麦产量相比增加了十倍 (Zhao et al. 2015)，所有作物的 N_2O 排放量均随着氮输入的增加而线性增长 (Butterbach-Bahl et al. 2013)，过度施肥导致的残余氮降低了作物的氮利用效率 (Peng et al. 2009)，并增加了硝化和反硝化过程中的底物浓度 (Butterbach-Bahl et al. 2013; Prosser et al. 2020)，从而加速了土壤中温室气体的释放。一个不容争议的事实是，较低的氮利用效率可能会削弱产量增长。因此，许多研究试图在保证作物产量的同时减少温室气体排放之间取得平衡。

小麦产量和温室气体在特定地点上受温度和湿度的联合控制。降水改变土壤孔隙

中的氧含量,进而会影响与土壤碳氮循环相关的微生物过程(Plaza-Bonilla et al. 2014)。在干旱和半干旱地区,水分可用性也限制了土壤中的有效氮(Tellez-Rio et al. 2015),导致产量减少并促进硝化作用(好氧条件下)。此外,升高的温度通过改变植物的生理和代谢过程阻碍了光合作用,加速小麦的衰老并导致产量下降(Asseng et al. 2017)。多项研究表明,小麦产量对高温的抵抗力随时间减弱,表明未来气温升高将增加产量损失的风险(Zhang et al. 2014)。此外,温度的变化加剧了土壤碳氮的不稳定性(Bhattacharyya et al. 2013),气温升高引起的微生物和根际活动将刺激土壤中更多的温室气体释放。

4.6 小结

(1) 本章研究提出了一种基于气候相似性的可迁移框架,用于预测数据稀疏地区的水稻产量。该框架整合了多源数据和机器学习技术,增强了模拟水稻产量变化的能力。与联合国粮农组织的统计数据相比,预测结果在 WGP 和 SHP 情景下分别解释了总产变异的 78.72%和 76.89%,以及单产变异的 69.42%和 71.15%。预测的空间格局与世界粮食计划署的记录相一致。其中 SIF 是水稻单产预测中的主导因素,在 SHP 和 WGP 情景下的贡献超过 15%。其次是日最高气温和蒸散发,共同解释了超过 20%的水稻单产变化。该框架可在进一步改进和评估的后,扩展到其他农作物和数据稀缺地区,用于作物生产力预测以满足更大尺度产量预测的需求。

(2) 此外,本章研究进一步探讨了基于机器学习和通量观测数据改进的生态系统光能利用率模型预测区域生物量的表现。研究发现过去 18 年,朝鲜和韩国区域生物量增加主要位于森林地区,农田生物量变化不明显甚至有不同程度的下降。而中国的辽宁和吉林省生物量在时间空间上呈现显著增加趋势,且多数位于农田地区。该模型很好地捕捉了区域生物量的空间模式和时间动态演化,在时间和空间上较为准确地还原了三个地区生物量的变化特征。与温度相关的气候变量主导了朝鲜区域生物量的动态变化,高温异常指数可能是朝鲜过去生物量损失的重要原因。该结果后续的未来气候变化下生物量损失的评估研究提供了一个稳定的保障。

(3) 最后,研究基于过程模型和空间遥感衍生数据模拟了 1960-2018 年美国小麦生产力和温室气体排放,并探究了环境因素和人为管理对历史变化的潜在贡献。研究发现过去的六十年中,美国小麦产量每年贡献了约 7.3 Tg 的温室气体排放和 56 Tg 的产量。从 1960 年到 1990 年,冬小麦的温室气体排放强度、净温室气体排放量和产量都大幅增加,但从 1990 年到 2018 年经历了显著下降,然而春小麦的温室气体排放强度持续上升,这是由于同期温室气体排放的显著增加所致。气候变化和氮肥施用是单位温室气体排放和产量变化的主要驱动因素,但土地利用、气候和氮肥施用决定了大多数温室气体总排放和总产量的变化。

第五章 典型区域粮食生产对极端天气事件的响应特征

5.1 引言

尽管总体上农业生产有所增加，然而过去 50 年间，全球范围内的气候变化却在一定程度上减缓了这种增长。与 1850-1900 年相比，预计一些地区的农业和生态干旱将变得更加频繁和，部分地区的气象干旱也有所增加。与此同时，愈演愈烈的极端天气和气候事件已经使数百万人陷入了粮食不安全和水资源匮乏的境地，其中对非洲、亚洲、中美洲、南美洲等多个地区的影响最为显著。全球多项研究均证实了气候变化对全球粮食生产造成了显著负面影响。例如，Bandara and Cai (2014) 指出，南亚地区（包括孟加拉国、印度、尼泊尔、巴基斯坦和斯里兰卡）受到气候变化的影响，可能导致粮食生产和价格下降。Fahmida et al. (2022) 的研究表明，气候变化使得尼泊尔、孟加拉国和缅甸的粮食安全受到不利影响，而巴基斯坦可能在一定程度上受益。然而，Abbas (2022) 发现巴基斯坦的农业生产受到气候变暖的负面影响，特别是旁遮普省的西部、南部和中部地区。

在非洲和北美也同样观察到了由气候变化造成的产量损失。Lobell et al. (2008) 基于统计方法预测 21 世纪初作物对气候的响应，研究指出如果没有足够的适应措施，非洲南部的农作物可能会面临气候变化造成的不利影响，预计玉米、小麦、大豆、甘蔗和高粱产量平均分别下降 28%、16%、8%、6% 和 2%。其他研究估计 25 个撒哈拉以南非洲国家和 77 个发展中经济体的粮食安全将受到降雨变化的影响，可能导致中非地区谷类作物产量减少 89%，西非、东非和南部非洲地区分别下降 85%、32% 和 29% (Thamaga-Chitja and Tamako 2017)。Rowhani et al. (2011) 的研究指出坦桑尼亚主要作物产量在未来可能急剧下降，预计到 2050 年气温升高 2 摄氏度，季节性降雨波动将会增加 20%，这可能导致玉米产量下降 3.6%，高粱下降 8.9%，水稻下降 28.6%。美国的模拟研究也支持了这一观点。Petersen (2019) 研究发现美国作物生产受到高温、热浪和干旱的影响，随着气温升高，玉米和大豆的产量将显著降低。因此，必须采取有效方法评估气候变化对粮食生产系统的影响，特别要考虑气候变化下极端天气事件的动态与发展，以确保全球粮食供应的稳定。

气候变化不仅会引发产量损失，还会通过改变作物敏感性进一步加剧未来减产风险。随着未来气候变暖，作物生产对气候变化（极端天气）的敏感性也越来越被研究者关注。Malikov et al. (2020) 揭示了气候变化对农业影响的分布异质性，即生产力较低地区的作物产量可能受到未来气候变化的影响也更大，而生产力较高地区的作物产量可能受到的影响较小。这可能由于作物产量对未来气候变化的敏感性因作物类型、灌

溉条件以及其他生物物理和社会经济因素而异 (Mondal et al. 2015), 并且作物不同生育期对气候变化的敏感性也存在巨大差异。Auffhammer et al. (2012) 发现在印度, 水稻收获期的低温将对产量造成更显著的负面影响。此外, 作物生产敏感性的动态变化也值得被进一步纳入到产量风险评估中去, 例如 Feng et al. (2021) 基于玉米主产国气候与产量的关系研究, 发现作物减产的风险通常随干旱条件和作物产量 (或炎热条件和作物产量) 之间依赖性的增强而增加。干旱条件下有限的水资源可能不足以弥补上升的干热气候导致的作物生产敏感性的增加 (Meng et al. 2016)。Trnka et al. (2016) 的跨区域分析同样证明了欧洲作物产量与气候的关系发生了显著变化, 并且在某些地区, 不同的环境因素在最近几十年对产量的影响比过去更大。尽管随着作物品种改良和不断增强的二氧化碳的施肥效应, 在特定地区观察到了持续增加的作物产量。但是在气候变暖的影响下, 农艺的改变往往会将植物耐旱性的提高转化为更高的平均产量, 但不会降低田间作物的干旱敏感性 (Lobell et al. 2014)。因此, 在未来极端干热事件增多的背景下, 人为管理实践是否能够改善或者加剧作物生产的敏感性在很大程度上是未知的, 这种响应的动态发展取决于特定地点的环境变化、极端事件的发生窗口、社会经济和资源利用的巨大变化。

综上所述, 本章研究以气候变化下极端气候事件频发区为例 (朝鲜和美国), 基于多种模型和数据整合的方法探究气候变化对作物生产的影响以及未来风险, 并进一步模拟分析作物干热敏感性的动态响应, 旨在回答以下科学问题: (1) 极端天气事件对水稻生产的历史影响以及未来的潜在损失风险是如何变化的; (2) 小麦生产对极端干热事件的响应以及其敏感性的长期动态是如何变化的; (3) 小麦生产过程中碳氮循环对极端干热事件的响应以及其敏感性的长期动态是如何变化的。

5.2 极端天气事件对水稻生产的历史影响以及未来的潜在损失风险

5.2.1 极端天气事件对朝鲜水稻生产的历史影响

基于 FAO 的朝鲜水稻产量和进出口统计, 本研究的结果显示在 2000 年和 2007 年朝鲜水稻产量出现急剧下降 (图 5-1), 在发生产量突然下降的随后几年里, 粮食进口量急剧攀升。虽然进入 20 世纪后, 朝鲜水稻生产总体上呈现持续上升的态势 (图 5-1), 但是年际间巨大的产量波动依然威胁着人口生计。当政治经济环境相对稳定时, 我们推断潜在的极端气候事件引发的气候冲击可能是导致朝鲜水稻产量的波动的主要原因, 并进一步影响全国粮食安全。




图 5-1 1984 年至 2017 年朝鲜水稻生产和进出口总值

Fig. 5-1 Value of rice production, imports, and exports for North Korea from 1984 to 2017 (from FAO).

基于多种极端天气指数和异常值分析, 研究发现极端高温事件和降水分别在 2000 年和 2007 年引起了朝鲜水稻产量波动, 进一步将每个气候变量的空间异常值与正常年份进行比较从而观察到了更多细节 (图 5-2)。具体而言, 研究观察到了 2000 年极端高温指数异常增加 (TXx, 日最高气温的最大值), 长期高温引发了大规模的热浪, 导致白天和夜间气温升高 (SU30, 最高气温大于 30°C 的天数; TR20, 夜间最高气温大于 20°C 的天数)。在 2000 年, TXx、TR20、SU30 和 FD0 异常增加的频率分别占整个地区的 27%、35%、37% 和 54%, 特别是在朝鲜西部和南部的水稻种植区 (图 5-2 和图 5-3)。在朝鲜东北部非水稻种植区, 降雨量的显著增加并不能缓解高温热浪导致的产量减少 (图 5-2)。对于 2007 年, 降水极端事件占主导地位, 降低了西南部的稻作区域的水稻产量 (TP, 生长季总降水量; R50, 日降水量大于 50 毫米的天数)。具体而言, TP、R50 和 R25 (降水量大于 25 毫米的天数) 的异常增加分别占整个地区的 87%、72% 和 80% (图 5-3), 长期大量的降水导致植物极易受到作物根腐病和洪水的侵害, 这些降水极端事件同样调节了地表温度, 致使当年最高气温阈值的下降和最低气温的上升 (TXx; TNn, 日最低气温的最小值)。值得一提的是, 2000 年的极端高温和 2007 年的降水极端事件发生在水稻生长发育的关键时期, 即抽穗-分蘖阶段, 处在这一窗口期的作物通常对气候变化十分敏感, 尤其对高温和干旱胁迫, 这可能导致植株发育不良甚至死亡

(图 5-2)。总而言之，极端天气事件导致朝鲜水稻产量在时间和空间上突发变化并急剧下降，进一步加剧潜在人口饥饿。

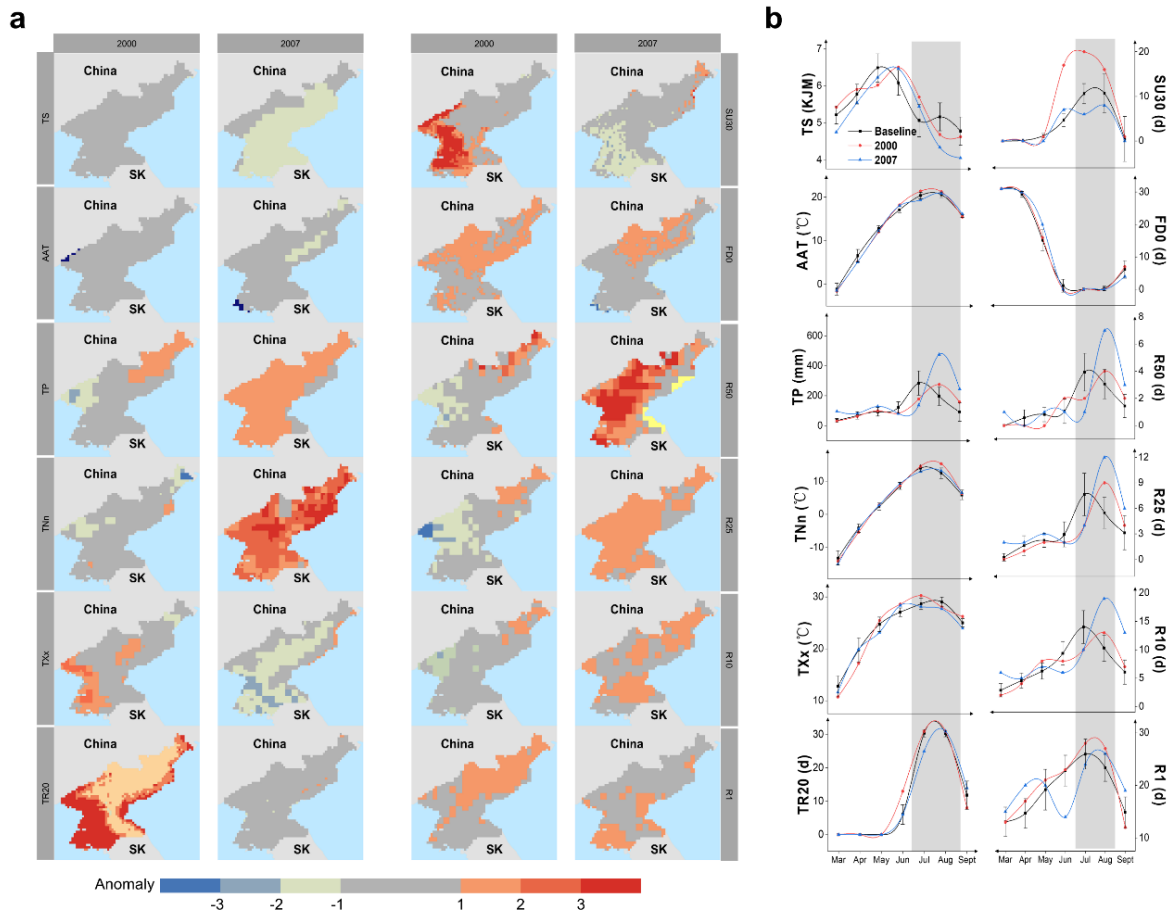


图 5-2 由极端天气事件导致的 2000 年和 2007 年朝鲜水稻产量损失的时空归因。

Anomalies > -1 或 < 1 表示显著的异常区域。图 b 中垂直灰色区域代表分蘖期到抽穗期。

Fig. 5-2 Spatial-temporal attribution of rice production losses in 2000 and 2007 across North Korea.

Panel. Anomalies > -1 or < 1 indicate regions of non-significant anomalies, and are shown in grey. The vertical gray areas in panel b represent the period from tillering stage to heading stage.

5.2.2 朝鲜未来气候变化

基于 27 个全球气候模型 (GCM) 集合的两个气候情景 (SSP245 和 SSP585)，本章研究分析了未来气候变化及其对水稻产量的影响。朝鲜未来气候将表现出显著的温度和降水增加。具体而言，根据 2080 年 SSP585 情景显示，AAT、TNn 和 TXx 将分别增加 $2.96 \pm 0.93^\circ \text{C}$ 、 $2.32 \pm 0.59^\circ \text{C}$ 和 $3.81 \pm 1.12^\circ \text{C}$ (图 5-4a, d, e)。令人惊讶的是，到本世纪末 SU30 在 SSP245 和 SSP585 情景下将分别增加 $97.6 \pm 43.77\%$ 和 $221.94 \pm 77.09\%$ ，这意味着高温天数将比 1979-2018 年期间增加两倍甚至三倍 (图 5-4g)。此外，TP、R50 和 R25 在 SSP585 情景下也将分别增加 $19.93 \pm 7.74\%$ 、 $7.57 \pm 12.53\%$ 和 13.42

±9.75%，但 R1 将减少 $19.23 \pm 0.86\%$ (图 S5-4c, i, j)。总的来说，无论考虑何种气候情景，由于未来的气候变暖，极端高温和降雨的风险都将显著增加。

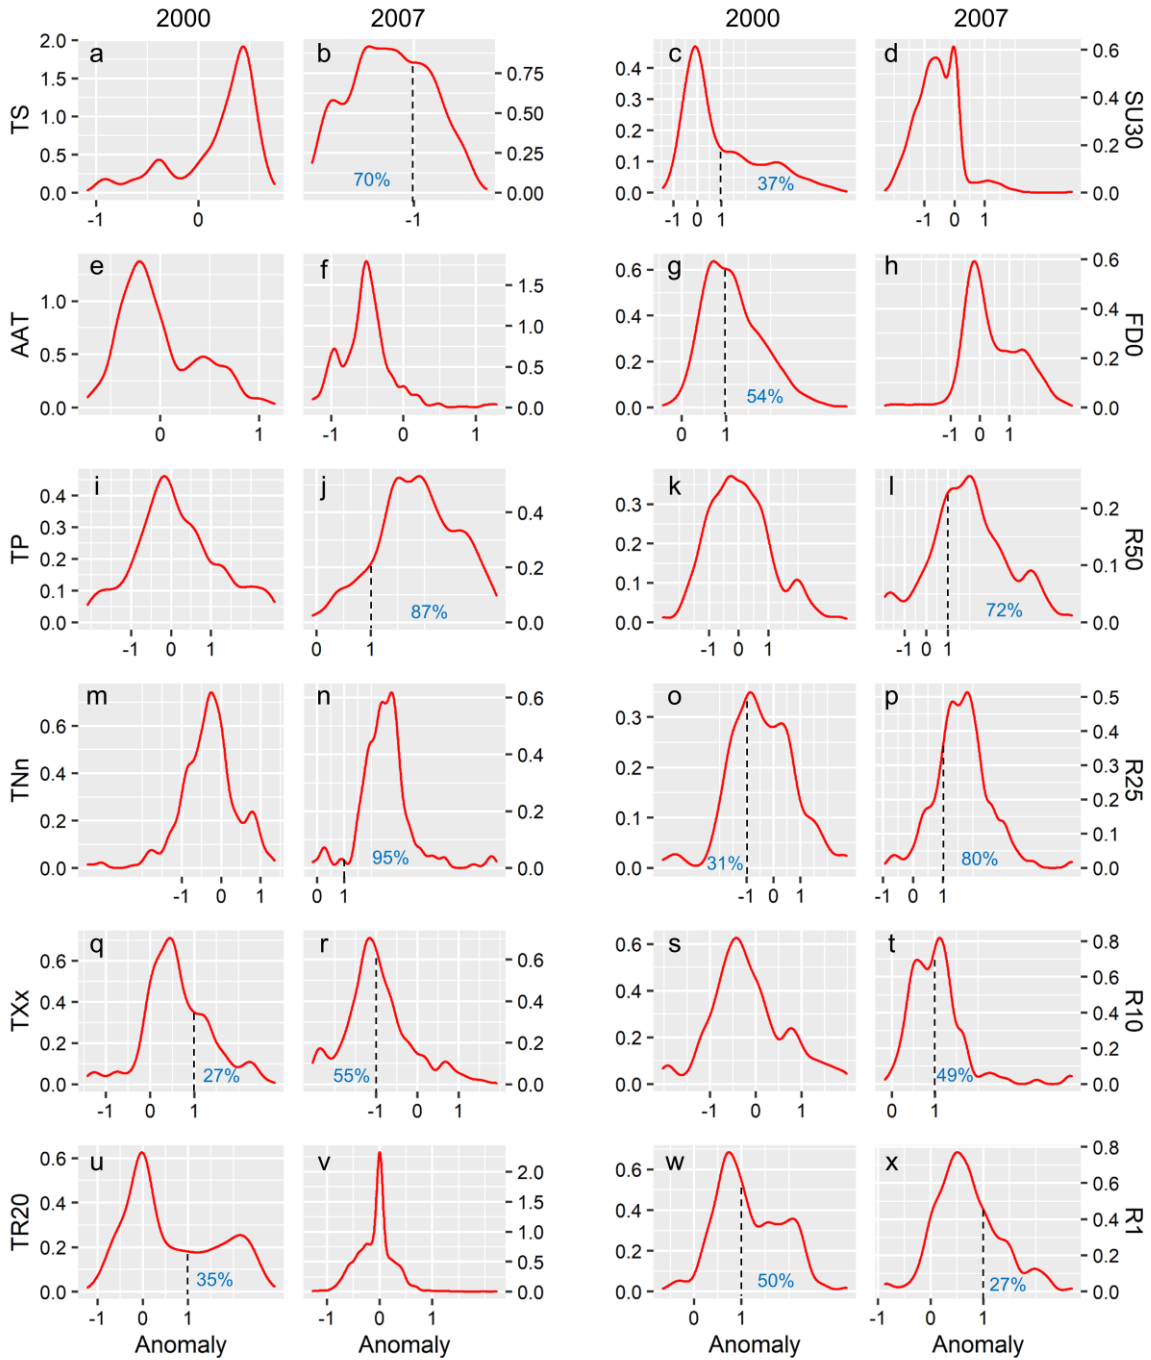


图 5-3 2000 年和 2007 年朝鲜气候异常的密度分布

Fig. 5-3 Density distributions for anomalies of the climatic variables in 2000 and 2007 over North Korea.




图 5-4 基于随机森林和 27 个 GCM 预测朝鲜未来极端天气因子。箱型图内的黑线表示多模型中位数。图 a-l 分别代表 TS、AAT、TP、TNn、TXx、TR20、SU30、FD0、R50、R25、R10、R1 的相对变化。

Fig. 5-4 Projected normal and extreme climate change in North Korea with a random forest model and 27 GCMs. The black lines within each box indicate the multi-model median. Panels a to l represent TS, AAT, TP, TNn, TXx, TR20, SU30, FD0, R50, R25, R10, and R1, respectively. The relative changes of AAT, TNn, and TXx are difference values, and the rest of the values are percentages.

研究发现尽管朝鲜和中国辽宁、吉林省之间的气候数据存在细微差异，但极端其后指标的平均值和极值都表现出相同频率的振荡现象，这表明两个地区剧烈和平稳的波动同时刻发生。具体而言，在过去 40 年中，气候风险相关变量的波动幅度展现出相似趋势，例如 TR20、SU30、FD0、R50 和 R25（图 5-5），其他变量（包括 TS、TNn、FD0、R10 和 R1）的量级和波动幅度也表现出高度的一致性。基于 27 个全球气候模式，本研究进一步比较了朝鲜和中国吉林、辽宁省在 SSP245 和 SSP585 情景下的气候风险。在高排情景下，研究观察到朝鲜和中国吉林、辽宁省的高温天数增加了两倍以上。此外，中国吉林、辽宁省还表现出更强的极端降水，温度上升的程度甚至超过了朝鲜，这意味着未来中国吉林、辽宁省将面临更高的气候风险（图 5-5 和图 5-6）。

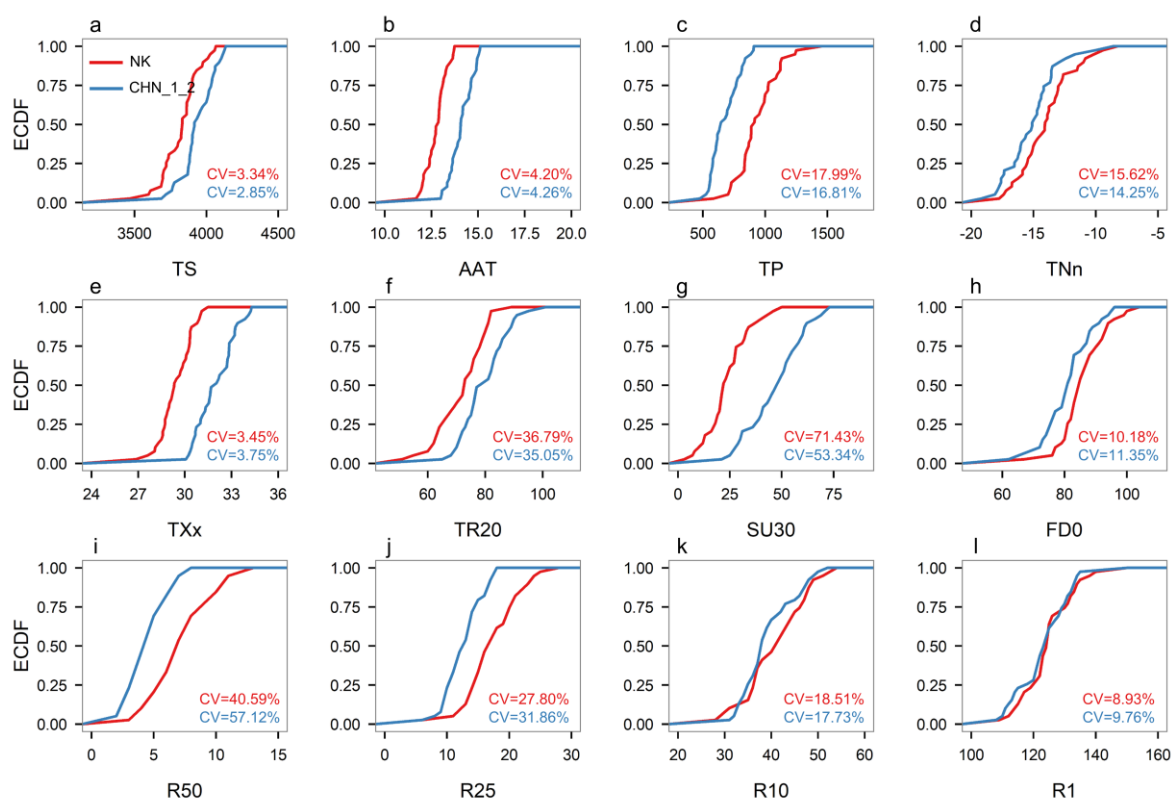


图 5-5 朝鲜与中国吉林、辽宁省 1979 至 2017 年极端气候变量的经验累积分布函数。变异系数用于衡量时间序列的波动。

Fig. 5-5 Empirical cumulative distribution function of twelve climate variables between North Korea and Jilin and Liaoning provinces of China from 1979 to 2017. Coefficient of variation is used to measure fluctuations of time series.

5.2.3 未来气候变化下朝鲜的粮食损失风险

由于未来极端高温频发和高变异性的降水条件，相比于 2000-2017 年，朝鲜的水稻生物量到 2080s 在 SSP245 和 SSP585 情景下将会分别减少 18.9%和 20.2%。而水稻产量届时将会损失 13%和 14.4%（图 5-7a）。朝鲜的气候脆弱性极高，历史上频繁出现的极端天气事件导致水稻产量急剧下降，未来 20.2%的生物量损失可能会对本就脆弱的粮食系统造成进一步的压力，进而引发新一轮的饥荒。未来气候变化可能会对朝鲜的生物量产生广泛的负面影响，并且在不同地区可能表现出不同的降低趋势。水稻生物量损失最严重的地区发生在朝鲜西南部和东部沿海（图 5-7b），这些地区是朝鲜的粮食主产区。尽管生物量在零星的地区有所增加，但从整体上来看，朝鲜中部到西部沿海地区的生物量损失掩盖了不同气候模型不一致估计。在 SSP585 情景下，根据 27 个全球气候模式的预测，预计在 2080s，粮食主产区的水稻生物量损失将呈现出更高的置信度（较低的标准偏差），这意味着粮食产区将成为水稻生产风险最严重的热点地区（图 5-8）。




图 5-6 基于随机森林和 27 个 GCM 预测中国辽宁、吉林省未来极端天气因子。箱型图的黑线表示多模型中位数。图 a-l 分别代表 TS、AAT、TP、TNn、TXx、TR20、SU30、FD0、R50、R25、R10、R1 的相对变化。

Fig. 5-6: Projected normal and extreme climate change in Liaoning and Jilin provinces of China with a random forest model and 27 GCMs. The black lines within each box indicate the multi-model median. Panels a to l represents TS, AAT, TP, TNn, TXx, TR20, SU30, FD0, R50, R25, R10, and R1, respectively. The relative changes of AAT, TNn, and TXx are difference values, and the rest of the values are percentages.

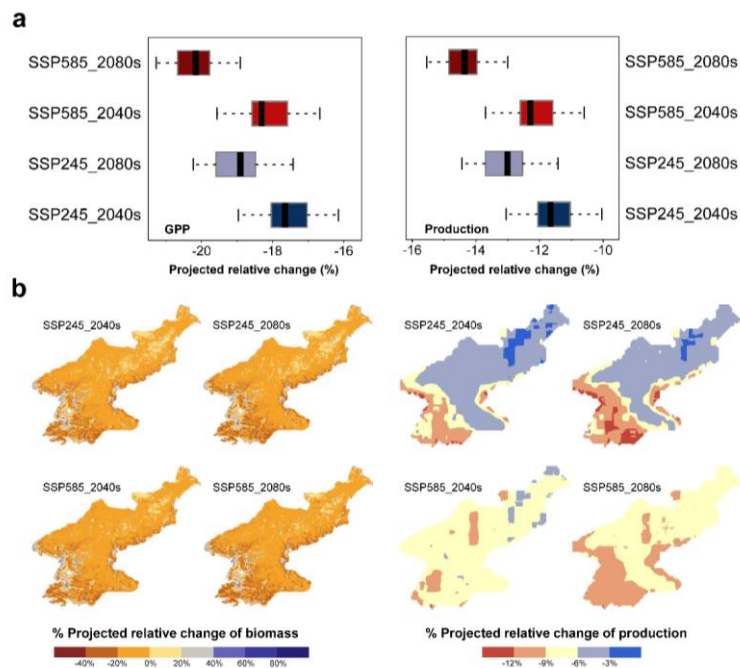


图 5-7 预测朝鲜未来四种情景下的水稻生物量和产量损失。图 a: 四种未来情景下预测的水稻生物量（左图）和产量（右图）损失的箱形图。每个箱内的黑线表示多模型中位数。图 b: 未来情景下水稻生物量和生产损失的空间热点。

Fig. 5-7 Projected rice biomass and production losses under four future scenarios in North Korea. **a**, Box plots of projected rice biomass (left panel) and production (right panel) losses under four different future scenarios. The black lines within each box indicate the multi-model median. **b**, Spatial hotspots of rice biomass and production losses under different future scenarios.

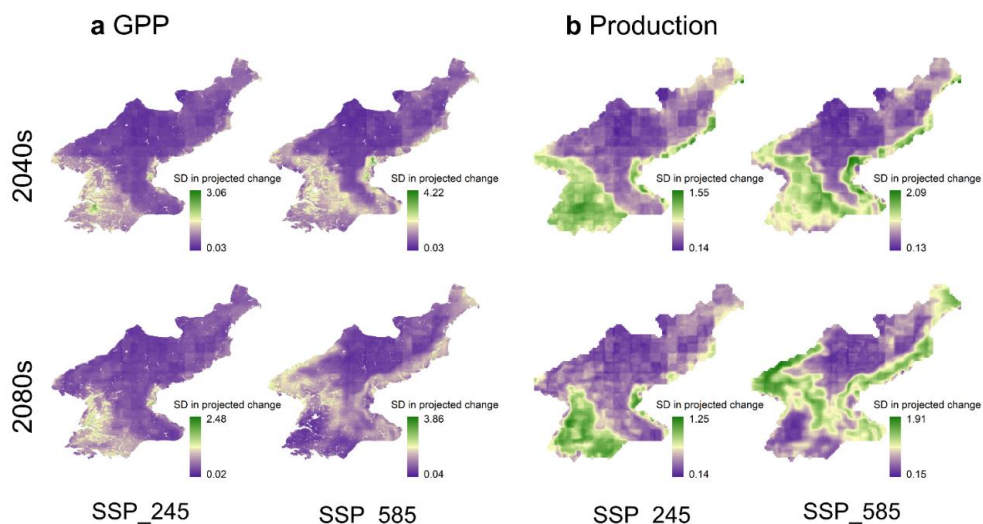


图 5-8 未来情景下基于 27 种 GCMs 预测水稻生物量和产量的误差估计。SD 值显示了生物量和产量预测热点的不确定性。

Fig. 5-8 Standard Deviation of projected biomass and production based on 27 GCMs under different future scenarios. SD values demonstrate the uncertainty of projected hotspots of biomass and production.

根据多种气候情景预测，未来极端气候事件对朝鲜水稻生产的负面影响在西南和西部沿海地区将更为显著。这里，研究进一步探讨了未来缓解朝鲜粮食生产的可能性。由于朝鲜北部多为山地和茂密的原始森林，预计水稻生产力的下降不太可能发生在内陆地区（图 5-9）。此外，由于北部山区的地形坡度大于 5° ，这些地区并不适宜水稻种植。未来基于农田开垦的方式提高粮食产量可能并不可取，因为农田扩张可能导致森林砍伐，进一步加剧洪水风险（Dill et al. 2021）。与韩国和中国辽宁、吉林省相比，朝鲜的山地范围更广，较陡的斜坡（坡度 $>10^\circ$ ）占据了该国 64% 的土地，而坡度较小的地区（ $5^\circ-10^\circ$ ）则占了 15%（图 5-9b），此外海拔超过 500 米的地区占据了朝鲜整个国土面积的 47%。相比之下，韩国和中国辽宁、吉林省的这些较高海拔地区分别占其国土面积的 23% 和 16%（图 5-9b），落叶阔叶林、常绿针叶林和混交林主要分布在海拔超过 500 米的地区（图 5-9a），该地区并不适宜种植农作物。因此，朝鲜的粮食产区向内陆转移的可能性较低。考虑到适应气候变化，朝鲜未来的作物生产迁移可能并非一个可靠的策略来缓解气候变化对粮食生产的不利影响。

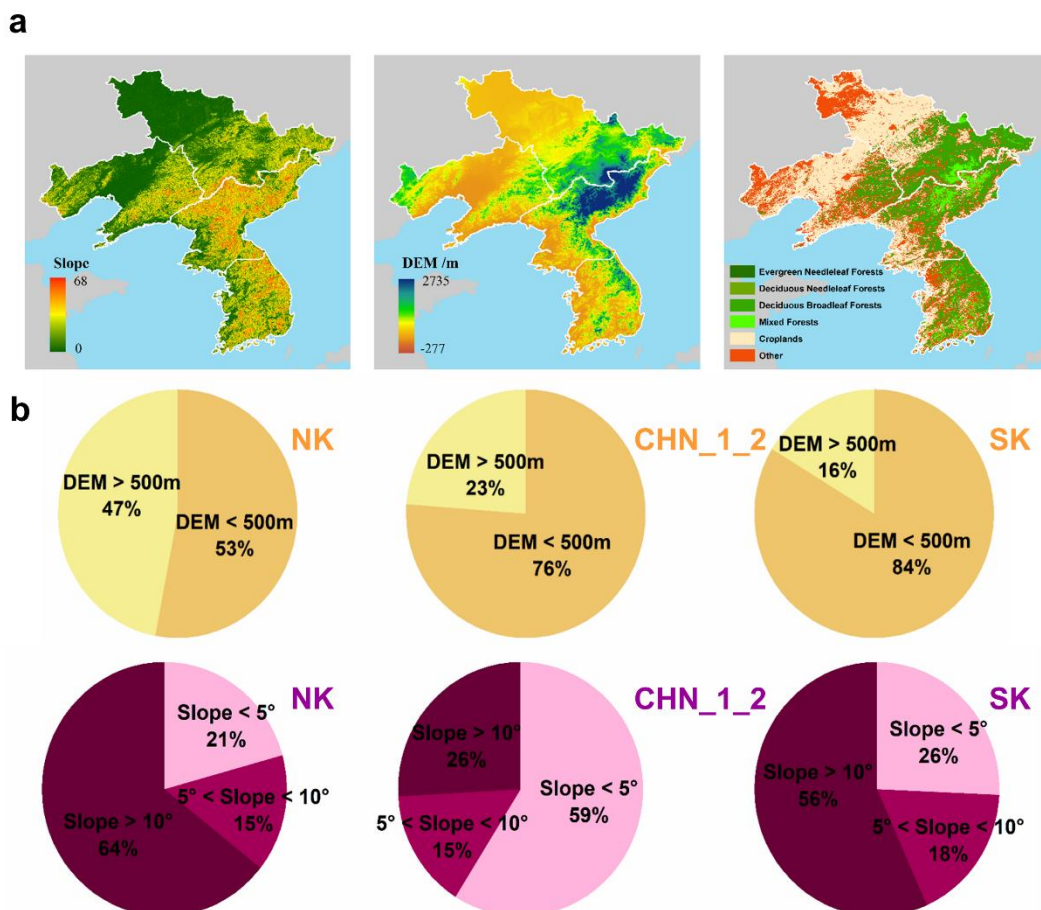


图 5-9 朝鲜、韩国和中国辽宁、吉林省的地形分布

Fig. 5-9 Topographical distribution in North Korea, South Korea, and Liaoning and Jilin provinces of China

5.3 小麦生产对极端天气事件敏感性的响应及其动态变化

5.3.1 小麦生产对极端干热事件的响应

过去六十年来，美国小麦种植区经历了不同程度的极端干热事件，超过 75% 的地区在小麦生长季内将面临干旱发生的风险（图 5-10）。高温和复合干热事件的风险也逐渐增加，呈现出从北向南沿纬度分布的趋势（图 5-10），尽管高温和复合干热事件没有表现出显著变化的时间趋势（图 5-10），但小麦种植区的干旱影响持续增加。具体而言，从 1960 年到 2018 年，冬小麦的干旱程度显著上升，每 10 年增加 2.3 天（ $P < 0.01$ ），同时春小麦的干旱程度也有显著上升趋势，每 10 年增加 1.6 天（ $P < 0.01$ ）（图 5-10c）。因此，未来复合干热事件的发生频率可能会持续上升，从而进一步增加潜在的碳损失风险。

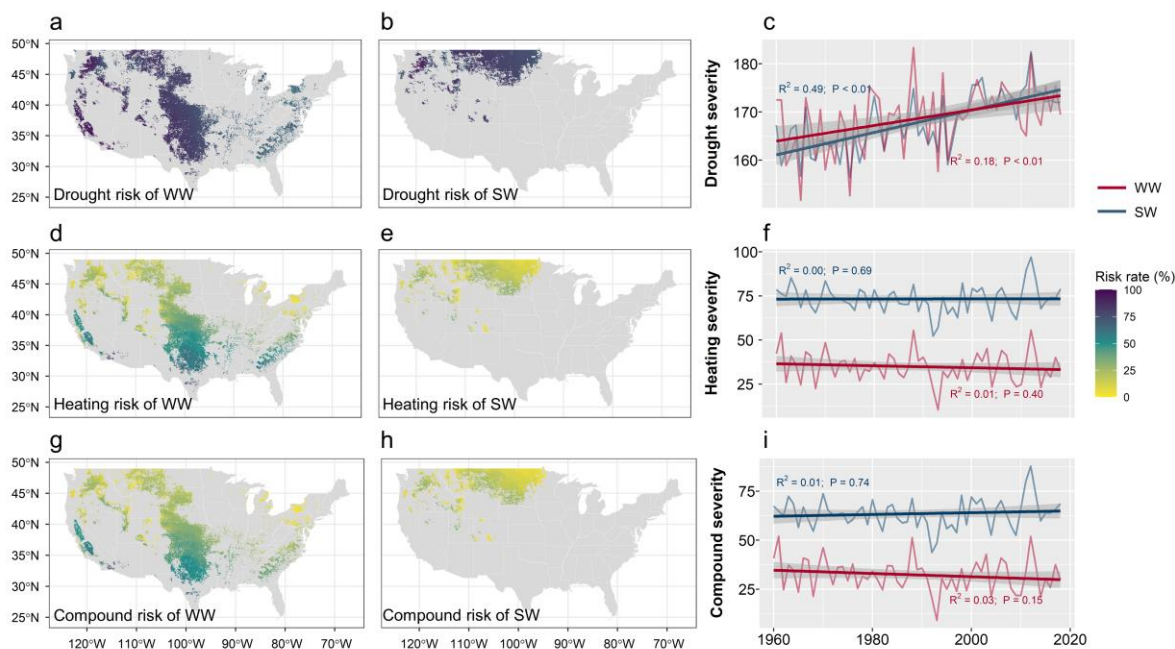


图 5-10 过去 60 年美国小麦极端干热事件的风险和趋势

Fig. 5-10 Risk and trends of extreme dry-heat events for US wheat over past six decades

极端干热事件加剧了美国约 70% 的冬小麦和 90% 的春小麦种植区的温室气体排放强度（GHGI）并导致巨大的碳损失，进一步破坏了双赢战略（图 5-11）。这种极端气候引起的不利影响在美国中部大平原尤其显著（图 5-11）。从 1960 年到 2018 年，干热事件导致小麦净温室气体排放增加，其中冬小麦的增幅为 $67.6 \pm 7.6\%$ ，而春小麦为 $90.8 \pm 1.4\%$ （图 5-11）。相比于单一的干旱事件，高温事件对小麦种植区的温室气体排放影响更为显著，预计持续增加的干旱事件可能进一步放大其对温室气体的不利影响，极端干热事件刺激了冬小麦种植区 CO_2 和 CH_4 的释放，但抑制 N_2O 排放（图 5-10，图 5-11 和图 5-12）。考虑到小麦种植区域的 CH_4 排放总量微乎其微，因此极端干热事件诱

导的 CO₂ 排在总体温室气体排放中占主导作用。相比之下，极端干热事件下的春小麦温室气体排放增加不仅归因于大量的 CO₂ 排放，还与干旱事件引发的更多 N₂O 排放的有关（图 5-13）。

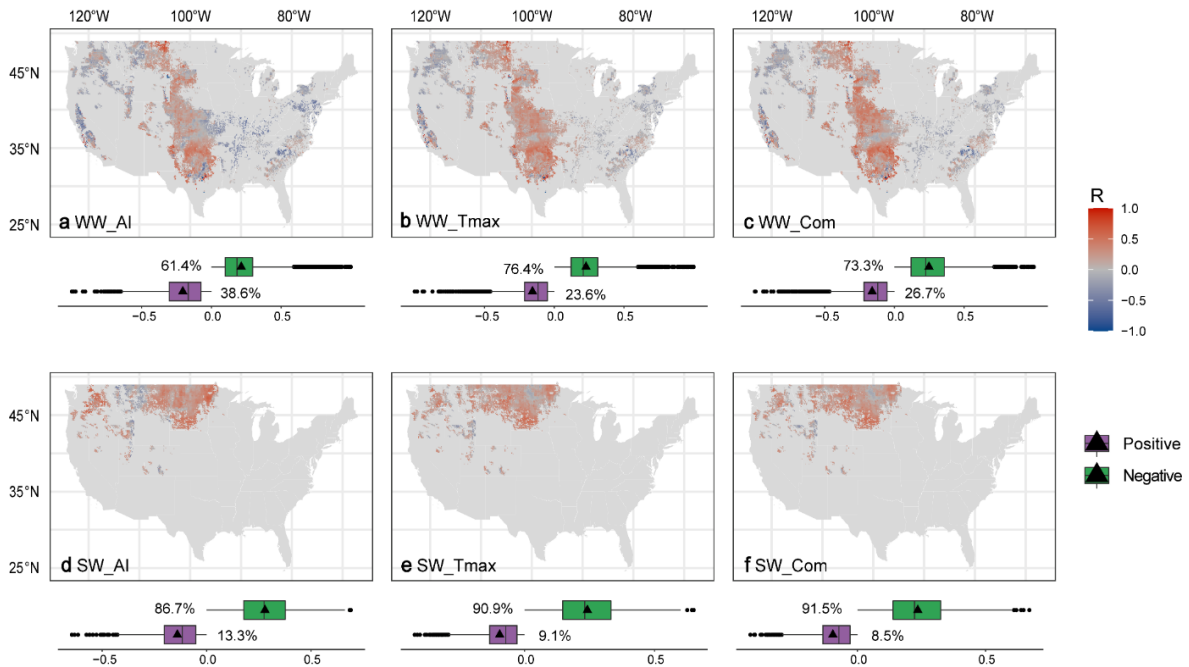


图 5-11 1960 - 2018 年小麦温室气体排放强度对干热事件的响应。红色和蓝色分别表示干热的消极和积极影响。黑色三角形代表平均值，黑点是每个箱线图外的离群值。WW 和 SW 分别代表冬小麦和春小麦。

Fig. 5-11 Response of wheat greenhouse gases emission intensity to the dry-heat events during 1960 to 2018. And the red and blue bands show the negative and positive effects of dry-heats, respectively. The black triangle represents the mean value and the black points are outliers in each boxplot. WW and SW are winter wheat and spring wheat, respectively.

极端干热事件的增加导致美国小麦产量显著下降，尤其在作为美国冬小麦主要产区的中南部地区（图 5-14），极端干热事件分别导致全美 $75.8 \pm 1.4\%$ 的冬小麦种植区和 $86.9 \pm 13.7\%$ 的春小麦种植区的产量下降（图 5-14d-f）。尽管适度的干旱可能对美国北部地区种植的春小麦有益，但随着该地区变得更加干旱，这种优势可能会减弱（图 5-14j-l）。

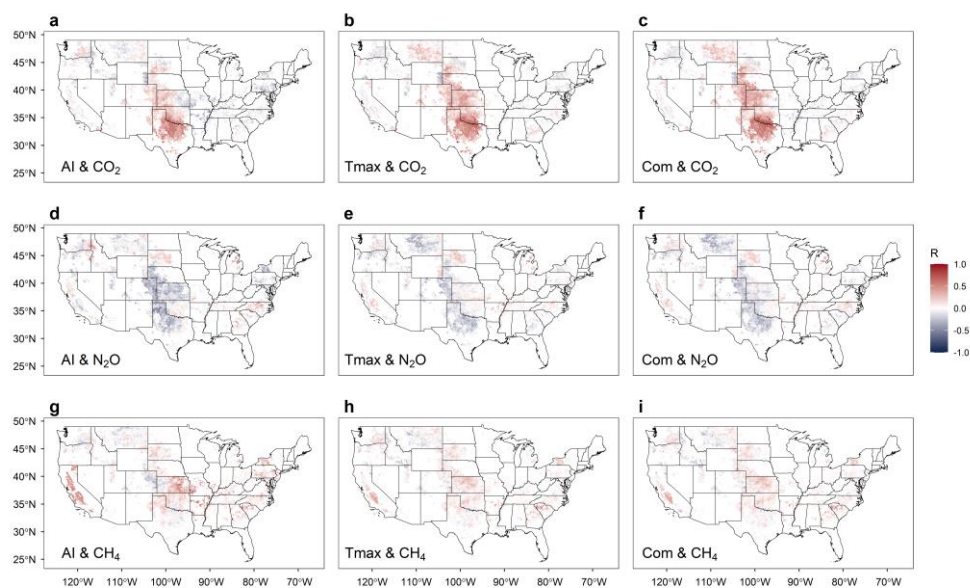


图 5-12 1960 - 2018 年冬小麦 CO_2 、 N_2O 和 CH_4 对干热事件的响应。红色和蓝色像元表示干热事件的积极和消极影响。

Fig. 5-12 Response of CO_2 , N_2O , and CH_4 to the dry-heat events for winter wheat during 1960 to 2018. And the red and blue pixels show the positive and negative effects of dry-heats events.

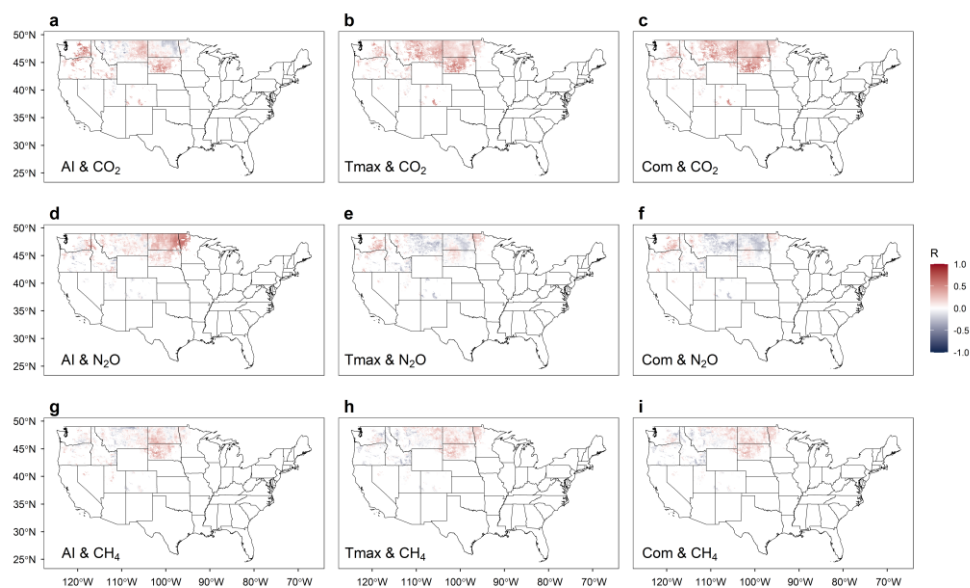


图 5-13 1960 - 2018 年春小麦 CO_2 、 N_2O 和 CH_4 对干热事件的响应。红色和蓝色像元表示干热事件的积极和消极影响。

Fig. 5-13 Response of CO_2 , N_2O , and CH_4 to the dry-heat events for spring wheat during 1960 to 2018. And the red and blue pixels show the positive and negative effects of dry-heats events.

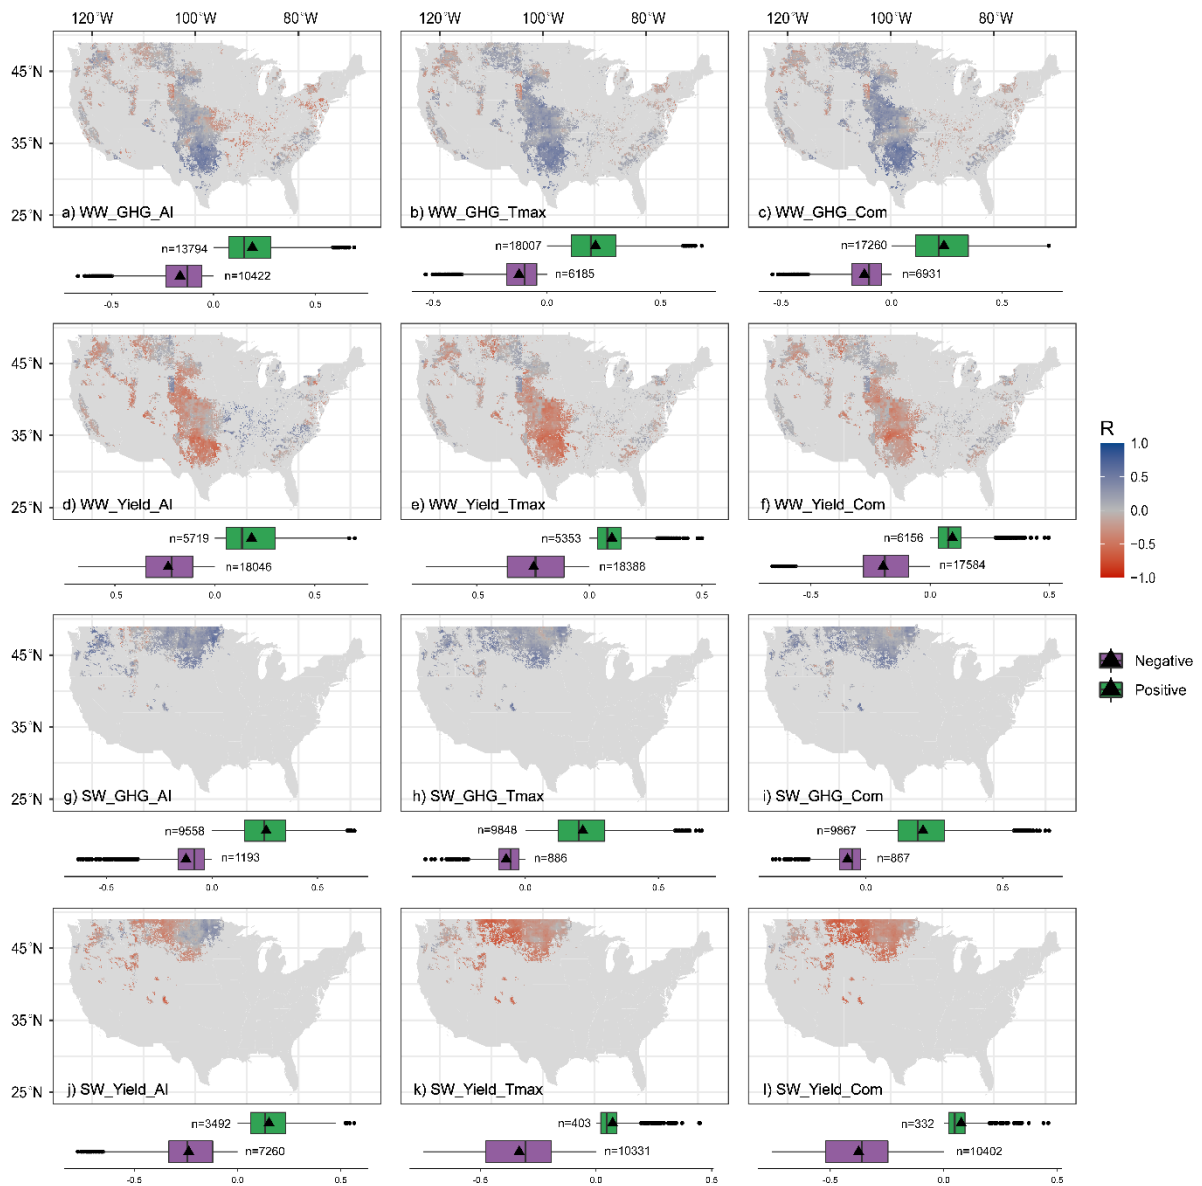


图 5-14 1960 - 2018 年小麦温室气体排放强度对干热事件的响应。红色和蓝色分别表示干热的消极和积极影响。黑色三角形代表平均值，黑点是每个箱线图外的离群值。WW 和 SW 分别代表冬小麦和春小麦。

Fig. 5-14 Response of wheat net GHG emission and yield to the dry-heat events during 1960 to 2018. And the red and blue bands show the positive and negative effects of dry-heats. The black triangle represents the mean value and the black points are outliers in each boxplot. WW and SW are winter wheat and spring wheat, respectively.

5.3.2 小麦生产对极端干热事件的敏感性长期动态变化

过去六十年间，小麦温室气体排放对干热事件的敏感性不断增强。研究在春小麦和冬小麦之间观察到了不同的产量敏感性变化趋势，即极端干热气候对冬小麦产量正向反馈略微增加，但对春小麦产量的不利影响正在加剧（图 5-15b 和图 5-15e）。干热事件显著增加了春小麦温室气体排放的敏感性，并且在 2008 年后刺激冬小麦温室气体排

放的敏感性急剧上升 ($P < 0.01$; 见图 5-15a 和图 5-15d)。此外, 对于小麦温室气体排放强度而言, 与干旱相关的负面影响现在已经接近甚至超过高温的影响 (图 5-15)。尽管干热事件对冬小麦产量的不利影响在统计上逐渐减弱 ($p < 0.01$), 但春小麦的不利影响显著增加, 尤其是在持续加剧的干旱条件下 (图 5-15b 和图 5-15e)。

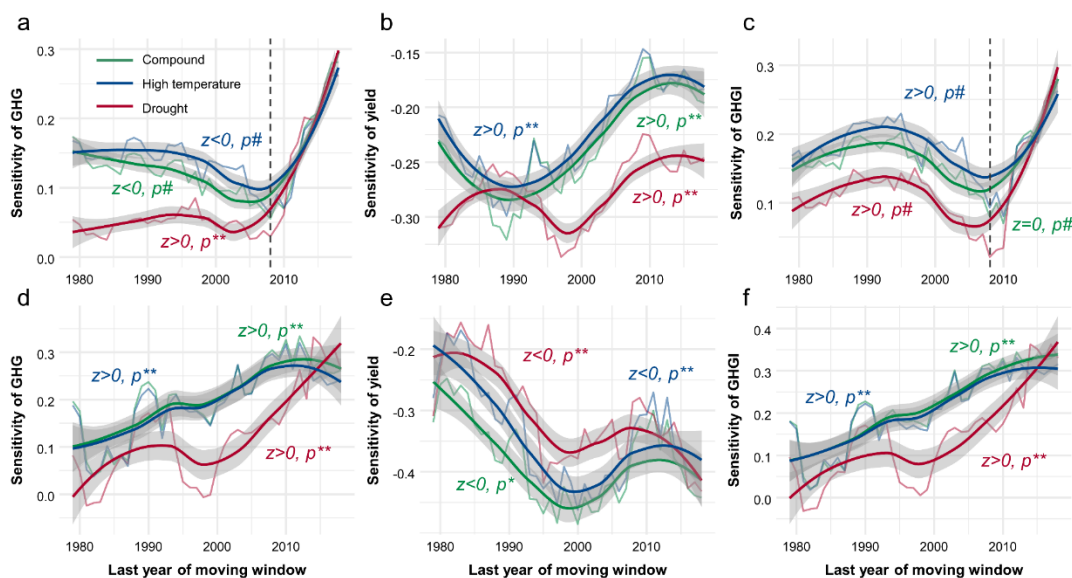


图 5-15 小麦 GHG 和产量对美国干热事件敏感性的时间变化。在图 (a) 中, 虚线表示 2008 年, 实线表示 loess 回归的敏感性趋势。阴影带表示 95% 置信区间, 趋势显著性检验: # $p > 0.05$, * $p < 0.05$, ** $p < 0.01$ 。

Fig. 5-15 Temporal dynamics in the sensitivity of wheat carbon to dry-heat events across the United States. In panel (a), the dashed line represents the year 2008, while the solid lines indicate the sensitivity of loess regression. The shaded bands denote the 95% confidence intervals. Symbols indicating the significance test of trend are as follows: # for $p > 0.05$, * for $p < 0.05$, and ** for $p < 0.01$.

小麦产量和温室气体排放对极端干热气候的敏感性动态变化也展现出明显的区域特征 (图 5-16)。在大部分美国小麦种植区, 2018 年小麦温室气体对干热事件的敏感性明显高于 1979 年 (附图 3a, 附图 4a, 附图 5a), 导致如今由干热气候控制的小麦温室气体排放强度的敏感性比 60 年前更加显著 (图 5-16)。此外, 中部和南部冬小麦种植区和北部春小麦种植区的温室气体排放强度敏感性随时间显著增加 (图 5-16, 附图 3b, 附图 4b, 附图 5b)。少数零星地区受益于干热气候, 例如冬小麦的北部地区和春小麦的西部地区。约 38% 的冬小麦种植区和 63% 的春小麦种植区都出现了干热气候下温室气体排放强度敏感性显著增加的状况 ($p < 0.05$), 这表明小麦在干热条件下的碳损失逐渐增加 (图 5-16)。此外, 概率分布显示, 近年来干旱对小麦的不利影响要大于高温和二者的联合效应 (附图 3b, 附图 4b, 附图 5b), 这一趋势在美国大部分小麦区可以被

明显观察到。

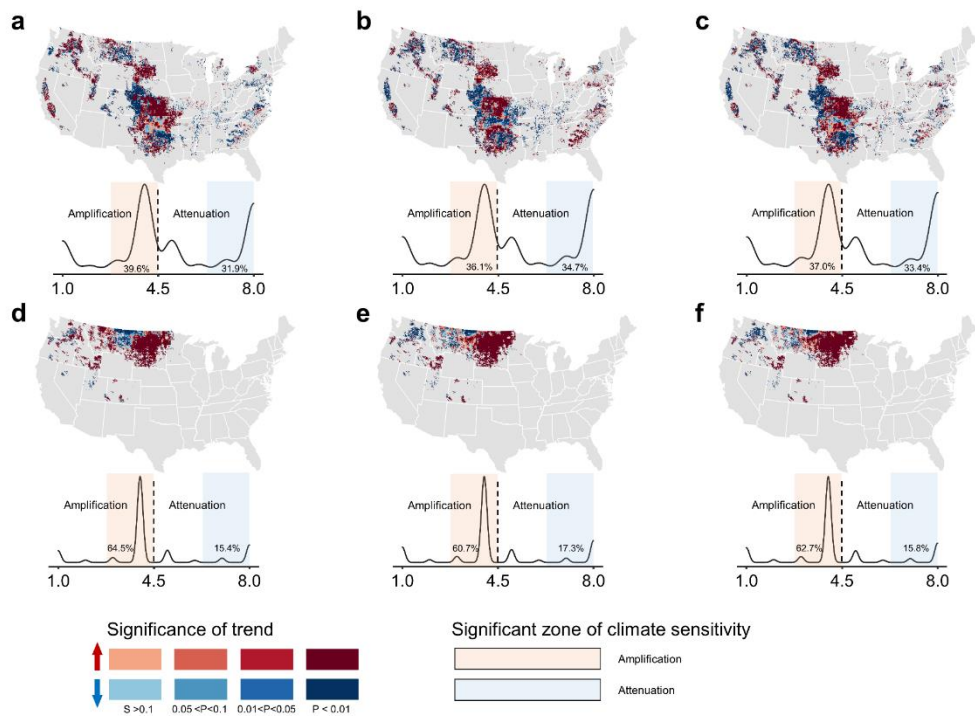


图 5-16 基于滑动窗方法的冬小麦（图 a-c）和春小麦（图 d-f）对干热事件的温室气体排放强度敏感性变化。干旱（图 a 和图 d）、高温（图 b 和图 e）和干热复合气候（图 c 和图 f）。

Fig. 5-16 GHG emission intensity sensitivity variability of winter wheat (panel a-c) and spring wheat (panel d-f) to dry-heat events using a sliding window approach. Drought (panel a and d), high-temperature (panel b and e), and compound climate (panel c and f).

小麦显著的干热敏感性趋势突出表明，干热事件影响了东部春小麦地区的产量，并且在其他地区也引起了产量波动（附图 3a，附图 4a，附图 5）。相比之下，冬小麦产量对干热事件的敏感性表现出较大的区域异质性。基于 1960 年至 2018 年的 29 个冬小麦和 23 个春小麦的观测结果，同样证明了小麦干热敏感性的持续升高（图 5-17）。具体而言，在大多数实验站点中，小麦产量经历了负面的干热气候冲击（例如复合干热气候下，冬小麦观测中的 20/29 个站点和春小麦观测中的 15/23 个站点）。在干热气候下，冬小麦产量的敏感性显著增加的情况在 29.9% 的站点中观察到，而显著减少的情况在 28.7% 的站点中观察到；春小麦在干热气候下的产量敏感性显著增加的情况在 27.5% 的站点中观察到，而显著减少的情况在 30.4% 的站点中观察到（图 5-17）。

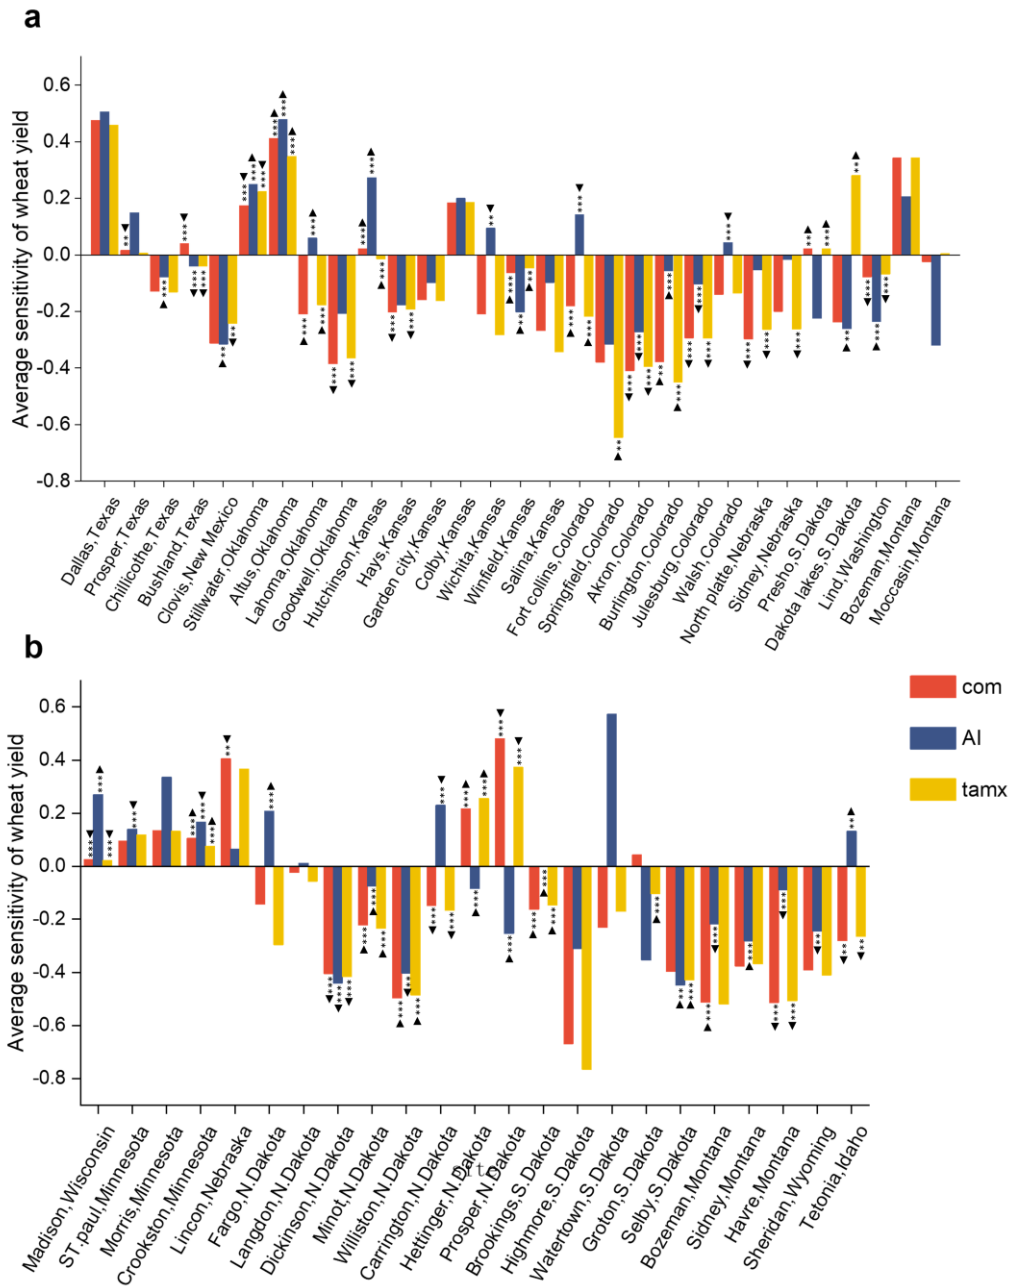


图 5-17 1960-2018 年站点小麦产量对极端干热事件的响应。图 a 和图 b 分别是冬小麦和春小麦。黑色三角形的方向表示小麦产量敏感性的趋势（上升或下降）。显著性检验： $*p < 0.05$ ， $**p < 0.01$ 。

Fig. 5-17 Response of wheat yield to extreme dry-heat events from nursery statistics over 1960-2018. Panel a (winter wheat) and b (spring wheat) are the response of yield to dry-heat event. The direction of black triangle represents the trend (up or down) resulting from dry-heat events for wheat yield. Symbols for the significance test are: * for $p < 0.05$, and ** for $p < 0.01$.

5.4 讨论

5.4.1 极端气候事件对朝鲜粮食生产的影响

本研究的结果表明,气候极端事件减少了朝鲜的水稻产量,未来气候变暖将导致进一步的饥荒发生。到2080年,高温指数(SU30)在SSP245和SSP585情景下分别增加了97.6%和221.94%(图5-4),这意味着未来高温天数将在SSP245情景下增加近一个月,而在SSP585情景下增加两个月。这一发现也得到了过去研究的支持,Kawasaki and Uchida(2016)指出,全球气候变化引起的温度异常生态对农业生产造成了严重的负面影响,而气候极端事件将随着未来气温升高而在频率和强度上持续增加(Wang et al. 2017)。本研究的结果还表明,在SSP585情景下,预计到2080s,朝鲜的生物量和产量可能分别减少20.2%和14.4%,然而由于本研究使用了整个地区的平均GPP和收获指数来计算生物量的相对变化,因此这一结果可能会被低估,对于作物来说,未来极端气候下的生产力损失可能更为严重。目前已知的是气候极端事件对食品供应链的恢复力已经产生了重大影响(Hansen et al. 2012),过去观察到的极端温度事件已经导致了全球作物产量变异性增加,未来极端温度事件可能会持续增加并进一步威胁区域粮食安全(Hawkins et al. 2013)。

然而,异常天气和气候极端事件并非总能带来负面后果。以不同的天气条件、极端气候强度和作物类型为研究对象,全球不同地区的研究结果存在差异。例如,Zhao et al.(2016)根据田间增温试验、统计分析和格网作物模型的模拟结果指出,随着温度升高,水稻产量显著下降。产量下降幅度超出了国际粮食政策研究所的评估结果。然而,在印度,根据气候情景和全球气候模型的预测,大部分农业生态区域的水稻产量将从气候变化中获益(Gupta and Mishra 2019)。此外,Lesk et al.(2020)等人认为,极端降雨(> 50 mm/hr)对作物产量造成严重破坏,而20 mm/hr的大雨则有利于作物生长。鉴于未来温度升高和降雨强度增加,极端气候事件对作物的影响仍存在一定的不确定性。考虑到极端天气发生频率较低,仅基于生产数据难以确切评估气候敏感性变化。因此,对作物的气候暴露度以及气候极端事件敏感性变化的归因分析是粮食安全评估的先决条件。

5.4.2 干热事件造成产量损失和温室气体排放

本研究发现当美国小麦种植区遭遇极端干热事件时,约81.4%的种植区产量减少,同时79.2%的种植区温室气体排放量明显增加,夏季的干热事件是影响这些地区小麦碳通量年际变异的主要因素。实验表明,在干旱条件下的植物死亡率显著增加(Phillips et al. 2010; Moser et al. 2014),并对碳变化产生潜在影响(Bonal et al. 2016)。干热胁迫会引起小麦叶绿素含量降低(Mafakheri et al. 2010)、颗粒灌浆加速(Lobell et al. 2012)、开花延迟甚至是过早衰老,进而导致产量损失。此外,与冬小麦相比,春小麦产量和温

室气体排放对干热气候更为敏感（图 5-15），这可能是由于春小麦品种对升温的适应性较弱，播种期较短，生长季内更容易遭受干热事件（Tao et al. 2022）。因此，全球范围内广泛报道了由干热气候引发的小麦减产。干热胁迫还刺激了生态系统的呼吸和凋落物周转的速率，加速温室气体排放，特别是 CO₂ 和 N₂O（Chaves et al. 2002; O'Connell et al. 2018）。具体而言，短期干旱可能促进土壤中根系和微生物呼吸，增强土壤有机物和活性氮的消耗（Bista et al. 2017）。此外，干热事件导致的凋落物增加提升了土壤生物化学循环的底物浓度，进一步促进温室气体排放（Chaves et al. 2002）。Bista et al. (2017) 发现在 2012 年美国特大干旱期间，小麦种植区发生大规模的温室气体排放，并且从碳汇转换为碳源。

5.4.3 小麦产量和温室气体排放的敏感性变化

在美国大平原的特定地区，冬小麦产量对极端干热事件的敏感性随时间逐渐下降，进而导致其时间序列的变化趋势不显著（图 5-15）。这种趋势可能与该地区的农业灌溉活动有关（图 5-18）。Wang et al. (2021c) 指出，灌溉下的作物产量相比雨养展示出巨大的差距，并且美国大平原冬小麦种植区拥有更充足的灌溉资源。基于田间试验的七千个观测结果也同样证明灌溉可以在干热条件下缓解小麦产量损失（Tack et al. 2017）。因此，在干旱地区，小麦产量对干热事件的敏感性可能会受益于农业灌溉活动，甚至有助于抵消气候变暖对产量的冲击。年度时间序列和空间格点趋势表明，春小麦产量对干热事件的负敏感性将在大部分地区显著增加，预计春小麦在加剧的干热气候下将遭受更大的损失。这可能是由于春小麦的开花期与冬小麦相比更接近较高温时段（Zhang et al. 2022a），从而导致春小麦的耐热性随时间下降（Tack et al. 2015）。

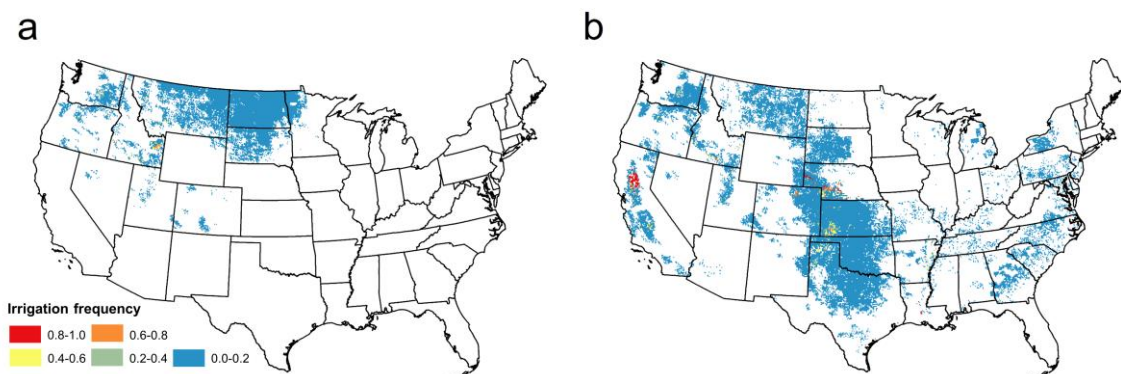


图 5-18 1960 - 2018 年美国小麦种植区的灌溉频率。图 a 和图 b 分别代表春小麦和冬小麦。

Fig. 5-18 Irrigation frequency in the planting regions of US wheat during 1960 to 2018. Panel a and b represent spring and winter wheat, respectively.

增加的温室气体排放(GHG)敏感性与种植的小麦类型无关，这可能有几个原因。

首先,目前的管理实践往往以增加作物产量为目标,而忽视了温室气体的排放。通过灌溉和氮肥等潜在的管理措施来增加产量并且抵消气候变暖的不利影响,但这些管理不能有效地减少温室气体排放。其次,在温室气体排放敏感性增加的小麦种植区,干旱胁迫比热胁迫更为重要(图 5-10),因为短期干旱可以引发叶片凋亡和土壤有机碳(SOC)的分解,导致大量 CO₂ 释放到大气中(图 5-12)。最后,2008 年后冬小麦温室气体排放敏感性的急剧增加可能是由于抗性杂草(长期施用对除草剂产生抗性)的出现而导致翻耕强度的增加(Lu et al. 2022a)。Lu et al. (2022a)发现,随着杂草抗性的持续增加,2008 年后翻耕强度呈逐渐增加的趋势,增加的耕作可能会增加作物温室气体排放对干热气候的敏感性。

5.5 小结

(1)本章研究结合不同模型探究了极端天气事件对典型区域粮食生产的影响以及作物敏感性的动态变化。研究发现极端高温事件和降水分别在 2000 年和 2007 年引起了朝鲜水稻产量的巨大波动。27 个气候情景一致显示,由于未来的气候变暖,朝鲜的极端高温和极端降雨的风险都将持续增加。面对未来的高气候风险,如果不调整适应策略,朝鲜水稻生物量到 2080s 在 SSP245 和 SSP585 情景下将分别减少 18.9%和 20.2,水稻总产届时分别下降 13%和 14.4%,这将进一步冲击本就脆弱的粮食生产系统,加剧未来人口饥饿。

(2)过去六十年来,美国小麦种植区经历了不同程度的极端干热事件,超过 75%的地区在小麦生长季面临干旱发生的风险。通过将先进的陆地生物圈模型与多个现场观测数据进行耦合的模型-数据整合框架,揭示了过去六十年间干热极端事件加剧了美国超过 70%的冬小麦种植区和 90%的春小麦种植区温室气体排放强度。春小麦的温室气体排放强度敏感性增加了 2.2 倍,可能是由于对气候变暖的有限适应力、播种期缩短以及暴露于更多的极端干热事件所致。然而 2008 年后冬小麦温室气体排放强度的干热敏感性急剧增加,显著增加了 5.4 倍。此外,概率分布显示近年来干旱对小麦的不利影响要大于高温和二者的联合效应。在大多数实验站点中,小麦产量经历了负面的干热气候冲击,干热气候显著增加了 29.9%的冬小麦站点的产量敏感性,而在 28.7%的站点中显著降低了敏感性;对于春小麦,干热气候显著增加了 27.5%站点的产量敏感性,而显著降低了 30.4%站点的产量敏感性。

第六章 极端气候下不同发展水平地区的优势缓解措施

6.1 引言

由气候变暖加剧导致的极端气候事件已经对全球不同地区的农业生产造成了严重的冲击 (Challinor et al. 2014; Yang et al. 2021), 例如更大时空变异性的极端降水以及烈度更高干旱热浪事件。面对愈演愈烈的极端气候事件, 不同发展水平的地区表现出了不同的气候适应行为, 同时也付出了不同程度的气候代价 (Wake 2012)。可预见的是, 当暴露于相似的极端气候下, 经济落后地区通常会遭受更多的负面影响 (Fischer and Knutti 2015; Diaz and Moore 2017; Hallegatte and Rozenberg 2017)。从实际角度出发, 欠发达地区通常以自然资源的直接利用作为潜在的农业缓解措施; 而发展中地区掌握一定的资源利用能力, 面对加剧的气候变暖和极端天气频发, 其农业缓解措施可能更加依赖于社会经济发展下的适应力 (Hallegatte et al. 2018; Marotzke et al. 2020)。对于发达地区, 在有了充足的资源利用能力和社会经济保障下, 需要寻求更精细化的因环境制宜的人为管理实践。保障粮食安全的前提下尽可能地减少温室气体排放, 增加农业生产的环境效益并且减少气候代价。因此, 在特定地区实施缓解措施首先要考虑社会经济发展水平, 即社会经济限制。然而, 过去的研究更多的集中在探究单一的适应措施对于粮食生产的缓解潜力, 忽略了当地社会经济恢复力的限制与补偿能力。

基于社会经济恢复力的适应能力通常被视为应对气候风险和保障食品安全的关键因素 (Smit and Wandel 2006)。社会经济恢复力不仅包括传统的金融资产和基础设施, 还包括人口结构、资源利用、技术、教育、以及风险态度和感知, 这些因素会影响人们应对环境变化的适应行为 (Hallegatte et al. 2011; Clayton et al. 2015)。对恢复力的一个重要理解是, 一旦超过了某个阈值, 系统可能会过渡到另一个状态, 并且很难恢复到原始状态。因此, 恢复力通常被认为是在保持相同结构和功能的情况下维持或吸收变化的能力, 并被描述为可以吸收或导致中断的系统变化幅度。社会恢复力基于人类活动与生态系统之间的相互依赖关系。当人们能够获得各种金融、技术和服务资源以及资产时, 他们通常更能适应社会变化 (Lutz et al. 2008; Crespo Cuaresma et al. 2014; O' Neill et al. 2020), 因此高收入社会通常比贫困社会更能适应环境变化, 富裕人群比贫困人群更具气候抵抗力 (Smit and Wandel 2006; Nakhoda et al. 2013; Cinner and Barnes 2019)。社会恢复力中教育是提高生产力和收入的关键, 人口红利的很大一部分来自教育红利。此外, 不断变化的人口结构是减缓和适应气候变化的一个直接社会经济挑战, 其中老龄化和劳动力变化被认定为基本的社会经济问题 (O'Neill et al. 2010; Wang et al. 2021c)。能源是社会经济发展的基本因素, 也是消除贫困的重要支撑 (Parikh et al. 2012;

Riahi et al. 2017; Fuso Nerini et al. 2018), 联合国千年发展目标强调了资源利用的重要性, 提出了“实现人人都能获得经济适用、可靠和可持续的能源”以及“社会经济发展取决于对地球自然资源的可持续管理”这两个核心目标。然而, 过去的研究很少将社会恢复力纳入到气候风险框架中, 以量化在区域粮食生产中难以刻画的人类行为和风险感知的贡献, 并且关于社会经济恢复力在减轻气候变化和极端事件对食品安全的不利影响方面的潜力也知之甚少。

基于人为管理的气候智慧 (climate-smart, CS) 实践是一种更为先进的气候适应理论框架, 较高的经济发展水平能够进一步支持 CS 的实际应用, 以最大程度的发挥其减轻气候变化不良影响的潜力 (Gilbert 2011; Lipper et al. 2014)。CS 耕作旨在通过特定土壤和气候背景下的耕作技术 (包括免耕、减耕和保护耕作等) 降低温室气体排放、促进土壤健康, 同时保持或增强作物生产力 (Lipper et al. 2014)。多样化的气候智慧型耕作由于其实用性、成本效益和易于实施性在全球农业生产和温室气体减排计划中得到广泛采纳 (Berry et al. 2008; Gan et al. 2014)。然而, 气候智慧型耕作的效果高度依赖于特定于地点的环境背景, 如土壤特性、气候和生物多样性 (Zhao et al. 2022a)。犁耕被证明可以改善土壤通气条件, 并将 NO_3^- 、 NH_4^+ 和有机碳从深层土壤运输到表层, 从而促进二氧化碳 (CO_2)、氧化亚氮 (N_2O) 和 NO 化物的排放 (Liu et al. 2005; Mkhabela et al. 2008)。相比之下, 一些研究表明免耕增加了上层的反硝化速率和微生物量, 从而造成了土壤中更多 CO_2 和 N_2O 的释放 (Janzen et al. 2006; Mkhabela et al. 2008; Lognoul et al. 2017)。此外, 耕作实践还会破坏土壤团聚体结构, 进而造成作物减产 (Six et al. 2000)。然而, 在全国和地区范围内, 极端气象事件频发以及复杂的下垫面条件, 使得气候智慧型耕作提高作物产量并减少温室气体排放的效果、可行性和可持续性受到挑战。因此, 以优化权衡的方式实施气候智慧型耕作实践是缓解气候变化负面影响和持续农业发展的前提。

本章节研究以包含相同气候暴露度但是拥有不同经济发展水平的典型地区为例, 初步探究了社会恢复力减缓气候变化对粮食生产负面影响的效果。具体而言, 研究基于人口发展、资源利用、科学教育、经济发展以及农业投入等五个因素, 通过对比朝鲜 (欠发达地区, 基于世界银行分类) 与其邻国 (韩国和中国) 之间的差异, 量化了社会恢复力对水稻生产的贡献。此外, 本研究进一步考虑了作物生产的必要管理措施以纳入到社会恢复力评估框架中。为了探究气候智慧型耕作缓解极端天气的对粮食生产的影响及其最大缓解潜力, 本文以美国小麦生产区作为研究对象, 采用包含新一代农业模块的基于过程的陆地生态系统模型 (DLEM v4.0)。需要强调的是以美国为研究对象是由于 (1) 美国是全球小麦最大的生产国和出口国之一; (2) 过去几十年美国是极端干旱和热浪频发的典型地区, 对粮食生产造成了严重的冲击; (3) 完整的时空连续数据能够支持过程模型参数检验和精确模拟; (4) 在高经济发展水平地区的气候智慧型

管理研究，能更为可靠且实际地估算缓解方案的潜力，并为世界其他地区提供完善的意见参考。

6.2 欠发达地区粮食安全的缓解途径—以朝鲜社会恢复能力为例

6.2.1 社会恢复力的构成及其对气候变化的缓解作用

尽管从气候风险框架来看，水稻生产通常受到自然环境变化的影响，但从社会恢复力的角度来看，地区或国家水平的适应能力更决定了水稻生产的损失。社会恢复力将受到人口、经济、技术和文化等因素的交互性影响。为了量化社会恢复力对水稻生产的贡献，本研究收集了世界粮农组织（FAO）、世界银行以及遥感农业数据集等经济统计数据，其中包括五个因素：人口发展、资源利用、科学教育、经济发展以及农业投入，共同构成了社会恢复力。附图 6-8 显示了单个社会经济变量与水稻产量之间的相关性，与韩国和中国相比，朝鲜社会恢复力的每个变量之间的相关性较弱（ $\rho < 0.5$ 且不显著）。

当气候模型纳入社会恢复力时，韩国（ $P < 0.05$ ）和中国（ $P < 0.01$ ）的生产力解释性显著增强，但在朝鲜方面效果不显著（表 6-1）。此外，社会恢复力主导了更多韩国和中国的水稻生产变化（ $P < 0.01$ ），使模型解释度分别提高了 26% 和 100%。社会恢复力并未在朝鲜产生额外的积极影响，这意味着水稻生产变化主要受气候因素主导（表 6-1）。此外，研究还发现社会恢复力在韩国和中国减轻了气候冲击甚至将不利影响转化为收益。具体而言，韩国地区的高温和热浪（TR20, AAT, TXx 和 SU30）对水稻生产构成威胁，然而区域氮肥投入、农村和青年人口变化缓解了这些气候冲击的影响，甚至促进了水稻生产（图 6-1）。在中国也观察到了类似的情况，即资源的合理利用（如电力供应）有助于减轻极端降雨事件所带来的损害（图 6-1）。但在朝鲜并未观察到这种明显的缓解效应，多种气候与社会恢复力之间的相互作用未导致水稻产量的增加（图 6-1）。

表 6-1 朝鲜、韩国和中国在不同输入变量下的多源回归拟合优度

	朝鲜	韩国	中国
输入变量	R ²	R ²	R ²
气候因素	0.60	0.72	0.47
社会恢复力因素	0.31	0.98***	0.81***
气候和社会恢复力因素	0.68	0.91**	0.94***

注：* $p < 0.1$ 为，** $p < 0.05$ ，*** $p < 0.01$ 。




图 6-1 朝鲜、韩国和中国的社会恢复力缓解气候对水稻生产的负面影响。每个变量（方向和大小的斜率代表了特定变量对水稻生产的积极/消极影响。黑色圆形的数值表明每个调节效应的拟合显著性（ P 值）。显著性检验符号： $*p < 0.1$ ， $**p < 0.05$ ， $***p < 0.01$ 。

Fig. 6-1 Social resilience mitigating climate shocks for rice production in North Korea, South Korea, and China. The slope of each variable (direction and size) represents the positive/negative effect of the specific variable to rice production. Circled values highlight the significance of fit (P value) obtained from the F-statistic for each moderation effect model. Symbols for the significance test are: $*$ for $p < 0.1$, $**$ for $p < 0.05$, and $***$ for $p < 0.01$.

6.2.2 粮食生产对社会恢复力的动态响应

本研究基于社会经济的随机森林模型 (*RFe*) 进行了更全面的分析, 以评估社会恢复力对朝鲜、韩国和中国水稻生产的贡献差异。在社会恢复力的十二个指标中, 高等教育、农村人口和 0-14 岁人口在朝鲜的水稻生产变化中占主导地位 ($P < 0.05$)。韩国的水稻生产变化受到专利申请、0-14 岁人口、人均国内生产总值和能源利用的显著影响 ($P < 0.01$), 而中国的水稻生产变化主要由 0-14 岁人口、农村人口、人均净官方发展援助和人均国内生产总值所主导 ($P < 0.05$) (图 6-2a)。无论是发达地区还是发展中地区, 经济发展和人口结构比欠发达地区更加关键, 而发达地区的科学教育对水稻生产的影响更大 (图 6-2a)。*RFe* 的模拟结果进一步强调了社会恢复力对韩国和中国水稻生产的重要贡献 (分别解释了 83.0% 和 86.1% 的年际水稻生产变化, $P < 0.05$)。相比之下, 社会恢复力对朝鲜的贡献较低, 仅为 15.2% ($P < 0.05$) (图 6-2a)。因此, 发达地区和发展中地区的水稻生产主要受到社会经济因素的影响, 而欠发达地区更受气候变化的制约 (图 6-2a)。

为了进一步验证非线性模型的稳定性, 本文基于时间序列分割法的交叉验证测试了模型 *RFe* 的预测表现 (表 6-2)。研究发现不同的交叉验证结果均证明了社会恢复力与朝鲜水稻生产之间的关系 (R^2 为 0.38) 远远弱于韩国和中国 (R^2 分别为 0.81 和 0.71), 并且这种非线性关系呈现出更低的误差水平 (朝鲜的 *nRMSE* 为 0.35, 韩国的 *nRMSE* 为 0.35, 中国的 *nRMSE* 为 0.35), 这表明社会恢复力稳健地反映了水稻生产变化。本研究获得的可靠结果表明, 社会恢复力在提高作物产量、抵御气候冲击和保障粮食安全方面具有巨大潜力。

表 6-2 基于时间序列分割法三折交叉验证 *RFe* 模型的表现

Table 6-2 3-fold Time Series Split Cross-Validation for random forest modeling of social resilience

编号	精度	朝鲜	韩国	中国
First fold	R^2	0.01	0.63	0.94
	<i>nRMSE</i> (%)	0.38	0.33	0.04
Second fold	R^2	0.52	0.81	0.93
	<i>nRMSE</i> (%)	0.32	0.37	0.05
Third fold	R^2	0.61	0.98	0.30
	<i>nRMSE</i> (%)	0.36	0.12	0.03
Average	R^2	0.38	0.81	0.72
	<i>nRMSE</i> (%)	0.35	0.27	0.04

在朝鲜, 影响水稻生产的四个关键变量 (如学校入学率、大专率等) 呈现出阈值式的响应模式 (图 6-2b)。当学校入学率高于 -0.6 个单位时, 水稻产量开始下降, 这可能是因为在科学教育方面的资金投入有限, 即入学率的提高增加了家庭经济支出并减

少了农业劳动力。水稻生产对人口发展的非线性响应在中国也得到了是一致的证据支持（图 6-2b）。具体而言，在欠发达或发展中地区（朝鲜和中国），水稻生产随着农业人口和 0-14 岁人口的增加而减少（图 6-2b）。人口增长带来的膳食需求压力和人口结构的不协调制约了欠发达地区的经济发展和产量增长（Schneider et al. 2011）。例如，相对较高机械化水平的农村地区贡献了大部分的水稻生产，并且需要较少的农业人口（Amare and Endalew 2016）。在发达地区（韩国），水稻产量对 0-14 岁人口的响应则相反，这可能可以解释为不同地区人口结构的差异，发达地区需要增加青少年人口比例，以应对严重的老龄化问题（Kim and Lee 2021），并确保有充足的农业劳动力来增加水稻产量。能源利用促进了发展中地区（中国）的水稻产量，但对发达地区（韩国）的影响则相反，这是由于发达地区有足够的资金进口资源（Scheelbeek et al. 2020）。综上所述，不同的社会恢复力要素对朝鲜、中国和韩国的水稻生产造成的影响不同。

本研究进一步分析了农业投入对水稻生产力的影响，三个地区的水稻生产对农业投入的非线性响应曲线如图 6-3 所示。其中氮肥、磷肥和灌溉的响应曲线在韩国和中国呈增加趋势，而在朝鲜这三种农业实践投入的产量响应以拱形或凹曲线的形式呈现（图 6-3）。根据随机森林模型及其袋外误差，氮肥、磷肥和灌溉分别解释了朝鲜、韩国和中国水稻生产变化的-4.8%、51%和 77%，其中朝鲜的解释度为负值，这表明在当前条件下，三种农业实践无法支持其水稻产量的增加。

6.3 发达地区粮食安全的缓解途径—以美国气候智慧型耕作为例

6.3.1 基于特定气候背景下的最优耕作方案

为了调查人为耕作实践是否能够减轻极端干热事件导致的小麦碳损失，本节研究分析了历史干热条件下传统耕作（CT）和免耕（NT）对小麦碳敏感性和耕作效果的影响。研究表明，在冬小麦产区，CT 和 NT 均具有相似的敏感性缓解效果，而在春小麦产区，NT 的影响更大（图 6-4）。具体而言，对 60 年的数据进行分析发现，CT 和 NT 均显著降低了美国中部地区冬小麦对高温的敏感性，NT 在美国北部地区的冬小麦和春小麦种植区表现出更为显著的效果（图 6-4），其中 NT 在超过 90% 的春小麦种植区中发挥了主导作用（图 6-4b）。在特定地区，我们采用在历史上有 75% 的概率降低敏感性的耕作实践作为最优耕作方案，以确保在未来可能恶化的干热气候条件下的粮食生产的稳定性。因此，本研究建议在美国中部地区采用 CT 和 NT 实践的交叉应用方案，而在北部地区更加推荐 NT 实践（图 6-4）。然而，一些地区未被纳入气候智慧型耕作方案中，这意味着在该地区潜在的耕作实践不能减轻小麦温室气体排放强度的干热敏感性，需要采取其他措施来填补这一差距（图 6-4）。

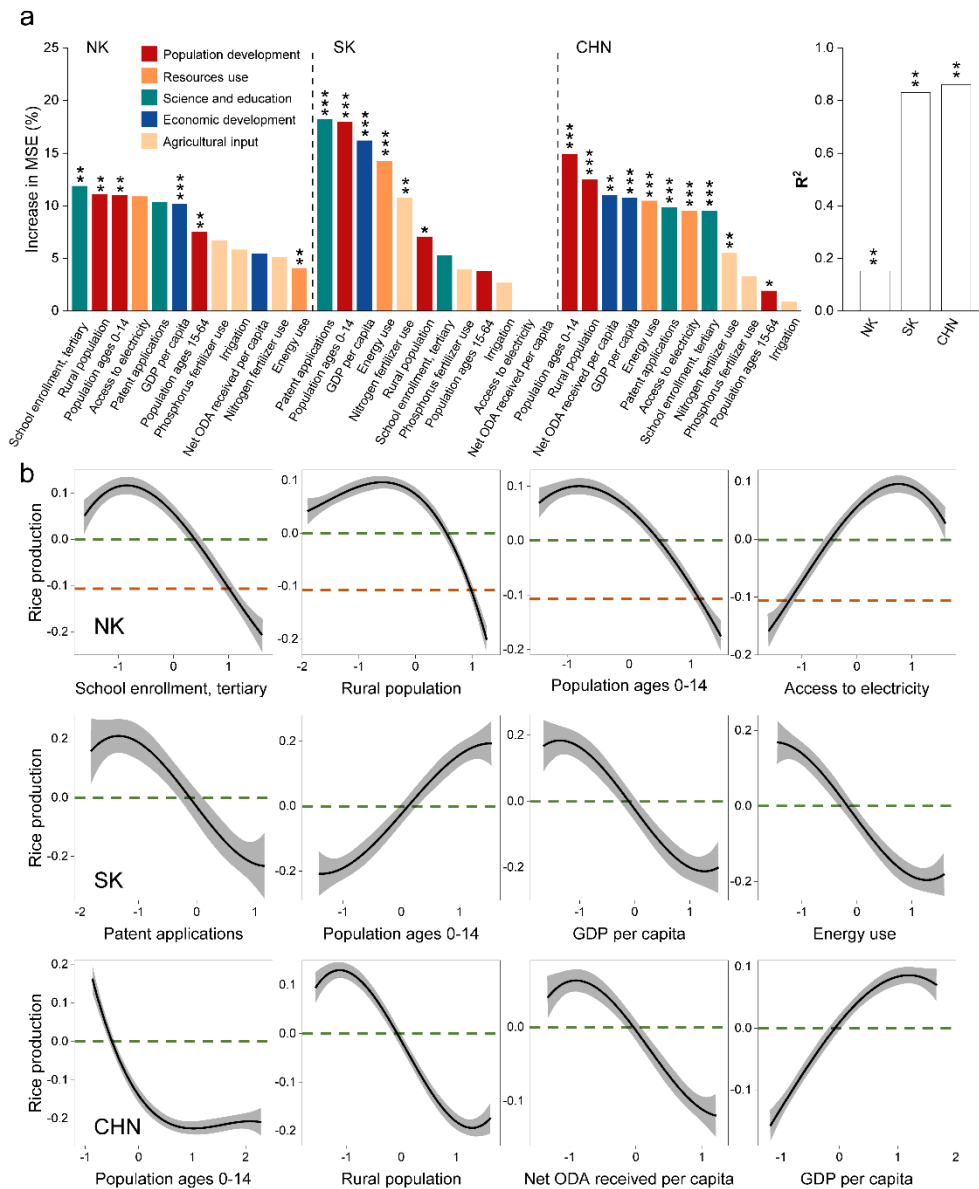


图 6-2 社会恢复力指数对水稻产量变异性的贡献。显著性检验符号： $*p < 0.1$ ， $**p < 0.05$ ， $***p < 0.01$ 。图 b 中黑线是使用最佳拟合多项式方程的响应曲线。部分依赖图中的绿色和橙色虚线分别代表基线和 SSP585 情景下的水稻产量。

Fig. 6-2 The contribution of vulnerability indexes for social resilience to rice production variability. a, Symbols for the significance test are: $*$ for $P < 0.1$, $**$ for $P < 0.05$, and $***$ for $P < 0.01$. b, The non-linear response of rice production to standardized values of the four most important variables of social resilience. The black lines are smoothed representations of the response using best-fit polynomial equations. The green and orange dash lines in the partial dependence plots represent rice production from the baseline and SSP585 scenarios, respectively.

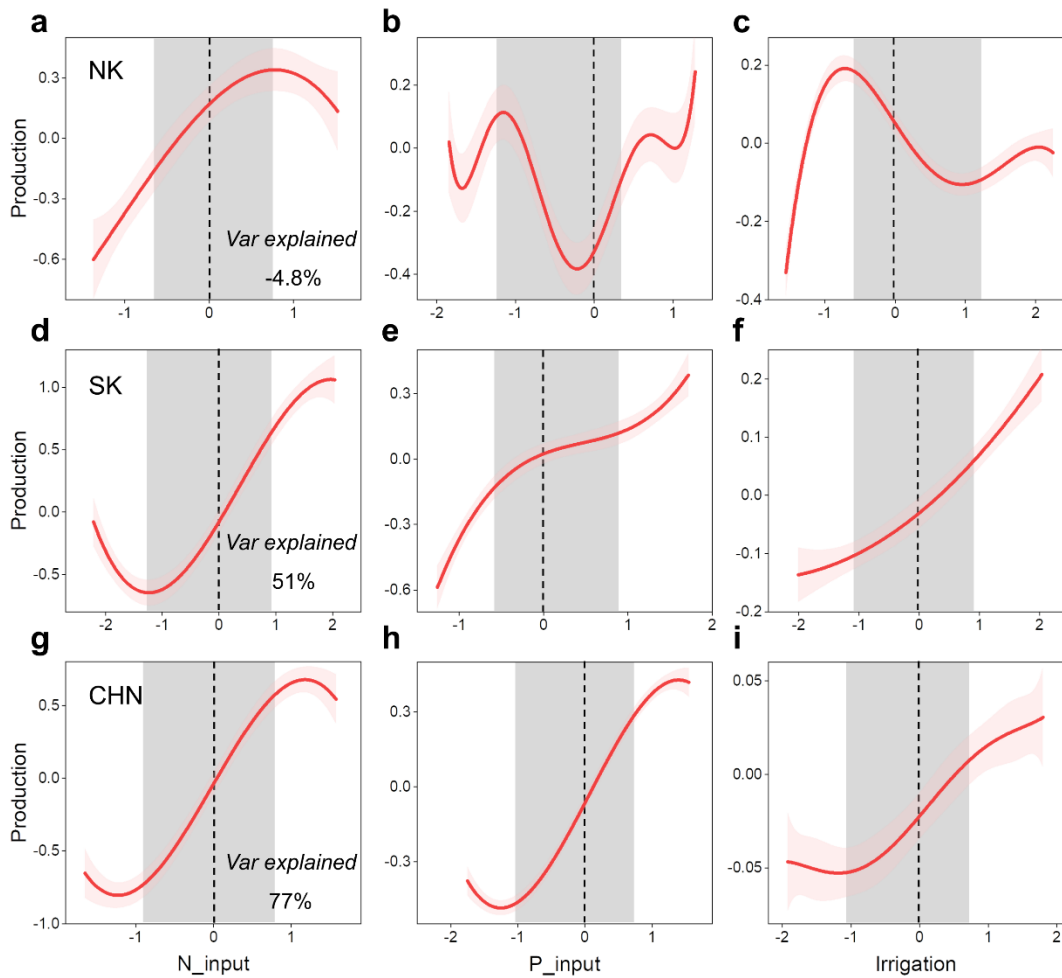


图 6-3 朝鲜、韩国和中国水稻生产的农业驱动因素。红线是使用最佳拟合多项式方程的响应曲线，描述了水稻生产对农业驱动因素的依赖。红色阴影带表示 95%置信区间。灰色阴影区域表示 25-75 分位数之间的数据，百分比表示三种农业投入对水稻生产的贡献。

Fig. 6-3 Agricultural drivers of rice production in the study areas. The red lines are smoothed representations of the response using best-fit polynomial equations. The trends of the lines, rather than the actual values, describe the nature of the dependence of rice production on the agricultural drivers. The shaded bands denote the 95% confidence intervals. The gray shaded areas indicate calibration data between the 25th and 75th percentiles, and the percentages of production variability explained by the three agricultural inputs are indicated for each sub-region.

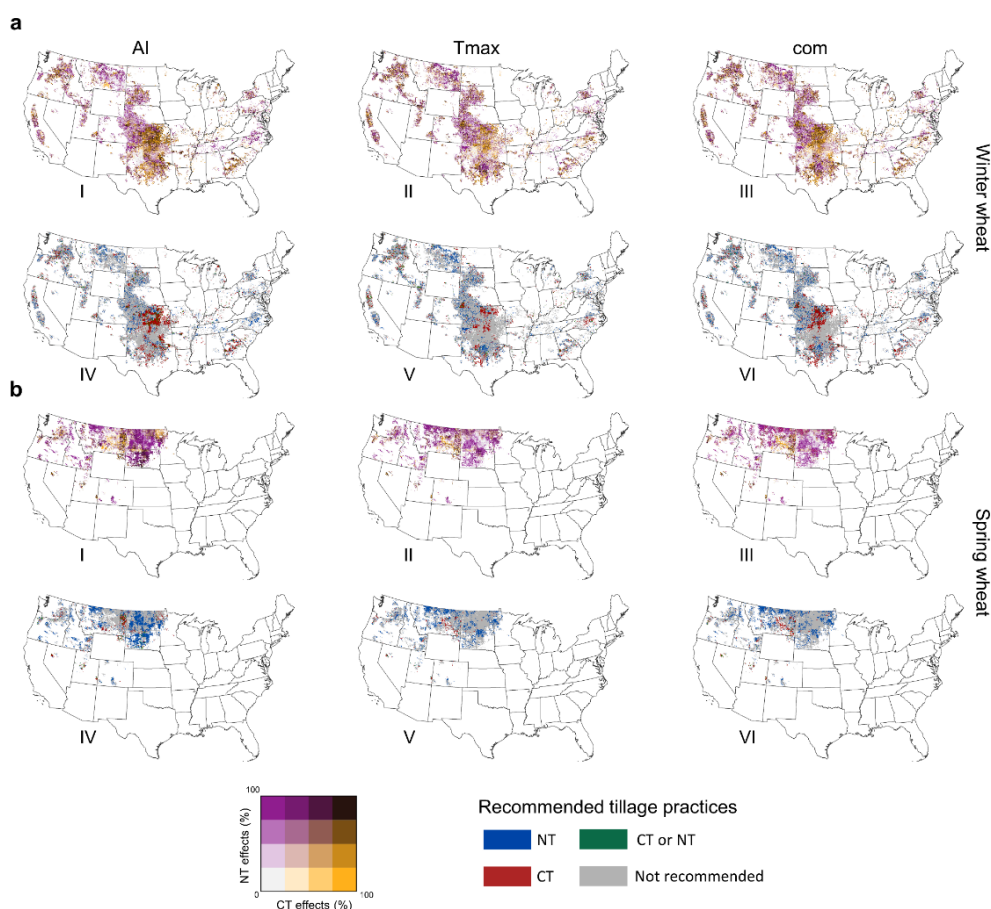


图 6-4 耕作实践缓解干热事件对温室气体强度的效应和建议策略。耕作效应（图 I-III）表示为过去 60 年通过耕作减少对干热事件敏感性的概率。对于每个网格，将降低敏感性概率大于 75% 的耕作方法列为推荐的耕作策略（图 IV-VI）。

Fig. 6-4 Tillage practice effects and recommended strategies for mitigating the impact of dry-heat events on GHG intensity. Tillage effects (panels I-III) are expressed as the probability of reduced sensitivity to dry-heat events through tillage practices over the past 60 years. For each grid, tillage practices with a probability greater than 75% of reducing sensitivity are listed as recommended tillage strategies.

6.3.2 最优耕作方案缓解小麦生产敏感的表现

优化后的耕作实践在推荐区域内显著降低了小麦对极端干热事件下产量和温室气体排放的敏感性，致使美国范围内温室气体排放强度的敏感性降低约 9%（图 6-5）。这种降低主要归因于对温室气体和产量敏感性变化的综合效应，即在全美范围内分别降低了约 6.4%和 1%的干热气候风险（图 6-5）。对于春小麦来讲，基于气候的最优耕作方案降低了 5.83%的温室气体排放的干热敏感性，并略微增加了小麦产量的干热敏感性（+1.39%，正号表示积极效应）。温室气体排放和产量敏感性的联合变化共同导致全美冬小麦温室气体排放强度敏感性下降 8.9%（图 6-5a）。最优耕作方案的缓解效果对冬小麦更为显著，具体而言，降低了 6.91%的温室气体排放的敏感性，并提高了 0.56%的产量敏感性，导致全美温室气体排放强度的敏感性下降了 9.29%（图 6-5b）。从时间序

列上来看，最优耕作方案在过去几十年均能不同程度地降低温室气体排放强度的敏感性（图 6-5）。然而，即使如此也不能逆转干热气候事件下温室气体排放强度的整体趋势，即过去六十年来，春小麦的敏感性一直在不断增加，而冬小麦的敏感性在二十世纪后急剧增加。

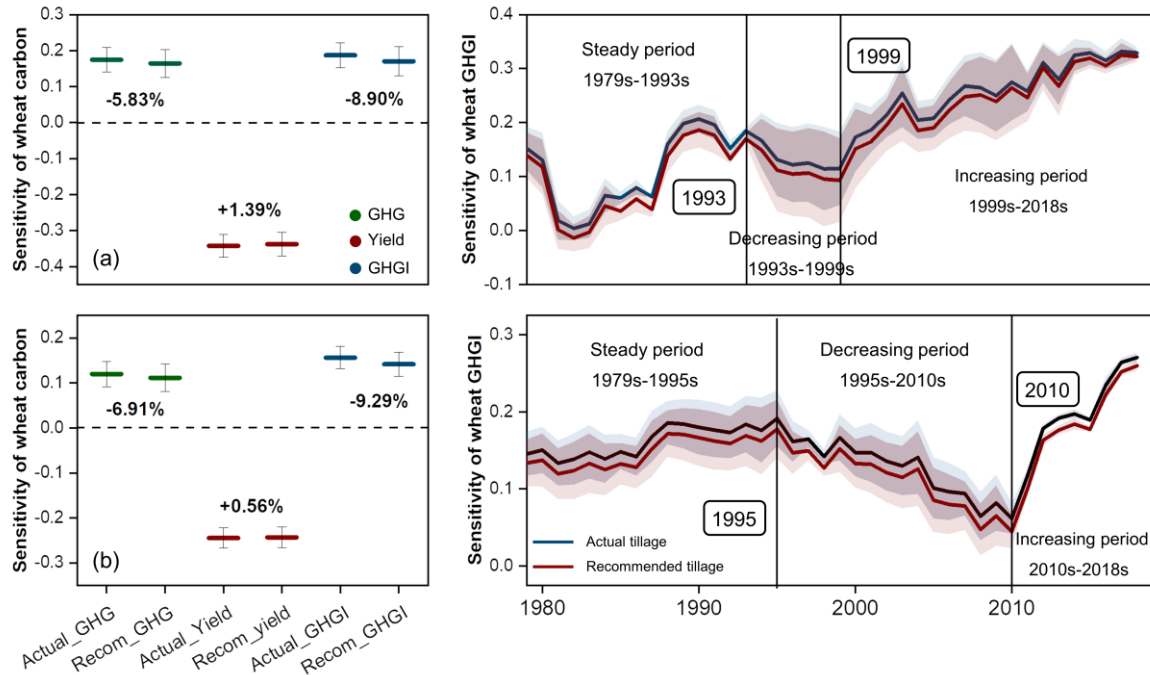


图 6-5 基于推荐的气候智慧型耕作的小麦温室气体排放强度敏感性变化。图 (a) 和 (b) 分别代表春小麦和冬小麦。

Fig. 6-5 Changes in wheat GHGI sensitivity based on the recommended climate-smart tillage. Panels (a) and (b) represent winter wheat and spring wheat, respectively.

此外，本章研究进一步探究了耕作实践对区域产量和温室气体排放的全效应的动态变化（即耕作在任何时期均能产生连续的积极效应或者消极效应）。对于冬小麦而言，耕作实践的完全消极效应随时间而强加，这意味着在未来干热气候加剧的情况下，持续的不良耕作可能会加剧温室气体排放并且放大气候对产量的损失效应。而对于完全积极效应，则观察到了随时间而逐渐减弱的趋势，这表明未来由耕作产生的积极正面效应将会被干热导致的敏感性增加而抵消（图 6-6）。如果在耕作实践为主导的负效应区域中不进行调整，极端干热气候会进一步加剧冬小麦的碳损失，这凸显了在特定地点采取合理的耕作实践以抵消干热引起的损失的重要性。

与冬小麦不同，春小麦温室气体和产量的耕作实践效应随时间的动态变化没有遵循一致的趋势（图 6-7）。例如，CT 对温室气体排放的完全积极效应会随气候变暖而降低，而 NT 对产量积极效应的动态变化则呈现了先增加后下降的趋势。不同干热情景

下，耕作对产量和温室气体排放的消极影响展现了缓慢减少的趋势，但这种趋势的时间变化并不显著。总而言之，如果美国小麦区的耕作实践不进行优化配置，过去历史耕作所带来的对小麦的积极效应将不复存在，负面效应将持续加剧，导致干热事件对小麦生产的气候成本进一步增加。此外，有限的耕作效应同样证明，应该实施其他可持续管理方案以降低小麦生产的干热敏感性，例如气候智慧型灌溉等。

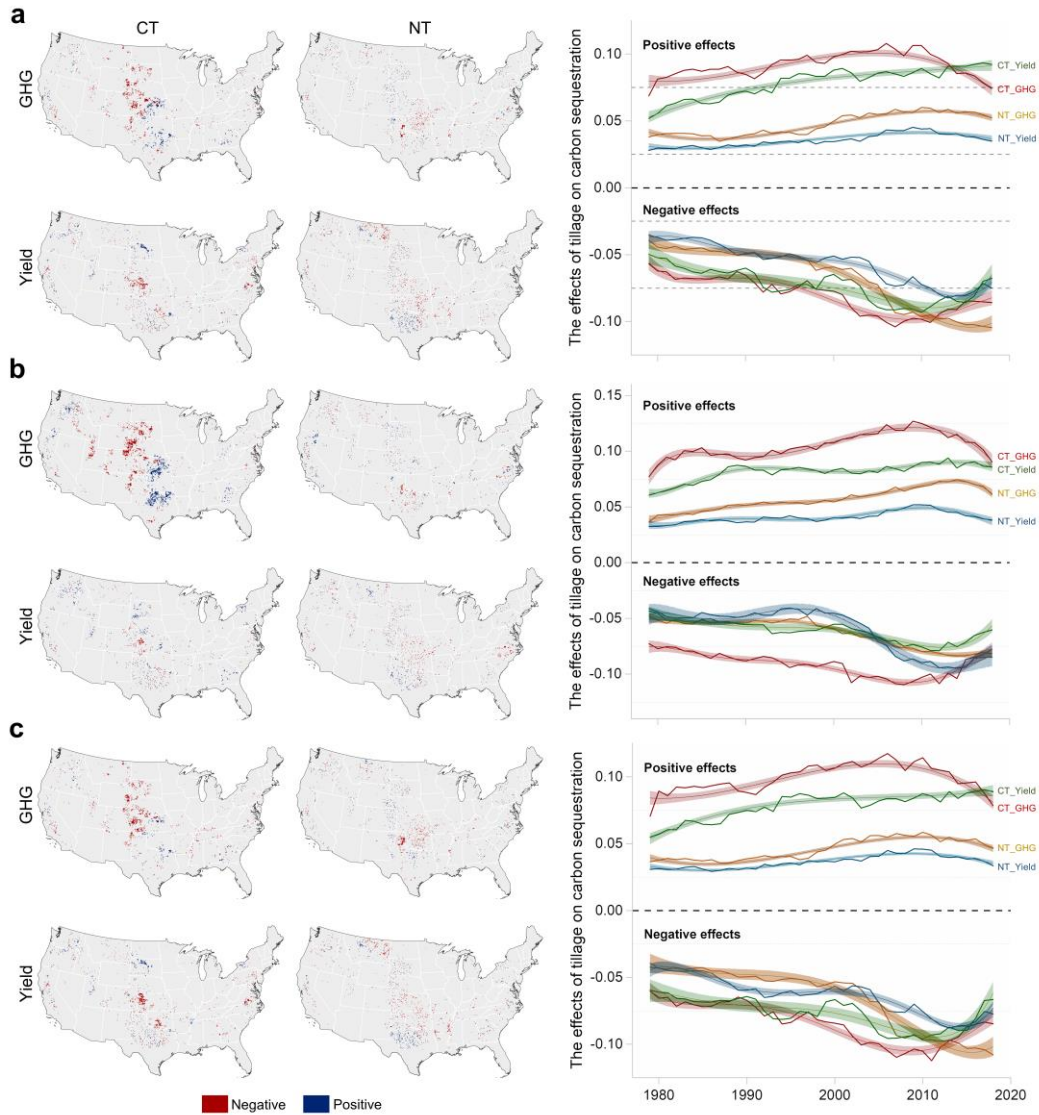


图 6-6 极端干热事件下耕作管理对冬小麦净温室气体排放和产量敏感性的影响。图 a, b, c 分别代表复合干热、干旱和高温事件。温室气体净排放和产量的积极影响分别代表减少（吸收）和增加，反之亦然。阴影带表示 95%置信区间。

Fig. 6-6 Effects of tillage management on the sensitivity of winter wheat net greenhouse gases (GHG) emission and yield under extreme dry-heat events. Panel a, b, and c represent compound dry-heat, drought, and high-temperature events, respectively. The positive effects for net GHG emission and yield represent the uptake and increases, respectively, compared to the all-combined scenario and vice versa. The shaded bands denote the 95% confidence intervals.

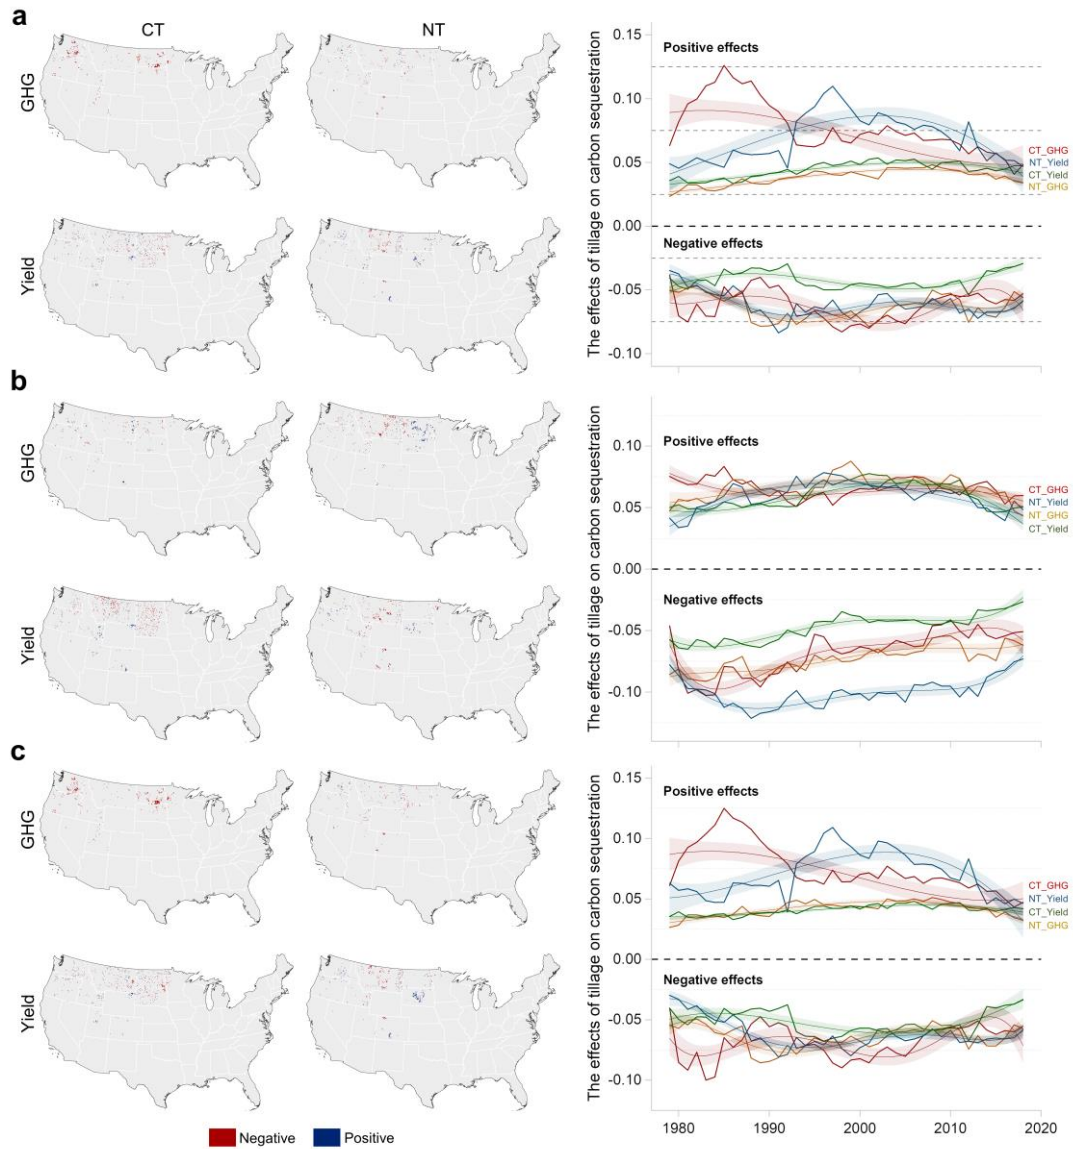


图 6-7 极端干热事件下耕作管理对春小麦净温室气体排放和产量敏感性的影响。图 a, b, c 分别代表复合干热、干旱和高温事件。温室气体净排放和产量的积极影响分别代表减少（吸收）和增加，反之亦然。阴影带表示 95%置信区间。

Fig. 6-7 Effects of tillage management on the sensitivity of spring wheat net greenhouse gases (GHG) emission and yield under extreme dry-heat events. Panel a, b, and c represent compound dry-heat, drought, and high-temperature events, respectively. The positive effects for net GHG emission and yield represent the uptake and increases, respectively, compared to the all-combined scenario and vice versa. The shaded bands denote the 95% confidence intervals.

6.4 讨论

6.4.1 社会恢复力对朝鲜粮食安全的影响

在朝鲜与其邻国（韩国和中国）之间，水稻生产的定量归因差异反映了基于社会恢复力的适应性在减轻极端气候不利影响方面的重要性。未来气候变化下，粮食安全

可能更大程度受益于适应能力的变化，如农业实践、经济发展（Acevedo et al. 2020）、资源利用和社会认知（Engle 2011）。此外，灌溉、施肥、保护性耕作和作物育种等农业适应方案更加注重产量的提高（Fang et al. 2019; Corbeels et al. 2020），例如 Challinor et al. (2014) 发现人为适应能力可将作物的平均产量提高 7-15%。然而，如果只关注提高作物产量，农民仍可能会因低估极端天气风险而遭受严重的产量损失。学习行为反映了对气候风险、适应和不确定性处理方面新信息的产生、吸收和转化的能力，学习和应用进一步科学知识的能力是应对气候变化的减缓机制（Neil Adger et al. 2005）。依赖于经济发展的资本投资是一种更直接的方法。这些投资包括建立预警系统和气候保险、资源利用、国际贸易以及减少贫困，其中保险是减轻气候风险和恢复生计的工具，特别是针对极端气候情况（Surminski et al. 2016）。然而，如果保险结构不正确，它可能会对风险产促进作用（Miao 2020）。对于无法通过贸易补偿损失的地区，较低的作物产量仍可能带来毁灭性后果。欠发达国家对气候变化更加脆弱且恢复力较低。当贫穷的家庭遭受气候冲击时，他们能从朋友、亲戚和金融体系方面得到的支持较少，因此在相似的气候风险条件下，减贫政策也可以减少气候变化的不利影响（De Cian et al. 2016; Hsiang et al. 2017）。社会经济因素的相互作用是降低经济脆弱性和增加社会恢复力的关键。在本研究中，通过对三个地区的情况进行比较，明确了社会恢复力在减缓饥饿问题方面的重要性。此外，地形可能限制朝鲜未来水稻的生产潜力，因为质量较差的土地不适宜种植水稻（图 5-9）。因此，未来的粮食安全规划需要考虑气候变化和社会经济的相互作用。

本研究提供了社会恢复力对粮食安全贡献的重要见解，世界上粮食不安全的地区也是公开可用数据稀少的地区，全面评估这些地区的粮食安全状况不仅是可持续发展的迫切需求，也是减少饥饿的必要途径。本研究整合了气象再分析产品、公开可用的统计数据 and 高分辨率图像，以填补数据稀缺的窗口并确保分析的稳健性。因此，粮食生产和粮食安全的分析可以扩展到其他有数据限制的地区。本研究所采用的框架结合了独特的区域特点，可以分析社会恢复力对粮食安全的重要性，该方法具有潜力用于全面评估世界其他地区（例如非洲、拉丁美洲和东南亚）的粮食安全状况。可预见的是，国家或地区的粮食安全更多归因于社会经济特征。鉴于粮食损失发生的原因和风险超出了气候风险框架，全球粮食生产还受到其他暴露度和适应能力的限制，例如非洲大部分地区的粮食不安全归因于自 2014 年以来暴力冲突的增加，同时产量损失也可以归因于蝗虫和干旱。因此，通过将不同因素纳入到暴露度要素中，可以为特定地区提供粮食安全的新见解，这将提升本研究进一步探索社会恢复力减轻破坏粮食安全因素的能力。随着多源数据（特别是遥感数据）的未来发展，那些目前缺乏可靠数据的研究地区将有机会获得完整的粮食安全评估。

未来，朝鲜的单一作物生产更有可能导致粮食不安全（水稻生产占总粮食生产的

60%以上), 从而导致饥饿。因此, 转变农业结构和增加作物多样性可能是保障粮食安全的关键途径。耐旱和耐热作物的引入有望为朝鲜等易气候敏感地区的粮食安全做出贡献, 特别是在国家层面上, 增加作物多样性, 种植多品种作物可以有效减少国家粮食生产损失, 从而确保整体粮食供应 (Renard and Tilman 2019)。作物多样性作为粮食系统恢复力的重要组成部分之一, 可以推动贸易多样性、膳食多样性和生态系统服务。未来气候变化预计会增加极端气候事件的频率和强度, 可能会减少全球粮食产量并导致饥荒。在世界上贫困地区, 对粮食安全状况进行准确评估至关重要, 因为它是世界粮食系统的关键环节, 也是联合国千年发展目标的重要组成部分。朝鲜是世界贫困地区的代表, 为研究欠发达地区的粮食安全提供了一个有价值的案例。本研究的可靠结果表明, 社会恢复力为理解和减轻未来极端天气的不利影响提供了可靠的途径。基于这种方法, 本研究可以明确未来的粮食风险, 并为制定可行性的行动方向和目标提供指导, 这将有助于提高国家风险意识、弥补粮食规划的不足并调整粮食战略以优化社会经济政策。

6.4.2 气候智慧型耕作对美国小麦产量和温室气体排放的影响

本研究表明, 不同的耕作方式 (包括常规耕作和免耕) 对小麦产量和温室气体排放的干热敏感性的影响存在区域差异。针对极端干热天气引发的气候冲击, 必须在特定地区采取合适的耕作策略, 以实现全面的风险缓解。这种强烈的空间异质性与当地环境密切相关, 例如 van Kessel et al. (2013) 指出, 在潮湿条件下, 无论是常规耕作还是免耕, N_2O 排放通常较高, 但在干燥条件下, 免耕的 N_2O 排放比常规耕作更高。此外, 土壤温室气体排放可能受到免耕和常规耕作的持续时间和深度的调控 (Groffman 1985; Venterea and Stanenas 2008)。由于 pH 值的变化 (Dick 1983)、微生物群落组成 (Minoshima et al. 2007) 和真菌病害胁迫 (Fernandez et al. 2009) 等不可控因素的影响, 耕作对温室气体的影响难以预测。通常情况下, 不利的耕作管理会导致土壤碳含量逐渐降低, 从而增加生态系统碳循环对极端干热天气的敏感性。实现极端干热不利影响和作物抵抗力之间的平衡不能完全依赖于气候智慧型耕作方案, 为了最大程度地减小极端天气对作物生产的影响, 需要因地制宜地采用多样地气候智慧型农业实践。

6.5 小结

(1) 基于朝鲜及其周边地区不同经济发展水平的对比研究, 朝鲜社会恢复力的不同变量之间的相关性较弱。当气候模型纳入社会恢复力时, 韩国 ($P < 0.05$) 和中国 ($P < 0.01$) 水稻生产的解释能力显著增强, 但在朝鲜方面效果不显著。此外, 社会恢复力在韩国和中国的水稻生产变化中具有更为显著的控制作用 ($P < 0.01$), 分别增加了超过 26% 和 100% 的水稻生产贡献。韩国地区的高温热浪对水稻生产构成威胁, 然而区域氮

肥投入、农村人口和 0-14 岁人口逆转了这些气候冲击的影响，甚至促进了更高的水稻产量。类似的现象也在中国观察到，即资源利用缓解了极端降雨事件带来的负面影响。然而，朝鲜的社会恢复力对粮食生产的影响并不显著，基于社会经济的非线性模型证明在欠发达地区，社会恢复力对粮食生产的贡献（15.2%）远远低于发达地区和发展中地区（分别为 83.0%和 86.1%）。

（2）基于 60 年的历史动态模拟发现，CT 和 NT 均显著降低了美国中部地区冬小麦对高温的敏感性，并且 NT 在北部地区的冬小麦和春小麦种植区表现出更为显著的效果，在超过 90%的春小麦种植区起到了主导作用。实施气候智慧型耕作策略可以有效降低 31.2%的地方的 GHGI 对干热气候的敏感性，优化的耕作实践显著降低了小麦碳的干热敏感性，使得美国范围内 GHGI 敏感性降低约 9%（春小麦为 8.9%，冬小麦为 9.29%）。此外，部分地区没有被纳入到气候智慧型耕作方案中，这表明在这些地区仅仅依靠气候智慧型耕作可能无法减轻干小麦生产的干热敏感性。本研究的发现强调了在气候变暖的情况下将作物碳敏感性和气候智慧型管理实践纳入到粮食安全和可持续发展评估的紧迫性。

第七章 结论与展望

7.1 主要结论

本研究以朝鲜和美国为例采取证实研究,基于多源模型和环境数据探究站点尺度、生态系统尺度和区域尺度粮食生产力的模拟精度,在此基础上归因粮食生产力与环境因素的动态响应关系,并从作物产量损失和敏感性变化角度,揭示极端天气事件对区域粮食生产的影响。根据经济发展水平差异,提出基于社会恢复力和气候智慧型管理的气候缓解方案并进一步量化了该缓解方案缓解潜力。本研究对于理清极端天气发生特征与粮食生产之间的动态关系以及人为活动如何影响气候变化与粮食生产的发展进程具有重要作用。通过探究不同发展水平下的优势性缓解措施的潜力,为政府部门在全球气候变化下制定合理的粮食生产规划和科学有效的气候风险应对策略提供了重要依据。主要结论如下:

(1) 基于多源环境数据和模型模拟站点粮食生产力

本研究采用逐像元模拟法结合多种遥感指数以及物候信息,模拟了朝鲜及其周边地区水稻种植分布的历史动态演变。随机森林模型在水稻单产和总产年际变化的预测方面表现出色,其预测准确性超过 80%,显著优于其他经验模型。同时,证实了水稻产量提前一个物候期预测的可行性。此外,随机森林模型还能够实现对农田生态系统光能利用效率的精确模拟。最后,通过对生态系统模型(DLEM v4.0)进行参数调优,精确模拟了美国小麦区站点尺度的产量变化,同时模型还精确模拟了小麦生产过程中温室气体排放和土壤有机碳的变化,为气候代价评估和粮食安全监测提供了可靠的工具。

(2) 区域粮食生产力模拟及其与环境因子的响应关系

本研究提出一种基于气候相似性的可迁移框架,用于稀缺数据地区的水稻产量预测。与联合国粮农组织的统计数据相比,预测结果在全生育期和播种-抽穗期情景下分别解释了总产变异的 78.72%和 76.89%,以及单产变异的 69.42%和 71.15%。其中,SIF在水稻产量预测中扮演了主要角色,其解释超过 15%,其次是最高温度和蒸散发,共同解释了超过 20%的水稻产量变化。此外,本研究还通过改进的生态系统光能利用率模型对区域生物量进行了预测,发现高温热浪是影响朝鲜水稻生物量变化最关键的环境因子。基于过程模型和遥感衍生数据模拟了美国小麦区作物生产力和温室气体排放的历史变化,发现气候变化和氮肥施用和单位小麦产量和温室气体排放变化中起着主导作用,但土地利用、气候变化和氮肥施用则对总产量和总排放的变化产生了更大的影响。

(3) 典型区域粮食生产对极端天气事件的响应特征

研究发现极端高温和极端降水事件分别导致了 2000 年和 2007 年朝鲜水稻产量的剧烈波动。随着未来气候变暖, 朝鲜将面临更高的极端热浪和降水风险, 如果不采取相关适应策略, 朝鲜水稻生物量到 2080s 在 SSP245 和 SSP585 情景下将分别减少 18.9% 和 20.2%, 届时水稻总产量将分别下降 13% 和 14.4%。此外, 美国小麦种植区在过去六十年经历了加剧的干热事件, 尤其在小麦生长季期间, 超过 75% 的地区面临干旱风险, 这导致了美国超过 70% 的冬小麦种植区和 90% 的春小麦种植区单位粮食生产所排放的温室气体增加, 显著提高了小麦生产的气候代价。其中春小麦的温室气体排放强度敏感性增加了 2.2 倍, 而冬小麦的敏感性则自 2008 年以来增加了 5.4 倍。在大多数小麦实验站点中观测到了负面的干热气候冲击, 这显著增加了 29.9% 的冬小麦站点和 27.5% 的春小麦站点的产量敏感性。

(4) 极端气候下不同发展水平地区的优势性缓解措施

基于朝鲜及其周边地区不同经济发展水平的对比研究发现, 现阶段社会恢复力对朝鲜水稻生产贡献较低, 而对韩国和中国的水稻生产有显著解释能力, 分别增加了超过 26% 和 100% 模型解释度。韩国地区的高温 and 热浪对水稻生产构成威胁, 但区域氮肥投入、农村人口和 0-14 岁人口的增加逆转了气候冲击的影响, 甚至促进了更高的水稻产量。同样, 中国的资源利用缓解了降雨极端事件带来的负面影响。非线性模型同样证明在欠发达地区 (15.2%), 社会恢复力对粮食生产的贡献远远低于发达地区和发展中地区 (分别为 83.0% 和 86.1%)。此历史动态模拟显示, 传统耕作和免耕的交叉应用显著降低了美国中部地区冬小麦对高温的敏感性, 特别是免耕在北部地区的冬小麦和春小麦种植区表现出更为显著的效果, 减轻了极端干热事件对温室气体排放强度负面影响。实施气候智慧型耕作策略可以在全美 31% 的小麦区内有效降低温室气体排放强度的干热气候敏感性, 从而使全美小麦生产区的温室气体排放强度敏感性降低约 9%, 有效降低了作物生产的气候代价。

7.2 论文创新点

本研究的创新点如下:

(1) 从研究方法层面上, 本研究基于气候相似性原理结合可扩展的模型和数据, 提出了一个可迁移的粮食生产力预测框架, 并成功实现了数据稀疏地区粮食生产时空动态变化的精确模拟。该框架可进一步被地区化以应用于全球其他数据稀疏地区 (例如非洲和南美洲), 有助于全球粮食生产力监测和粮食安全状况评估。

(2) 从研究内容和结果层面上, 本研究基于相同气候敏感性但不同的经济发展水平的地区性对比研究, 创新性地提出社会恢复力对粮食生产的支持和补偿作用, 并量化了社会恢复力缓解极端气候事件对粮食生产负面作用的潜力及其非线性响应。为提

高全球粮食安全提供了关键见解和可实现路径，揭示了欠发达地区社会恢复力的现实限制，有助于引导未来粮食决策和战略规划，以更有效地维护粮食安全并促进可持续发展。

(3) 从研究内容和结果层面上，本研究证实了作物生产过程中的温室气体排放强度对极端天气的敏感性急剧增加。这一发现填补了过去模型研究和试验观测所忽略的重要空白。即使采用先进的气候智慧型耕作实践只能在特定地区缓解干热敏感性，并不能扭转其持续上升的趋势。该结果意味着在气候变暖、未来干热事件频发的情景下，作物生产所面临的气候和环境代价将以不可预料的速度增加，并强调了未来育种工程和模型开发需要紧迫地关注作物产量和温室气体排放的敏感性，以确保可持续的农业发展。

7.3 研究不足和展望

本研究使用了再分析数据替代了气象观测数据，再分析数据源包括地面、天空、卫星和雷达数据，集成成一个包含许多不确定性的网格数据集 (Dee et al. 2011)。此外，本研究使用地表温度 (LST) 代替气温将生长季划分为物候阶段，尽管本研究发现 LST 和空气温度之间存在良好的相关性，但 LST 受到下垫面 (例如植被冠层和树木基部之间的温度差异) 的影响可能会引入不确定性 (Peng et al. 2014)。公开可用的环境变量被作为输入数据构建可迁移模型，然而由于难以确定空间连续的土壤属性并且年度土壤数据的误差传播可能会放大不确定性，因此土壤特性并未考虑在内。不可否认的是，基于不同土壤性质下的作物生产力估计可能存在显著差异。即使朝鲜及其周边地区展示了相似的气候特征，土壤异质性和变异性使得难以确保一致的土壤条件，Folberth et al. (2016) 发现，评估气候变化对产量的影响取决于土壤类型，因为土壤性质和水分缓冲或放大了气候影响。最后，一个重要限制是不同地区的作物品种和管理 (包括种植方法) 存在显著差异，从生产力的角度来看，朝鲜的水稻品种和管理能力可能远低于中国，这可能与两国经济规模有关。在未来，需要进一步研究影响不同地区和年份的作物生产因素，将其纳入气候脆弱性考虑范畴。

对于朝鲜生物量模拟以及未来气候风险，本研究仍然存在一些未解决限制和不确定性。例如，短期施肥数据和额外管理数据的缺失是本研究未考虑的潜在不确定性来源 (Spehar 1995; Butler et al. 2018)。本研究没有考虑水稻基因型的影响，由于缺乏品种数据，因此在区域生产差异方面可能存在潜在的不确定性 (Wang et al. 2021b)。对于 GPP 损失估计，模型中没有引入二氧化碳 (CO₂) 浓度，这是由于增加 CO₂ 浓度能否降低作物对水的需求、提高产量同时降低谷物的营养含量的能力存在争议 (Hasegawa et al. 2018)，不引入 CO₂ 浓度的影响可能会对可靠和稳健的气候和经济脆弱性估计产生影响。水稻制图方法也是不确定性的来源，具体而言，水稻制图的不确定性可能来自遥

感数据、不良天气、数据质量和可用的遥感图像数量(Dong et al. 2016; Zhou et al. 2016)。本研究通过统计降尺度方法生成了未来的日常气象数据,但不同的降尺度方法(如动态降尺度法)会产生不同的结果(Wang et al. 2020)。

对于生态系统模型模拟的不确定性可能来源于模型固有的限制。首先,该模型可能无法充分捕捉其他管理措施(如地被覆盖和残留物管理)对产量和温室气体敏感性的影响。此外,本研究没有调查干热事件的持续时间,而特定生长阶段中干热事件的发生和持续时间已被证明会影响小麦的固碳能力(Hlaváčová et al. 2018)。最后,本研究没有考虑连续干旱事件,因此年际间的长期干热事件(超过1年以上)对作物的影响难以被评估。虽然目前的模型已纳入干热胁迫下作物碳同化和分配的机制,但还需要进一步研究作物产量和温室气体排放敏感性的动态变化以及其不同小麦品种间的差异。在未来的气候变暖中,由于作物碳敏感性的变化,产量和温室气体排放预测的不确定性将会增大。因此,本文的研究结果强调需要考虑不同小麦品种间的敏感性差异以及干热胁迫对碳敏感性的长期动态影响。由于不同模型方法存在固有的系统误差,在未来基于多种模型模拟的交叉验证方法将有助于减少研究结果的不确定性,并提升结论的可靠性。

未来研究将继续深入不同经济背景下极端气候与粮食生产的关系,以拓展对该领域的理解。首先,我们将着重关注全球变化对中国粮食生产力的影响,尤其是在气候变化的背景下,特别关注干旱和台风引发的降水变化对农业的影响。深入研究气象数据、农业产量和土壤质量等方面的关联性,未来的研究有望揭示更为清晰的影响机制。此外,未来的研究还可以进一步探讨我国现有的耕作制度是否足以适应气候变化的挑战。通过对不同耕作制度在不同气候条件下的实际效果进行比较分析,我们可以为优化农业生产提供更具体的建议。同时,结合先进的农业技术,探讨新型的耕作方式和农业管理模式,以提高抗灾能力和适应性。在减肥减药和定量化施肥方面,可以通过对各地区农业实践的案例研究和长期监测数据的分析,更全面地了解减肥减药和定量化施肥对土壤健康和农产品质量的影响,为推动可持续农业发展提供更为具体的参考。

总体而言,未来的研究将在深入挖掘全球变化对中国农业生产力的影响的同时,注重提出可行的解决方案和政策建议,促进我国农业的可持续发展。这将需要跨学科的合作,结合气象学、土壤学、农业工程等多领域的知识,共同应对气候变化带来的复杂挑战。

参考文献

- 房世波, 韩国军, 张新时, 周广胜. 2011. 气候变化对农业生产的影响及其适应. *气象科技进展*, 1(2): 15-19.
- 胡根华, 鲁向晖. 2017. 气候变化对农作物生长发育影响分析. *安徽农业科学*, 45(22): 129-131.
- 菅艺伟, 付瑾, 周丰. 2021. 极端降水对水稻产量的影响研究综述. *地理科学进展*, 40(10): 1746-1760.
- 姜彤, 翟建青, 罗勇, 苏布达, 巢清尘, 王艳君, 王国杰, 黄金龙, 徐润宏, 高妙妮, 缪丽娟. 2022. 气候变化影响适应和脆弱性评估报告进展: IPCC AR5 到 AR6 的新认知. *大气科学学报*, 45(4): 502-511.
- 刘宪锋, 傅伯杰. 2021. 干旱对作物产量影响研究进展与展望. *地理学报*, 76(11): 2632-2646.
- 许迪, 李益农, 龚时宏, 张宝忠. 2019. 气候变化对农业水管理的影响及应对策略研究. *农业工程学报*, 35(14): 79-89.
- 魏金连, 潘晓华, 邓强辉. 2014. 夜间温度升高对双季早晚稻产量的影响. *生态学报*, 30(10): 2793-2798.
- Abbas S. 2022. Climate change and major crop production: evidence from Pakistan. *Environmental Science and Pollution Research*, 29(4): 5406-5414.
- Acevedo M, Pixley K, Zinyengere N, Meng S, Tufan H, Cichy K, Bizikova L, Isaacs K, Ghezzi-Kopel K, Porciello J. 2020. A scoping review of adoption of climate-resilient crops by small-scale producers in low- and middle-income countries. *Nature Plants*, 6(10): 1231-1241.
- Adamseged ME, Kebede SW. 2023. Are farmers' climate change adaptation strategies understated? Evidence from two communities in Northern Ethiopian Highlands. *Climate Services*, 30: 100369.
- Ahmadi A, Baker DA. 2001. The effect of water stress on the activities of key regulatory enzymes of the sucrose to starch pathway in wheat. *Plant Growth Regulation*, 35(1): 81-91.
- Almorox J, Quej VH, Martí P. 2015. Global performance ranking of temperature-based approaches for evapotranspiration estimation considering Köppen climate classes. *Journal of Hydrology*, 528: 514-522.
- Alo CA, Wang G. 2008. Potential future changes of the terrestrial ecosystem based on climate projections by eight general circulation models. *Journal of Geophysical Research: Biogeosciences*, 113(G1).
- Amare D, Endalew W. 2016. Agricultural mechanization: Assessment of mechanization impact experiences on the rural population and the implications for Ethiopian smallholders. *Engineering and Applied Sciences*, 1(2): 39-48.
- Ashraf M, Habib ur R. 1999. Interactive effects of nitrate and long-term waterlogging on growth, water relations, and gaseous exchange properties of maize (*Zea mays* L.). *Plant Science*, 144(1): 35-43.
- Ashraf M, Hafeez M. 2004. Thermotolerance of Pearl Millet and Maize at Early Growth Stages: Growth and Nutrient Relations. *Biologia Plantarum*, 48(1): 81-86.
- Assefa E, Gebrehiwot G. 2023. Gender dimensions of climate change adaptation in Tigray, Ethiopia. *Global Environmental Change*, 82: 102737.
- Asseng S, Cammarano D, Basso B, Chung U, Alderman PD, Sonder K, Reynolds M, Lobell DB. 2017. Hot spots of wheat yield decline with rising temperatures. *Global Change Biology*, 23(6): 2464-2472.
- Asseng S, Zhu Y, Wang E, Zhang W. 2015. Chapter 20 - Crop modeling for climate change impact and adaptation. Academic Press
- Auffhammer M, Ramanathan V, Vincent JR. 2012. Climate change, the monsoon, and rice yield in India.

- Climatic Change*, 111(2): 411-424.
- Baker E, Bezner Kerr R, Deryng D, Farrell A, Gurney-Smith H, Thornton P. 2023. Mixed farming systems: potentials and barriers for climate change adaptation in food systems. *Current Opinion in Environmental Sustainability*, 62: 101270.
- Bandara JS, Cai Y. 2014. The impact of climate change on food crop productivity, food prices and food security in South Asia. *Economic Analysis and Policy*, 44(4): 451-465.
- Barlow KM, Christy BP, O'Leary GJ, Riffkin PA, Nuttall JG. 2015. Simulating the impact of extreme heat and frost events on wheat crop production: A review. *Field Crops Research*, 171: 109-119.
- Batjes NH. ISRIC-WISE Harmonized Global Soil Profile Dataset. ISRIC-World Soil Information, W.
- Beck HE, Zimmermann NE, McVicar TR, Vergopolan N, Berg A, Wood EF. 2018. Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Scientific Data*, 5(1): 180214.
- Berg A, McColl KA. 2021. No projected global drylands expansion under greenhouse warming. *Nature Climate Change*, 11(4): 331-337.
- Berry PM, Kindred DR, Paveley ND. 2008. Quantifying the effects of fungicides and disease resistance on greenhouse gas emissions associated with wheat production. *Plant Pathology*, 57(6): 1000-1008.
- Bezner Kerr R, Hasegawa T, Lasco R. Food, fibre, and other ecosystem products Climate Change 2022: Impacts, Adaptation, and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press
- Bhatia R, Thorne-Lyman AL. 2002. Food shortages and nutrition in North Korea. *The Lancet*, 360: s27-s28.
- Bhattacharyya P, Roy KS, Neogi S, Dash PK, Nayak AK, Mohanty S, Baig MJ, Sarkar RK, Rao KS. 2013. Impact of elevated CO₂ and temperature on soil C and N dynamics in relation to CH₄ and N₂O emissions from tropical flooded rice (*Oryza sativa* L.). *Science of The Total Environment*, 461-462: 601-611.
- Bian Z, Tian H, Yang Q, Xu R, Pan S, Zhang B. 2021. Production and application of manure nitrogen and phosphorus in the United States since 1860. *Earth System Science Data*, 13(2): 515-527.
- Bista P, Norton U, Ghimire R, Norton JB. 2017. Effects of tillage system on greenhouse gas fluxes and soil mineral nitrogen in wheat (*Triticum aestivum* L.)-fallow during drought. *Journal of Arid Environments*, 147: 103-113.
- Blanc É. 2017. Statistical emulators of maize, rice, soybean and wheat yields from global gridded crop models. *Agricultural and Forest Meteorology*, 236: 145-161.
- Blanke JH, Olin S, Stürck J, Sahlin U, Lindeskog M, Helming J, Lehsten V. 2017. Assessing the impact of changes in land-use intensity and climate on simulated trade-offs between crop yield and nitrogen leaching. *Agriculture, Ecosystems & Environment*, 239: 385-398.
- Bonal D, Burban B, Stahl C, Wagner F, Hérault B. 2016. The response of tropical rainforests to drought-lessons from recent research and future prospects. *Annals of Forest Science*, 73(1): 27-44.
- Bondeau A, Smith PC, Zaehle S, Schaphoff S, Lucht W, Cramer W, Gerten D, Lotze-Campen H, MÜLLER C, Reichstein M, Smith B. 2007. Modelling the role of agriculture for the 20th century global terrestrial carbon balance. *Global Change Biology*, 13(3): 679-706.
- Boucher O, Servonnat J, Albright AL, Aumont O, Balkanski Y, Bastrikov V, Bekki S, Bonnet R, Bony S, Bopp L, Braconnot P, Brockmann P, Cadule P, Caubel A, Cheruy F, Codron F, Cozic A, Cugnet D, D'Andrea F, Davini P, de Lavergne C, Denvil S, Deshayes J, Devilliers M, Ducharne A, Dufresne J-L, Dupont E, Éthé C, Fairhead L, Falletti L, Flavoni S, Foujols M-A, Gardoll S, Gastineau G, Ghattas J,

- Grandpeix J-Y, Guenet B, Guez LE, Guilyardi E, Guimberteau M, Hauglustaine D, Hourdin F, Idelkadi A, Jousaume S, Kageyama M, Khodri M, Krinner G, Lebas N, Levvasseur G, Lévy C, Li L, Lott F, Lurton T, Luysaert S, Madec G, Madeleine J-B, Maignan F, Marchand M, Marti O, Mellul L, Meurdesoif Y, Mignot J, Musat I, Ottlé C, Peylin P, Planton Y, Polcher J, Rio C, Rochetin N, Rousset C, Sepulchre P, Sima A, Swingedouw D, Thiéblemont R, Traore AK, Vancoppenolle M, Vial J, Vialard J, Viovy N, Vuichard N. 2020. Presentation and Evaluation of the IPSL-CM6A-LR Climate Model. *Journal of Advances in Modeling Earth Systems*, 12(7): e2019MS002010.
- Breiman L. 2001. Random Forests. *Machine Learning*, 45(1): 5-32.
- Brown JF, Pervez MS. 2014. Merging remote sensing data and national agricultural statistics to model change in irrigated agriculture. *Agricultural Systems*, 127: 28-40.
- Butler EE, Huybers P. 2013. Adaptation of US maize to temperature variations. *Nature Climate Change*, 3(1): 68-72.
- Butler EE, Mueller ND, Huybers P. 2018. Peculiarly pleasant weather for US maize. *PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA*, 115(47): 11935-11940.
- Butterbach-Bahl K, Baggs EM, Dannenmann M, Kiese R, Zechmeister-Boltenstern S. 2013. Nitrous oxide emissions from soils: how well do we understand the processes and their controls? *Philosophical Transactions of the Royal Society B: Biological Sciences*, 368(1621): 20130122.
- Cao J, Zhang Z, Tao F, Zhang L, Luo Y, Zhang J, Han J, Xie J. 2021. Integrating multi-source data for rice yield prediction across china using machine learning and deep learning approaches. *Agricultural and Forest Meteorology*, 297: 108275.
- Cao P, Lu C, Yu Z. 2018. Historical nitrogen fertilizer use in agricultural ecosystems of the contiguous United States during 1850–2015: application rate, timing, and fertilizer types. *Earth System Science Data*, 10(2): 969-984.
- Cattivelli L, Rizza F, Badeck F-W, Mazzucotelli E, Mastrangelo AM, Francia E, Marè C, Tondelli A, Stanca AM. 2008. Drought tolerance improvement in crop plants: An integrated view from breeding to genomics. *Field Crops Research*, 105(1): 1-14.
- Challinor AJ, Watson J, Lobell DB, Howden SM, Smith DR, Chhetri N. 2014. A meta-analysis of crop yield under climate change and adaptation. *Nature Climate Change*, 4(4): 287-291.
- Chandio AA, Jiang Y, Amin A, Ahmad M, Akram W, Ahmad F. 2023. Climate change and food security of South Asia: fresh evidence from a policy perspective using novel empirical analysis. *Journal of Environmental Planning and Management*, 66(1): 169-190.
- Chang KW, Shen Y, Lo JC. 2005. Predicting rice yield using canopy reflectance measured at booting stage. *Agronomy Journal*, 97(3): 872-878.
- Chaudhary AR, Hanif U. 2022. Climate Change and Food Security: Steps towards Sustainable Development Goals. *iRASD Journal of Economics*, 4(2): 310-328.
- Chaves MM, Pereira JS, Maroco J, Rodrigues ML, Ricardo CPP, OSÓRIO ML, CARVALHO I, FARIA T, PINHEIRO C. 2002. How Plants Cope with Water Stress in the Field. Photosynthesis and Growth. *Annals of Botany*, 89(7): 907-916.
- Chen Y, Lee G, Lee P, Oikawa T. 2007. Model analysis of grazing effect on above-ground biomass and above-ground net primary production of a Mongolian grassland ecosystem. *Journal of Hydrology*, 333(1): 155-164.

- Chenu K, Porter JR, Martre P, Basso B, Chapman SC, Ewert F, Bindi M, Asseng S. 2017. Contribution of crop models to adaptation in wheat. *Trends in plant science*, 22(6): 472-490.
- Cinner JE, Barnes ML. 2019. Social dimensions of resilience in social-ecological systems. *One Earth*, 1(1): 51-56.
- Clauss K, Ottinger M, Leinenkugel P, Kuenzer C. 2018. Estimating rice production in the Mekong Delta, Vietnam, utilizing time series of Sentinel-1 SAR data. *International Journal of Applied Earth Observation and Geoinformation*, 73: 574-585.
- Clayton S, Devine-Wright P, Stern PC, Whitmarsh L, Carrico A, Steg L, Swim J, Bonnes M. 2015. Psychological research and global climate change. *Nature Climate Change*, 5(7): 640-646.
- Corbeels M, Naudin K, Whitbread AM, Kühne R, Letourmy P. 2020. Limits of conservation agriculture to overcome low crop yields in sub-Saharan Africa. *Nature Food*, 1(7): 447-454.
- Crane-Droesch A. 2018. Machine learning methods for crop yield prediction and climate change impact assessment in agriculture. *Environmental Research Letters*, 13(11): 114003.
- Crespo Cuaresma J, Danylo O, Fritz S, Hofer M, Kharas H, Laso Bayas JC. 2020. What do we know about poverty in North Korea? *Palgrave Communications*, 6(1): 40.
- Crespo Cuaresma J, Lutz W, Sanderson W. 2014. Is the Demographic Dividend an Education Dividend? *Demography*, 51(1): 299-315.
- Darnhofer I, Fairweather J, Moller H. 2010. Assessing a farm's sustainability: insights from resilience thinking. *International journal of agricultural sustainability*, 8(3): 186-198.
- De Cian E, Hof AF, Marangoni G, Tavoni M, van Vuuren DP. 2016. Alleviating inequality in climate policy costs: an integrated perspective on mitigation, damage and adaptation. *Environmental Research Letters*, 11(7): 074015.
- Dee DP, Uppala SM, Simmons AJ, Berrisford P, Poli P, Kobayashi S, Andrae U, Balmaseda M, Balsamo G, Bauer dP. 2011. The ERA - Interim reanalysis: Configuration and performance of the data assimilation system. *Quarterly Journal of the royal meteorological society*, 137(656): 553-597.
- Diaz D, Moore F. 2017. Quantifying the economic risks of climate change. *Nature Climate Change*, 7(11): 774-782.
- Dick WA. 1983. Organic Carbon, Nitrogen, and Phosphorus Concentrations and pH in Soil Profiles as Affected by Tillage Intensity. *Soil Science Society of America Journal*, 47(1): 102-107.
- Didan K. MOD13A1 MODIS/Terra Vegetation Indices 16-Day L3 Global 500m SIN Grid V006. DAAC, N.E.L.P.
- Dill C, Naegele A, Baillargeon N, Caparas M, Dusseau D, Holland M, Schwalm C. Converging Crises in North Korea, Security, Stability and Climate Change. Woodwell Climate Research Center
- Dong J, Xiao X, Kou W, Qin Y, Zhang G, Li L, Jin C, Zhou Y, Wang J, Biradar C, Liu J, Moore B. 2015. Tracking the dynamics of paddy rice planting area in 1986–2010 through time series Landsat images and phenology-based algorithms. *Remote Sensing of Environment*, 160: 99-113.
- Dong J, Xiao X, Menarguez MA, Zhang G, Qin Y, Thau D, Biradar C, Moore B. 2016. Mapping paddy rice planting area in northeastern Asia with Landsat 8 images, phenology-based algorithm and Google Earth Engine. *Remote Sensing of Environment*, 185: 142-154.
- Ebrahim MK, Zingsheim O, El-Shourbagy MN, Moore PH, Komor E. 1998. Growth and sugar storage in sugarcane grown at temperatures below and above optimum. *Journal of Plant Physiology*, 153(5): 593-602.

- Engle NL. 2011. Adaptive capacity and its assessment. *Global Environmental Change*, 21(2): 647-656.
- Estrada-Campuzano G, Miralles DJ, Slafer GA. 2008. Genotypic variability and response to water stress of pre- and post-anthesis phases in triticale. *European Journal of Agronomy*, 28(3): 171-177.
- Everingham Y, Sexton J, Skocaj D, Inman-Bamber G. 2016. Accurate prediction of sugarcane yield using a random forest algorithm. *Agronomy for Sustainable Development*, 36(2): 27.
- Eyring V, Lamarque J-F, Hess P, Arfeuille F, Bowman K, Chipperfield MP, Duncan B, Fiore A, Gettelman A, Giorgetta MA. 2013. Overview of IGAC/SPARC Chemistry-Climate Model Initiative (CCMI) community simulations in support of upcoming ozone and climate assessments. *SPARC newsletter*, 40(Januar): 48-66.
- Eyshi Rezaei E, Webber H, Gaiser T, Naab J, Ewert F. 2015. Heat stress in cereals: Mechanisms and modelling. *European Journal of Agronomy*, 64: 98-113.
- Fahmida, Chaudhary AR, Hanif U. 2022. Climate Change and Food Security: Steps towards Sustainable Development Goals. *iRASD Journal of Economics*, 4(2): 310-328.
- Fang H, Li W, Wei S, Jiang C. 2014. Seasonal variation of leaf area index (LAI) over paddy rice fields in NE China: Intercomparison of destructive sampling, LAI-2200, digital hemispherical photography (DHP), and AccuPAR methods. *Agricultural and Forest Meteorology*, 198: 126-141.
- Fang W, Huang S, Huang Q, Huang G, Wang H, Leng G, Wang L, Guo Y. 2019. Probabilistic assessment of remote sensing-based terrestrial vegetation vulnerability to drought stress of the Loess Plateau in China. *Remote Sensing of Environment*, 232: 111290.
- FAO, Ifad, UNICEF, WFP, WHO. Transforming food systems for food security, improved nutrition and affordable healthy diets for all. . The State of Food Security and Nutrition in the World 2021
- Feng P, Wang B, Liu DL, Yu Q. 2019. Machine learning-based integration of remotely-sensed drought factors can improve the estimation of agricultural drought in South-Eastern Australia. *Agricultural Systems*, 173: 303-316.
- Feng S, Hao Z, Zhang X, Hao F. 2021. Changes in climate-crop yield relationships affect risks of crop yield reduction. *Agricultural and Forest Meteorology*, 304-305: 108401.
- Fernandez MR, Zentner RP, Basnyat P, Gehl D, Selles F, Huber D. 2009. Glyphosate associations with cereal diseases caused by *Fusarium* spp. in the Canadian Prairies. *European Journal of Agronomy*, 31(3): 133-143.
- Ferris R, Ellis RH, Wheeler TR, Hadley P. 1998. Effect of High Temperature Stress at Anthesis on Grain Yield and Biomass of Field-grown Crops of Wheat. *Annals of Botany*, 82(5): 631-639.
- Fischer EM, Knutti R. 2015. Anthropogenic contribution to global occurrence of heavy-precipitation and high-temperature extremes. *Nature Climate Change*, 5(6): 560-564.
- Fisher JB, Huntzinger DN, Schwalm CR, Sitch S. 2014. Modeling the Terrestrial Biosphere. *Annual Review of Environment and Resources*, 39(1): 91-123.
- Floods M-w. Flood Hazard Mitigation through Property Hazard Acquisition and Relocation Program. FEMA Mitigation Directorate: Washington, DC, USA
- Folberth C, Skalský R, Moltchanova E, Balkovič J, Azevedo LB, Obersteiner M, van der Velde M. 2016. Uncertainty in soil data can outweigh climate impact signals in global crop yield simulations. *Nature Communications*, 7(1): 11872.
- Frich P, Alexander LV, Della-Marta P, Gleason B, Haylock M, Tank AK, Peterson T. 2002. Observed coherent changes in climatic extremes during the second half of the twentieth century. *Climate*

- Research*, 19(3): 193-212.
- Fritz S, See L, Bayas JCL, Waldner F, Jacques D, Becker-Reshef I, Whitcraft A, Baruth B, Bonifacio R, Crutchfield J. 2019. A comparison of global agricultural monitoring systems and current gaps. *Agricultural Systems*, 168: 258-272.
- Fuller MP, Fuller AM, Kaniouras S, Christophers J, Fredericks T. 2007. The freezing characteristics of wheat at ear emergence. *European Journal of Agronomy*, 26(4): 435-441.
- Fuso Nerini F, Tomei J, To LS, Bisaga I, Parikh P, Black M, Borrion A, Spataru C, Castán Broto V, Anandarajah G, Milligan B, Mulugetta Y. 2018. Mapping synergies and trade-offs between energy and the Sustainable Development Goals. *Nature Energy*, 3(1): 10-15.
- Gan Y, Liang C, Chai Q, Lemke RL, Campbell CA, Zentner RP. 2014. Improving farming practices reduces the carbon footprint of spring wheat production. *Nature Communications*, 5(1): 5012.
- Gaupp F, Hall J, Mitchell D, Dadson S. 2019. Increasing risks of multiple breadbasket failure under 1.5 and 2 °C global warming. *Agricultural Systems*, 175: 34-45.
- Gilbert N. 2011. Climate-smart agriculture is needed. *Nature*.
- Gobin A. 2018. Weather related risks in Belgian arable agriculture. *Agricultural Systems*, 159: 225-236.
- Gourdji SM, Sibley AM, Lobell DB. 2013. Global crop exposure to critical high temperatures in the reproductive period: historical trends and future projections. *Environmental Research Letters*, 8(2): 024041.
- Groffman PM. 1985. Nitrification and Denitrification in Conventional and No-Tillage Soils. *Soil Science Society of America Journal*, 49(2): 329-334.
- Guan K, Berry JA, Zhang Y, Joiner J, Guanter L, Badgley G, Lobell DB. 2016. Improving the monitoring of crop productivity using spaceborne solar-induced fluorescence. *Global Change Biology*, 22(2): 716-726.
- Guanter L, Zhang Y, Jung M, Joiner J, Voigt M, Berry JA, Frankenberg C, Huete AR, Zarco-Tejada P, Lee J-E, Moran MS, Ponce-Campos G, Beer C, Camps-Valls G, Buchmann N, Gianelle D, Klumpp K, Cescatti A, Baker JM, Griffis TJ. 2014. Global and time-resolved monitoring of crop photosynthesis with chlorophyll fluorescence. *PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA*, 111(14): E1327-E1333.
- Guarin JR, Asseng S, Martre P, Bliznyuk N. 2020. Testing a crop model with extreme low yields from historical district records. *Field Crops Research*, 249: 107269.
- Guo Y, Fu Y, Hao F, Zhang X, Wu W, Jin X, Bryant CR, Senthilnath J. 2021. Integrated phenology and climate in rice yields prediction using machine learning methods. *Ecological Indicators*, 120: 106935.
- Gupta R, Mishra A. 2019. Climate change induced impact and uncertainty of rice yield of agro-ecological zones of India. *Agricultural Systems*, 173: 1-11.
- Guy CL. 1990. Cold acclimation and freezing stress tolerance: role of protein metabolism. *Annual review of plant biology*, 41(1): 187-223.
- Hallegatte S, Fay M, Barbier EB. 2018. Poverty and climate change: introduction. *Environment and Development Economics*, 23(3): 217-233.
- Hallegatte S, Przulski V, Vogt-Schilb A. 2011. Building world narratives for climate change impact, adaptation and vulnerability analyses. *Nature Climate Change*, 1(3): 151-155.
- Hallegatte S, Rozenberg J. 2017. Climate change through a poverty lens. *Nature Climate Change*, 7(4): 250-256.

- Hansen J, Sato M, Ruedy R. 2012. Perception of climate change. *PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA*, 109(37): E2415-E2423.
- Hargreaves GH, Samani ZA. 1982. Estimating Potential Evapotranspiration. *Journal of the Irrigation and Drainage Division*, 108(3): 225-230.
- Hasegawa T, Fujimori S, Havlík P, Valin H, Bodirsky BL, Doelman JC, Fellmann T, Kyle P, Koopman JFL, Lotze-Campen H, Mason-D'Croz D, Ochi Y, Pérez Domínguez I, Stehfest E, Sulser TB, Tabeau A, Takahashi K, Takakura Jy, van Meijl H, van Zeist W-J, Wiebe K, Witzke P. 2018. Risk of increased food insecurity under stringent global climate change mitigation policy. *Nature Climate Change*, 8(8): 699-703.
- Hawkins E, Fricker TE, Challinor AJ, Ferro CAT, Ho CK, Osborne TM. 2013. Increasing influence of heat stress on French maize yields from the 1960s to the 2030s. *Global Change Biology*, 19(3): 937-947.
- Hlaváčová M, Klem K, Rapantová B, Novotná K, Urban O, Hlavinka P, Smutná P, Horáková V, Škarpa P, Pohanková E, Wimmerová M, Orság M, Jurečka F, Trnka M. 2018. Interactive effects of high temperature and drought stress during stem elongation, anthesis and early grain filling on the yield formation and photosynthesis of winter wheat. *Field Crops Research*, 221: 182-195.
- Hochman Z, van Rees H, Carberry PS, Hunt JR, McCown RL, Gartmann A, Holzworth D, van Rees S, Dalgliesh NP, Long W, Peake AS, Poulton PL, McClelland T. 2009. Re-inventing model-based decision support with Australian dryland farmers. 4. Yield Prophet^{sup} helps farmers monitor and manage crops in a variable climate. *Crop and Pasture Science*, 60(11): 1057-1070.
- Hoffman AL, Kemanian AR, Forest CE. 2018. Analysis of climate signals in the crop yield record of sub-Saharan Africa. *Global Change Biology*, 24(1): 143-157.
- Hogan PS, Chen SX, Teh WW, Chib VS. 2020. Neural mechanisms underlying the effects of physical fatigue on effort-based choice. *Nature Communications*, 11(1): 4026.
- Holling CS. 1973. Resilience and stability of ecological systems. *Annual review of ecology and systematics*, 4(1): 1-23.
- Hsiang S, Kopp R, Jina A, Rising J, Delgado M, Mohan S, Rasmussen DJ, Muir-Wood R, Wilson P, Oppenheimer M, Larsen K, Houser T. 2017. Estimating economic damage from climate change in the United States. *Science*, 356(6345): 1362-1369.
- Huang J, Gómez-Dans JL, Huang H, Ma H, Wu Q, Lewis PE, Liang S, Chen Z, Xue J-H, Wu Y. 2019. Assimilation of remote sensing into crop growth models: Current status and perspectives. *Agricultural and Forest Meteorology*, 276: 107609.
- Huang J, Zhang X, Zhang Q, Lin Y, Hao M, Luo Y, Zhao Z, Yao Y, Chen X, Wang L, Nie S, Yin Y, Xu Y, Zhang J. 2017. Recently amplified arctic warming has contributed to a continual global warming trend. *Nature Climate Change*, 7(12): 875-879.
- Huang Y, Ren W, Grove J, Poffenbarger H, Jacobsen K, Tao B, Zhu X, McNear D. 2020. Assessing synergistic effects of no-tillage and cover crops on soil carbon dynamics in a long-term maize cropping system under climate change. *Agricultural and Forest Meteorology*, 291: 108090.
- Huete A, Didan K, Miura T, Rodriguez EP, Gao X, Ferreira LG. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2): 195-213.
- Hussain M, Malik MA, Farooq M, Ashraf MY, Cheema MA. 2008. Improving Drought Tolerance by Exogenous Application of Glycinebetaine and Salicylic Acid in Sunflower. *Journal of Agronomy and*

- Crop Science*, 194(3): 193-199.
- Innes PJ, Tan DKY, Van Ogtrop F, Amthor JS. 2015. Effects of high-temperature episodes on wheat yields in New South Wales, Australia. *Agricultural and Forest Meteorology*, 208: 95-107.
- IPCC. 2021. Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge, United Kingdom and New York, NY, USA
- Jaafar H, Mourad R. 2021. GYMEE: A Global Field-Scale Crop Yield and ET Mapper in Google Earth Engine Based on Landsat, Weather, and Soil Data. *Remote Sensing*, 13(4): 773.
- Jägermeyr J, Müller C, Ruane AC, Elliott J, Balkovic J, Castillo O, Faye B, Foster I, Folberth C, Franke JA, Fuchs K, Guarin JR, Heinke J, Hoogenboom G, Iizumi T, Jain AK, Kelly D, Khabarov N, Lange S, Lin T-S, Liu W, Mialyk O, Minoli S, Moyer EJ, Okada M, Phillips M, Porter C, Rabin SS, Scheer C, Schneider JM, Schyns JF, Skalsky R, Smerald A, Stella T, Stephens H, Webber H, Zabel F, Rosenzweig C. 2021. Climate impacts on global agriculture emerge earlier in new generation of climate and crop models. *Nature Food*, 2(11): 873-885.
- Janzen HH, Angers DA, Boehm M, Bolinder M, Desjardins RL, Dyer J, Ellert BH, Gibb DJ, Gregorich EG, Helgason BL, Lemke R, Massé D, McGinn SM, McAllister TA, Newlands N, Pattey E, Rochette P, Smith W, VandenBygaart AJ, Wang H. 2006. A proposed approach to estimate and reduce net greenhouse gas emissions from whole farms. *Canadian Journal of Soil Science*, 86(3): 401-418.
- Ji H, Xiao L, Xia Y, Song H, Liu B, Tang L, Cao W, Zhu Y, Liu L. 2017. Effects of jointing and booting low temperature stresses on grain yield and yield components in wheat. *Agricultural and Forest Meteorology*, 243: 33-42.
- Jiang H, Hu H, Zhong R, Xu J, Xu J, Huang J, Wang S, Ying Y, Lin T. 2020. A deep learning approach to conflating heterogeneous geospatial data for corn yield estimation: A case study of the US Corn Belt at the county level. *Global Change Biology*, 26(3): 1754-1766.
- Joiner J, Yoshida Y, Guanter L, Middleton EM. 2016. New methods for the retrieval of chlorophyll red fluorescence from hyperspectral satellite instruments: simulations and application to GOME-2 and SCIAMACHY. *Atmospheric Measurement Techniques*, 9(8): 3939-3967.
- Jones JW, Antle JM, Basso B, Boote KJ, Conant RT, Foster I, Godfray H CJ, Herrero M, Howitt RE, Janssen S, Keating BA, Munoz-Carpena R, Porter CH, Rosenzweig C, Wheeler TR. 2017. Toward a new generation of agricultural system data, models, and knowledge products: State of agricultural systems science. *Agricultural Systems*, 155: 269-288.
- Kassie BT, Asseng S, Porter CH, Royce FS. 2016. Performance of DSSAT-Nwheat across a wide range of current and future growing conditions. *European Journal of Agronomy*, 81: 27-36.
- Kawasaki K, Uchida S. 2016. Quality Matters More Than Quantity: Asymmetric Temperature Effects on Crop Yield and Quality Grade. *American Journal of Agricultural Economics*, 98(4): 1195-1209.
- Kaya MD, Okçu G, Atak M, Çikılı Y, Kolsarıcı Ö. 2006. Seed treatments to overcome salt and drought stress during germination in sunflower (*Helianthus annuus* L.). *European Journal of Agronomy*, 24(4): 291-295.
- Kim HK, Lee S-H. 2021. The effects of population aging on South Korea's economy: The National Transfer Accounts approach. *The Journal of the Economics of Ageing*, 20: 100340.
- Kozdrój J, van Elsland JD. 2000. Response of the bacterial community to root exudates in soil polluted with heavy metals assessed by molecular and cultural approaches. *Soil Biology and Biochemistry*, 32(10):

- 1405-1417.
- Kukul MS, Irmak S. 2018. Climate-Driven Crop Yield and Yield Variability and Climate Change Impacts on the U.S. Great Plains Agricultural Production. *Scientific Reports*, 8(1): 3450.
- Lambert M-J, Blaes X, Traoré PS, Defourny P, 2017. Estimate yield at parcel level from S2 time serie in sub-Saharan smallholder farming systems. 2017 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp). IEEE, pp. 1-7.
- Laux P, Jäckel G, Tingem RM, Kunstmann H. 2010. Impact of climate change on agricultural productivity under rainfed conditions in Cameroon—A method to improve attainable crop yields by planting date adaptations. *Agricultural and Forest Meteorology*, 150(9): 1258-1271.
- Leng G, Hall JW. 2020. Predicting spatial and temporal variability in crop yields: an inter-comparison of machine learning, regression and process-based models. *Environmental Research Letters*, 15(4): 044027.
- Leng G, Zhang X, Huang M, Asrar GR, Leung LR. 2016. The Role of Climate Covariability on Crop Yields in the Conterminous United States. *Scientific Reports*, 6(1): 33160.
- Lesk C, Coffel E, Horton R. 2020. Net benefits to US soy and maize yields from intensifying hourly rainfall. *Nature Climate Change*, 10(9): 819-822.
- Li T, Hasegawa T, Yin X, Zhu Y, Boote K, Adam M, Bregaglio S, Buis S, Confalonieri R, Fumoto T, Gaydon D, Marcaida Iii M, Nakagawa H, Oriol P, Ruane AC, Ruget F, Singh B, Singh U, Tang L, Tao F, Wilkens P, Yoshida H, Zhang Z, Bouman B. 2015. Uncertainties in predicting rice yield by current crop models under a wide range of climatic conditions. *Global Change Biology*, 21(3): 1328-1341.
- Li X, Troy TJ. 2018. Changes in rainfed and irrigated crop yield response to climate in the western US. *Environmental Research Letters*, 13(6): 064031.
- Liaw A, Wiener M. 2002. Classification and regression by randomForest. *R news*, 2(3): 18-22.
- Lipper L, Thornton P, Campbell BM, Baedeker T, Braimoh A, Bwalya M, Caron P, Cattaneo A, Garrity D, Henry K, Hottle R, Jackson L, Jarvis A, Kossam F, Mann W, McCarthy N, Meybeck A, Neufeldt H, Remington T, Sen PT, Sessa R, Shula R, Tibu A, Torquebiau EF. 2014. Climate-smart agriculture for food security. *Nature Climate Change*, 4(12): 1068-1072.
- Liu B, Asseng S, Müller C, Ewert F, Elliott J, Lobell David B, Martre P, Ruane Alex C, Wallach D, Jones James W, Rosenzweig C, Aggarwal Pramod K, Alderman Phillip D, Anothai J, Basso B, Biernath C, Cammarano D, Challinor A, Deryng D, Sanctis Giacomo D, Doltra J, Fereres E, Folberth C, Garcia-Vila M, Gayler S, Hoogenboom G, Hunt Leslie A, Izaurralde Roberto C, Jabloun M, Jones Curtis D, Kersebaum Kurt C, Kimball Bruce A, Koehler A-K, Kumar Soora N, Nendel C, O'Leary Garry J, Olesen Jørgen E, Ottman Michael J, Palosuo T, Prasad PVV, Priesack E, Pugh Thomas AM, Reynolds M, Rezaei Ehsan E, Rötter Reimund P, Schmid E, Semenov Mikhail A, Shcherbak I, Stehfest E, Stöckle Claudio O, Stratonovitch P, Streck T, Supit I, Tao F, Thorburn P, Waha K, Wall Gerard W, Wang E, White Jeffrey W, Wolf J, Zhao Z, Zhu Y. 2016. Similar estimates of temperature impacts on global wheat yield by three independent methods. *Nature Climate Change*, 6(12): 1130-1136.
- Liu C, Wang K, Zheng X. 2012. Responses of N₂O and CH₄ fluxes to fertilizer nitrogen addition rates in an irrigated wheat-maize cropping system in northern China. *Biogeosciences*, 9(2): 839-850.
- Liu D, Toman E, Fuller Z, Chen G, Londo A, Zhang X, Zhao K. 2018. Integration of historical map and aerial imagery to characterize long-term land-use change and landscape dynamics: An object-based analysis via Random Forests. *Ecological Indicators*, 95: 595-605.

- Liu DL, Zuo H. 2012. Statistical downscaling of daily climate variables for climate change impact assessment over New South Wales, Australia. *Climatic Change*, 115(3): 629-666.
- Liu M, Tian H, Yang Q, Yang J, Song X, Lohrenz SE, Cai W-J. 2013. Long-term trends in evapotranspiration and runoff over the drainage basins of the Gulf of Mexico during 1901–2008. *Water Resources Research*, 49(4): 1988-2012.
- Liu XJ, Mosier AR, Halvorson AD, Zhang FS. 2005. Tillage and Nitrogen Application Effects on Nitrous and Nitric Oxide Emissions from Irrigated Corn Fields. *Plant and Soil*, 276(1): 235-249.
- Lobell DB, Asner GP. 2003. Climate and Management Contributions to Recent Trends in U.S. Agricultural Yields. *Science*, 299(5609): 1032-1032.
- Lobell DB, Asseng S. 2017. Comparing estimates of climate change impacts from process-based and statistical crop models. *Environmental Research Letters*, 12(1): 015001.
- Lobell DB, Burke MB, Tebaldi C, Mastrandrea MD, Falcon WP, Naylor RL. 2008. Prioritizing Climate Change Adaptation Needs for Food Security in 2030. *Science*, 319(5863): 607-610.
- Lobell DB, Roberts MJ, Schlenker W, Braun N, Little BB, Rejesus RM, Hammer GL. 2014. Greater Sensitivity to Drought Accompanies Maize Yield Increase in the U.S. Midwest. *Science*, 344(6183): 516-519.
- Lobell DB, Sibley A, Ivan Ortiz-Monasterio J. 2012. Extreme heat effects on wheat senescence in India. *Nature Climate Change*, 2(3): 186-189.
- Lognoul M, Theodorakopoulos N, Hiel M-P, Regaert D, Broux F, Heinesch B, Bodson B, Vandenbol M, Aubinet M. 2017. Impact of tillage on greenhouse gas emissions by an agricultural crop and dynamics of N₂O fluxes: Insights from automated closed chamber measurements. *Soil and Tillage Research*, 167: 80-89.
- Lombardozzi DL, Bonan GB, Levis S, Lawrence DM. 2018. Changes in Wood Biomass and Crop Yields in Response to Projected CO₂, O₃, Nitrogen Deposition, and Climate. *Journal of Geophysical Research: Biogeosciences*, 123(10): 3262-3282.
- Lombardozzi DL, Lu Y, Lawrence PJ, Lawrence DM, Swenson S, Oleson KW, Wieder WR, Ainsworth EA. 2020. Simulating Agriculture in the Community Land Model Version 5. *Journal of Geophysical Research: Biogeosciences*, 125(8): e2019JG005529.
- Lu C, Tian H. 2017. Global nitrogen and phosphorus fertilizer use for agriculture production in the past half century: shifted hot spots and nutrient imbalance. *Earth System Science Data*, 9(1): 181-192.
- Lu C, Yu Z, Hennessy DA, Feng H, Tian H, Hui D. 2022a. Emerging weed resistance increases tillage intensity and greenhouse gas emissions in the US corn–soybean cropping system. *Nature Food*, 3(4): 266-274.
- Lu C, Yu Z, Zhang J, Cao P, Tian H, Nevison C. 2022b. Century-long changes and drivers of soil nitrous oxide (N₂O) emissions across the contiguous United States. *Global Change Biology*, 28(7): 2505-2524.
- Lutz W, Cuaresma JC, Sanderson W. 2008. The Demography of Educational Attainment and Economic Growth. *Science*, 319(5866): 1047-1048.
- Lychuk TE, Hill RL, Izaurralde RC, Momen B, Thomson AM. 2017. Evaluation of climate change impacts and effectiveness of adaptation options on crop yield in the Southeastern United States. *Field Crops Research*, 214: 228-238.
- Lynch DV. 1990. Chilling injury in plants: the relevance of membrane lipids. *Environmental Injury to Plants*
- Macholdt J, Piepho H-P, Honermeier B. 2019. Does fertilization impact production risk and yield stability

- across an entire crop rotation? Insights from a long-term experiment. *Field Crops Research*, 238: 82-92.
- Mafakheri A, Siosemardeh A, Bahramnejad B, Struik PC, Sohrabi Y. 2010. Effect of Drought Stress on Yield, Proline and Chlorophyll Contents in Three Chickpea Cultivars. *Australian Journal of Crop Science*, 4(8): 580-585.
- Mahlein A-K, Oerke E-C, Steiner U, Dehne H-W. 2012. Recent advances in sensing plant diseases for precision crop protection. *European Journal of Plant Pathology*, 133(1): 197-209.
- Mahmood R, Zhang L, Li G, Ranjon Roy N, Rawnaq N, Yan M, Dong Y, Chen B. 2023. Geospatial assessment of intrinsic resilience to the climate change for the central coast of Bangladesh. *Climate Risk Management*, 40: 100521.
- Malikov E, Miao R, Zhang J. 2020. Distributional and temporal heterogeneity in the climate change effects on U.S. agriculture. *Journal of Environmental Economics and Management*, 104: 102386.
- Marotzke J, Semmann D, Milinski M. 2020. The economic interaction between climate change mitigation, climate migration and poverty. *Nature Climate Change*, 10(6): 518-525.
- Mase AS, Gramig BM, Prokopy LS. 2017. Climate change beliefs, risk perceptions, and adaptation behavior among Midwestern U.S. crop farmers. *Climate Risk Management*, 15: 8-17.
- Masutomi Y, Ono K, Mano M, Maruyama A, Miyata A. 2016. A land surface model combined with a crop growth model for paddy rice (MATCRO-Rice v. 1) – Part 1: Model description. *Geoscientific Model Development*, 9(11): 4133-4154.
- Mateo-Sanchis A, Piles M, Muñoz-Marí J, Adsuares JE, Pérez-Suay A, Camps-Valls G. 2019. Synergistic integration of optical and microwave satellite data for crop yield estimation. *Remote Sensing of Environment*, 234: 111460.
- Mbow C, Rosenzweig C, Barioni L, Benton T, Herrero M, Krishnapillai M, Liwenga E, Pradhan P, Rivera - Ferre M, Sapkota T. 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. Ginevra, IPCC, 650.
- McCurry J. 2012. No end in sight for North Korea's malnutrition crisis. *The Lancet*, 379(9816): 602.
- McDermid SS, Mearns LO, Ruane AC. 2017. Representing agriculture in Earth System Models: Approaches and priorities for development. *Journal of Advances in Modeling Earth Systems*, 9(5): 2230-2265.
- McKersie BD, Bowley SR. 1997. Plant Cold Hardiness: Molecular Biology, Biochemistry, and Physiology. Springer US
- McManamay RA, Kc B, Allen-Dumas MR, Kao S-C, Brelsford CM, Ruddell BL, Sanyal J, Stewart RN, Bhaduri BL. 2021. Reanalysis of Water Withdrawal for Irrigation, Electric Power, and Public Supply Sectors in the Conterminous United States, 1950–2016. *Water Resources Research*, 57(2): e2020WR027751.
- Mehring AL, Adams JR, Jacob KD. 1957. Statistics on fertilizers and liming materials in the United States. Soil and Water Conservation Research Branch, Agricultural Research Service
- Meng Q, Chen X, Lobell DB, Cui Z, Zhang Y, Yang H, Zhang F. 2016. Growing sensitivity of maize to water scarcity under climate change. *Scientific Reports*, 6(1): 19605.
- Meroni M, Rossini M, Guanter L, Alonso L, Rascher U, Colombo R, Moreno J. 2009. Remote sensing of solar-induced chlorophyll fluorescence: Review of methods and applications. *Remote Sensing of*

- Environment*, 113(10): 2037-2051.
- Messina C, Hammer G, Dong Z, Podlich D, Cooper M. 2009. Chapter 10 - Modelling Crop Improvement in a G×E×M Framework via Gene–Trait–Phenotype Relationships. Academic Press
- Miao R. 2020. Climate, insurance and innovation: the case of drought and innovations in drought-tolerant traits in US agriculture. *European Review of Agricultural Economics*, 47(5): 1826-1860.
- Middleton N, Thomas D. World atlas of desertification. Edward Arnold : UNEP
- Minoshima H, Jackson LE, Cavagnaro TR, Sánchez-Moreno S, Ferris H, Temple SR, Goyal S, Mitchell JP. 2007. Soil Food Webs and Carbon Dynamics in Response to Conservation Tillage in California. *Soil Science Society of America Journal*, 71(3): 952-963.
- Mitchell KE, Lohmann D, Houser PR, Wood EF, Schaake JC, Robock A, Cosgrove BA, Sheffield J, Duan Q, Luo L, Higgins RW, Pinker RT, Tarpley JD, Lettenmaier DP, Marshall CH, Entin JK, Pan M, Shi W, Koren V, Meng J, Ramsay BH, Bailey AA. 2004. The multi-institution North American Land Data Assimilation System (NLDAS): Utilizing multiple GCIP products and partners in a continental distributed hydrological modeling system. *Journal of Geophysical Research: Atmospheres*, 109(D7): D07S90.
- Mitchell TD, Jones PD. 2005. An improved method of constructing a database of monthly climate observations and associated high-resolution grids. *International Journal of Climatology*, 25(6): 693-712.
- Mkhabela MS, Madani A, Gordon R, Burton D, Cudmore D, Elmi A, Hart W. 2008. Gaseous and leaching nitrogen losses from no-tillage and conventional tillage systems following surface application of cattle manure. *Soil and Tillage Research*, 98(2): 187-199.
- Mondal P, Jain M, DeFries RS, Galford GL, Small C. 2015. Sensitivity of crop cover to climate variability: Insights from two Indian agro-ecoregions. *Journal of Environmental Management*, 148: 21-30.
- Monteith J. 1972a. Solar radiation and productivity in tropical ecosystems. *Journal of applied ecology*, 9(3): 747-766.
- Monteith JL. 1972b. Solar radiation and productivity in tropical ecosystems. *Journal of applied ecology*, 9(3): 747-766.
- Moser G, Schuldt B, Hertel D, Horna V, Coners H, Barus H, Leuschner C. 2014. Replicated throughfall exclusion experiment in an Indonesian perhumid rainforest: Wood production, litter fall and fine root growth under simulated drought. *Global Change Biology*, 20(5): 1481-1497.
- Mueller ND, Gerber JS, Johnston M, Ray DK, Ramankutty N, Foley JA. 2012. Closing yield gaps through nutrient and water management. *Nature*, 490(7419): 254-257.
- Myneni RY, Knyazikhin TP. MOD15A2H MODIS/Terra Leaf Area Index/FPAR 8-Day L4 Global 500m SIN Grid V006. DAAC, N.E.L.P.
- Nakhoda S, Franssen T, Kuramochi T, Caravani A, Prizzon A, Shimizu N, Tilley H, Halimanjaya A, Welham B. Mobilising international climate finance: Lessons from the fast-start finance period. Open Climate Network
- Nass U. 2010. Field crops: Usual planting and harvesting dates. USDA National Agricultural Statistics Service, Agricultural Handbook
- Neil Adger W, Arnell NW, Tompkins EL. 2005. Successful adaptation to climate change across scales. *Global Environmental Change*, 15(2): 77-86.
- Nonami H. 1998. Plant water relations and control of cell elongation at low water potentials. *Journal of*

- Plant Research*, 111(3): 373-382.
- O'Connell CS, Ruan L, Silver WL. 2018. Drought drives rapid shifts in tropical rainforest soil biogeochemistry and greenhouse gas emissions. *Nature Communications*, 9(1): 1348.
- O'Neill BC, Dalton M, Fuchs R, Jiang L, Pachauri S, Zigova K. 2010. Global demographic trends and future carbon emissions. *PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA*, 107(41): 17521-17526.
- O'Connell D, Walker B, Abel N, Grigg N. 2015. The resilience, adaptation and transformation assessment framework: from theory to application. Canberra, CSIRO
- O'Neill BC, Jiang L, Kc S, Fuchs R, Pachauri S, Laidlaw EK, Zhang T, Zhou W, Ren X. 2020. The effect of education on determinants of climate change risks. *Nature Sustainability*, 3(7): 520-528.
- Okçu G, Kaya MD, Atak M. 2005. Effects of salt and drought stresses on germination and seedling growth of pea (*Pisum sativum* L.). *Turkish journal of agriculture and forestry*, 29(4): 237-242.
- Olesen JE, Trnka M, Kersebaum KC, Skjelvåg AO, Seguin B, Peltonen-Sainio P, Rossi F, Kozyra J, Micale F. 2011. Impacts and adaptation of European crop production systems to climate change. *European Journal of Agronomy*, 34(2): 96-112.
- Oluwatimilehin IA, Ayanlade A. 2023. Climate change impacts on staple crops: Assessment of smallholder farmers' adaptation methods and barriers. *Climate Risk Management*, 41: 100542.
- Pagani V, Guarneri T, Fumagalli D, Movedi E, Testi L, Klein T, Calanca P, Villalobos F, Lopez-Bernal A, Niemeyer S, Bellocchi G, Confalonieri R. 2017. Improving cereal yield forecasts in Europe – The impact of weather extremes. *European Journal of Agronomy*, 89: 97-106.
- Palmer TN, Räisänen J. 2002. Quantifying the risk of extreme seasonal precipitation events in a changing climate. *Nature*, 415(6871): 512-514.
- Parikh P, Chaturvedi S, George G. 2012. Empowering change: The effects of energy provision on individual aspirations in slum communities. *Energy Policy*, 50: 477-485.
- Parker GG. 2020. Tamm review: Leaf Area Index (LAI) is both a determinant and a consequence of important processes in vegetation canopies. *Forest Ecology and Management*, 477: 118496.
- Pei Y, Dong J, Zhang Y, Yuan W, Doughty R, Yang J, Zhou D, Zhang L, Xiao X. 2022. Evolution of light use efficiency models: Improvement, uncertainties, and implications. *Agricultural and Forest Meteorology*, 317: 108905.
- Peltonen-Sainio P, Jauhiainen L, Laurila IP. 2009. Cereal yield trends in northern European conditions: Changes in yield potential and its realisation. *Field Crops Research*, 110(1): 85-90.
- Peltonen-Sainio P, Palosuo T, Ruosteenoja K, Jauhiainen L, Ojanen H. 2018. Warming autumns at high latitudes of Europe: an opportunity to lose or gain in cereal production? *Regional Environmental Change*, 18(5): 1453-1465.
- Peng B, Guan K, Zhou W, Jiang C, Frankenberg C, Sun Y, He L, Köhler P. 2020. Assessing the benefit of satellite-based Solar-Induced Chlorophyll Fluorescence in crop yield prediction. *International Journal of Applied Earth Observation and Geoinformation*, 90: 102126.
- Peng S-S, Piao S, Zeng Z, Ciais P, Zhou L, Li LZ, Myneni RB, Yin Y, Zeng H. 2014. Afforestation in China cools local land surface temperature. *PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA*, 111(8): 2915-2919.
- Peng S, Tang Q, Zou Y. 2009. Current Status and Challenges of Rice Production in China. *Plant Production Science*, 12(1): 3-8.

- Pertot I, Caffi T, Rossi V, Mugnai L, Hoffmann C, Grando MS, Gary C, Lafond D, Duso C, Thiery D, Mazzoni V, Anfora G. 2017. A critical review of plant protection tools for reducing pesticide use on grapevine and new perspectives for the implementation of IPM in viticulture. *Crop Protection*, 97: 70-84.
- Pervez MS, Brown JF. 2010. Mapping Irrigated Lands at 250-m Scale by Merging MODIS Data and National Agricultural Statistics. *Remote Sensing*, 2(10): 2388-2412.
- Petersen LK. 2019. Impact of Climate Change on Twenty-First Century Crop Yields in the U.S. *Climate*, 7(3): 40.
- Phillips OL, van der Heijden G, Lewis SL, López-González G, Aragão LEOC, Lloyd J, Malhi Y, Monteagudo A, Almeida S, Dávila EA, Amaral I, Andelman S, Andrade A, Arroyo L, Aymard G, Baker TR, Blanc L, Bonal D, de Oliveira ÁCA, Chao K-J, Cardozo ND, da Costa L, Feldpausch TR, Fisher JB, Fyllas NM, Freitas MA, Galbraith D, Gloor E, Higuchi N, Honorio E, Jiménez E, Keeling H, Killeen TJ, Lovett JC, Meir P, Mendoza C, Morel A, Vargas PN, Patiño S, Peh KSH, Cruz AP, Prieto A, Quesada CA, Ramírez F, Ramírez H, Rudas A, Salamão R, Schwarz M, Silva J, Silveira M, Ferry Slik JW, Sonké B, Thomas AS, Stropp J, Taplin JRD, Vásquez R, Vilanova E. 2010. Drought–mortality relationships for tropical forests. *New Phytologist*, 187(3): 631-646.
- Plaza-Bonilla D, Álvaro-Fuentes J, Arrúe JL, Cantero-Martínez C. 2014. Tillage and nitrogen fertilization effects on nitrous oxide yield-scaled emissions in a rainfed Mediterranean area. *Agriculture Ecosystems & Environment*, 189: 43-52.
- Prosser JI, Hink L, Gubry-Rangin C, Nicol GW. 2020. Nitrous oxide production by ammonia oxidizers: Physiological diversity, niche differentiation and potential mitigation strategies. *Global Change Biology*, 26(1): 103-118.
- Qin Y, Xiao X, Dong J, Zhou Y, Zhu Z, Zhang G, Du G, Jin C, Kou W, Wang J. 2015. Mapping paddy rice planting area in cold temperate climate region through analysis of time series Landsat 8 (OLI), Landsat 7 (ETM+) and MODIS imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105: 220-233.
- Ren W, Tian H, Tao B, Huang Y, Pan S. 2012. China's crop productivity and soil carbon storage as influenced by multifactor global change. *Global Change Biology*, 18(9): 2945-2957.
- Renard D, Tilman D. 2019. National food production stabilized by crop diversity. *Nature*, 571(7764): 257-260.
- Rezaei EE, Ghazaryan G, Moradi R, Dubovyk O, Siebert S. 2021. Crop harvested area, not yield, drives variability in crop production in Iran. *Environmental Research Letters*, 16(6): 064058.
- Riahi K, van Vuuren DP, Kriegler E, Edmonds J, O'Neill BC, Fujimori S, Bauer N, Calvin K, Dellink R, Fricko O, Lutz W, Popp A, Cuaresma JC, Kc S, Leimbach M, Jiang L, Kram T, Rao S, Emmerling J, Ebi K, Hasegawa T, Havlik P, Humpenöder F, Da Silva LA, Smith S, Stehfest E, Bosetti V, Eom J, Gernaat D, Masui T, Rogelj J, Strefler J, Drouet L, Krey V, Luderer G, Harmsen M, Takahashi K, Baumstark L, Doelman JC, Kainuma M, Klimont Z, Marangoni G, Lotze-Campen H, Obersteiner M, Tabeau A, Tavoni M. 2017. The Shared Socioeconomic Pathways and their energy, land use, and greenhouse gas emissions implications: An overview. *Global Environmental Change*, 42: 153-168.
- Richardson CW, Wright DA, United States. Agricultural Research S. 1984. WGEN : a model for generating daily weather variables. USDA Agricultural Research Service
- Rosenzweig C, Elliott J, Deryng D, Ruane AC, Müller C, Arneth A, Boote KJ, Folberth C, Glotter M,

- Khabarov N, Neumann K, Piontek F, Pugh TAM, Schmid E, Stehfest E, Yang H, Jones JW. 2014. 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.
- Rowhani P, Lobell DB, Linderman M, Ramankutty N. 2011. Climate variability and crop production in Tanzania. *Agricultural and Forest Meteorology*, 151(4): 449-460.
- Rudin C. 2019. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5): 206-215.
- Running S, Mu Q, Zhao M. MOD16A2 MODIS/Terra Net Evapotranspiration 8-Day L4 Global 500m SIN Grid V006. DAAC, N.E.L.P.
- Scheelbeek PFD, Moss C, Kastner T, Alae-Carew C, Jarmul S, Green R, Taylor A, Haines A, Dangour AD. 2020. United Kingdom's fruit and vegetable supply is increasingly dependent on imports from climate-vulnerable producing countries. *Nature Food*, 1(11): 705-712.
- Schlenker W, Roberts MJ. 2009. Nonlinear temperature effects indicate severe damages to U.S. crop yields under climate change. *PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA*, 106(37): 15594-15598.
- Schneider UA, Havlik P, Schmid E, Valin H, Mosnier A, Obersteiner M, Böttcher H, Skalský R, Balkovič J, Sauer T, Fritz S. 2011. Impacts of population growth, economic development, and technical change on global food production and consumption. *Agricultural Systems*, 104(2): 204-215.
- Schut AGT, Traore PCS, Blaes X, de By RA. 2018. Assessing yield and fertilizer response in heterogeneous smallholder fields with UAVs and satellites. *Field Crops Research*, 221: 98-107.
- Semenov MA, Shewry PR. 2011. Modelling predicts that heat stress, not drought, will increase vulnerability of wheat in Europe. *Scientific Reports*, 1(1): 66.
- Shaw R, Luo Y, T.S. C, Abdul Halim S, Chaturvedi S, Hashizume M, Insarov GE, Ishikawa Y, Jafari M, Kitoh A, Pulhin J, Singh C, Vasant K, Zhang Z. 2022. Climate Change 2022 – Impacts, Adaptation and Vulnerability: Working Group II Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press
- Shew AM, Tack JB, Nalley LL, Chaminuka P. 2020. Yield reduction under climate warming varies among wheat cultivars in South Africa. *Nature Communications*, 11(1): 4408.
- Shi H, Tian H, Lange S, Yang J, Pan S, Fu B, Reyer CPO. 2021. Terrestrial biodiversity threatened by increasing global aridity velocity under high-level warming. *PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA*, 118(36): e2015552118.
- Shi L, Feng P, Wang B, Li Liu D, Cleverly J, Fang Q, Yu Q. 2020a. Projecting potential evapotranspiration change and quantifying its uncertainty under future climate scenarios: A case study in southeastern Australia. *Journal of Hydrology*, 584: 124756.
- Shi W, Tao F, Zhang Z. 2013. A review on statistical models for identifying climate contributions to crop yields. *Journal of Geographical Sciences*, 23(3): 567-576.
- Shi Y, Jin N, Ma X, Wu B, He Q, Yue C, Yu Q. 2020b. Attribution of climate and human activities to vegetation change in China using machine learning techniques. *Agricultural and Forest Meteorology*, 294: 108146.
- Shi Y, Zhang Y, Wu B, Wang B, Li L, Shi H, Jin N, Liu DL, Miao R, Lu X, Geng Q, Lu C, He L, Fang N, Yue C, He J, Feng H, Pan S, Tian H, Yu Q. 2022. Building social resilience in North Korea can mitigate

- the impacts of climate change on food security. *Nature Food*, 3(7): 499-511.
- Shimono H. 2011. Earlier rice phenology as a result of climate change can increase the risk of cold damage during reproductive growth in northern Japan. *Agriculture, Ecosystems & Environment*, 144(1): 201-207.
- Siddique KHM, Loss SP, Regan KL, Jettner RL. 1999. Adaptation and seed yield of cool season grain legumes in Mediterranean environments of south-western Australia. *Australian Journal of Agricultural Research*, 50(3): 375-388.
- Sidhu BS, Mehrabi Z, Ramankutty N, Kandlikar M. 2023. How can machine learning help in understanding the impact of climate change on crop yields? *Environmental Research Letters*, 18(2): 024008.
- Six J, Elliott ET, Paustian K. 2000. Soil macroaggregate turnover and microaggregate formation: a mechanism for C sequestration under no-tillage agriculture. *Soil Biology and Biochemistry*, 32(14): 2099-2103.
- Smit B, Wandel J. 2006. Adaptation, adaptive capacity and vulnerability. *Global Environmental Change*, 16(3): 282-292.
- Spehar CR. 1995. Impact of strategic genes in soybean on agricultural development in the Brazilian tropical savannahs. *Field Crops Research*, 41(3): 141-146.
- Steponkus P. 1993. A contrast of the cryostability of the plasma membrane of winter rye and spring oat-two species that widely differ in their freezing tolerance and plasma membrane lipid composition. *Advances in low temperature biology*, 2: 211-312.
- Steponkus PL. 1984. Role of the plasma membrane in freezing injury and cold acclimation. *Annual Review of Plant Physiology*, 35(1): 543-584.
- Stratonovitch P, Semenov MA. 2015. Heat tolerance around flowering in wheat identified as a key trait for increased yield potential in Europe under climate change. *Journal of Experimental Botany*, 66(12): 3599-3609.
- Sui Y, Lang X, Jiang D. 2018. Projected signals in climate extremes over China associated with a 2 °C global warming under two RCP scenarios. *International Journal of Climatology*, 38(S1): e678-e697.
- Surminski S, Bouwer LM, Linnerooth-Bayer J. 2016. How insurance can support climate resilience. *Nature Climate Change*, 6(4): 333-334.
- Suzuki K, Nagasuga K, Okada M. 2008. The Chilling Injury Induced by High Root Temperature in the Leaves of Rice Seedlings. *Plant and Cell Physiology*, 49(3): 433-442.
- Tack J, Barkley A, Hendricks N. 2017. Irrigation offsets wheat yield reductions from warming temperatures. *Environmental Research Letters*, 12(11): 114027.
- Tack J, Barkley A, Nalley LL. 2015. Effect of warming temperatures on US wheat yields. *PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA*, 112(22): 6931-6936.
- Taiz L, Zeiger E, Møller IM, Murphy A. 2015. Plant physiology and development. Sinauer Associates Incorporated
- Tao F, Yokozawa M, Hayashi Y, Lin E. 2003. Future climate change, the agricultural water cycle, and agricultural production in China. *Agriculture, Ecosystems & Environment*, 95(1): 203-215.
- Tao F, Zhang L, Zhang Z, Chen Y. 2022. Climate warming outweighed agricultural managements in affecting wheat phenology across China during 1981–2018. *Agricultural and Forest Meteorology*, 316: 108865.

- Tao F, Zhang Z, Shi W, Liu Y, Xiao D, Zhang S, Zhu Z, Wang M, Liu F. 2013. Single rice growth period was prolonged by cultivars shifts, but yield was damaged by climate change during 1981–2009 in China, and late rice was just opposite. *Global Change Biology*, 19(10): 3200-3209.
- Tebaldi C, Lobell D. 2018. Estimated impacts of emission reductions on wheat and maize crops. *Climatic Change*, 146(3): 533-545.
- Tellez-Rio A, García-Marco S, Navas M, López-Solanilla E, Rees RM, Tenorio JL, Vallejo A. 2015. Nitrous oxide and methane emissions from a vetch cropping season are changed by long-term tillage practices in a Mediterranean agroecosystem. *Biology and Fertility of Soils*, 51(1): 77-88.
- Tesfaye K, Takele R, Sapkota TB, Khatri-Chhetri A, Solomon D, Stirling C, Albanito F. 2021. Model comparison and quantification of nitrous oxide emission and mitigation potential from maize and wheat fields at a global scale. *Science of The Total Environment*, 782: 146696.
- Thamaga-Chitja J, Tamako N. 2017. Does social capital play a role in climate change adaptation among smallholder farmers for improving food security and livelihoods? *Journal of Consumer Sciences*, 2: 16-27.
- Thorp K, Drajat D. 2021. Deep machine learning with Sentinel satellite data to map paddy rice production stages across West Java, Indonesia. *Remote Sensing of Environment*, 265: 112679.
- Tian H, Chen G, Liu M, Zhang C, Sun G, Lu C, Xu X, Ren W, Pan S, Chappelka A. 2010a. Model estimates of net primary productivity, evapotranspiration, and water use efficiency in the terrestrial ecosystems of the southern United States during 1895–2007. *Forest Ecology and Management*, 259(7): 1311-1327.
- Tian H, Lu C, Melillo J, Ren W, Huang Y, Xu X, Liu M, Zhang C, Chen G, Pan S, Liu J, Reilly J. 2012. Food benefit and climate warming potential of nitrogen fertilizer uses in China. *Environmental Research Letters*, 7(4): 044020.
- Tian H, Xu R, Pan S, Yao Y, Bian Z, Cai W-J, Hopkinson CS, Justic D, Lohrenz S, Lu C, Ren W, Yang J. 2020. Long-Term Trajectory of Nitrogen Loading and Delivery From Mississippi River Basin to the Gulf of Mexico. *Global Biogeochemical Cycles*, 34(5): e2019GB006475.
- Tian H, Xu X, Liu M, Ren W, Zhang C, Chen G, Lu C. 2010b. Spatial and temporal patterns of CH₄ and N₂O fluxes in terrestrial ecosystems of North America during 1979–2008: Application of a global biogeochemistry model. *Biogeosciences*, 7(9): 2673-2694.
- Tian H, Xu X, Liu M, Ren W, Zhang C, Chen G, Lu C. 2010c. Spatial and temporal patterns of CH₄ and N₂O fluxes in terrestrial ecosystems of North America during 1979–2008: application of a global biogeochemistry model. *Biogeosciences*, 7(9): 2673-2694.
- Tigchelaar M, Battisti DS, Naylor RL, Ray DK. 2018. Future warming increases probability of globally synchronized maize production shocks. *PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA*, 115(26): 6644-6649.
- Tilman D, Balzer C, Hill J, Befort BL. 2011. Global food demand and the sustainable intensification of agriculture. *PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA*, 108(50): 20260-20264.
- Toreti A, Belward A, Perez-Dominguez I, Naumann G, Luterbacher J, Cronie O, Seguini L, Manfron G, Lopez-Lozano R, Baruth B, van den Berg M, Dentener F, Ceglar A, Chatzopoulos T, Zampieri M. 2019. The Exceptional 2018 European Water Seesaw Calls for Action on Adaptation. *Earth's Future*, 7(6): 652-663.
- Trnka M, Olesen JE, Kersebaum KC, Rötter RP, Brázdil R, Eitzinger J, Jansen S, Skjelvåg AO, Peltonen-

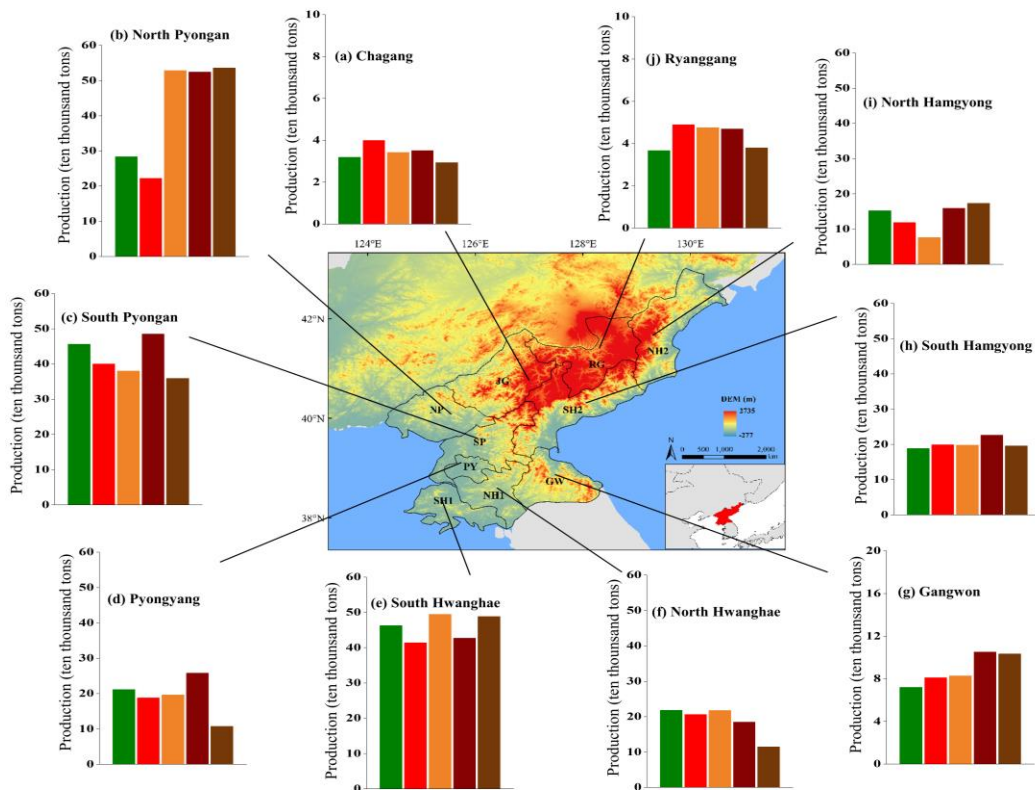
- Sainio P, Hlavinka P, Balek J, Eckersten H, Gobin A, Vuc̆etić V, Dalla Marta A, Orlandini S, Alexandrov V, Semerádová D, ětěpánek P, Svobodová E, Rajdl K. 2016. Changing regional weather-crop yield relationships across Europe between 1901 and 2012. *Climate Research*, 70(2-3): 195-214.
- Uemura M, Steponkus PL. 1997. Effect of Cold Acclimation on Membrane Lipid Composition and Freeze-Induced Membrane Destablization. Springer US
- USDA - ERS. Fertilizer use and price. Service, U.S.D.o.A.-E.R.
- van Kessel C, Venterea R, Six J, Adviento-Borbe MA, Linquist B, van Groenigen KJ. 2013. Climate, duration, and N placement determine N₂O emissions in reduced tillage systems: A meta-analysis. *Global Change Biology*, 19(1): 33-44.
- Venterea RT, Stanenas AJ. 2008. Profile Analysis and Modeling of Reduced Tillage Effects on Soil Nitrous Oxide Flux. *Journal of Environmental Quality*, 37(4): 1360-1367.
- Verschuur J, Li S, Wolski P, Otto FEL. 2021. Climate change as a driver of food insecurity in the 2007 Lesotho-South Africa drought. *Scientific Reports*, 11(1): 3852.
- Wake B. 2012. Hunger and climate. *Nature Climate Change*, 2(8): 566-566.
- Wang B, Feng P, Liu DL, O'Leary GJ, Macadam I, Waters C, Asseng S, Cowie A, Jiang T, Xiao D, Ruan H, He J, Yu Q. 2020. Sources of uncertainty for wheat yield projections under future climate are site-specific. *Nature Food*, 1(11): 720-728.
- Wang G, Wang D, Trenberth KE, Erfanian A, Yu M, Bosilovich Michael G, Parr DT. 2017. The peak structure and future changes of the relationships between extreme precipitation and temperature. *Nature Climate Change*, 7(4): 268-274.
- Wang W, Yuan S, Wu C, Yang S, Zhang W, Xu Y, Gu J, Zhang H, Wang Z, Yang J. 2021a. Field experiments and model simulation based evaluation of rice yield response to projected climate change in Southeastern China. *Science of The Total Environment*, 761: 143206.
- Wang X, Jing Z-H, He C, Liu Q-Y, Jia H, Qi J-Y, Zhang H-L. 2021b. Breeding rice varieties provides an effective approach to improve productivity and yield sensitivity to climate resources. *European Journal of Agronomy*, 124: 126239.
- Wang X, Müller C, Elliot J, Mueller ND, Ciais P, Jägermeyr J, Gerber J, Dumas P, Wang C, Yang H, Li L, Deryng D, Folberth C, Liu W, Makowski D, Olin S, Pugh TAM, Reddy A, Schmid E, Jeong S, Zhou F, Piao S. 2021c. Global irrigation contribution to wheat and maize yield. *Nature Communications*, 12(1): 1235.
- Wardlaw IF, Willenbrink J. 2000. Mobilization of fructan reserves and changes in enzyme activities in wheat stems correlate with water stress during kernel filling. *New Phytologist*, 148(3): 413-422.
- Waring R, Landsberg J, Williams M. 1998. Net primary production of forests: a constant fraction of gross primary production? *Tree physiology*, 18(2): 129-134.
- Weaich K, Bristow KL, Cass A. 1996. Modeling Preemergent Maize Shoot Growth: II. High Temperature Stress Conditions. *Agronomy Journal*, 88(3): 398-403.
- Wheeler T, Von Braun J. 2013. Climate change impacts on global food security. *Science*, 341(6145): 508-513.
- Whitcraft AK, Becker-Reshef I, Justice CO. 2015. A framework for defining spatially explicit earth observation requirements for a global agricultural monitoring initiative (GEOGLAM). *Remote Sensing*, 7(2): 1461-1481.

- Wolanin A, Mateo-García G, Camps-Valls G, Gómez-Chova L, Meroni M, Duveiller G, Liangzhi Y, Guanter L. 2020. Estimating and understanding crop yields with explainable deep learning in the Indian Wheat Belt. *Environmental Research Letters*, 15(2): 024019.
- Woo DK, Riley WJ, Grant RF, Wu Y. 2022. Site-specific field management adaptation is key to feeding the world in the 21st century. *Agricultural and Forest Meteorology*, 327: 109230.
- Xia Y, Mitchell K, Ek M, Sheffield J, Cosgrove B, Wood E, Luo L, Alonge C, Wei H, Meng J, Livneh B, Lettenmaier D, Koren V, Duan Q, Mo K, Fan Y, Mocko D. 2012. Continental-scale water and energy flux analysis and validation for the North American Land Data Assimilation System project phase 2 (NLDAS-2): 1. Intercomparison and application of model products. *Journal of Geophysical Research: Atmospheres*, 117(D3): D03109.
- Xiao X, Boles S, Frohling S, Li C, Babu JY, Salas W, Moore III B. 2006. Mapping paddy rice agriculture in South and Southeast Asia using multi-temporal MODIS images. *Remote Sensing of Environment*, 100(1): 95-113.
- Xiao X, Boles S, Liu J, Zhuang D, Frohling S, Li C, Salas W, Moore B. 2005. Mapping paddy rice agriculture in southern China using multi-temporal MODIS images. *Remote Sensing of Environment*, 95(4): 480-492.
- Xin Q, Gong P, Yu C, Yu L, Broich M, Suyker AE, Myneni RB. 2013. A Production Efficiency Model-Based Method for Satellite Estimates of Corn and Soybean Yields in the Midwestern US. *Remote Sensing*, 5(11): 5926-5943.
- Xu R, Tian H, Pan S, Prior SA, Feng Y, Batchelor WD, Chen J, Yang J. 2019. Global ammonia emissions from synthetic nitrogen fertilizer applications in agricultural systems: Empirical and process-based estimates and uncertainty. *Global Change Biology*, 25(1): 314-326.
- Xu XF, Tian HQ, Zhang C, Liu ML, Ren W, Chen GS, Lu CQ, Bruhwiler L. 2010. Attribution of spatial and temporal variations in terrestrial methane flux over North America. *Biogeosciences*, 7(11): 3637-3655.
- Yadav RS, Hash CT, Bidinger FR, Devos KM, Howarth CJ. 2004. Genomic regions associated with grain yield and aspects of post-flowering drought tolerance in pearl millet across stress environments and tester background. *Euphytica*, 136(3): 265-277.
- Yang J, Zhou M, Ren Z, Li M, Wang B, Liu DL, Ou C-Q, Yin P, Sun J, Tong S, Wang H, Zhang C, Wang J, Guo Y, Liu Q. 2021. Projecting heat-related excess mortality under climate change scenarios in China. *Nature Communications*, 12(1): 1039.
- Yin X, Olesen JE, Wang M, Öztürk I, Zhang H, Chen F. 2016. Impacts and adaptation of the cropping systems to climate change in the Northeast Farming Region of China. *European Journal of Agronomy*, 78: 60-72.
- You Y, Tian H, Pan S, Shi H, Bian Z, Gurgel A, Huang Y, Kicklighter D, Liang X-Z, Lu C, Melillo J, Miao R, Pan N, Reilly J, Ren W, Xu R, Yang J, Yu Q, Zhang J. 2022. Incorporating dynamic crop growth processes and management practices into a terrestrial biosphere model for simulating crop production in the United States: Toward a unified modeling framework. *Agricultural and Forest Meteorology*, 325: 109144.
- Yu Z, Lu C. 2018. Historical cropland expansion and abandonment in the continental U.S. during 1850 to 2016. *Global Ecology and Biogeography*, 27(3): 322-333.
- Yu Z, Lu C, Cao P, Tian H. 2018. Long-term terrestrial carbon dynamics in the Midwestern United States

- during 1850–2015: Roles of land use and cover change and agricultural management. *Global Change Biology*, 24(6): 2673-2690.
- Yuan W, Chen Y, Xia J, Dong W, Magliulo V, Moors E, Olesen JE, Zhang H. 2016. Estimating crop yield using a satellite-based light use efficiency model. *Ecological Indicators*, 60: 702-709.
- Zendehboudi A, Baseer MA, Saidur R. 2018. Application of support vector machine models for forecasting solar and wind energy resources: A review. *Journal of Cleaner Production*, 199: 272-285.
- Zhang G, Xiao X, Dong J, Kou W, Jin C, Qin Y, Zhou Y, Wang J, Menarguez MA, Biradar C. 2015a. Mapping paddy rice planting areas through time series analysis of MODIS land surface temperature and vegetation index data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 106: 157-171.
- Zhang J, Ren W, An P, Pan Z, Wang L, Dong Z, He D, Yang J, Pan S, Tian H. 2015b. Responses of Crop Water Use Efficiency to Climate Change and Agronomic Measures in the Semiarid Area of Northern China. *PLOS ONE*, 10(9): e0137409.
- Zhang J, Tian H, Yang J, Pan S. 2018. Improving Representation of Crop Growth and Yield in the Dynamic Land Ecosystem Model and Its Application to China. *Journal of Advances in Modeling Earth Systems*, 10(7): 1680-1707.
- Zhang L, Zhang Z, Luo Y, Cao J, Xie R, Li S. 2021. Integrating satellite-derived climatic and vegetation indices to predict smallholder maize yield using deep learning. *Agricultural and Forest Meteorology*, 311: 108666.
- Zhang T, He Y, DePauw R, Jin Z, Garvin D, Yue X, Anderson W, Li T, Dong X, Zhang T, Yang X. 2022a. Climate change may outpace current wheat breeding yield improvements in North America. *Nature Communications*, 13(1): 5591.
- Zhang T, Yang X, Wang H, Li Y, Ye Q. 2014. Climatic and technological ceilings for Chinese rice stagnation based on yield gaps and yield trend pattern analysis. *Global Change Biology*, 20(4): 1289-1298.
- Zhang X, Zhang Q. 2016. Monitoring interannual variation in global crop yield using long-term AVHRR and MODIS observations. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114: 191-205.
- Zhang Y, Piao S, Sun Y, Rogers BM, Li X, Lian X, Liu Z, Chen A, Peñuelas J. 2022b. Future reversal of warming-enhanced vegetation productivity in the Northern Hemisphere. *Nature Climate Change*, 12(6): 581-586.
- Zhao C, Piao S, Wang X, Huang Y, Ciais P, Elliott J, Huang M, Janssens IA, Li T, Lian X, Liu Y, Müller C, Peng S, Wang T, Zeng Z, Peñuelas J. 2016. Plausible rice yield losses under future climate warming. *Nature Plants*, 3(1): 16202.
- Zhao H, Zhang L, Kirkham MB, Welch SM, Nielsen-Gammon JW, Bai G, Luo J, Andresen DA, Rice CW, Wan N, Lollato RP, Zheng D, Gowda PH, Lin X. 2022a. U.S. winter wheat yield loss attributed to compound hot-dry-windy events. *Nature Communications*, 13(1): 7233.
- Zhao J, Bindi M, Eitzinger J, Ferrise R, Gaile Z, Gobin A, Holzkämper A, Kersebaum K-C, Kozyra J, Kriaučiūnienė Z, Loit E, Nejedlik P, Nendel C, Niinemets Ü, Palosuo T, Peltonen-Sainio P, Potopová V, Ruiz-Ramos M, Reidsma P, Rijk B, Trnka M, van Ittersum MK, Olesen JE. 2022b. Priority for climate adaptation measures in European crop production systems. *European Journal of Agronomy*, 138: 126516.
- Zhao M, Tian Y, Zhang M, Yao Y, Ao Y, Yin B, Zhu Z. 2015. Nonlinear response of nitric oxide emissions to a nitrogen application gradient: A case study during the wheat season in a Chinese rice-wheat rotation system. *Atmospheric Environment*, 102: 200-208.

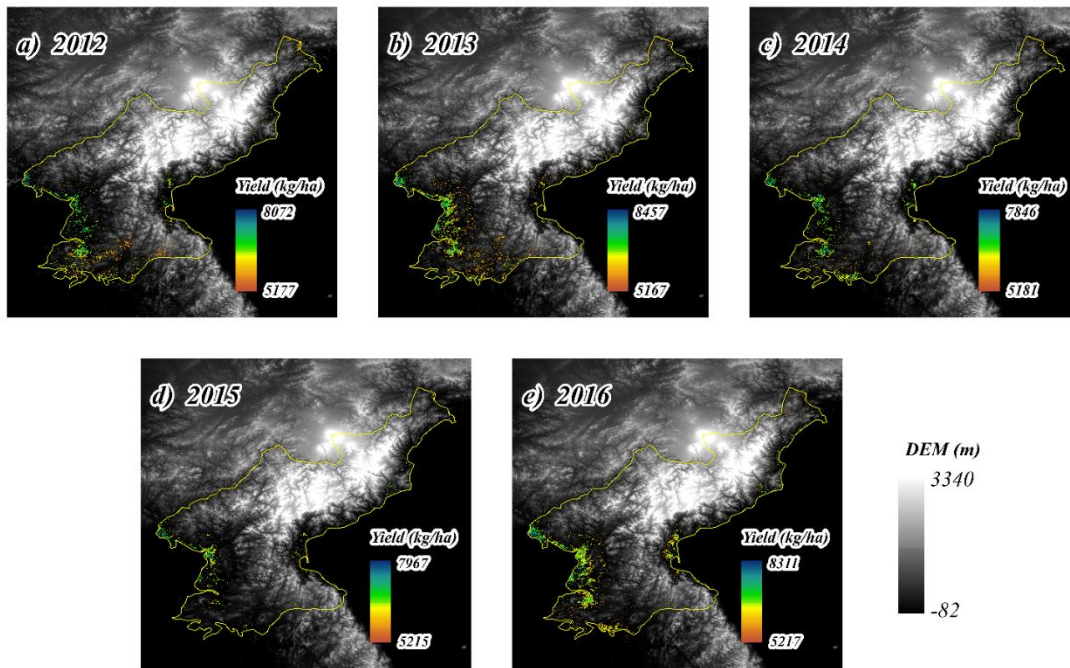
- Zhou X, Zheng HB, Xu XQ, He JY, Ge XK, Yao X, Cheng T, Zhu Y, Cao WX, Tian YC. 2017. Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130: 246-255.
- Zhou Y, Xiao X, Qin Y, Dong J, Zhang G, Kou W, Jin C, Wang J, Li X. 2016. Mapping paddy rice planting area in rice-wetland coexistent areas through analysis of Landsat 8 OLI and MODIS images. *International Journal of Applied Earth Observation and Geoinformation*, 46: 1-12.
- Zhu P, Burney J. 2021. Temperature-driven harvest decisions amplify US winter wheat loss under climate warming. *Global Change Biology*, 27(3): 550-562.
- Zhu P, Burney J, Chang J, Jin Z, Mueller ND, Xin Q, Xu J, Yu L, Makowski D, Ciais P. 2022. Warming reduces global agricultural production by decreasing cropping frequency and yields. *Nature Climate Change*, 12(11): 1016-1023.

附录



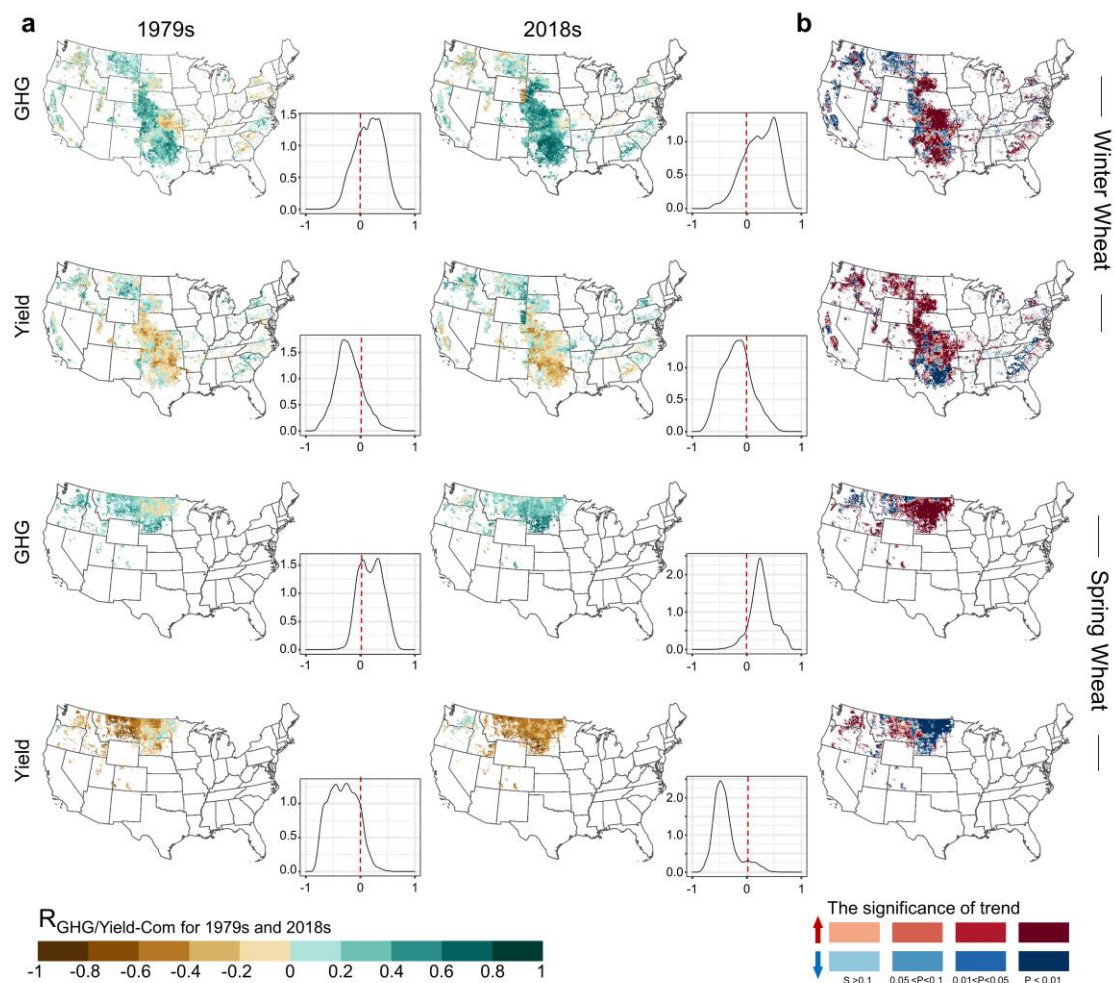
附图 1 基于抽穗期数据预测朝鲜不同省份水稻总产

Fig. S1 Projected rice production in different provinces of NK using the data of the seedling-heading period. The green, red, orange, dark red, and brown bars represent the 2012 to 2016 years, respectively.



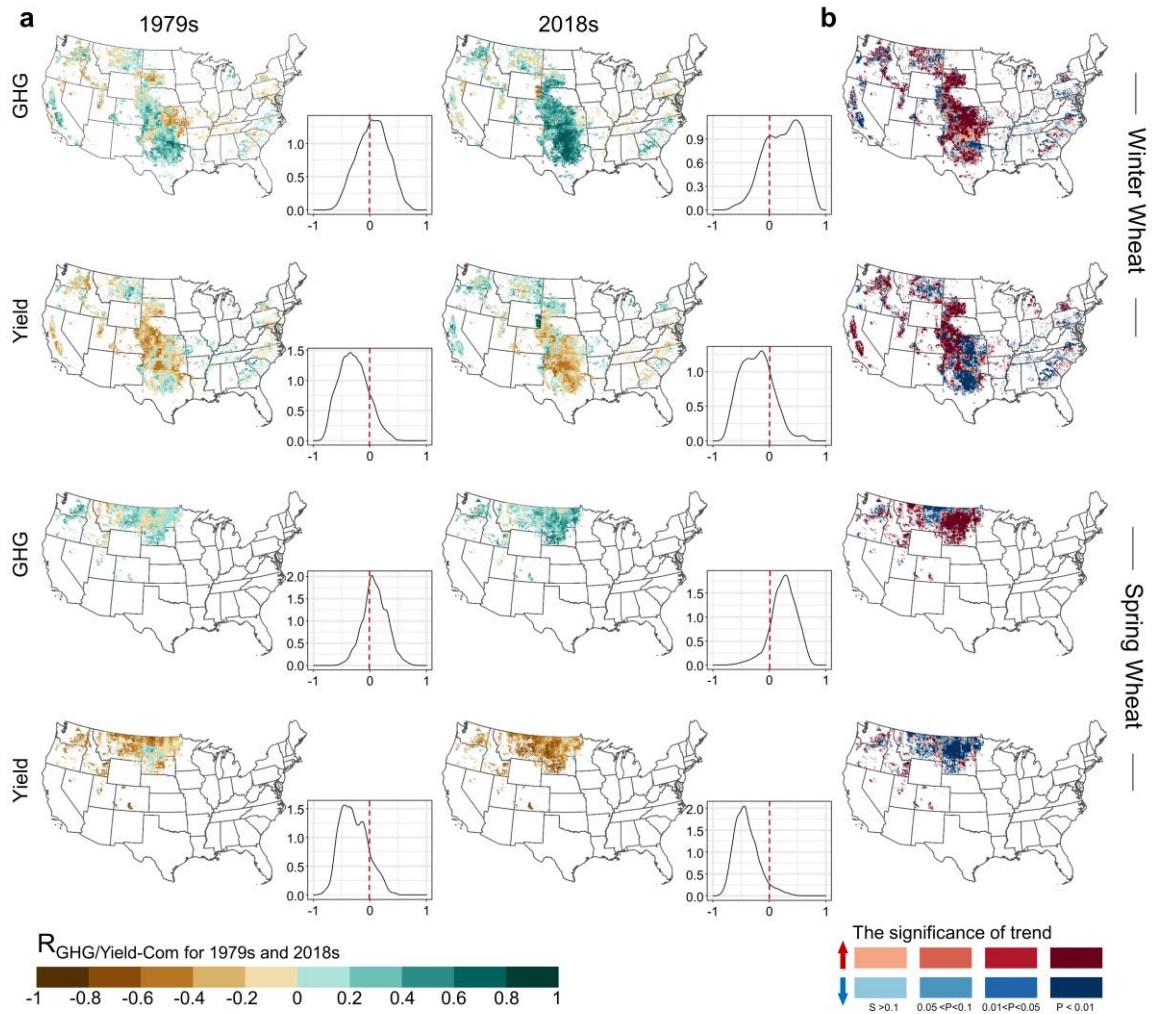
附图 2 基于抽穗期的环境变量预测 2012-2016 年朝鲜水稻单产

Fig. S2 Predicted rice yield at a resolution of 500 m in NK from 2012 to 2016 when predictor variables during the seedling-heading period were used. The spatial distribution was masked using rice maps of the same years.



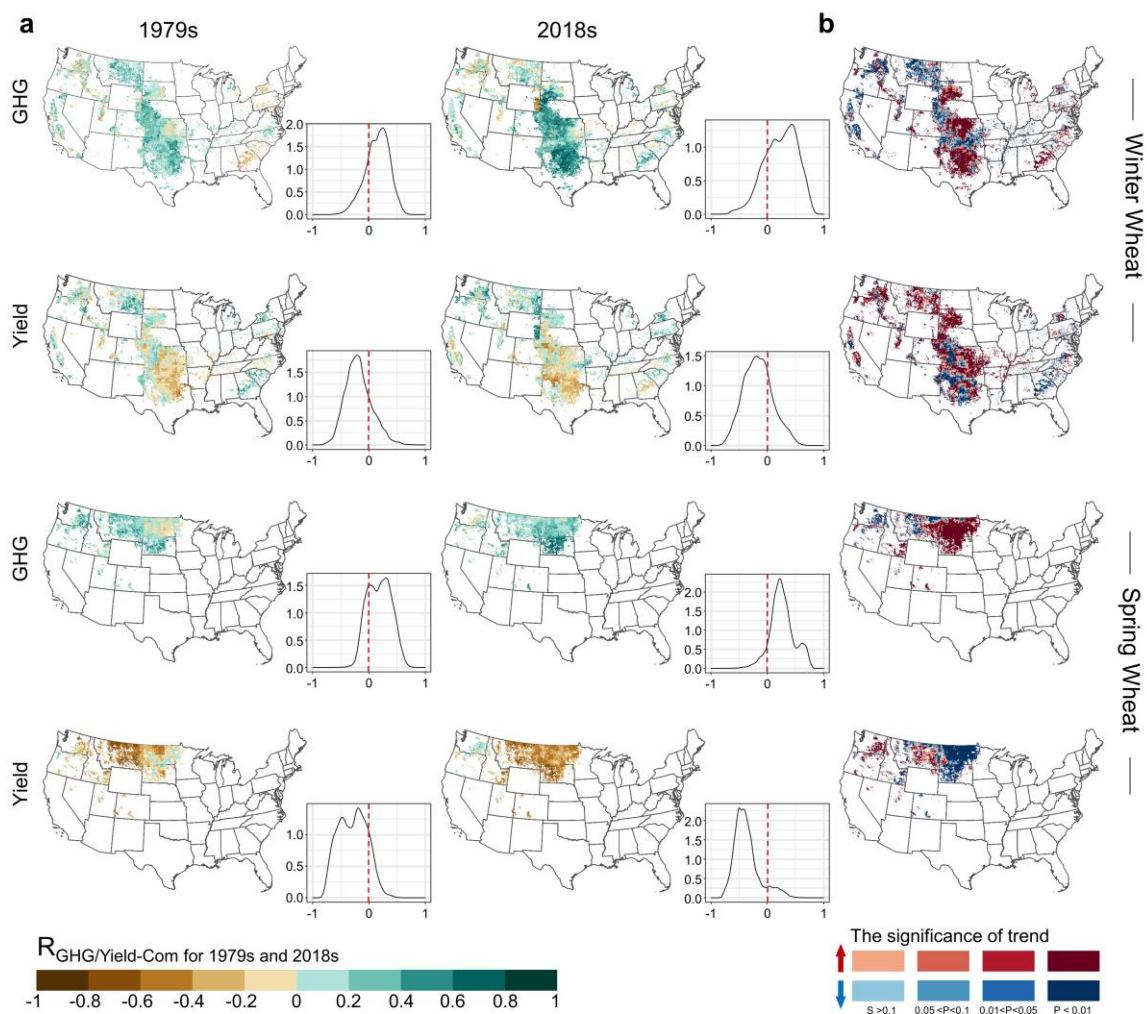
附图 3 1979-2018 年小麦净温室气体排放和产量对复合干热事件的响应。1979s 和 2018s (图 a) 分别指 1960-1979 年和 1999-2018 年期间。S 和 P 是线性回归的斜率和 P 值。

Fig. S3 The response variation of net greenhouse gases (GHG) emissions and yield to the compound dry-heat events for wheat during 1979s to 2018s. 1979s and 2018s (panel a) refer to the period 1960–1979 and 1999–2018, respectively. S and P are the slope and p value of the linear regression.



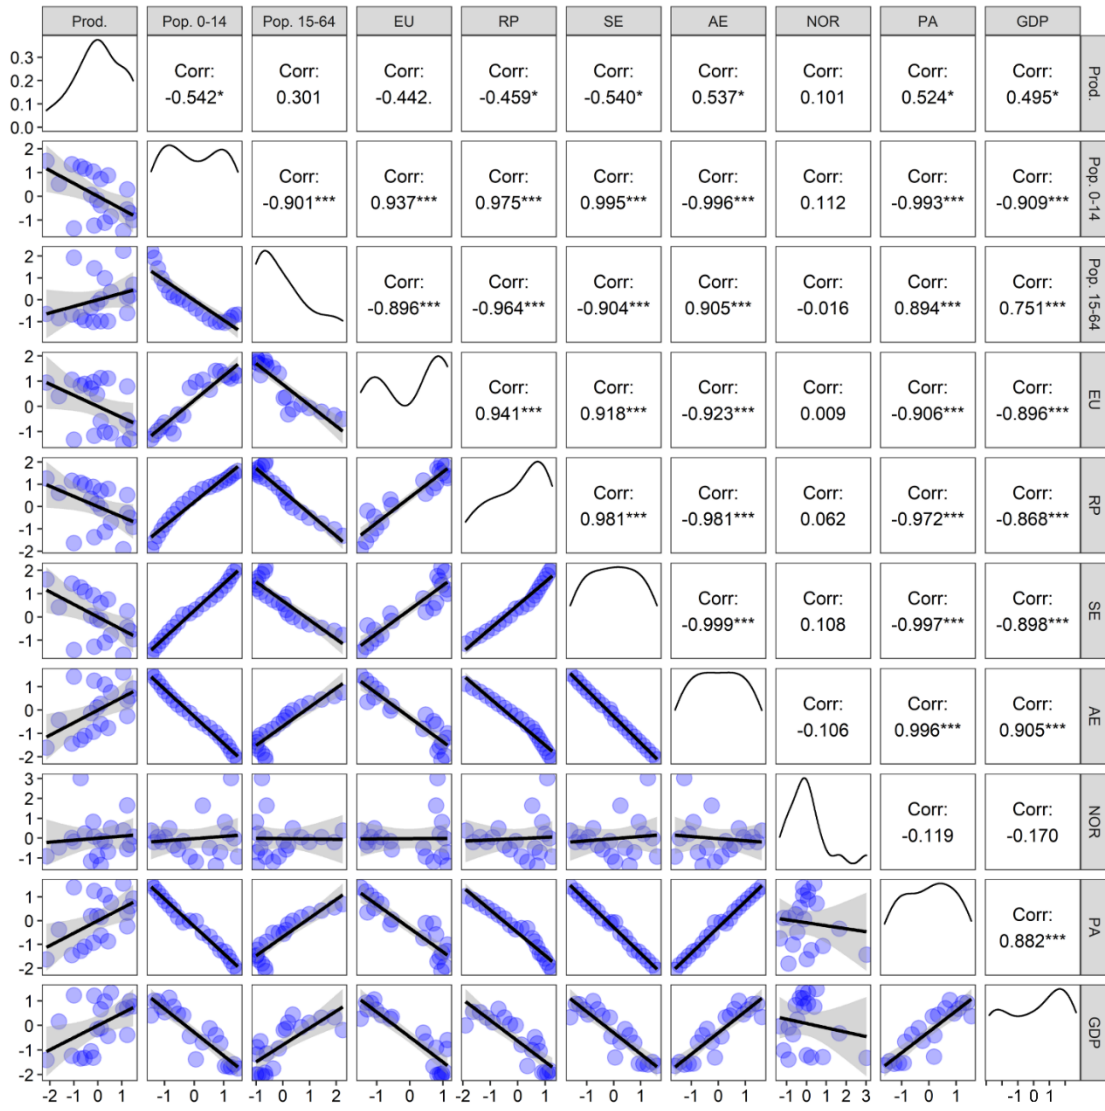
附图 4 1979-2018 年小麦净温室气体排放和产量对干旱事件的响应。1979s 和 2018s（图 a）分别指 1960-1979 年和 1999-2018 年期间。S 和 P 是线性回归的斜率和 P 值。

Fig. S4 The response variation of net greenhouse gases (GHG) emissions and yield to the drought events for wheat during 1979s to 2018s. 1979s and 2018s (panel a) refer to the period 1960–1979 and 1999–2018, respectively. S and P are the slope and p value of the linear regression.



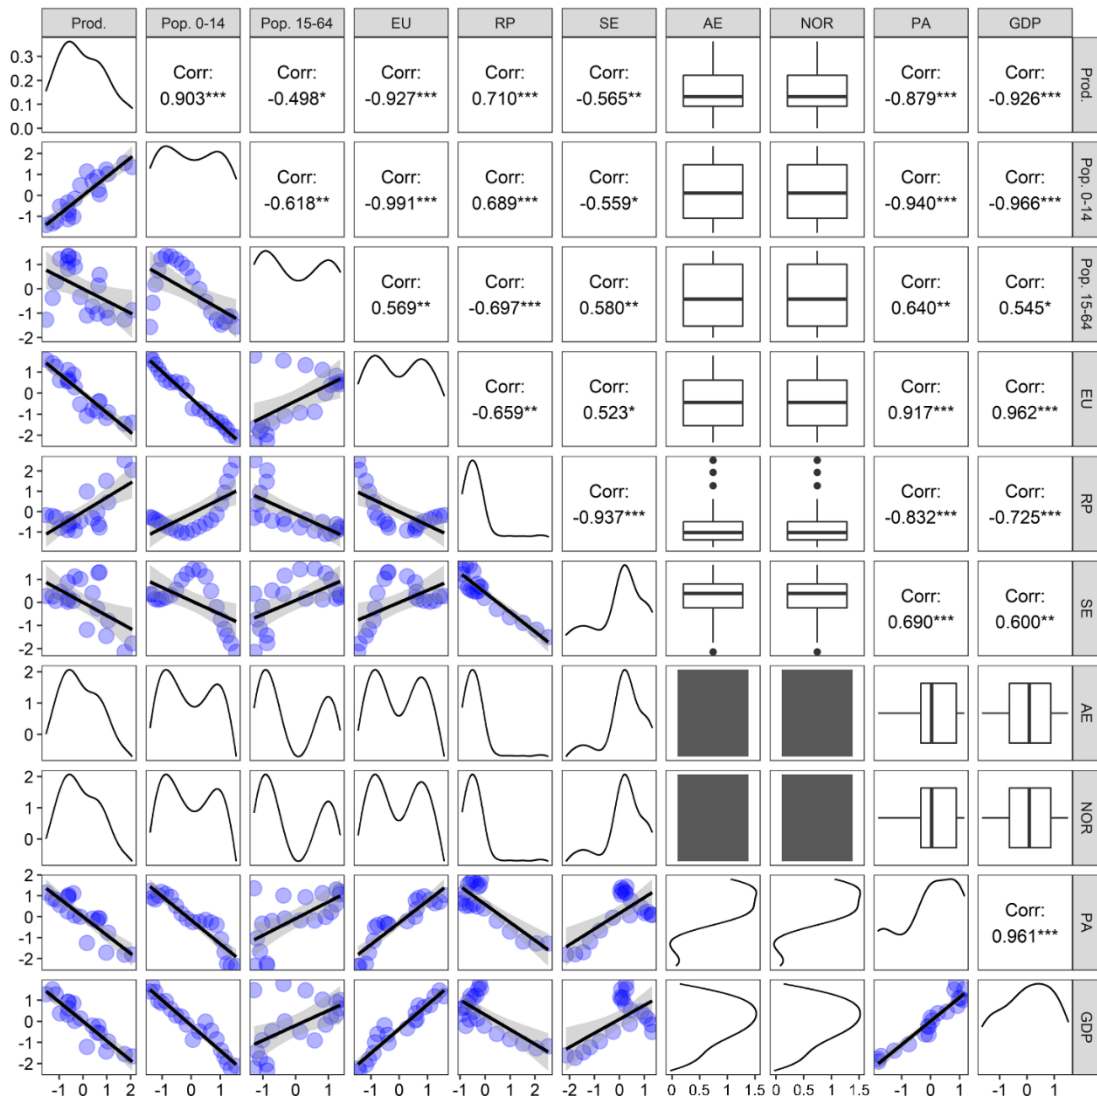
附图 5 1979-2018 年小麦净温室气体排放和产量对高温事件的响应。1979s 和 2018s（图 a）分别指 1960-1979 年和 1999-2018 年期间。S 和 P 是线性回归的斜率和 P 值。

Fig. S5 The response variation of net greenhouse gases (GHG) emissions and yield to the high-temperature events for wheat during 1979s to 2018s. 1979s and 2018s (panel a) refer to the period 1960–1979 and 1999–2018, respectively. S and P are the slope and p value of the linear regression.



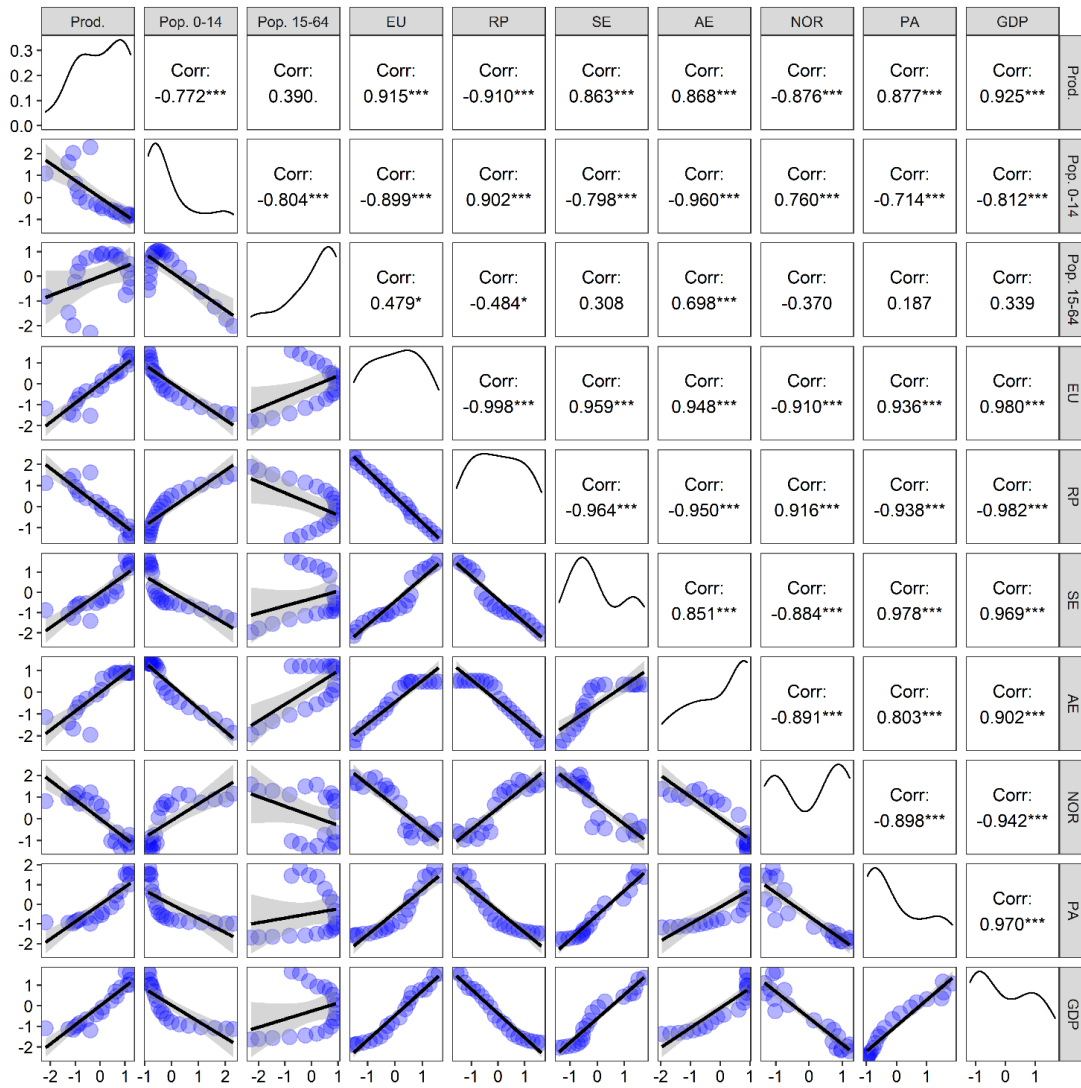
附图 6 朝鲜社会恢复力变量散点矩阵。左下的面板显示了两个变量之间的线性回归，灰色带表示 95%置信区间。对角线是频率分布，右上方的面板显示了两个变量之间的皮尔逊相关系数。 $*p < 0.05$, $**p < 0.01$, $***p < 0.001$

Fig. S6: Scatter matrix of social resilience indexes for North Korea (undeveloped region). The lower left panels show the linear regressions among two variables, and the gray bands represent the 95% confidence intervals. The diagonal panels are the frequency distributions. The upper right panels show the Pearson correlation coefficients among the two variables. The symbols for the significance test are: * for $p < 0.05$, ** for $p < 0.01$, and *** for $p < 0.001$.



附图 7 韩国社会恢复力变量散点矩阵。左下的面板显示了两个变量之间的线性回归，灰色带表示 95%置信区间。对角线是频率分布，右上方的面板显示了两个变量之间的皮尔逊相关系数。 $*p < 0.05$, $**p < 0.01$, $***p < 0.001$

Fig. 7 Scatter matrix of social resilience indexes for South Korea (developed region). The lower left panels show linear regressions among two variables, and the gray bands represent the 95% confidence intervals. The diagonal panels are frequency distributions. The upper right panels show the Pearson correlation coefficients among the two variables. The symbols for the significance test are: * for $p < 0.05$, ** for $p < 0.01$, and *** for $p < 0.001$.



附图 8 中国社会恢复力变量散点矩阵。左下的面板显示了两个变量之间的线性回归，灰色带表示 95%置信区间。对角线是频率分布，右上方的面板显示了两个变量之间的皮尔逊相关系数。 $*p < 0.05$, $**p < 0.01$, $***p < 0.001$

Fig. S8: Scatter matrix of social resilience indexes for China (developing region). The lower left panels show the linear regressions among two variables, and the gray bands represent the 95% confidence intervals. The diagonal panels are the frequency distributions. The upper right panels show the Pearson correlation coefficients among the two variables. The symbols for the significance test are: * for $p < 0.05$, ** for $p < 0.01$, and *** for $p < 0.001$.

附表 1A 1960-2018 年环境因素和管理措施影响下的小麦温室气体排放强度 (kg CO₂-eq/kg), 产量 (×10⁹ kg/year) 和土壤温室气体排放 (Tg CO₂-eq/year)Table S1 Multifactor- and management-practice induced GHGI (kg CO₂-eq/kg), production (×10⁹ kg/year), and soil GHG (Tg CO₂-eq/year) from 1960 to 2018 for US wheat

输出	年份	冬小麦		春小麦	
		均值	趋势	均值	趋势
多因素影响					
GHG emissions intensity (kg CO ₂ -eq/kg)	1960-2018	0.17	-0.006**	0.06	0.005**
	1960-1990	0.27	0.004	-0.01	0.003
	1990-2018	0.06	-0.010**	0.14	0.009*
Production (×10 ⁹ kg/year)	1960-2018	40.17	0.238**	15.39	0.217**
	1960-1990	37.44	1.035**	11.88	0.364**
	1990-2018	43.18	-0.544**	19.29	-0.219**
GHG emissions (Tg CO ₂ -eq/year)	1960-2018	6.26	-0.163**	1.05	0.082**
	1960-1990	9.92	0.411**	-0.10	0.029
	1990-2018	2.21	-0.438**	2.33	0.148
氮肥影响					
GHG emissions intensity (kg CO ₂ -eq/kg)	1960-2018	0.03	-0.001	-0.066	0.006**
	1960-1990	0.06	0.007**	-0.148	0.005
	1990-2018	-0.01	-0.05	0.024	0.009**
Production (×10 ⁹ kg/year)	1960-2018	16.21	0.263**	5.23	0.131**
	1960-1990	12.49	0.528**	3.00	0.157**
	1990-2018	20.33	-0.119	7.71	-0.110
GHG emissions (Tg CO ₂ -eq/year)	1960-2018	3.05	-0.085	-0.21	0.077**
	1960-1990	5.13	0.403**	-1.28	0.018
	1990-2018	0.75	-0.299*	0.98	0.160**
粪肥影响					
GHG emissions intensity (kg CO ₂ -eq/kg)	1960-2018	0.003	0.000**	0.003	0.000
	1960-1990	0.004	0.000	0.003	0.001**
	1990-2018	0.002	0.000	0.003	0.000**
Production (×10 ⁹ kg/year)	1960-2018	0.15	0.004**	0.00	-0.001**
	1960-1990	0.09	0.002	0.01	-0.002**
	1990-2018	0.22	0.002	0.00	0.001
GHG emissions (Tg CO ₂ -eq/year)	1960-2018	0.12	-0.003*	0.05	0.001
	1960-1990	0.17	0.005	0.05	0.006**
	1990-2018	0.07	-0.007*	0.06	-0.004**

注: * $p < 0.05$ 、** $p < 0.01$

附表 1B 1960-2018 年环境因素和管理措施影响下的小麦温室气体排放强度 (kg CO₂-eq/kg), 产量 (×10⁹ kg/year) 和土壤温室气体排放 (Tg CO₂-eq/year)Table S1 Multifactor- and management-practice induced GHGI (kg CO₂-eq/kg), production (×10⁹ kg/year), and soil GHG (Tg CO₂-eq/year) from 1960 to 2018 for US wheat

灌溉影响					
	1960-2018	-0.018	0.000	-0.005	0.000
GHG emissions intensity (kg CO ₂ -eq/kg)	1960-1990	-0.022	-0.002**	-0.006	0.000**
	1990-2018	-0.014	0.001**	-0.004	0.000**
	1960-2018	0.19	0.001	0.08	0.001
Production (×10 ⁹ kg/year)	1960-1990	0.20	0.013**	0.07	0.004**
	1990-2018	0.17	-0.009*	0.10	-0.002**
	1960-2018	-0.75	0.004	-0.07	0.000
GHG emissions (Tg CO ₂ -eq/year)	1960-1990	-0.91	-0.073**	-0.08	-0.005**
	1990-2018	-0.57	0.057**	-0.06	0.006**
耕作影响					
	1960-2018	0.065	0.004**	-0.004	0.000**
GHG emissions intensity (kg CO ₂ -eq/kg)	1960-1990	0.009	0.001**	-0.007	0.000**
	1990-2018	0.127	0.008**	-0.001	0.000
	1960-2018	-0.18	0.073**	-0.13	-0.005**
Production (×10 ⁹ kg/year)	1960-1990	-1.24	-0.051**	-0.05	-0.002**
	1990-2018	1.00	0.225**	-0.21	-0.007**
	1960-2018	2.52	0.169**	-0.08	0.000
GHG emissions (Tg CO ₂ -eq/year)	1960-1990	0.08	0.024**	-0.09	0.000
	1990-2018	5.22	0.331**	-0.07	-0.003

注: * $p < 0.05$ 、** $p < 0.01$

致谢

时光荏苒，转眼间，我即将迈入到人生新的阶段，回首走过的旅程，心潮澎湃，感慨万分。这是一段奇妙的旅程，充满艰辛与欢笑，更是得到了众多人的悉心指导与无私支持。值此毕业论文完成之际，我想对所有在学习生活中关心、支持、陪伴过我的老师、同学、朋友及家人表达深深的感激之情。

首先，我要向我的博士研究生导师于强教授表达最诚挚的谢意。于强教授是我求学生涯中的启蒙者，是您的悉心教诲和悠远学识让我在学术的海洋里能够航行得更远。您严谨的治学态度、富有创见的思维方式一直是我学习的楷模。感谢您在我研究生阶段的耐心指导，您的教诲让我受益终身。同时，我深深感激我的国外合作导师田汉勤教授和潘淑芬教授。您们对于学科知识的深刻理解和丰富经验让我受益匪浅，独到见解和广博知识让我深受启发。在每一次学术讨论中，您们总是能够以开阔的视野和深邃的思考引领我们，让我在学术的海洋中不断探索、不断进步。

其次我要感谢同门的师兄师姐和师弟师妹们，是你们陪伴我一路成长，共同奋斗，互相鼓励，一同面对学术上的困难，一同分享生活中的欢笑。感谢潘乃青、游永发、卞子浩、姚远志、李雅、李孝永、柳祺祺、余慧倩、刘楚杰、徐斌元、李林超、何沁锶、赵杰、张艳、戎亮秉、贾倩兰等在工作生活中给予我的支持与帮助，是特别的缘分让我们从五湖四海聚集到同一个地方，和你们在一起的时间是我求学时光中最珍贵的财富。特别感谢靳宁师兄、何亮师兄和张亚捷师兄，你们是我学术道路上的良师益友，为我提供了宝贵的经验和指导，让我在学术研究中不断成长，能够勇往直前，克服重重困难。感谢科研道路上遇到的一群志同道合的朋友，韩佳乐、陈晓凯、闫桦、杜卓霖、杨方剑、宋子腾、宋航、赵蓉等，你们的真情陪伴使我度过了博士生涯虽苦尤甜的岁月。

十分感谢国家对我学业的支持与帮助。是国家的支持，让我有幸踏上国际学术舞台，感受异国他乡的学术氛围，扩展学科视野。正是有了祖国的强大支持，才能让在我面对复杂而又艰难的外部环境中保守着坚定前行的信念。感谢国家的培养，我将以更高的标准、更严谨的态度，为国家的发展贡献自己的一份力量。

最后，我要向我亲爱的父母表达最深沉的谢意。您们一直是我人生中最坚实的依靠和最温暖的港湾。感谢您们的辛勤付出和无私支持，是你们的支持让我能够专心致志地追求学业。您们的教诲，是我成长道路上最重要的指引，感激之情无法言表。

这段博士求学之路是充实而宝贵的，让我倍感幸运。感谢每一位曾经给予我帮助的人，也感谢每一位曾经质疑我的人，你们是我前行道路上最大的动力。祝愿你们一生平安、幸福、安康！

作者简介

一、个人简介

施宇，男，汉族，中共党员。博士就读于西北农林科技大学资源环境学院土地资源与空间信息技术专业，研究方向为气候变化与粮食安全。

1. 2018.09-2023.12，西北农林科技大学资源环境学院土地资源与空间信息技术，攻读博士学位。

2. 2014.09-2018.09，山西农业大学资源环境学院农业资源与环境专业，攻读学士学位。

3. 2021.12-2023.11，美国奥本大学森林野生动物与环境学院林学专业，联合培养博士。

二、博士期间获奖情况

2022年11月，中华人民共和国教育部，宝钢优秀学生奖

2021年11月，西北农林科技大学，优秀研究生

2021年08月，参加“扬帆计划”·中央和国家机关大学生实习

2021年07月，获2021年国家建设高水平大学公派研究生项目资助（CSC国家公派）

2021年06月，中共陕西省教育工委，陕西省高校优秀共产党员

2021年06月，中共西北农林科技大学委员会，优秀共产党员

2021年06月，光明日报采访报导个人事迹

2021年01月，西北农林科技大学，唐立新奖学金

2020年12月，中华人民共和国教育部，博士研究生国家奖学金

2020年12月，中共西北农林科技大学委员会，优秀共产党员

2020年10月，西北农林科技大学，学业一等奖学金

2020年05月，共青团西北农林科技大学委员会，优秀共青团干部

2020年03月，中共西北农林科技大学资源环境学院委员会，优秀共产党员

2019年11月，西北农林科技大学，优秀研究生干部

2019年11月，西北农林科技大学，学业一等奖学金

三、博士期间已完成的论文

1. Shi, Y.*, Zhang, Y., Wu, B.,, Tian, H.*, Yu, Q.*, 2022. Building social resilience in North Korea can mitigate the impacts of climate change on food security. **Nature Food**, 3: 499-511. (G1, 中科院一区, IF: 23.2)

2. **Shi, Y.**, Jin, N.*, Ma, X., Wu, B., He, Q., Yue, C., Yu, Q.*, 2020. Attribution of climate and human activities to vegetation change in China using machine learning techniques. **Agricultural and Forest Meteorology**, 294: 108146. (G2, 中科院一区, IF: 6.2)
3. Jin N., **Shi, Y.***, Niu W., He L.*, 2023. Spatial and Temporal Patterns of Agricultural Drought in China during 1960–2020 Characterized by Use of the Crop Water Deficit Abnormal Index. **Journal of Hydrology**, 627: 130454. (G2, 中科院一区, IF: 6.4)
4. **Shi, Y.**, Wu, B.Y., Wang, B., Zhang, Y., Li, L., He, L., Jin, N., Wang, Z., Pan, S., Tian, H.*, Yu, Q.*, 2023. Predicting rice productivity for ground data-sparse regions: A transferable framework and its application to North Korea. **Field Crops Research**, Under Review. (G3, 中科院一区, IF: 5.8)
5. **Shi, Y.**, Pan, S., You, Y., Prior, S.A., Tian, D., Yu, H., Yu, Q., Tian, H.*, 2023. Harnessing climate-smart tillage for wheat production to mitigate increased sensitivity of greenhouse gas emission intensity in a dry-heat world. **Nature Food**, Submitted. (G1, 中科院一区, IF: 23.2)
6. Wu, B., **Shi, Y.***, Jin, N., Wang, Z., Yu, Q., Wang, S.*, 2023. The impact of machine learning models and spatial resolution on land cover classification accuracy in Dali County. **International Journal of Agricultural and Biological Engineering**, Accepted. (中科院三区, IF: 2.4)
7. Li, L., Zhang, Y., Wang, B., Feng, P., He, Q., **Shi, Y.**, ..., Yu, Q.*, 2023. Integrating machine learning and environmental variables to constrain uncertainty in crop yield change projections under climate change. **European Journal of Agronomy**, 149: 126917. (G3, 中科院一区, IF: 5.722)
8. Li, L., Wang, B., Feng, P., ..., He, Q., **Shi, Y.**, ..., Yu, Q.*, 2023. The optimization of model ensemble composition and size can enhance the robustness of crop yield projections. **Communications Earth & Environment**, 4: 362. (中科院二区, IF: 7.9)
9. Zhang, Y., Zhao, J., Yan, Y., **Shi, Y.**, Yu, Q., 2021. Relationship of population migration, crop production pattern, and socioeconomic development: evidence from the early 21st century. **Environmental Research Letters**, 16: 074045. (中科院二区, IF: 6.7)

四、博士期间学术交流

2022年9月, 参加江苏省“路面过程与陆气相互作用”研究生暑期学校

2019年7月, 参加江苏省研究生“污染控制与生态环境效应”暑期学校并获优秀学员

2019年7月, 参加中农资源环境与学院“农业系统模拟与农业气象”暑期学校

2019年12月-2020年12月, 担任全国地理研究生联合会理事职务