西北农林科技大学

博 士 学 位 论 文

基于高精度土壤温度产品的中国土壤复合干热事件识别及其对玉米的影响解析

培 养 单 位 资源环境学院

学 科 专 业 土地资源与空间信息技术

论 文 作 者 王雪彤

指 导 教 师 于强 研究员

合作指导教师 何亮 正高级工程师 石浩 副研究员

2026 年 09 月

Dissertation Submitted to Northwest A&F University

in Partial Fulfillment of the Requirements

for Degree of

Doctor of Philosophy

Identification of Soil Compound Drought-Heatwaves in China and Their Impacts on Maize Using a High-Resolution Soil Temperature Dataset

Colleges: College of Natural Resources and Environment

Major: Land Resources and Spatial Information Technology

Candidate: Xuetong Wang

Supervisor: Qiang Yu

Co-Supervisor: Liang He & Hao Shi

September, 2026

分类号：S127　　学校代码：10712
UDC：631　　研究生学号：2022060390
密级：公开

西北农林科技大学博士学位论文

基于高精度土壤温度产品的中国土壤复合干热事件识别及其对玉米的影响解析

论文作者：王雪彤

指导教师：于强 研究员

指导小组：何亮 正高级工程师　石浩 副研究员

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）
西北农林科技大学水土保持研究所赵刚教授（委员）
西北农林科技大学水土保持研究所吴耕泓教授（委员）
中国气象局兰州干旱气象研究所赵福年研究员（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：2026 年 8 月 18 日

本研究得到国家重点研发计划项目（编号：2023YFF1303700）和国家自然科学基金面上项目（编号：42375195）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成果；论文中的研究数据及结果的获得完全符合学术道德的有关规定,如有违反，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成果，也不包含为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：2026 年 8 月 20 日

导师指导研究生学位论文的承诺

本人承诺：我的研究生  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成果，并严格遵守学术道德的有关规定。如有违反，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：2026 年 8 月 20 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。本人及导师同意学校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；同意学校将本学位论文的全部或部分内容授权汇编录入《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研究成果时，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、缩印或扫描复制保存）

研究生签名： 时间：2026 年 8 月 20 日

导师签名： 时间：2026 年 8 月 20 日

摘要

土壤温度（Soil temperature，T_s）是表征陆地表层热状态和土壤热环境变化的关键变量，直接影响地表能量交换、地下热传输、土壤水热耦合过程及生态系统功能，并对土壤碳氮循环、冻融过程、根系活动和作物生产力形成具有重要调控作用。在气候变暖和极端事件增强背景下，土壤高温与土壤水分亏缺的同步发生可能改变作物生长季根区水热环境，进而加剧农业系统对复合干热胁迫的敏感性。然而，现有复合干热事件研究多基于气温、降水、蒸散或大气干旱指标，难以直接表征土壤高温与土壤水分亏缺共同作用下的根区复合胁迫。同时，长时序高精度多土层 T_s 数据仍较为缺乏，尤其在中国地形复杂、下垫面异质性强和观测站点分布不均的区域，现有再分析 T_s 产品的精度表现和关键土壤热过程表征能力仍存在较大不确定性。这些问题限制了基于土壤水热状态的复合干热事件识别及其农业影响评估。因此，亟需明确现有 T_s 产品在中国区域的适用性，构建高精度多层 T_s 数据集，并进一步将其用于土壤复合干热事件（Soil Compound Drought-Heatwaves,，SCDHWs）识别和作物影响机制解析。

针对上述问题，本文围绕“高精度 T_s 数据如何支撑 SCDHWs 识别及其对玉米影响评估”这一主线在中国区域展开研究。首先，基于时间跨度为 1980-2020 年的 1682 个气象站点的多层（0、5、10、15、20 和 40 cm）T_s 观测数据，系统评估 ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q 四个再分析产品在不同土层、季节、土地覆盖类型和海拔条件下的模拟精度，并进一步分析其对长期增温趋势、土壤热浪和冻融过程的表征能力。其次，融合地面 T_s 观测、卫星遥感、再分析气象资料以及地形和土壤属性变量，构建基于旋转四叉树和 XGBoost 的空间自适应建模框架，生成 2001-2020 年中国逐日 1 km 分辨率多层 T_s 数据集。最后，基于本文重构的 T_s 数据集和已有高精度土壤湿度（Soil Moisture，SM）数据集，构建 SCDHWs 识别框架，并结合玉米物候、净初级生产力（Net Primary Production，NPP）和产量格网数据，揭示 SCDHWs 的时空变化特征及其对玉米生产力与产量影响的物候阶段差异。本文主要结论如下：

（1）明确了不同 T_s 再分析产品在中国区域的适用性及关键土壤热过程表征能力。基于多层原位 T_s 观测数据的评估结果表明，JRA-3Q 在 0-40 cm 深度的整体一致性最高，R^2 为 0.68-0.81，Bias 为-1.70 至-0.72 K；ERA5-Land 在深层土壤中表现较优，40 cm 深度 R^2 达到 0.82；GLDAS 表现居中，R^2 为 0.59-0.65，而 MERRA-2 的 R^2 为 0.42-0.49，并表现出更明显的低估。不同产品误差总体表现为浅层较大、深层较小，并在夏季、冬季、高海拔及复杂地形区进一步增大。在长期变化方面，不同产品总体能够捕捉中国区域多层 T_s 的增温方向，但对增温幅度及其空间分布的表征能力存在差异。在关键土壤热过程表征方面，土壤热浪指标对产品选择较为敏感，其中峰值强度的产品间

相关系数 r 为 0.69-0.80，表现出较高一致性，但发生频次一致性较弱；冻融指标能够大体反映冻结日数随纬度和海拔变化的空间梯度，但在冻融转换过程及局地数值表现上仍存在差异。总体来看，再分析 T_s 产品可为区域土壤热环境研究提供重要数据支撑，但在长期趋势分析、土壤热浪识别和冻融过程研究等应用中，仍需根据具体产品特征和研究目标进行合理选择。

（2）构建了基于空间自适应和多源数据融合的层级递进 T_s 估算框架，并生成了中国 1 km 分辨率逐日多层（0、5、10、15、20 和 40 cm）T_s 数据集。该框架融合地面 T_s 观测、卫星遥感、再分析气象资料以及地形和土壤属性变量，利用旋转四叉树实现空间自适应局部建模，提高了复杂区域 T_s 估算能力。多角度旋转集成有效缓解了局部建模导致的边界效应，层级递进策略进一步提升了多层 T_s 估算的稳定性和精度。模型验证结果表明，空间自适应模型在训练集和测试集上的 R^2 中位数为 0.92-0.98，RMSE 中位数为 1.6-2.4 K；独立观测站逐日验证中，R^2 为 0.78-0.87，RMSE 为 3.89-5.14 K，表明该数据集具有较好的空间泛化能力。与 ERA5-Land 和 GLDAS 等再分析产品相比，本文生成的数据集在空间分辨率和站点一致性方面均有所提升，可为中国区域多层土壤热环境精细刻画提供数据基础。

（3）构建了基于 T_s 和 SM 数据协同约束的 SCDHWs 识别框架，并揭示了中国 SCDHWs 的时空变化特征。2001-2020 年期间，中国区域 SCDHWs 呈现明显的空间异质性和总体增强趋势，不同农业区在事件频次、持续时间、峰值强度和累积强度上存在明显差异。从年际变化来看，SCDHWs 持续时间、发生频次、峰值强度和累积强度分别以 2.40 d decade^{-1}、0.13 events decade^{-1}、0.34 °C decade^{-1} 和 3.89 °C·days decade^{-1} 的速率增加，表明土壤复合干热胁迫正在由短期暴露向持续性和累积性风险增强转变。从空间分布来看，黄土高原及北方干旱半干旱农业区等玉米主产区通常表现出较高的土壤水热复合胁迫风险，但不同指标的高值区并不完全一致，说明仅依赖单一指标难以全面表征区域 SCDHWs 风险。

（4）基于玉米物候、NPP 和产量格网数据的联合分析，揭示了不同物候阶段 SCDHWs 对玉米生产力损失和产量损失影响的差异。NPP 损失结果显示，在东北平原、黄淮海平原、黄土高原和北方干旱半干旱区等玉米主产区，营养生长阶段（vegetative growth stage，VGS）玉米 NPP 相对损失通常高于生殖生长阶段（reproductive growth stage，RGS）。XGBoost-SHAP 分析表明，SCDHWs 对玉米生产力损失的主导因子具有明显物候阶段差异。VGS 阶段生产力损失主要受蒸散过程和水分条件控制，其中蒸散过程因子的平均绝对 SHAP 贡献占比最高，为 36.6%；RGS 阶段气象条件因子贡献最高，占 33.6%，且 T_s 和太阳辐射等热量相关因子的作用明显增强。进一步基于广义加性混合模型（Generalized Additive Mixed Model，GAMM）的产量损失敏感性分析显示，在相同 SCDHWs 强度和持续时间条件下，RGS 阶段对应的玉米产量损失率整体高于

VGS 阶段，且这种差异在长持续时间事件下更加明显。总体来看，VGS 阶段 SCDHWs 更易表现为 NPP 损失，而 RGS 阶段 SCDHWs 更易转化为最终产量损失，说明生产力响应与产量响应之间存在阶段依赖性差异。

综上，本研究以中国高精度多层 T_s 数据构建与应用为核心，围绕 SCDHWs 识别及其对玉米影响评估开展系统研究。研究首先明确了四种再分析 T_s 产品在中国区域不同应用场景下的适用性和不确定性，并在此基础上提出了适用于大尺度高精度多层 T_s 制图的空间自适应建模框架，生成了 2001-2020 年中国逐日 1 km 分辨率多层 T_s 数据集。进一步地，本文将该 T_s 数据集与高精度 SM 数据相结合，建立了基于土壤高温与水分亏缺协同约束的 SCDHWs 识别方法，并揭示了 SCDHWs 对玉米生产力损失和产量损失影响的物候阶段差异。研究结果可为土壤热环境监测、基于土壤状态的复合极端事件识别、作物水热胁迫诊断和农业气候风险预警提供数据基础与科学依据。

关键词：土壤温度；多源数据融合；机器学习；土壤复合干热事件；玉米生产力

ABSTRACT

Soil temperature (T_s) is a key variable for characterizing the thermal state of the land surface and changes in the soil thermal environment. It directly affects land surface energy exchange, subsurface heat transfer, soil hydrothermal coupling, and ecosystem functioning, and plays an important role in regulating soil carbon and nitrogen cycling, freeze-thaw processes, root activity, and crop productivity formation. Under climate warming and intensifying extreme events, the concurrent occurrence of soil high temperature and soil moisture (SM) deficit may alter the root-zone hydrothermal environment during the crop growing season, thereby increasing the sensitivity of agricultural systems to compound drought and heat stress. However, existing studies on compound drought and heat events have mostly relied on air temperature, precipitation, evapotranspiration, or atmospheric drought indicators, making it difficult to directly characterize root-zone compound stress caused by the joint effects of soil high temperature and SM deficit. Meanwhile, long-term, high-spatial-resolution, multi-layer T_s datasets remain limited, particularly in China, where complex terrain, heterogeneous land surfaces, and unevenly distributed observation sites lead to substantial uncertainties in the accuracy of existing reanalysis T_s products and their ability to represent key soil thermal processes. These limitations constrain the identification of compound drought and heat events based on soil hydrothermal states and the assessment of their agricultural impacts. Therefore, it is necessary to clarify the applicability of existing T_s products over China, develop a high-resolution multi-layer T_s dataset, and further apply it to the identification of Soil Compound Drought-Heatwaves (SCDHWs) and the mechanistic analysis of their impacts on crops..

To address these issues, this dissertation conducts a systematic study over China with a focus on how high-resolution T_s data can support the identification of SCDHWs and the assessment of their impacts on maize. First, based on multi-layer T_s observations from 1682 meteorological stations spanning 1980-2020 at depths of 0, 5, 10, 15, 20, and 40 cm, this study systematically evaluated the performance of four reanalysis products, namely ERA5-Land, GLDAS, MERRA-2, and JRA-3Q, across different soil depths, seasons, land-cover types, and elevation conditions. Their ability to characterize long-term warming trends, soil heatwaves, and freeze-thaw processes was further assessed. Second, by integrating in situ T_s observations, satellite remote sensing data, reanalysis meteorological variables, and terrain and soil property variables, a spatially adaptive modeling framework based on rotated quadtrees and XGBoost

is developed to generate a daily 1 km multi-layer T_s dataset across China for 2001-2020. Finally, based on the reconstructed T_s dataset and an existing high-resolution SM dataset, a framework for identifying SCDHWs is established. Combined with maize phenology, net primary production (NPP), and gridded yield data, this study reveals the spatiotemporal characteristics of SCDHWs and their phenology-dependent impacts on maize productivity and yield. The main conclusions are as follows.

(1) The applicability of different reanalysis T_s products over China and their capability to characterize key soil thermal processes were systematically evaluated. Evaluation against multi-layer in situ T_s observations showed that JRA-3Q exhibited the highest overall agreement across the 0-40 cm soil profile, with R^2 values ranging from 0.68 to 0.81 and Bias values from -1.70 to -0.72 K. ERA5-Land performed particularly well in deeper soil layers, achieving an R^2 of 0.82 at 40 cm depth. GLDAS showed intermediate performance, with R^2 values of 0.59-0.65, whereas MERRA-2 exhibited relatively weaker agreement, with R^2 values of 0.42-0.49, together with a more pronounced cold bias. The errors of different products are generally larger in shallow soil layers and smaller in deeper layers, and are further amplified in summer, winter, high-elevation areas, and complex terrain regions. In terms of long-term changes, the different products generally capture the warming direction of multi-layer T_s across China, but differ in their representation of warming magnitude and spatial patterns. For key soil thermal processes, soil heatwave metrics are relatively sensitive to product selection. Among them, peak intensity shows relatively high inter-product consistency, with spatial correlation coefficients of 0.69-0.80, whereas event frequency shows weaker consistency. Freeze-thaw indicators can broadly reflect the spatial gradients of freezing days along latitude and elevation, but differences remain in the characterization of freeze-thaw transitions and local magnitudes. Overall, reanalysis T_s products provide important data support for regional soil thermal environment studies, but their application to long-term trends and key thermal process indicators requires careful selection according to specific products and research objectives.

(2) A hierarchical and progressive T_s estimation framework based on spatial adaptation and multi-source data fusion is developed, and a daily 1 km multi-layer T_s dataset at depths of 0, 5, 10, 15, 20, and 40 cm is generated for China. The framework integrates in situ T_s observations, satellite remote sensing data, reanalysis meteorological variables, and terrain and soil property variables. It uses rotated quadtrees to implement spatially adaptive local modeling, thereby improving T_s estimation in complex regions. Multi-angle rotation ensemble modeling effectively reduces boundary effects caused by local modeling, while the

hierarchical and progressive strategy further improves the stability and accuracy of multi-layer T_s estimation. Model validation shows that the spatially adaptive model achieves median R^2 values of 0.92-0.98 and median RMSE values of 1.6-2.4 K on the training and test sets. Independent daily validation against flux-tower observations yields R^2 values of 0.78-0.87 and RMSE values of 3.89-5.14 K, indicating good spatial generalization capability. Compared with reanalysis products such as ERA5-Land and GLDAS, the dataset generated in this study improves both spatial resolution and station-level consistency, providing a data basis for fine-scale characterization of China's multi-layer soil thermal environment.

(3) A SCDHW identification framework based on the joint constraints of T_s and SM is established, and the spatiotemporal characteristics of soil compound drought and heatwave events across China are revealed. During 2001-2020, SCDHWs in China exhibit pronounced spatial heterogeneity and an overall intensification trend. Different agricultural regions show clear differences in event frequency, duration, peak intensity, and cumulative intensity. From the perspective of interannual changes, SCDHW duration, frequency, peak intensity, and cumulative intensity increase at rates of 2.40 d decade^{-1}, 0.13 events decade^{-1}, 0.34 °C decade^{-1}, and 3.89 °C·days decade^{-1}, respectively. These results indicate that compound soil drought and heat stress is shifting from short-term exposure toward more persistent and cumulative risk. Spatially, the northern maize-producing areas, the Loess Plateau, and the arid and semi-arid agricultural regions of northern China generally show higher risks of compound soil hydrothermal stress. However, the high-value areas of different metrics do not fully overlap, suggesting that reliance on a single indicator is insufficient for comprehensively characterizing regional SCDHW risk.

(4) This study reveals the differential impacts of SCDHWs on maize productivity and yield across phenological stages. The NPP loss results show that in the Northeast Plain, the Huang-Huai-Hai Plain, the Loess Plateau, and the northern arid and semi-arid regions, relative maize NPP losses during the vegetative growth stage (VGS) are generally greater than those during the reproductive growth stage (RGS). XGBoost-SHAP analysis indicates that the dominant drivers of maize productivity loss under SCDHWs differ substantially between phenological stages. During VGS, productivity loss is mainly controlled by evapotranspiration processes and water conditions, with evapotranspiration-related factors contributing the largest share of mean absolute SHAP values, at 36.6%. During RGS, meteorological condition factors make the largest contribution, accounting for 33.6%, and the roles of heat-related factors such as T_s and solar radiation become more pronounced. Further sensitivity analysis of yield loss based on a generalized additive mixed model (GAMM) shows that, under the same

SCDHW intensity and duration, maize yield loss rates associated with RGS events are generally higher than those associated with VGS events, and this difference becomes more evident under long-duration events. Overall, SCDHWs during VGS are more likely to manifest as NPP losses, whereas SCDHWs during RGS are more likely to translate into final yield losses, indicating phenology-dependent differences between productivity responses and yield responses.

Overall, this dissertation focuses on the development and application of a high-resolution multi-layer T_s dataset for China and conducts a systematic study on the identification of soil compound drought and heatwave events and the assessment of their impacts on maize. First, this study clarifies the applicability and uncertainty of four reanalysis T_s products under different application scenarios across China. On this basis, a spatially adaptive modeling framework suitable for large-scale high-resolution multi-layer T_s mapping is proposed, and a daily 1 km multi-layer T_s dataset for China from 2001 to 2020 is generated. Furthermore, this dataset is combined with a high-resolution SM dataset to establish a SCDHW identification method based on the joint constraints of soil high temperature and moisture deficit. The phenology-dependent differences in the impacts of SCDHWs on maize productivity losses and yield losses are also revealed. The results provide a data basis and scientific support for soil thermal environment monitoring, the identification of compound extreme events based on soil temperature and moisture conditions, crop hydrothermal stress diagnosis, and agricultural climate risk early warning.

Keywords: Soil temperature; Multi-source data fusion; Machine learning; Soil compound drought and heatwaves; Maize productivity

目录

摘要..... I

ABSTRACT..... I

目录.....1

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 土壤温度数据来源与产品发展.....4

1.2.2 土壤温度长期变化趋势.....6

1.2.3 土壤温度估算方法研究进展.....8

1.2.4 土壤温度对作物生长及产量的影响.....12

1.3 研究内容.....14

1.4 技术路线.....15

第二章 材料与方法.....17

2.1 研究区概况.....17

2.2 数据来源与预处理.....18

2.2.1 原位观测数据.....18

2.2.2 遥感数据.....20

2.2.3 再分析/同化产品 22

2.2.4 高精度土壤湿度产品.....24

2.2.5 作物相关数据集.....24

2.2.6 蒸散发数据集.....26

2.2.7 其他数据.....26

2.3 研究方法.....27

2.3.1 统计分析方法.....27

2.3.2 空间分析方法.....28

2.3.3 机器学习方法.....33

2.3.4 趋势分析方法.....34

2.3.5 关键土壤热过程识别方法.....35

2.3.6 SCDHW 识别方法 36

2.3.7 广义加性混合模型.....37

2.3.8 精度评价方法.....38
第三章 再分析土壤温度产品的适用性评估.....41
3.1 引言.....41
3.2 数据和方法.....42
3.3 再分析产品对多层 Ts 平均状态的表征能力.....44
3.4 不同环境背景下再分析 T_s 产品的精度表现.....46
3.4.1 不同季节精度表现.....46
3.4.2 不同土地类型精度表现.....47
3.4.3 不同海拔区间精度表现.....48
3.5 不同数据捕捉长期变暖信号的能力.....49
3.5.1 基于观测数据的变暖信号.....49
3.5.2 再分析产品对变暖幅度的表征及其空间格局.....50
3.6 不同产品热过程指标的一致性.....51
3.6.1 土壤热浪指标的空间格局及产品间一致性.....51
3.6.2 土壤冻融指标的空间格局及产品间一致性.....53
3.7 讨论.....56
3.7.1 再分析 *Ts* 产品精度表现的垂向分异及环境依赖性.....56
3.7.2 再分析产品表征长期土壤变暖的可靠性.....56
3.7.3 关键土壤热动态过程中的过程依赖性表现.....57
3.7.4 产品选择与未来模型发展的启示.....58
3.8 小结.....58
第四章 基于空间自适应模型的中国逐日多层土壤温度估算.....61
4.1 引言.....61
4.2 数据和方法.....63
4.3 空间自适应建模的精度表现.....64
4.3.1 局部自适应建模的多模型精度表现.....64
4.3.2 基于通量站点的精度评估.....65
4.4 不同土地覆盖类型和季节的精度评估.....67
4.5 不同土壤温度产品比较.....69
4.6 不同深度土壤温度产品时空格局.....70
4.7 讨论.....73
4.7.1 空间自适应模型的优势.....73
4.7.2 土壤温度产品的潜在应用.....74
4.7.3 局限性与未来展望.....74

4.8 小结.....76
第五章 土壤复合干热事件时空变化及其对玉米的影响.....79
5.1 引言.....79
5.2 数据和方法.....80
5.3 SCDHWs 的时空趋势.....82
5.3.1 SCDHWs 的空间格局.....82
5.3.2 SCDHWs 的变化趋势.....84
5.4 SCDHW 期间玉米 NPP 损失的物候期差异及驱动机制.....85
5.4.1 不同农业区玉米关键物候期 NPP 损失的分布差异.....85
5.4.2 玉米 NPP 损失的关键驱动因子及非线性响应.....86
5.5 不同物候期 SCDHWs 对玉米产量损失的敏感性.....89
5.6 讨论.....92
5.6.1 SCDHWs 的时空分布特征及区域差异.....92
5.6.2 SCDHWs 对玉米生产力影响的物候差异.....93
5.6.3 生产力与产量损失的差异及风险启示.....94
5.7 小结.....95
第六章 结论与展望.....97
6.1 主要结论.....97
6.2 创新点.....98
6.3 研究不足和展望.....99
参考文献.....101
附录.....119
致谢.....127
作者简介.....129

第一章 绪论

1.1 研究背景、目的和意义

以全球变暖为主要特征的气候变化已成为科学界、政府和公众关注的重要环境问题之一（Alexandrov et al. 2000）。气候变暖不仅改变了陆地生态系统的结构和功能，也引起了多种生态过程变化，并影响生态系统稳定性（Hansen et al. 2015）。已有大量研究关注全球变暖背景下生态系统过程对气温升高的响应（Hansen et al. 1987；Vose et al. 2005）。然而，与空气温度相比，土壤温度（Soil temperature, T_s）作为连接地表能量交换、地下热传输、水热耦合过程和生态系统功能的重要陆面热学变量，其长期变化特征、空间异质性及生态效应仍缺乏系统认识，尤其是不同深度 T_s 变化的时空差异及其对农业生态系统的影响仍有待进一步阐明（Zhang et al. 2005；García-García et al. 2023）。

T_s 是调控土壤系统中物理、化学、生物及微生物相互作用类型与速率的关键环境因子（Kim et al. 2014；Crowther et al. 2016）。其变化能够直接影响有机质分解与形成过程，调节氮、磷、钾等养分的矿化与固定，以及硝化和反硝化等氮转化过程（Ulrich et al. 1978；Sierra 2002）。在土壤剖面尺度上，营养物质的分解与迁移速率在很大程度上受温度条件调节（Davidson et al. 2006），进而影响土壤碳库动态、土壤肥力和生态系统生产力，并通过改变二氧化碳释放速率参与全球碳循环调节（Yang et al. 2011）。与此同时，T_s 也是控制地表与大气相互作用的重要因素（Ham et al. 1992；Qian et al. 2011），能够通过调节感热与潜热通量分配影响陆气能量交换过程和大气边界层结构（Mahanama et al. 2008；Chen et al. 2021）。在寒区生态系统中，T_s 对冻融循环具有显著控制作用（Shati et al. 2018），多年冻土融化可能引发地表结构变化及地下水文过程重组（Zhang et al. 2005）。因此，T_s 不仅影响土壤内部生物地球化学过程，也通过能量交换、水热传输和碳循环反馈作用于区域乃至全球气候系统。

在农业生态系统中，T_s 是影响作物生长发育和生产力形成的关键环境因子之一（Sadras et al. 2009；Zhang et al. 2023a）。耕层 T_s 直接影响作物播种期、出苗期和早期生长条件，进而影响整个生育期长度及产量形成过程（Li et al. 2016）。适宜的 T_s 能够促进种子萌发、幼苗整齐出苗和根系生长，而过低或过高的 T_s 则可能导致发芽延迟、生长受抑或生理胁迫。合理确定播种日期是实现作物稳产高产的重要农艺措施，在当前及未来气候变化背景下尤为关键（Abbas et al. 2019；Kath et al. 2019）。随着气候持续变暖，全球表层 T_s 可能持续升高（IPCC 2019；Soong et al. 2020），作物生长期缩短、生育后期热胁迫风险增强、品种适应性改

变和播期调整等问题将更加突出（Abbas et al. 2019；Kath et al. 2019）。此外，T_s的季节性与地域差异还会影响作物品种适应性及其表型和基因型表达（Valdés et al. 2019）。除直接影响作物生育进程外，T_s还通过调节土壤微生物活动、有机物分解与养分矿化等生物地球化学过程，间接影响作物养分供给和生长状况（Kang et al. 2000；Honma et al. 2022）。与此同时，T_s还影响土壤中病原体与害虫的生命周期及繁殖节律（Katan 1981；Roberts et al. 1981），异常升温可能改变病虫害发生频率与强度，进而影响农田生态系统稳定性。因此，可靠的T_s数据不仅是土壤热环境监测和生态过程模拟的重要基础，也是开展作物水热胁迫诊断、农业气候风险评估和粮食安全研究的关键支撑（Opedal et al. 2015；Zellweger et al. 2020）。

在全球气候变化背景下，极端气候事件的频率与强度显著增强，其中复合干热（Compound Drought-Heatwave，CDHW）事件已成为农业气候风险研究的重要议题（胡金鹏等 2025）。大量研究表明，高温与干旱的协同作用往往对作物生长和产量形成产生非线性叠加效应，其影响强度显著高于单一气候胁迫。现有CDHW 识别框架主要基于气温与降水指标构建，强调大气层面的“热异常”与“水分亏缺”协同特征，在刻画区域气候干热背景方面具有合理性（黄茂伟等 2025）。然而，从农业生态系统过程看，作物对复合干热事件的响应不仅取决于大气热胁迫和降水亏缺，也直接受到耕层土壤热状态和土壤湿度（Soil Moisture，SM）条件的共同调控。土壤高温能够改变土壤蒸发、根系活动、养分转化和作物水分吸收过程，SM 亏缺则会限制蒸腾和光合碳同化，并可能放大高温胁迫对作物生长的不利影响。因此，仅依赖大气指标可能难以充分刻画农业系统实际面临的根区土壤水热复合胁迫。中国是全球重要粮食生产国，玉米是我国主要粮食作物之一，其生长发育和产量形成对耕层水热环境高度敏感（周广胜 2015）。中国横跨寒温带至热带多个气候带，地形起伏显著，T_s和 SM 空间异质性强，不同农业区在气候背景、SM 条件、种植制度和作物物候进程方面存在明显差异。在气候变暖与复合干热事件频发背景下，不同区域玉米受到的土壤水热复合胁迫强度及其生产力和产量响应可能存在显著差异。尤其是玉米不同物候阶段对水热胁迫的敏感性并不一致。因此，基于本研究生成的高精度 T_s 数据和已有的高分辨率 SM 数据识别中国土壤复合干热事件（Soil Compound Drought-Heatwaves，SCDHWs），并进一步解析其对玉米生产力损失和产量损失影响的物候阶段差异，对于提升农业气候风险评估的科学性和针对性具有重要意义。

解决上述科学问题的前提是获得长时间序列、高精度T_s数据。然而，在实际观测层面，T_s数据获取仍面临显著挑战。多层T_s观测主要依赖地面站点布设，设备成本高、维护复杂，导致观测网络空间分布不均，尤其在复杂地形、干旱半干

旱区和高海拔区域更为稀疏，深层 T_s 数据尤为缺乏。此外，T_s 受气象因子、地形条件、土壤性质、积雪覆盖、植被类型和土地利用方式等多重因素共同影响，其形成机制具有显著的非线性和空间异质性。仅依赖有限站点观测，难以全面刻画区域尺度 T_s 的连续时空变化特征，也难以支撑大范围 SCDHWs 识别和农业影响分析。因此，长时间序列、高分辨率、多层 T_s 数据不足，是制约基于土壤状态开展复合干热事件研究的重要数据瓶颈。

再分析产品为弥补 T_s 观测不足提供了重要数据来源。ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q 等产品能够提供时空连续的格网化 T_s 数据，已被广泛应用于区域和全球尺度土壤热环境研究。然而，不同再分析产品在陆面模式结构、土壤层划分、土壤热传导参数设定、气象驱动和同化策略等方面存在差异，其在复杂地形、多气候背景和不同下垫面条件下的模拟精度并不一致。特别是在多层 T_s 结构、长期变化趋势和关键土壤热过程表征方面，不同产品之间可能存在明显偏差。如果不明确这些产品在中国复杂地理环境下的适用性和不确定性，直接将其用于 SCDHWs 识别，可能会影响事件识别结果和农业风险评估结论的可靠性。因此，系统评估主流再分析 T_s 产品在中国区域的模拟精度、长期趋势可靠性以及关键土壤热过程表征能力，是开展高精度 T_s 数据重构和后续 SCDHWs 识别的重要前提。

在明确再分析 T_s 产品适用性和局限性的基础上，进一步构建高精度、多层、长时间序列 T_s 数据集，是支撑 SCDHWs 识别的关键环节。现有 T_s 预测方法主要包括机理模型、数值模型和数据驱动模型。机理与数值模型具有明确的物理基础，但参数需求高、公式复杂，难以在大范围、高精度和长时间序列条件下直接推广应用。传统线性数据驱动模型难以充分捕捉 T_s 与气象、地形、土壤和植被因子之间复杂的非线性关系，预测能力有限（张慧智等 2009）。近年来，机器学习方法在 T_s 预测中取得进展，能够更有效刻画多因子之间的非线性耦合关系（徐俊杰等 2025）。但现有研究多侧重表层或浅层 T_s 预测，对 10-40 cm 等较深层 T_s 模拟中涉及的土壤垂向热传输、空间异质性和区域泛化能力考虑仍然不足。中国地形复杂、气候类型多样、下垫面异质性强，单一全局模型难以同时兼顾局地差异和空间泛化能力。因此，融合地面 T_s 观测、卫星遥感、再分析气象资料以及地形和土壤属性变量，构建空间自适应的多层 T_s 重构框架，对于生成中国区域高精度多层 T_s 数据集具有重要意义。

基于上述科学问题，本文围绕“基于中国高精度 T_s 数据的 SCDHWs 识别及其对玉米的影响研究”这一主题展开。首先，针对现有 T_s 产品能否支撑中国区域土壤热过程刻画和 SCDHWs 识别的问题，系统评估 ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q 等主流再分析 T_s 产品在中国区域的适用性与局限性，明确

其在不同土层、季节、土地覆盖类型和海拔条件下的精度表现，以及对长期增温趋势、土壤热浪和冻融过程的表征能力。其次，针对长时间序列、高分辨率、多层 T_s 数据不足的问题，融合地面 T_s 观测、卫星遥感、再分析气象资料以及地形和土壤属性数据，构建空间自适应建模框架，重构 2001-2020 年中国逐日 1 km 分辨率多层 T_s 数据集。最后，利用本研究生成的高精度 T_s 数据集，并结合已有的高精度 SM 数据，识别中国 SCDHWs 并量化其时空变化特征和区域差异，进一步结合玉米物候、净初级生产力（Net Primary Production，NPP）和产量数据，解析 SCDHWs 对玉米生产力和最终产量影响的物候阶段差异。通过上述研究，本文旨在从 T_s 数据可靠性评估、高精度 T_s 数据构建、SCDHWs 识别和玉米影响解析四个方面，深化对气候变化背景下农业系统土壤水热复合胁迫及其作物响应过程的认识，为土壤热环境监测、复合极端事件风险评估、农业适应策略制定和粮食安全保障提供数据支撑与理论依据。

1.2 国内外研究进展

1.2.1 土壤温度数据来源与产品发展

T_s 是陆面能量平衡、水热交换及生物地球化学循环中的关键状态变量，对植被生长、根系活动、微生物代谢及土壤碳循环等过程具有重要调控作用（Kim and Singh 2014）。然而，在大尺度生态建模与气候变化影响评估中，受限于数据可得性，研究者往往以 2 m 空气温度作为 T_s 或地下热环境的替代变量（Du et al. 2020；van den Hoogen et al. 2019）。这种做法在气候尺度分析中具有一定合理性，但在涉及地下过程或微气候调控机制时，可能存在理论与尺度层面的偏差（Lembrechts et al. 2019）。

简单使用观测的气温替代 T_s 时往往会产生一定的偏差。这种差异或偏移的方向和大小是由两个因素组合所产生。一方面，二者在垂直方向上存在显著的小气候差异；另一方面，标准气象站通常设置于平坦、开阔环境，其观测结果难以代表复杂地形或不同植被覆盖条件下土壤的实际热环境（De Frenne et al. 2021；Lembrechts et al. 2020）。本质上，这种偏移反映了地表能量收支过程在垂直与水平方向上的空间异质性。地表通过吸收太阳短波辐射获得能量，并通过长波辐射、感热通量与潜热通量等形式向大气释放能量。辐射吸收与再分配过程经由对流交换与蒸散作用传递至近地层空气，从而形成空气与土壤之间的垂直温度梯度；同时，由于净辐射与湍流交换在不同下垫面上的差异，又进一步导致温度场在水平方向上的不均一分布（Gelaro et al. 2017）。这种垂直与水平方向的温度差异在不同空间与时间尺度上呈现显著变化，其强度与方向受多种环境因子调控。例如，地形朝向、坡度、冠层覆盖度及地表反照率等因素会改变辐射收支格局；而对流

交换强度、蒸散过程以及土壤的储热与导热能力（如土壤质地、结构及含水量）则进一步影响热量在土壤—大气界面之间的传输效率（Bond-Lamberty et al. 2005；Geiger et al. 2009；De Frenne et al. 2021）。

T_s 作为陆面过程研究中的关键变量，也是气象站常规观测的重要参数之一。然而，由于地形复杂性、人类活动干扰及恶劣气候条件的限制，气象站点在全球范围内分布高度不均。以中国为例，气象站点空间分布具有明显的不均衡性，观测站主要集中于东部平原和人口活动较为集中的地区，而西北干旱半干旱地区以及青藏高原（Qinghai-Tibet Plateau，QTP）等高海拔复杂地形区域站点密度相对较低，部分区域严重缺乏长期连续的观测资料。此外，站点迁移、仪器更新引起的观测中断等因素可能引入非气候性突变或数据缺测，影响原位 T_s 记录的连续性和一致性（Quayle et al. 1991；Chenoweth 1992）。同时，原位观测主要以点位测量为主，空间代表性有限，难以直接刻画 T_s 连续的空间分布特征。

为弥补原位观测的以上不足，基于陆面模式与数据同化技术构建的格网化 T_s 产品逐渐成为重要的数据来源。当前广泛应用的再分析产品主要包括 ERA5-Land 和 GLDAS 等（Muñoz-Sabater et al. 2021）。这类产品通过模式驱动与同化技术，在全球或区域尺度上提供多层 T_s 数据，具有时间连续、空间覆盖广泛的优势。然而，其空间分辨率通常在数公里至数十公里尺度（如 ERA5-Land 约 9 km，GLDAS 约 25 km），在复杂地形或下垫面高度异质区域难以刻画微尺度热环境变化。除再分析产品外，一些区域尺度的插值型 T_s 数据集也相继构建。例如，Wang 等（2023）基于 2000 余个气象站观测数据，采用薄板样条插值和反距离加权方法构建了 1960-2017 年中国逐日多层（0、5、10、15、20 和 40 cm）T_s 数据集。该数据在长期趋势刻画方面具有重要意义，但其空间分辨率为 0.25°（约 27 km），仍然难以满足精细生态建模及局地尺度研究需求。近年来，随着 ML 方法在地球系统科学中的广泛应用，基于多源观测数据构建经验型 T_s 产品成为新的发展方向。例如，Lembrechts 等（2022）利用全球 8519 个 T_s 传感器构建随机森林模型，生成全球尺度的土壤生物气候变量数据集。该数据集在揭示土壤热环境的空间格局方面具有重要意义，但其结果为长期气候平均值，而非高时间分辨率的逐日估计值，因而难以直接应用于过程模拟或极端事件分析。

总体而言，现有 T_s 格网数据产品（详细的数据介绍见表 1.1）主要可分为再分析、站点数据插值与 ML 方法三类。前者在时间连续性方面具有优势，但空间分辨率有限；后两类在区域尺度或空间异质性刻画方面有所提升，但仍受制于分辨率、观测密度或时间尺度的限制。因此，在复杂地形和高度异质下垫面条件下，高时空分辨率、能够准确反映土壤热环境动态变化的格网化 T_s 产品仍然缺乏。尽管 T_s 变化的物理机制已得到较为系统的理论阐释（Geiger et al. 2009），但受

限于观测网络不足、驱动变量尺度不匹配及现有产品空间分辨率有限等问题（Lembrechts et al. 2020），高时空分辨率、能够准确反映复杂下垫面热环境异质性的 T_s 格网产品仍然缺乏。因此，融合多源数据和 ML 方法、构建具有更高精度与更长时序的 T_s 数据集，已成为当前陆面过程与生态系统研究的重要方向。

表 1-1 当前主要的 T_s 格网数据集

Table 1-1 Summary of the T_s datasets

数据集 Dataset	T_s 深度（cm） T_s layers (cm)	时间分辨率 Temporal resolution	空间分辨率 Spatial resolution	时间范围 Time coverage	空间范围 Spatial coverage	参考文献 References
ERA5-Land	skin temperature, 0-7, 7-28, 28-100	Daily	0.1°	1980-2020	Global	（Muñoz-Sabater et al. 2021）
GLDAS 2.0	AvgSurfT_inst, 0-10, 10-40, 40-100	Daily	0.25°	1980-1999	Global	（Rodell et al. 2004）
GLDAS 2.1	AvgSurfT_inst, 0-10, 10-40, 40-100	Daily	0.25°	2000-2020	Global	（Rodell et al. 2004）
JRA-3Q	0, 7, 19, 49	Daily	0.25°	1980-2020	Global	（Kosaka et al. 2024）
MERRA-2	0, 9.8, 19.5, 38.5	Daily	0.5° × 0.625°	1980-2020	Global	（Gelaro et al. 2017）
TS25	0, 5, 10, 15, 20, 40	Daily	0.25°	1960-2017	China	（Wang D et al. 2023）
Global Soil Bioclimatic	0-5，5-15	Monthly	1km	1979-2013	Global	（Lembrechts et al. 2022）

1.2.2 土壤温度长期变化趋势

在全球气候变暖背景下，T_s 的变化趋势及其气候反馈效应日益受到关注。区域和全球气候模型预测结果显示，全球平均气温已显著上升并将持续上升（Adopted 2014）。气温升高影响了土壤热状况，进而影响了土壤与大气之间的能量交换（Kurylyk et al. 2014；Streletskiy et al. 2015）。IPCC 第五次评估报告指出，在多套数据集中，过去几十年全球地表温度（Land Surface Temperature，LST）均呈现显著升温趋势（Masson-Delmotte et al. 2021）。在这一背景下，长期观测数据和模型模拟成为了解其变化趋势及可能影响的关键途径。

基于长期站点观测的研究表明，T_s 在多数地区呈现不同程度的升温趋势，但其变化特征在区域、季节与不同深度上存在显著差异。Hu 等（2003）对美国 292 个站点数据分析发现，10 cm 深度的 T_s 在 10 年内增加了 0.32 ℃。Qian 等（2011）

基于加拿大 30 个气候站在 1958-2008 年期间的 T_s 数据，同时结合对应站点的气象数据（气温、降水）和积雪深度，对 5、10、20、50、100 和 150 cm 深度的 T_s 变化趋势进行了分析，结果表明春夏季 T_s 呈轻微上升趋势，但冬季和全年的平均水平显示 T_s 没有明显上升趋势。Araghi 等（2017）通过对 1993-2016 年间伊朗北部七个气象站点多个深度土壤（5、10、20、50 和 100 cm）长时间序列观测数据分析，研究发现大多数站点在较温暖月份（4-8 月）呈现出一定的增温趋势，而其他月份这种趋势则不明显。Dorau 等（2022）在德国西部的长期观测中发现，T_s 增温幅度（1.76 ± 0.59 ℃）高于气温（1.35 ± 0.35 ℃），且夏季（6-8 月）增温最为显著。总体而言，国外研究表明 T_s 变化呈现出明显的季节依赖性和深度差异特征，且在部分地区增温幅度可能超过空气温度。

T_s 的长期变化在中国范围内同样表现出显著的区域和季节差异。Zhang 等（2016）基于 1962-2011 年全国 360 个站点数据分析发现，地表 T_s 整体呈显著升温趋势，且不同区域增温幅度存在明显差异，冬季升温幅度普遍高于其他季节，也使中国的潜在生长季节最多延长 20 天。研究还指出，预计 T_s 上升将导致土壤呼吸增加约 28%，进而导致向大气中释放的碳比预期更多并进一步加剧气候变暖。Wang 等（2018）的研究表明，自 20 世纪中叶以来，空气和土壤表面温度的整体升温趋势表现出相似的空间模式，除 QTP 外，纬度较高的地区相对经历了更大的变化。最低和最高土壤表面温度表现出显著的升温趋势，其中最低温度的上升速度快于最高温度，导致土壤表面的昼夜温差降低。不同于原位观测，Fang 等（2021）基于改进的社区土地模型（CLM4.5）评估了 1961-2010 年期间 QTP 水热状态的年际变化，结果表明 T_s 产生显着的变暖趋势，幅度范围为 0.19 ℃/10 年-0.42 ℃/10 年。这些研究均表明 T_s 变化具有明显的空间异质性和季节差异性，且土壤增温趋势可能对生态系统功能产生深远影响。

T_s 还可能通过热储存效应与陆气相互作用影响区域气候过程。Hu 等（2004）通过对美国 30 年内 300 个站点的 T_s 进行分析，结果表明 20-50 cm 土壤深度处的热储存可以持续 2 到 3 个月，进而可能影响美国西南部降水的年际变化。此外，也有研究表明，在中国西北干旱半干旱地区，前期的 T_s 是预测中国东部平原地区气候变化的主要因子之一（Wang et al. 2013）。区域气候模式模拟亦表明，地下 T_s 对中国干旱和半干旱地区夏季地表气温变化具有重要调节作用（Wu et al. 2014）。此外，T_s 异常还可能通过动力与热力过程向下游传播，对远距离气候系统产生影响（Xue et al. 2012）。

综上所述，现有研究表明 T_s 不仅呈现显著的长期变化趋势，而且在陆气相互作用与区域气候调节中发挥重要作用。然而，由于长时间序列与大尺度 T_s 数据仍然相对匮乏，特别是在复杂地形与高寒地区，现有研究对其变化特征与气候

反馈机制的认识仍不充分。这一数据瓶颈限制了对 T_s 在气候系统中作用的全面理解，也进一步凸显了构建高质量 T_s 数据集的重要性。

1.2.3 土壤温度估算方法研究进展

T_s 是连接地表能量分配、土壤水热传输、陆气相互作用和生态系统过程的重要状态变量，对土壤物理化学过程、冻融循环、根系活动及植物生长发育均具有重要影响。因此，准确监测与预测 T_s，尤其是不同深度 T_s 的时空变化，一直是陆面过程模式、数值天气预报、气候预测、水文模拟及生态模型研发中的重要内容。然而，T_s 原位观测通常受到站点数量、观测深度、维护成本和数据连续性的限制，许多区域缺乏长期、连续、多层次的空间化 T_s 观测资料。尤其在地形复杂、下垫面异质性强和观测站点分布不均的区域，如何基于有限观测信息对 T_s 进行高精度预测，并将站点尺度 T_s 扩展到区域尺度，仍是当前研究中的关键问题。

T_s 的变化受太阳辐射、气温、湿度、降水、风速等气象因子，以及地形条件、土壤质地、土壤含水量、土壤导热率、植被覆盖和地表覆盖状况等多因素共同影响（Kang et al. 2000；邵明安等 2006；Bond-Lamberty et al. 2005；Feng et al. 2019）。围绕这些影响因素及其作用机制，已有研究发展多种 T_s 预测方法。总体上，可将其归纳为两大类：一类是基于热传导、能量守恒和水热耦合过程的物理过程模型，包括解析型机理模型和过程型数值模型；另一类是基于观测数据建立经验关系或非线性映射的数据驱动模型，包括传统统计模型和 ML 模型。

（1）基于物理过程的 T_s 模拟方法

基于物理过程的 T_s 模拟方法以热传导理论、能量守恒原理和土壤水热耦合过程为基础，是 T_s 预测研究中最早发展的方法类型。其中，解析型机理模型通常从一维热传导方程出发，将土壤视为半无限介质，并以地表温度或地表热通量作为上边界条件，推导不同深度 T_s 的周期性变化。经典热传导理论认为，土壤中某一深度处的热通量主要由温度梯度控制，可表示为：

$$Q_g = -\lambda \frac{\partial T}{\partial z} \tag{0-1}$$

式（1-1）中，负号表示热流沿温度梯度方向传输。Q_g 为土壤热通量，λ 为土壤导热率（$W \cdot m^{-1} \cdot K^{-1}$），$T$ 为土壤温度，z 为土壤深度。进一步结合土壤热量守恒，在忽略水平热传导并假定土壤介质均质的条件下，可得到一维热传导方程

$$\frac{\partial T}{\partial t} = k \frac{\partial^2 T}{\partial z^2} \tag{0-2}$$

$$k = \frac{\lambda}{C_g} \tag{0-3}$$

式（1-2）中，k（$m^2 \cdot s^{-1}$）为土壤热扩散率，C_g 为土壤体积热容量。该式刻

画了 T_s 随时间和深度变化的基本物理过程，是后续 T_s 解析模型和陆面模式土壤热传输方案的重要理论基础。

在此基础上，早期研究通常将地表温度日变化近似为正弦函数，并利用谐波法、振幅法和相位法推算不同深度的 T_s 变化。相关研究比较了谐波法、振幅法和相位法在估算土壤热扩散率和预测不同深度 T_s 方面的适用性（莫兴国等 2002；Thoma et al. 2013；Hu et al. 2016a）。这类方法结构简洁、物理意义明确，能够较好解释 T_s 振幅随深度衰减和相位随深度滞后的现象，但其通常依赖理想化假设，如土壤介质均质、热扩散率恒定、边界条件规则周期变化等，因此在复杂下垫面和强水热耦合环境中的适用性有限。随着对土壤水热过程认识的加深，研究者逐渐认识到，T_s 的变化不仅受热传导控制，还与 SM 垂直运动引起的热对流过程有关。Gao 等（2003）在一维热传导方程基础上引入液态水垂直运动项，提出了土壤热传导—对流方程：

$$\frac{\partial T}{\partial t} = k\frac{\partial^2 T}{\partial z^2} + W\frac{\partial T}{\partial z} \tag{0-4}$$

式（1-4）中，W 为总体对流参数，反映 SM 垂直迁移对热量传输的影响。相较于经典热传导模型，热传导—对流方程进一步考虑了 SM 运动引起的热量输送，因而更适用于描述湿润土壤、干湿交替及近地表水热耦合过程。围绕该方程的求解，已有研究主要采用谐波法、拉普拉斯变换法和傅里叶级数扩展等方法（Gao et al. 2003；Wang et al. 2012）。其中，谐波法通常假设地表温度日变化呈正弦形式，用于揭示 T_s 随深度增加而产生的振幅衰减和相位滞后；拉普拉斯变换法可处理初始 T_s 剖面随深度变化的情形；傅里叶级数扩展则可更好逼近实际地表温度的复杂周期变化。后续研究还进一步考虑土壤热扩散率随深度变化和对流参数日变化，从而提高了热传导—对流方程对真实土壤水热传输过程的表征能力（Hu et al. 2016a；张建彬等 2023）。

尽管解析型 T_s 预报方程具有明确的物理意义，并能够揭示 T_s 垂向传播的基本规律，但其通常依赖较强的理想化假设，如土壤介质均质、半无限、热力学参数稳定及边界条件周期规则等，难以充分反映实际土壤剖面中土壤质地、含水量、容重和导热率的空间异质性。同时，现有热传导—对流方程虽然考虑了液态水垂直运动的影响，但对液态水、固态冰和气态水等全相态土壤水的耦合作用，以及冻融、积雪、植被覆盖和根系活动等过程考虑仍不充分。上述局限使得解析型模型更适合用于解释土壤热传输机制、反演土壤热扩散率和约束模型物理过程，而在复杂环境下开展连续 T_s 模拟时，仍需借助能够显式刻画多过程耦合的过程型数值模型。

除解析型方程外，过程型数值模型也是 T_s 预测的重要方向。与解析型模型

相比，数值模型能够更全面地刻画 SM 迁移、热量传输、冻融相变、积雪覆盖和地表覆盖变化等复杂过程。早期研究基于能量守恒和水分迁移理论，建立了描述土壤中液态水、气态水和热量耦合传输的模型（De Vries1958）。随后，相关研究进一步利用 Richards 方程、有限差分方法和陆面过程模型模拟非饱和土壤中的水热传输过程。例如，Liu 等（2005）模拟了干燥土壤中的水分蒸发及温湿度分布，Belghit 等（2014）构建了考虑非饱和土壤热量和质量传输的模型，Gao 等（2016）分析了降雨对土壤热量和湿度条件的影响，并使用 Richards 方程建立了一维土壤热量和湿度迁移模型。Herb 等（2008）利用隐式有限差分模型模拟了不同地表覆盖条件下的土壤表面温度。在陆面模式中，土壤导热率、热容量和热扩散率等热力学参数直接影响 T_s 模拟结果。其中，土壤导热率是控制土壤热传导过程的关键参数，通常可表示为干土壤导热率、饱和土壤导热率和 Kersten 数的函数：

$$\lambda = (\lambda_{\text{sat}} - \lambda_{\text{dry}})K_e + \lambda_{\text{dry}} \tag{0-5}$$

式（1-5）中，λ_{sat} 和 λ_{dry} 分别为饱和土壤和干土壤导热率，K_e 为 Kersten 数。不同导热率参数化方案对 T_s 模拟具有显著影响。Johansen 模型较早被广泛用于陆面模式，但其在低含水量条件下可能低估土壤导热率（Johansen 1977）；Côté-Konrad 模型和 Lu-Ren 模型进一步改进了 K_e 的表达形式，并考虑土壤质地或低含水量条件下的适用性（Côté et al. 2005；Lu et al. 2007）。任余龙等（2022）在 CLM4.5 模式中比较了 Johansen、Côté-Konrad 和 Lu-Ren 三种土壤导热率模型对中国北方地表温度模拟的影响，结果表明 Lu-Ren 方案在模拟误差、均方根误差和变化趋势表征方面整体表现较好，说明土壤热参数化方案对陆面模式 T_s 模拟具有重要影响。

总体而言，基于物理过程的 T_s 模拟方法以热传导、能量守恒和水热耦合理论为基础，能够较好刻画土壤热量传输、水分迁移、冻融相变、积雪覆盖及地表能量交换等关键过程，具有明确的物理意义和较强的可解释性，是陆面模式、气候模式和水文生态模型中 T_s 模拟的重要基础。然而，此类方法通常依赖较多边界条件、土壤热力学参数和初始条件，对土壤质地、含水量、导热率、植被覆盖和地表覆盖状况等参数设置较为敏感。尤其在地形复杂、下垫面异质性强和观测资料不足的区域，模型参数化误差和初始条件不确定性容易影响 T_s 模拟精度。同时，物理过程模型在大尺度、高分辨率和长时间序列模拟中通常面临较高计算成本，限制了其在区域连续 T_s 数据重建中的直接应用。为弥补上述不足，基于观测数据和多源环境变量建立统计关系或非线性映射的数据驱动方法逐渐成为 T_s 预测和空间扩展的重要补充。

（2）基于数据驱动的 T_s 预测方法

随着地面观测、遥感数据、再分析资料和人工智能技术的发展，基于数据驱动的 T_s 预测方法逐渐成为区域 T_s 估算和空间扩展的重要手段。与物理过程模型不同，数据驱动模型不直接求解土壤水热传输方程，而是基于观测数据建立 T_s 与气象、遥感、地形、土壤和植被因子之间的统计关系或非线性映射关系。早期研究多采用线性回归、多元回归和非线性回归等传统统计模型。例如，部分研究基于气温、降水、太阳辐射、地形和地表覆盖等变量构建线性模型预测不同深度 T_s（Kang et al. 2000；Bond-Lamberty et al. 2005）。此类方法结构简单、参数含义明确，在数据条件有限时具有一定适用性，但由于其通常假设自变量与 T_s 之间呈线性或预设函数关系，难以充分刻画复杂环境因子之间的非线性作用和交互效应。

相较于传统统计模型，机器学习模型能够更灵活地处理多源变量之间的非线性关系和高维特征空间，因此近年来被广泛应用于 T_s 预测研究。Mihalakakou 等（2002）较早将人工神经网络（ANN）用于土壤表面温度模拟，结果表明 ANN 能够较好再现土壤表面温度的日变化和年变化特征。Bilgili（2010）比较了线性回归、非线性回归和 ANN 在月均 T_s 预测中的表现，并分析了气象参数与 T_s 之间的关系。Kisi 等（2015）进一步比较了广义回归神经网络、径向基神经网络和多层感知器神经网络等方法，表明基于数据挖掘的非线性模型能够有效预测月尺度 T_s。Ozturk 等（2011）基于地理和气象变量构建 ANN 模型预测月均 T_s；Araghi 等（2017）表明，结合小波变换的 ANN 模型能够较好预测提前 1-7d、5-30 cm 深度的 T_s；Citakoglu（2017）比较了 ANN、自适应神经模糊推理系统（ANFIS）和多元线性回归模型，发现 ANFIS 在 T_s 预测中表现较优；Sanikhani 等（2018）利用极限学习机（ELM）、ANN 和 M5 树模型预测不同深度月均 T_s，结果显示 ELM 具有较好的预测能力。Xing 等（2018）应用支持向量机（SVM）预测美国不同气候区的逐日 T_s，验证了 SVM 在不同气候背景下的适用性；Feng 等（2019）进一步比较了 ELM、广义回归神经网络、反向传播神经网络和随机森林模型在半小时尺度 T_s 预测中的表现，发现不同模型在多深度 T_s 预测中均具有可接受精度。

近年来，遥感数据和再分析资料的快速发展进一步推动了 T_s 数据驱动预测从站点尺度向区域尺度扩展。遥感 LST、归一化植被指数（Normalized Difference Vegetation Index, NDVI）、地表反照率、SM、植被覆盖度和地形因子等变量，为 T_s 空间化建模提供了重要信息（李召良等 2016；刘纯等 2025）。Huang 等（2020）基于逐日遥感 LST 和 NDVI 数据构建多元线性回归模型，在站点尺度估算 0、5、10、15、20 和 40 cm 深度 T_s，结果表明浅层 T_s 估算效果较好。随着随机森林、梯度提升树、XGBoost、LightGBM 和深度学习等方法的发展，多源数据融合模型逐渐成为高精度 T_s 估算的重要方向。这类模型能够综合利用站点观测、再分

析资料、遥感产品、土壤属性和地形信息，在提高 T_s 空间连续性和预测精度方面具有明显优势。

总体来看，数据驱动模型在复杂非线性关系建模、多源数据融合和区域尺度 T_s 空间扩展方面具有突出优势，能够在缺乏完整物理参数的情况下实现较高精度的 T_s 预测。然而，此类模型也存在一定局限。首先，模型性能高度依赖训练样本质量和空间代表性，在观测站点稀疏或分布不均区域容易产生外推不确定性。其次，许多机器学习模型的物理可解释性相对不足，难以直接表征热传导、水分迁移、冻融和植被根系等具体过程。再次，已有研究多集中于站点尺度、局地尺度或短时间尺度预测，对长时间序列、高空间分辨率、多层 T_s 数据集构建的关注仍然不足。特别是在中国这样地形复杂、气候类型多样、下垫面异质性强的区域，如何在保证模型精度的同时提高跨区域泛化能力，仍是 T_s 数据驱动建模面临的重要挑战。

综上，现有 T_s 预测方法经历了从解析型热传导模型、热传导—对流模型，到过程型数值模型和机器学习模型的发展过程。基于物理过程的模型强调热传导、水热耦合和能量守恒，具有较强的机制解释能力；数据驱动模型强调从观测和多源数据中学习 T_s 与环境因子之间的复杂关系，具有较强的预测能力和空间扩展潜力。但在长时间序列、高精度、多层 T_s 数据构建方面，现有研究仍存在不足。因此，融合地面观测、再分析资料、卫星遥感、土壤属性和地形辅助数据，并结合具有空间适应能力的机器学习方法，构建适用于复杂区域的多层 T_s 高精度估算框架，是当前 T_s 研究的重要发展方向。

1.2.4 土壤温度对作物生长及产量的影响

T_s 是调控农业生态系统水热环境和作物生长过程的重要因子。与气温相比，T_s 更直接表征作物地下生长环境的热状态，能够通过影响根系形态建成、根系活性、养分吸收、水分利用效率及土壤微生物过程，进而调控作物地上部生长、干物质积累和最终产量形成（Rahman et al. 2019；Honma et al. 2022）。因此，T_s 不仅是地表能量平衡和土壤水热过程的重要组成部分，也是影响农业生产系统稳定性和作物产量响应的重要环境变量。

在作物整个生育进程中，T_s 的调控作用呈现显著的阶段性特征。在播种至出苗阶段，T_s 直接影响种子吸水速率与酶活性水平，进而调节胚根和胚芽的伸长速度与整齐度（Kleber 2010）。适宜的 T_s 有利于提高发芽势与成苗率，而低温会延缓萌发进程，过高温度则可能损伤胚组织并降低出苗质量。在营养生长期，T_s 通过影响根系生长速率、根系构型及根系活性，调节水分与矿质养分的吸收能力（Poorter et al. 2012）。适温条件有助于增强根长、根体积及根系活力，从而提高地上部光合产物的积累效率；当 T_s 超过最适范围时，根系细胞膜稳定性下降，

呼吸消耗增加，导致根系干物质减少与活性降低，进而削弱地上部生长潜力（Xia et al. 2021a）。在生殖生长期，尤其是抽雄、开花至灌浆阶段，T_s 对产量形成的影响更加敏感。耕层热环境通过调节根系供水能力与蒸腾效率，影响光合产物向籽粒的运输与分配（Bu et al. 2013）。土壤增温往往会加速物候进程并缩短灌浆持续时间，在一定范围内可能促进早期生长，但在高温条件下常伴随叶片衰老加速与光合持续时间缩短，从而降低籽粒充实度和最终产量。此外，T_s 还通过调节微生物活性与养分矿化速率，改变氮、磷等养分的有效性，进一步影响作物干物质积累与碳氮分配格局（Liu et al. 2017）。总体而言，T_s 对作物生长的调控具有显著的阶段性与非线性特征，其对产量的影响取决于温度变化幅度、持续时间以及与水分条件的耦合状态。

除对生理过程的直接调控外，T_s 还通过影响发育速率而改变作物生育期长短。增温通常会加快物候进程，缩短从出苗到成熟的时间，从而改变热量资源利用效率与生长季长度（Hou et al. 2014；Guga et al. 2025）。在一定范围内，这可能延长潜在生长季长度并提高早期生长速率，但在高温情景下往往导致生殖阶段提前结束，影响产量形成（Zimmermann et al. 2017；刘玉洁等 2020）。由于不同作物及不同品种对温度的敏感性存在差异，T_s 的地域性差异进一步影响品种适应性与种植制度选择。耐热或根系活性维持能力较强的基因型在高温土壤条件下表现出更稳定的根系形态和光合功能，而热敏感品种则更易出现根系退化与早衰现象（Li et al. 2020）。相关研究表明，T_s 变化不仅影响表型特征，如根长密度、叶面积指数与灌浆速率，还可能通过调控与热胁迫相关的基因表达及抗氧化酶系统活性，改变基因型与环境之间的互作关系（Valdés et al. 2019）。因此，在气候变暖背景下，合理匹配区域土壤热环境与作物基因型特征，成为保障农业生产稳定性的关键策略。

基于实证研究，小麦与玉米等主粮作物对 T_s 变化表现出显著响应。早期田间观测结果显示，10 cm 深度 T_s 与小麦出苗速率之间存在稳定的回归关系，出苗过程可通过 T_s 累积度日进行有效预测（Russelle et al. 1980）。Wu 等（2022）通过增温实验研究土壤变暖对华北地区冬小麦物候、光合作用和产量的影响。结果显示，土壤变暖会促进花前小麦的生长，但会加速花后小麦的衰老，进而影响干物质的运输和积累并降低小麦的产量，特别是在干旱条件下。此外，Li 等（2016）的研究表明，冬季土壤升温会降低小麦对春季低温胁迫的耐受性，表现为水势下降、抗氧化能力减弱、光合性能受损和糖分积累减少，并最终加剧春季低温对产量的不利影响。Roberts 等（1981）证实，T_s 通过调控根结线虫的迁移与侵染活动（阈值约 18 ℃）影响其在冬播小麦上的繁殖过程，延迟播种至 T_s 低于活动阈值可有效降低线虫越冬种群，但对作物产量无显著影响。

玉米对 T_s 变化同样高度敏感，其最适生长温度约为 21-27 ℃（Greaves 1996；Haldimann 1998）。适宜的 T_s 能够促进芽生长和叶片光合作用，从而有利于作物产量形成（Frossard et al. 1985；Borisova 1991）。但有研究指出，当玉米根和茎暴露于空气和土壤高温时，根和茎在过高的 T_s 下会发生更严重的生长抑制（Huang et al. 2000；Ruter et al. 1990）。Stone 等（1999）指出，在寒温带环境下，玉米分生组织出土前的发育速率主要受 T_s 控制，将 T_s 纳入积温计算可显著提高发育预测精度；同时，较高 T_s 通过加速叶面积形成并优化与辐射峰值的同步性，使生物量和产量提高约 21%。Zhang 等（2023b）通过盆栽实验结果进一步证实，土壤变暖通过减少根长、根体积及根干重，降低根系活性，并间接抑制叶片抗氧化酶活性与光合能力，加速叶片衰老，最终降低单株籽粒产量。全球变暖背景下土壤表层温度预计将持续上升（IPCC 2019）。相关研究指出，未来 T_s 升高对玉米生长的限制效应可能超过单纯气温升高的影响（Zhou et al. 2012；Gan et al. 2013；Pramanik et al. 2015；Zhang et al. 2023a）。这进一步说明根区热环境可能成为气候变暖条件下制约玉米生产稳定性的关键因子。

近年来，复合农业干旱与高温事件逐渐成为影响粮食安全的重要气候风险。相关研究表明，基于 SM 与温度的多要素识别框架能够更准确刻画 CDHW 事件强度，与单一干旱或单一高温相比，其对玉米产量的抑制效应更为显著（Wu et al. 2023）。进一步研究表明，T_s 在复合干旱高温事件的形成与强化过程中发挥核心驱动作用，将其纳入复合指数后显著提高了对产量损失的解释能力（Lu et al. 2026）。这表明，T_s 不仅通过直接影响根区生理过程调控作物生长，还可能通过增强水热耦合效应放大极端气候事件对农业系统的冲击（Zhang et al. 2023a）。此外，T_s 的区域差异会影响品种适应性与栽培制度选择。不同基因型对根区温度敏感性不同，耐热品种在高温土壤条件下表现出更强的根系稳定性和光合维持能力（Valdés et al. 2019）。因此，在气候变化背景下，理解 T_s 对作物生理生态过程的调控机制，对于品种选育、播期调整和灌溉管理具有重要指导意义。

综上所述，T_s 通过调控根区热环境影响作物萌发、生长、物候进程及产量形成，并在气候变暖背景下可能对农业生产系统产生放大效应。然而，当前多数农业气候研究仍以气温指标替代 T_s，缺乏对 T_s 时空变化特征及其对作物影响机制的系统评估。观测站点分布稀疏、层次不一致及再分析产品精度差异复杂等问题，进一步限制了 T_s 在农业风险评估中的应用。因此，构建高时空分辨率、长时间序列的 T_s 数据集，对于深入揭示根区热环境变化规律及其对作物生产稳定性的影响机制具有重要意义，也为气候变化背景下农业适应策略的制定提供了关键数据支撑。

1.3 研究内容

研究内容主要分为以下三个部分：

（1）不同再分析 T_s 产品在中国复杂地理环境下的精度评估

基于 1980-2020 年中国区域多层 T_s 原位观测数据，本研究系统评估 ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q 等再分析 T_s 产品的适用性及其不确定性。研究从不同土层深度、季节、土地覆盖类型和海拔梯度等方面，对比分析各产品的精度表现；进一步评估其对中国区域 T_s 长期增温趋势的表征能力，并比较不同产品在土壤热浪和冻融过程等关键土壤热过程指标中的一致性。该部分研究旨在明确不同再分析 T_s 产品在中国区域多层土壤热环境研究中的优势、局限及适用场景。

（2）面向复杂空间异质性的中国长时序、高精度多层 T_s 重构

融合原位 T_s 观测数据、卫星遥感数据、再分析气象资料以及土壤质地、地形因子等静态环境变量，构建空间自适应的多层 T_s 估算框架。该框架通过旋转四叉树划分和 XGBoost 局部建模，刻画 T_s 与气象、植被、地形和土壤属性之间的非线性关系，并实现不同气候带和复杂地形区域下模型参数的自适应调整。同时，采用层级递进的建模思路，利用浅层 T_s 估算结果辅助深层 T_s 模拟，以增强多层 T_s 估算的垂向一致性和稳定性。最终生成 2001-2020 年中国逐日 1 km 分辨率多层（0、5、10、15、20 和 40 cm）T_s 格网数据集，为 SCDHWs 识别及农业气候风险评估提供高时空分辨率数据支撑。

（3）SCDHWs 识别及对玉米生产力和产量的响应

基于本文构建的高精度 T_s 数据集和已有 SM 数据集，构建 SCDHWs 识别框架，将土壤高温与 SM 亏缺的协同发生作为事件识别核心，量化 2001-2020 年中国玉米种植区 SCDHWs 的发生频次、持续时间、峰值强度和累积强度等特征。进一步结合玉米物候、NPP 和产量格网数据，分析不同农业区和不同物候阶段 SCDHWs 对玉米生产力损失和产量损失的影响差异。通过机器学习解释方法和广义加性混合模型，识别不同物候阶段玉米生产力响应的主导因子，并评估 SCDHWs 强度和持续时间对产量损失的阶段性影响。该部分研究旨在揭示 SCDHWs 的时空变化特征及其对玉米生产力与产量影响的差异化过程，为农业复合极端事件风险评估和玉米生产适应性管理提供科学依据。

1.4 技术路线

本研究围绕中国高精度多层 T_s 数据构建及其在 SCDHWs 识别和玉米影响评估中的应用展开，形成了由 T_s 数据可靠性评估、高精度多层 T_s 重构、SCDHWs 识别到玉米生产力与产量影响研究的技术路线。具体包括以下三个阶段：

（1）再分析产品适用性评估

基于全国 T_s 站点观测数据，系统评估四种主流再分析 T_s 产品在中国不同气候区与下垫面条件下的模拟性能，分析其精度表现及环境依赖性，从而识别现有产品的优势与局限。

（2）空间自适应 T_s 数据集构建

针对再分析产品存在的精度不足等问题，构建空间自适应建模框架，整合气候变量、遥感指标、地形与土壤属性等多源数据，在旋转四叉树划分结构下建立局部 ML 模型，重建长时间序列、多深度、日尺度的 T_s 数据集。

（3）SCDHW 识别与农业应用

基于重构的 T_s 数据集和已有的 SM 数据集，识别 SCDHWs 的时空变化特征，分析 SCDHWs 在不同物候阶段对玉米生产力损失和产量损失的影响差异，揭示土壤水热复合胁迫对玉米影响的阶段依赖性。

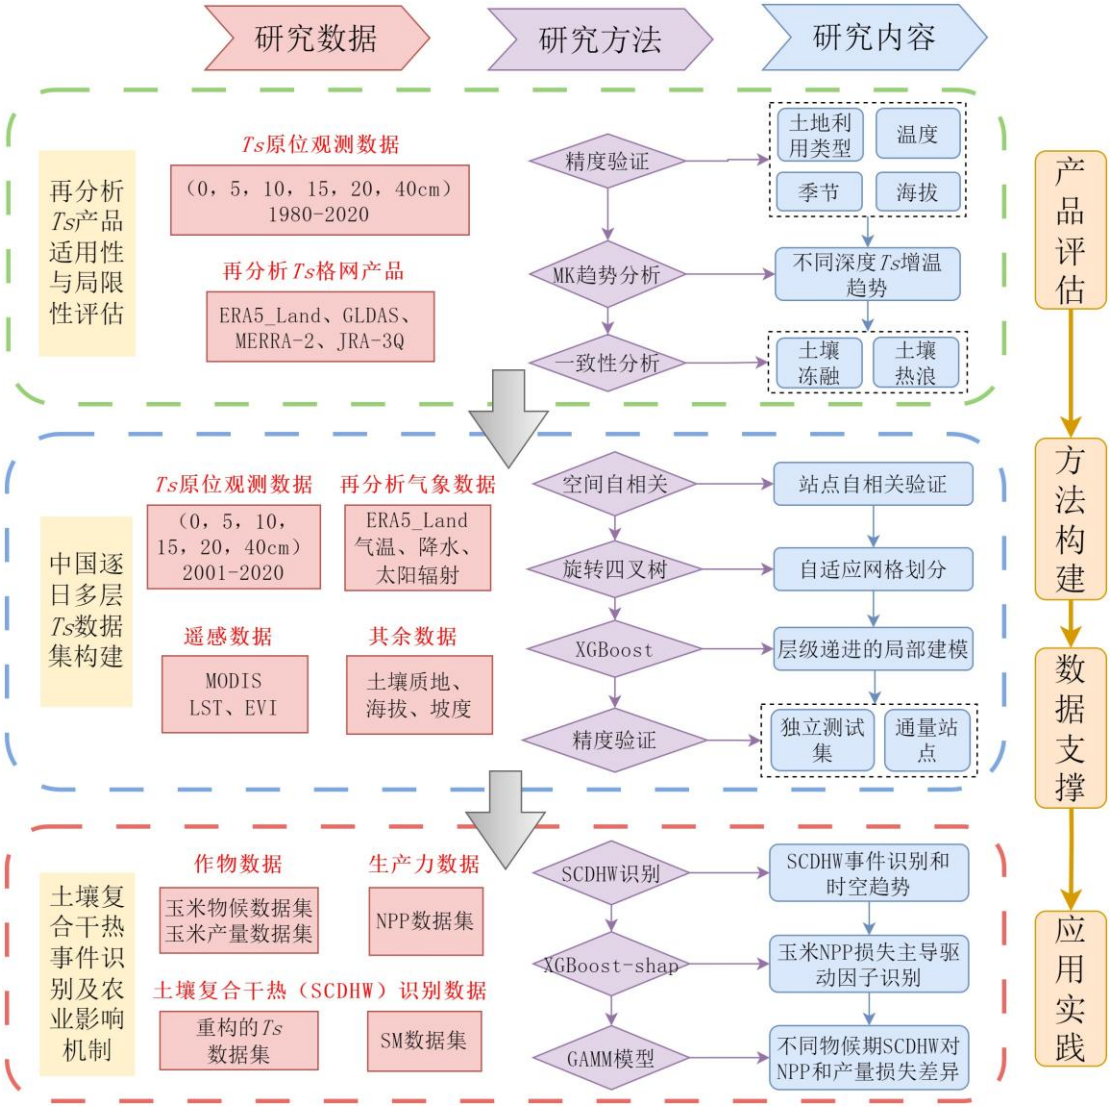


图 1-1 技术路线图。

Figure 1-1. Overall technical roadmap of the dissertation.

第二章 材料与方法

2.1 研究区概况

中国位于亚欧大陆东部，地理范围约为 18°N-54°N、73°E-135°E，横跨寒温带、温带、亚热带和热带等多个气候带。地形总体呈现西高东低的阶梯状分布格局，东部以平原和丘陵为主，西部以高原、山地和盆地为主。其中，青藏高原（Qinghai-Tibet Plateau，QTP）平均海拔超过 4000 m，是全球典型的高寒高海拔区域。复杂的地形起伏和海拔梯度改变了太阳辐射接收、地表能量收支和下垫面热力条件，使中国区域 T_s 具有显著的空间异质性。

中国水热条件也具有明显的区域差异。年降水量总体由东南沿海向西北内陆递减，东南湿润区降水充沛，而西北干旱半干旱区降水稀少；气温总体呈现由南向北、由低海拔向高海拔递减的特征。降水和气温的空间梯度共同影响土壤含水量、热容量、热扩散率以及冻融过程，进而调节 T_s 的季节变化、垂向传输和长期变化特征。因此，中国复杂的地形格局和显著的水热梯度为研究多层 T_s 的时空变化及其水热耦合机制提供了典型区域。

此外，中国土地覆盖类型多样，包括森林、草地、耕地、荒漠、水体和建设用地等。不同土地覆盖类型通过改变植被覆盖、地表反照率、SM 状况和地表能量分配，对 T_s 的形成和变化产生重要影响。例如，东部平原区以耕地分布较为集中，南方丘陵山地区森林覆盖较高，而西北干旱半干旱区草地和荒漠分布较广。土地覆盖差异与气候、地形梯度共同作用，使中国区域 T_s 呈现显著的空间异质性。总体而言，中国在气候条件、地形地貌和土地覆盖方面具有显著的区域差异。这种多维环境梯度不仅有助于系统评估再分析 T_s 产品在不同背景条件下的精度表现，也为构建适用于复杂地理环境的多层 T_s 重建模型提供了重要基础。

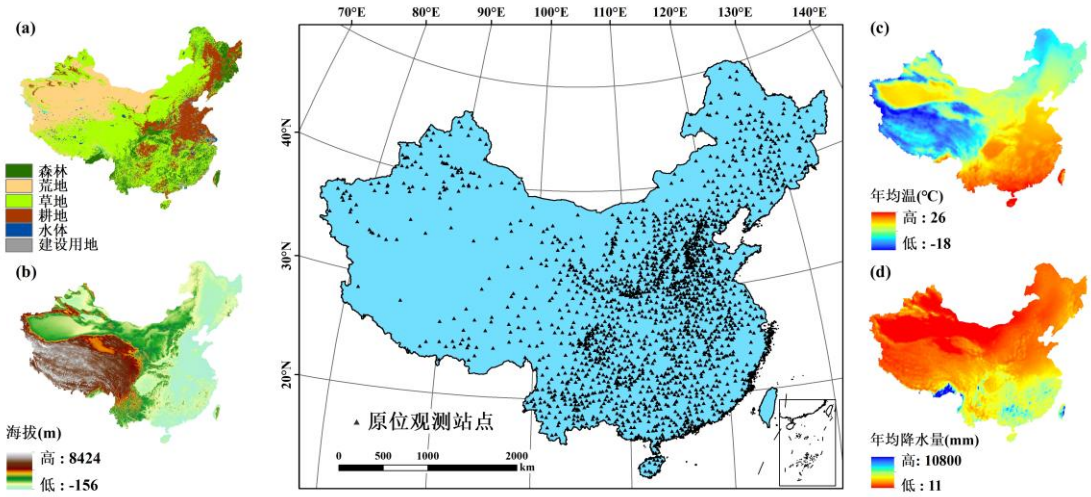


图 2-1 中国不同深度 T_s 观测点的空间分布及其对应的环境变量。图中展示了 2093 个原位观测站点的空间分布情况及不同站点所对应的环境变量，具体包括：（a）土地覆盖类型（森林、荒地、草地、耕地、水体和城市区域）；（b）海拔（范围从-156 m 到 8424 m）；（c）年均温（范围从-18 °C 到 26 °C）；（d）年均降水量（范围从 11 mm-10800 mm）。

Figure 2-1. Spatial distribution of in situ T_s sites at different depths across China and the corresponding environmental variables. This figure presents the spatial distribution of 2,093 in situ T_s sites across China. The environmental variables corresponding to these sites include (a) land cover types (forests, barren land, grasslands, croplands, water bodies, and urban areas), (b) elevation (ranging from -156 m to 8424 m), (c) mean annual temperature (ranging from -18 °C to 26 °C), and (d) mean annual precipitation (ranging from 11 mm to 10,800 mm).

2.2 数据来源与预处理

2.2.1 原位观测数据

2.2.1.1 气象站点数据

本研究所使用的 T_s 原位观测数据来源于中国气象局（China Meteorological Administration，CMA）运营的国家气象站网络（http://data.cma.cn）。该网络为目前中国覆盖范围最广、观测标准最统一的地面气象观测体系，能够为国家尺度的土壤热环境分析提供可靠的数据支撑。在各气象站点，T_s 观测深度包括地表（0 m）以及 0.05 m、0.10 m、0.15 m、0.20 m 和 0.40 m 等多个层次。观测数据以 10 分钟为时间分辨率自动记录，并实时上传至中央数据库。为匹配再分析产品及遥感数据的时间尺度，本研究基于高频观测数据计算各深度的逐日平均值，从而构建统一时间分辨率的站点尺度 T_s 数据集。根据研究目标的不同，原位观测数据被划分为两个子样本集，并分别在对应时间范围内进行质量控制筛选。

（1）长时序分析站点（1980-2020 年）

为系统评估四种再分析 T_s 产品（ERA5-Land、GLDAS、MERRA-2 和 JRA-

3Q）在中国区域的长期适用性与趋势一致性，本研究选取时间序列完整（1980-2020 年）的气象站点作为验证样本。在 1980-2020 年时间范围内，若某一站点在任一观测深度的日尺度数据缺失比例超过 10%，则予以剔除。经质量控制后，共保留 1682 个站点用于再分析产品的精度检验与趋势一致性分析。该子样本可用于比较再分析产品与观测数据在不同深度上的偏差特征、相关性及长期变化趋势一致性，从而检验其对 T_s 长期变化信号的刻画能力。

（2）自适应建模站点（2001-2020 年）

为构建高时空分辨率、多深度 T_s 数据集，本研究选取 2001-2020 年期间数据完整性较高的观测站点作为建模候选样本。考虑到 MODIS LST 等遥感特征变量的时间覆盖范围为 2001-2020 年，为保证模型输入变量时间序列的一致性与可比性，最终建模时段统一为 2001-2020 年。随后，在对应的时间窗口内进行数据完整性筛选，若某一站点在任一观测深度的日尺度数据缺失比例超过 10%，则予以剔除。经质量控制后，共保留 2093 个站点用于后续的空间自适应建模与多层 T_s 数据重建。

该 T_s 观测网络覆盖寒温带、温带、亚热带和热带等不同气候区，并涉及森林、草地、农田和荒地等多种下垫面类型，为分析不同环境背景下 T_s 变化特征提供了重要基础。然而，站点空间分布存在显著不均衡性。东北地区、中东部平原及南方丘陵地区站点密度较高，而西北干旱与半干旱区以及 QTP 等高海拔区域站点相对稀疏。这种空间不均匀性在一定程度上增加了区域尺度建模与产品重建的难度，也凸显了构建空间自适应算法以弥补观测空缺的必要性。现场观测站点的空间分布图见图 2-1 所示。

2.2.1.2 通量站点数据

为对本研究构建的 T_s 数据产品进行独立精度验证，本文引入中国通量观测研究网络（ChinaFLUX）的 T_s 观测数据。通量站点通常采用自动化连续观测系统，数据质量控制较为严格，且独立于气象业务站网，可作为模型外部验证数据源，用于检验 T_s 产品在不同生态系统和气候背景下的泛化能力。本研究共选取 18 个通量观测站点，覆盖草地、森林、农田和湿地等典型生态系统类型。为保证不同数据源之间的可比性，筛选与气象业务站网一致的观测深度，即 0、5、10、15、20 和 40 cm，并选取 2010-2020 年期间的连续 T_s 观测数据开展精度评估。通量站点的具体信息如下表 2-1 所示：

表 2-1 用于精度验证的通量站原始数据

Table 2-1 Metadata of daily T_s observations from flux towers used for validation

通量站 Site	类型 Ecosystem	T_s 深度 (cm) Depth (cm)	时间范围 Time series
宝天曼	森林	0, 5, 20	2010-2014
长岭	农田	5, 10, 20	2018-2020
大安	农田	0, 5, 10, 15, 20	2017-2020
达茂	草地	0, 5, 10, 15, 20, 40	2017-2020
儋州	森林	5, 10, 20	2010
海北草甸	草地	5, 10, 15, 20, 40	2015-2020
海北灌丛	草地	0, 5, 20, 40	2016-2018
呼中	森林	5, 10, 20	2014-2018
锦州	农田	5, 10, 15, 20, 40	2011-2014
丽江	草地	5, 10, 15, 20, 40	2013-2020
帽儿山	森林	5	2016-2018
盘锦	湿地	10, 20, 40	2018-2020
千烟洲	森林	5, 10, 20	2011-2015
若尔盖	湿地	0, 5, 10, 20	2013-2020
三江源	草地	0, 5, 15	2013-2015
桃园	农田	5, 10, 15, 20, 40	2010-2014
西双版纳	森林	0, 5, 20	2010-2014
元江	森林	5, 10, 20, 40	2013-2015

2.2.2 遥感数据

相关研究表明地面凋落物、植被冠层覆盖度对 T_s 有显著影响（Kang et al. 2000），另外，基于遥感反演的 LST 能够反映地表能量交换过程，与浅层 T_s 在时间变化尺度上通常具有较强相关性，常被用作区域尺度土壤热环境分析的重要代理变量。因此本研究引入了归一化植被指数（NDVI）、增强型植被指数（EVI）和 LST 三个遥感指数用于后续建模。

2.2.2.1 归一化植被指数

NDVI 是一种基于植被光谱特征构建的常用遥感植被指数，用于表征植被覆盖度与生长状况（Rouse et al. 1974）。其原理基于绿色植被在近红外波段（Near

Infrared, NIR）具有较强反射能力，而在红光波段（Red）存在显著吸收特征。通过对两个波段反射率差异进行归一化处理，可有效增强植被信号并降低光照条件及传感器增益差异的影响。NDVI 的取值范围为−1 至+1，其中负值通常对应水体或云等非植被覆盖地物，接近 0 的值多代表裸地或建筑用地等低植被覆盖区域，较高的正值则表征高覆盖度、长势良好的绿色植被。本研究使用存储于 Google Earth Engine（GEE）平台上的 MODIS Terra 表面反射率产品（MOD09GA）计算 NDVI。该产品提供经大气校正后的地表光谱反射率数据，具有较高的时间连续性和空间一致性，适用于长期植被动态监测。NDVI 按如下公式计算：

$$NDVI = \frac{\rho_{NIR} - \rho_{\mathrm{Red}}}{\rho_{NIR} + \rho_{\mathrm{Red}}} \tag{1-1}$$

式（2-1）中，ρ_{NIR} 表示 NIR 反射率，ρ_{Red} 表示 Red 反射率。通过对 NDVI 时序进行分析，可有效刻画植被生长状况及其对气候异常的响应特征。

2.2.2.2 增强型植被指数

本研究进一步引入 EVI 以提高对高覆盖度植被区域的识别能力（Huete et al. 2002）。相比 NDVI，EVI 在算法结构中引入了蓝光波段用于大气校正，并通过背景调节因子降低土壤反射率的影响，同时有效缓解高生物量区域中的光谱饱和问题。因此，在冠层覆盖度较高或大气条件复杂的区域，EVI 通常能够提供更稳定且灵敏的植被动态表征。

本研究基于 GEE 平台提供的 MODIS Terra 表面反射率产品（MOD09GA）计算 EVI。该产品包含经大气校正后的 NIR、Red 及蓝光（Blue）波段反射率数据，适用于长期植被变化监测。EVI 的计算公式如下：

$$\mathrm{EVI} = \frac{(\rho_{\mathrm{NIR}} - \rho_{\mathrm{Red}})}{(\rho_{\mathrm{NIR}} + C_1 \times \rho_{\mathrm{Red}} - C_2 \times \rho_{\mathrm{Blue}} + L)} \times G \tag{1-2}$$

式（2-2）中，ρ_{NIR}、ρ_{Red} 和 ρ_{Blue} 分别表示 NIR、Red 和 Blue 波段反射率；G 为增益因子（通常取 2.5）；C_1 与 C_2 为大气校正系数（分别取 6.0 和 7.5）；L 为冠层背景调节因子（通常取 1.0）。通过与 NDVI 结合使用，可从不同光谱敏感性角度刻画植被结构变化与生长状态，提高对气候胁迫响应的识别能力。

2.2.2.3 地表温度

本研究选取了 MODIS Terra 陆地表面温度全球 L3 网格产品（MOD11A1），该数据集具有 1 km 的空间分辨率和每日时间步长。该产品包括白天（$\mathrm{LST_{day}}$）和夜间（$\mathrm{LST_{night}}$）温度，分别对应于上午 10:30 和晚上 10:30，此外还提供了对

应的质量评估信息（Wan et al. 1996）。为提高对日均地表热状态的刻画能力，本研究计算 LST_{day} 与 LST_{night} 的算术平均值，构建日均 LST 变量，用于后续与 T_s 及植被响应的关联分析。该处理方式能够在一定程度上降低单时相观测偏差对日尺度分析的影响，从而提高时间序列稳定性。

由于云污染的影响，逐日 LST 和 EVI 像元在空间有部分缺失。为保证时间序列的连续性与空间完整性，本研究采用时空线性插值方法对缺失值进行填补。该方法综合利用时间序列邻近日期信息及空间邻近像素特征，在保持原始变化趋势的前提下重建缺失观测值，从而减少云污染对连续分析的干扰。该方法借鉴了 Chen 等（2017）和 Cao 等（2018）提出的算法，并进行了适当修改，以更好地适应我们的数据集。在插值重建后，为进一步降低高频噪声并提取平滑的变化信号，本研究采用了 Savitzky-Golay (S-G)滤波器对插值后的数据进行了平滑处理，得到了时空连续的 LST 和植被指数数据（Kong et al. 2019；Chen et al. 2021）。所有遥感数据预处理工作，包括影像插值和滤波，都在 GEE 平台上完成。

2.2.3 再分析/同化产品

为系统评估不同再分析/同化框架下 T_s 产品在中国区域的精度表现及适用性，本研究选取四套具有代表性的全球再分析数据集，包括 ERA5-Land、GLDAS-2.1、MERRA-2 和 JRA-3Q。这些数据集在同化体系、陆面模式结构、分辨率及时间跨度方面存在显著差异，因此为比较不同框架下 T_s 模拟能力提供了多源对照基础。

2.2.3.1 ERA5-Land 数据集

ERA5-Land 是由欧洲中期天气预报中心（ECMWF）发布的第五代陆面重分析数据产品，基于 ERA5 大气再分析驱动陆面模式进行离线陆面模拟。该数据集融合多源观测资料与数值天气预报模型，通过数据同化技术生成具有物理一致性的长期连续数据序列（Muñoz-Sabater et al. 2021）。ERA5-Land 提供了与水分和能量通量相关的高质量环境变量，描述了地表与大气之间的相互作用，并且自 1981 年至今具有连续的覆盖。ERA5-Land 的空间分辨率为 0.1°（约 9 km），时间分辨率为 1 小时，自 1981 年以来提供连续覆盖。该产品包含丰富的地表能量与水分通量变量，能够刻画陆气相互作用过程。本研究从 ERA5-Land 日尺度数据集中提取包括太阳净辐射（Surface_net_solar_radiation_sum)、向下长波辐射（Surface_thermal_radiation_downwards_sum）、气温（Temperature_2m）和降水量（Precipitation）等变量作为空间自适应建模的特征因子。同时提取其不同土壤层（0-7 cm、7-28 cm、28-100 cm）的 T_s 产品，用于区域尺度适用性评估。所有变量均通过 GEE 平台获取并预处理。

2.2.3.2 GLDAS 数据集

GLDAS（全球陆地数据同化系统）由 NASA、GSFC 和 NOAA 联合开发，旨在通过陆面模式与多源观测数据融合生成全球陆地表面变量（Rodell et al. 2004）。新一代 GLDAS-2.1 产品提供了从 2000 年至今的近实时全球陆面气候变量。考虑到后续章节对 1980-2020 年长时序再分析 T_s 产品评估，而 GLDAS-2.1 产品主要覆盖 2000 年至今，因此本文整合了 GLDAS-2.0 和 GLDAS-2.1 数据。其中 1980-1999 年采用 GLDAS-2.0，2000-2020 年采用 GLDAS-2.1，以构建覆盖 1980-2020 年的 GLDAS T_s 时间序列。两套数据的空间分辨率均为 0.25° × 0.25°，时间分辨率为 3 小时。本研究选取 GLDAS 产品中不同深度（即 0、0-10、10-40 和 40-100 cm）的 T_s 变量，用于与原位观测数据进行对比评估。为保证不同再分析产品之间的时间尺度一致性，首先将 3 小时分辨率的 GLDAS 数据聚合为逐日平均值，随后基于站点位置提取对应格点值。

2.2.3.3 MERRA-2 数据集

MERRA-2（Modern-Era Retrospective Analysis for Research and Applications, Version 2）由美国国家航空航天局（NASA）开发，提供自 1979 年以来的全球再分析气候数据。该数据集结合卫星观测与数值预报模型输出，通过同化系统生成具有长期一致性的多层变量数据（Gelaro et al. 2017）。该数据集结合了观测数据与数值天气预报模型的输出，适用于全球尺度的气候研究和环境变化监测。MERRA-2 的空间分辨率为 0.5° × 0.625°（~50 km），时间分辨率为 1 小时。在其陆面诊断数据集中，包含多个土壤深度层的温度变量。本研究选择 TS（0 cm）、TSOIL1（0.098 m）、TSOIL2（0.195 m）、TSOIL3（0.385 m）用于评估其在中国范围内的 T_s 模拟能力。所有变量均统一处理为日尺度数据以保证分析一致性。

2.2.3.4 JRA-3Q 数据集

JRA-3Q（Japanese Reanalysis for Three Quarters of a Century）是由日本气象厅（Japan Meteorological Agency, JMA）开发的第三代全球大气再分析数据集（Kosaka et al. 2024）。该数据集通过资料同化系统融合多源观测资料与数值模式背景场，提供时间分辨率为 3 小时的气象变量、地表状态变量和土壤水热变量，可用于长时间序列气候变化及陆气过程研究。JRA-3Q 的空间分辨率为 0.25°×0.25°，时间范围覆盖 1958 年至今。相较于较早期再分析产品，JRA-3Q 在观测资料使用、同化系统和模式物理过程等方面进行了更新，为评估长期气候变化背景下土壤热环境变化提供了重要数据来源。本研究选取 JRA-3Q 数据集中四个深度的 T_s 变量，包括 jst_0cm、jst_7cm、jst_19cm 和 jst_49cm，用于中国区域适用性评估。该数据集通过（https://gdex.ucar.edu）网站获取并在本地完成预处理与日尺度转换。

2.2.4 高精度土壤湿度产品

本研究采用中国 1 km 高质量 SM 数据集 SMCI1.0（Soil Moisture of China by in situ data, version 1.0）表征 SM 状况（Li et al. 2022a）。该数据集基于地面站点观测数据构建，提供了 2000-2022 年中国范围内日尺度 SM 数据，空间分辨率为 30 秒（约 1 km）。SMCI 1.0 具有较高的时空连续性，能够较好反映中国区域 SM 的时空变化特征。该数据集包含 10 个深度，间隔为 10 cm，覆盖 0-100 cm 土壤剖面，可用于分析不同深度 SM 对植被生长和极端气候事件响应的影响。为保证不同数据源之间的空间一致性，本研究对 SM 数据进行了统一的裁剪、重采样和时间匹配处理，并将其用于 SCDHWs 识别及作物响应分析。

SMCI1.0 已通过时间和空间两个维度的独立验证评估其精度。在时间尺度验证中，其无偏均方根误差（ubRMSE）为 0.041-0.052，相关系数（r）为 0.883-0.919；在空间尺度验证中，ubRMSE 为 0.045-0.051，r 为 0.866-0.893，表明该数据集在时间变化和空间分布方面均具有较高的精度与可靠性，可满足本研究对 SCDHWs 识别和分析的需求。

2.2.5 作物相关数据集

2.2.5.1 种植分布与物候数据

为准确界定玉米种植范围及其关键生育阶段，本研究采用中国长期高分辨率玉米物候数据集（China Crop Phenology Dataset-Maize, CCPD-Maize）作为玉米空间分布与物候阶段识别的基础数据（彭琼艳等 2024）。该数据集覆盖 2001-2020 年中国 22 个玉米主产省份，文件格式为 GeoTIFF，空间参考为 WGS84（EPSG:4326），原始空间分辨率为 30 m。该数据集包括玉米生长季开始期（start of season，SOS）、生长季结束期（end of season，EOS）、营养生长阶段（vegetative growth stage，VGS）、生殖生长阶段（reproductive growth stage，RGS）以及生长期长度（length of season，LOS）共五个物候相关指标。

CCPD-Maize 的物候识别结果已通过农业气象站观测数据进行验证。通过将识别得到的 SOS 和 EOS 分别与站点观测的玉米出苗期和成熟期进行比较，结果表明二者具有较高的一致性，其中 SOS 和 EOS 的决定系数（R^2）分别达到 0.964 和 0.823，表明该数据集能够较准确地刻画中国主要玉米种植区的物候时空变化特征，可满足本研究开展玉米生育阶段划分及 SCDHWs 影响分析的需求。

在本研究中，CCPD-Maize 首先用于确定逐年玉米种植像元，并进一步提取每个像元对应年份的 SOS、EOS、VGS、RGS 和 LOS 等物候信息。随后，将该数据与像元尺度的 SCDHW 重采样到统一空间分辨率进行空间匹配。基于 LOS 界定玉米完整生长季，并基于 VGS 和 RGS 两个不同物候期，从而实现 SCDHWs

与玉米实际生长阶段的精确匹配。该处理有助于避免非生长季极端事件对生产力响应分析的干扰，并为量化不同生育阶段 SCDHWs 对玉米生产力损失的影响提供了可靠的物候基础。

2.2.5.2 生产力数据集

作物生产力数据来源于国家生态系统科学数据中心（National Ecosystem Science Data Center）发布的逐日 NPP 产品（1981-2019 年，空间分辨率约等于 8 km，DOI: https://doi.org/10.12199/nesdc.ecodb.2016YFA0600200.02.002）。该产品融合多源遥感观测数据与生态过程模型模拟结果，在时空一致性与生态过程表征方面具有较高可靠性。因此，为突出 SCDHW 对玉米生产力的短期冲击效应，并减少 NPP 自身季节性生长节律和长期背景变化对事件响应识别的干扰，本研究仅对逐日 NPP 时间序列进行预处理。具体而言，首先基于多年同一日序的平均 NPP 构建逐日季节循环，并从原始逐日 NPP 中扣除该季节项，得到去季节项后的 NPP 异常；随后对该异常序列进行线性去趋势处理，以剔除长期变化趋势，提取主要反映短期波动和事件响应的 NPP 异常分量。通过依次去除逐日 NPP 的季节项和长期趋势项，使其能够更准确地量化 SCDHWs 发生期间玉米生产力相对于正常生长状态的偏离程度，从而提高生产力损失评估的稳健性。

2.2.5.3 产量数据集

本研究采用国家生态科学数据中心发布的 1982-2015 年全球四大主粮作物单产数据集（GlobalCropYield5min）来表征作物产量（Cao et al. 2025）。该数据集提供了全球范围内主要粮食作物的年尺度单产空间分布信息。主要包括四类作物，分别是玉米、小麦、水稻和大豆，空间分辨率为 5 arc-minute（约 10 km），时间范围为 1982-2015 年，数据单位为 $kg \cdot ha^{-1}$。

GlobalCropYield5min 具有较高的作物单产估算精度。全球尺度验证结果表明，玉米单产估算值与统计观测值之间的决定系数（R^2）达到 0.93，均方根误差（RMSE）为 757.1 $kg \cdot ha^{-1}$，对应的归一化均方根误差（NRMSE）为 17.8%，表明该数据集能够较好地刻画全球玉米单产的空间分布特征。数据集不确定性的空间分布结果进一步表明，GlobalCropYield5min 在全球大部分区域的不确定性总体较低，但存在一定的空间异质性。其中，玉米单产不确定性较高的区域（NRMSE > 40%）主要分布于巴西东北部、阿根廷北部、中国东北部和菲律宾等地区。

在本研究中，主要提取玉米年尺度单产数据，用于分析 SCDHWs 对作物产量的影响。为保证产量数据与气象、土壤和植被等数据在空间上的一致性，本研究对其进行了统一的空间匹配和像元尺度提取。进一步对玉米单产时间序列进行去趋势处理，以削弱农业技术进步、品种改良及管理水平变化等长期非气候因素

的影响，并利用去趋势后的产量异常表征 SCDHWs 发生背景下的玉米产量损失。

2.2.6 蒸散发数据集

本研究采用 GEE 平台获取的 PML-V2.2a（Penman-Monteith-Leuning version 2.2a）蒸散发数据集来表征玉米生长季 SCDHW 期间的蒸散发过程（Zhang et al. 2019）。该产品覆盖 2000-2024，空间分辨率为 500 m，时间分辨率为 8 天。本研究选取总蒸散发量（evapotranspiration, ET）、植被蒸腾（vegetation transpiration, Ec）、土壤蒸发（soil evaporation, Es）和潜在蒸散发（potential evapotranspiration, PET）作为蒸散发过程因子。其中，ET 表征地表向大气输送的总水分通量，Ec 反映植被蒸腾耗水过程，Es 表征土壤表层蒸发过程，PET 反映大气蒸发需求。上述变量能够分别从水分消耗、植被蒸腾、土壤蒸发和大气蒸发需求等方面刻画 SCDHW 期间作物所处的水分胁迫背景。

PML 系列蒸散发产品已通过通量观测和流域尺度水量平衡等多种方式进行验证，并表现出较高的估算精度。在不同植被功能类型上，模型效率系数（Nash-Sutcliffe efficiency, NSE）均高于 0.60，绝对偏差低于 5%；在流域尺度水量平衡验证中，NSE 达到 0.89-0.91，表明该产品能够较可靠地刻画不同生态系统及区域尺度的蒸散发变化，可为分析 SCDHWs 背景下农田生态系统水分过程提供数据基础。为保证 PML-V2.2a 与其他栅格数据在空间上的一致性，本研究首先将其裁剪至中国研究区域，并重采样至与 NPP 数据一致的空间分析网格。随后，结合逐年玉米物候信息和 SCDHWs 事件发生时间，对 8 d 尺度蒸散发变量进行时间窗口匹配，分别提取玉米不同物候阶段及 SCDHWs 事件期间的 ET、Ec、Es 和 PET 数据，并将其作为水分过程相关驱动因子，用于后续玉米 NPP 相对损失的驱动机制分析。

2.2.7 其他数据

为刻画影响 T_s 空间分布的静态环境调节因子，本研究引入地形与土壤属性等相关变量，用于增强空间自适应建模对区域异质性的表达能力。

2.2.7.1 高程数据

为了评估海拔和坡度、坡向对 T_s 预测模型性能的影响，本研究采用航天飞机雷达地形测量任务（Shuttle Radar Topography Mission, SRTM）数字高程数据 SRTM V3 产品（SRTM Plus）（Farr et al. 2007）。该数据原始空间分辨率为 30 m。基于高程数据进一步计算坡度与坡向变量，以表征地形对太阳辐射接收量与能量分配的调节效应。所有数据获取与预处理工作均在 GEE 平台完成。

2.2.7.2 土壤质地数据

土壤质地通过影响土壤热导率、热容量和水分保持能力，调控 T_s 的垂向传导过程，是多层 T_s 建模中的重要静态环境变量。本研究采用 Liu 等（2022）构建的中国土壤信息格网数据集，选取粘土（细颗粒）、粉砂（中等颗粒）和砂粒（粗颗粒）含量作为土壤质地指标。该数据集提供 0-5 cm、5-15 cm、15-30 cm 和 30-60 cm 四个深度层的土壤组分估算值，空间分辨率为 1 km。本文将不同深度的土壤质地变量与对应建模深度进行匹配，以更准确地表征不同深度土壤热学性质的差异及土壤热环境的垂向变化特征。

2.2.7.3 土地利用数据

土地利用类型通过影响地表能量收支、植被覆盖状况及土壤水热条件，显著改变 T_s 的时空变化特征，并进一步影响再分析产品对 T_s 的模拟精度。为评估不同下垫面条件下再分析 T_s 产品的精度表现，本研究采用 GEE 平台提供的 MODIS 土地覆盖产品 MCD12Q1。该产品基于 MODIS Terra 和 Aqua 反射率数据生成，空间分辨率为 1 km，时间范围为 2001-2020 年。在本研究中，土地利用数据主要用于识别森林、草地、耕地和荒地四种不同类型用于后续分析。

2.3 研究方法

2.3.1 统计分析方法

2.3.1.1 一致性分析

为定量评估不同再分析产品对关键土壤热过程空间格局的表征一致性，本研究采用皮尔森相关系数（Pearson's correlation coefficient, r）进行两两空间相关分析。该方法用于刻画不同产品在同一土壤热过程指标上的空间分布相似程度，包括土壤热浪指标和土壤冻融指标。对于每一类过程指标，分别提取两个产品在中国区域内共同有效像元上的多年平均值，并基于这些像元样本计算产品间的空间相关系数。该分析有助于识别不同再分析产品在极端高温过程和冷季冻融过程表征方面的一致性与不确定性。皮尔逊相关系数的计算公式如下：

$$r = \frac{\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2 \sum_{i=1}^{n}(y_i - \bar{y})^2}} \tag{1-3}$$

式（2-3）中，r 为皮尔森相关系数；x_i 和 y_i 分别表示两个再分析产品在第 i 个共同有效像元上的土壤热过程指标值；$\bar{x}$ 和 $\bar{y}$ 分别表示两个产品对应指标在所有共同有效像元上的平均值；n 为共同有效像元数量。计算过程中剔除任一产品中存在缺失值的像元，仅保留两个产品均具有有效值的像元参与相关分析。

皮尔森相关系数的取值范围为−1 到 1。r=1 表示两个产品的空间分布完全一致，呈完全正相关；r=−1 表示两个产品的空间分布完全相反，呈完全负相关；r=0 表示两个产品之间不存在线性空间相关关系。一般而言，较高的正相关系数表明不同再分析产品对该指标空间格局的表征较为一致，而较低或接近零的相关系数则表明产品间差异较大，相关指标存在较高不确定性。

2.3.1.2 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。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。

因此，在建模之前使用方差膨胀因子（VIF）严格评估了自变量之间的多重共线性，并移除高度相关的变量。VIF 是一种诊断统计量，用于量化多重共线性的程度，衡量回归系数的方差因与其他预测因子的相关性而膨胀的程度（Akinwande et al. 2015）。其计算公式为：

$$VIF_i = \frac{1}{1-R_i^2} \tag{1-4}$$

式（2-4）中，R_i^2 是将第 i-th 个预测变量回归于所有其他预测变量时得到的决定系数。VIF 值超过 10 的变量通常被认为存在严重的多重共线性，应予以剔除。在本研究中，对于 VIF 超过阈值的变量予以剔除或重新筛选，以确保进入模型的变量具有相对独立的贡献，从而提高模型参数估计的稳定性与泛化能力。

2.3.2 空间分析方法

2.3.2.1 旋转四叉树

由于中国区域 T_s 观测站点空间分布高度不均匀，若采用统一尺度的静态网格或全局建模方法，可能导致样本密集区信息冗余、样本稀疏区模型不稳定，从而影响区域尺度建模精度。为解决这一问题，本研究构建了一种自下向上的旋转四叉树（Rotated Quadtree, RQ）空间划分策略，以实现空间尺度的自适应建模。

四叉树是一种分层的空间数据结构，通过递归地将二维空间划分为四个象限，从而实现高效的空间索引和局部数据组织。本研究采用了一种自下向上的 RQ 空

间划分策略，该策略在样本密集的区域自适应地生成更精细的网格，而在样本稀疏的区域生成更粗的网格进行局部建模。与全局建模或静态网格划分相比，这种自适应方法在提高区域建模精度的同时，显著提升了计算效率。具体流程如下：

（1）最小单元初始化

首先将整个空间域划分为均匀的最小尺寸单元（叶节点），每个单元代表一个基本的空间元素。这些单元可能包含零个或多个现场观测数据。此初始步骤为后续的分层构建提供了基本分辨率。RQ 空间索引的结构和原理见附图 1。

（2）分层合并

从叶节点开始，如果每个单元包含的观测站点少于 30 个（阈值选择方法详见图 2-2），则四个相邻的象限会递归地合并成父节点。合并过程一直向上进行，直到没有更多的组满足阈值条件为止。这种方法确保每个节点具有足够的样本量，同时在整个研究区域内实现空间自适应划分。每个子区域随后会分配一个局部的 T_s 预测模型。具体而言，采用三个指标评估不同阈值下的空间划分效果，包括站点数量变异系数（coefficient of variation, CV）、站点密度变异系数以及网格单元总数。其中，站点数量的 CV 用于评价不同阈值下各空间单元内样本分布的均衡性。站点密度定义为每个网格单元内观测站点数量与该网格面积之比。较低的站点密度 CV 表明，空间划分能够根据局部站点密度自适应地调整网格大小，即在站点密集区形成较小网格，在站点稀疏区形成较大网格，从而体现出更强的空间自适应划分能力。相反，较高 CV 则表明该划分方式未能充分刻画站点密度的空间异质性。因此，站点密度 CV 可作为评价空间自适应划分能力的关键指标。网格单元总数对应于需要训练的局部模型数量，因此可间接反映模型训练所需的计算成本和时间成本。

如图 2-2a-c 所示，本研究基于不同的站点数量阈值（10、30、50、70 和 90）评估四叉树划分性能。图 2-2a 显示，随着阈值增大，站点数量 CV 快速下降，表明各网格间样本分配的均衡性得到改善。然而，当阈值超过 30 后，该下降趋势趋于平缓，说明继续增大阈值带来的改进有限。因此，阈值选定为 30 可视为兼顾样本均衡性与划分效果的较优折中点。图 2-2b 显示，站点密度 CV 在阈值约为 30 附近出现明显拐点。尽管该点并非全局最小值，但其代表了较优的折中状态，即网格划分既能够充分反映样本密度的空间变化，又可避免过度划分或划分不足，从而较好地体现空间自适应性。图 2-2c 显示，随着阈值增大，网格单元数量快速减少，从而显著降低计算成本。然而，当阈值超过 30 后，网格数量的减少速率明显放缓，表明进一步增大阈值所带来的额外收益有限。

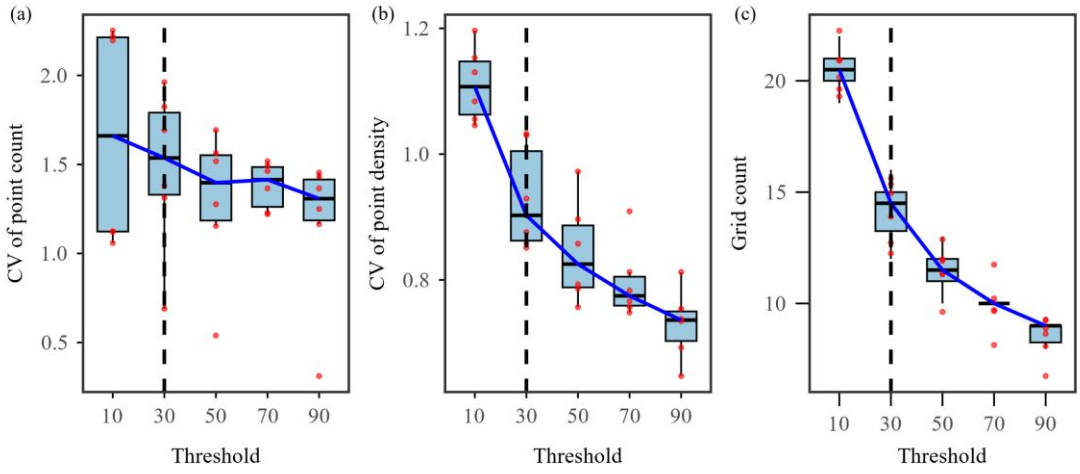


图 2-2 不同划分阈值下四叉树性能评估。（a）各空间单元站点数量的 CV；（b）站点密度，即单位面积站点数量的 CV；（c）生成的网格单元总数。垂直虚线表示最终选定的阈值 30。

Figure 2-2. Performance evaluation of quadtree partitioning under different point-count thresholds. (a) CV of point count across spatial units. (b) CV of point density (point count per unit area). (c) Total number of generated grid cells. Dashed vertical line indicates the selected threshold of 30.

（3）旋转不同角度

为了减少静态网格边界可能带来的边缘效应，我们实施了 RQ 划分策略。四叉树结构以六个角度（0°、15°、30°、45°、60°和 75°）进行旋转，针对每个方向生成不同的空间划分（见图 2-3）。我们为每个旋转配置训练独立的模型，最终通过对所有六个模型的输出进行平均，得到最终的 T_s 估算值并基于旋转的集成方法进一步提高局部建模边缘的平滑度。

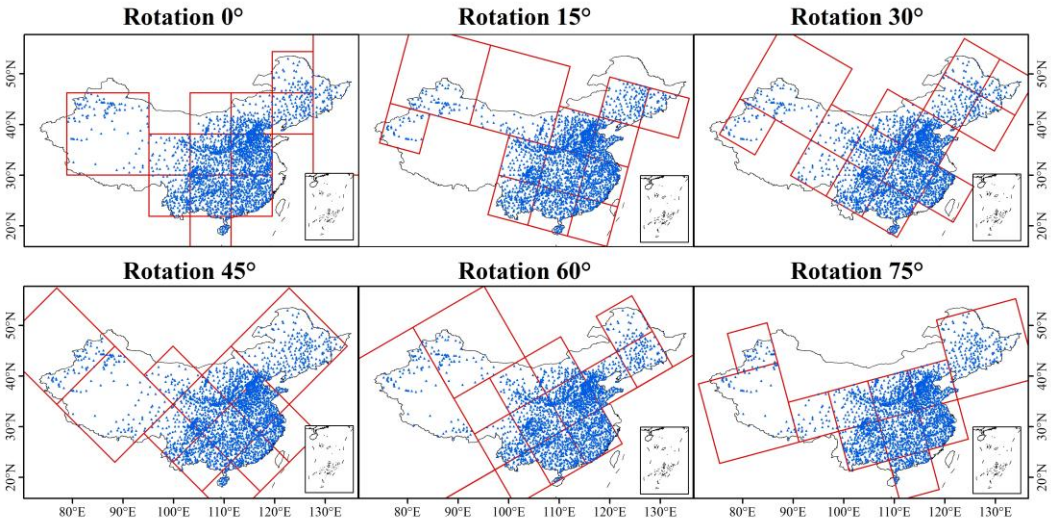


图 2-3 基于 RQ 的观测站点多角度划分（0°、15°、30°、45°、60°、75°）。

Figure 2-3. Multi-angle adaptive quadtree partitioning of site observations (0°, 15°, 30°, 45°, 60°, and 75°).

2.3.2.2 半变异函数

为刻画 T_s 观测站点的空间自相关特征，并识别其空间影响尺度，本研究采用半变异函数（Semi-variogram）对站点尺度 T_s 数据进行空间结构分析（Burgess et al. 1980）。Semi-variogram 是空间统计分析中常用的工具，用于描述空间数据中的自相关结构。它通过量化空间变量在不同距离尺度上的变化来揭示空间数据的变异性，为空间建模尺度选择与自适应划分提供依据。具体方法是，计算样本数据之间的半变异度，它的定义为：

$$\gamma(h)=\frac{1}{2N(h)}\sum_{i=1}^{N(h)}\left[Z(x_i)-Z(x_i+h)\right]^2 \tag{1-5}$$

式（2-5）中，γ(h)是距离为 h 的半变异度，N(h)是距离为 h 的样本对数，$Z(x_i)$ 和 $Z(x_i+h)$ 分别为位于空间位置 x_i 和 x_i+h 处的观测值。该函数用于评估不同距离间数据的变异性，并提供一个空间尺度的参考。在本研究中，通过构建经验半变异函数并拟合理论模型（如指数模型、球状模型和高斯模型），提取 T_s 预测值的块金值（nugget）、基台值（sill）及变程（range）等关键参数，具体结果见附图 2。块金值反映微尺度变异和观测误差，基台值表示空间变异达到稳定状态时的总体变异水平，变程则表示空间自相关的有效作用距离。本文重点利用变程参数表征 T_s 在空间上的相关尺度，为空间自适应划分尺度和局部建模范围设定提供参考，并通过比较不同区域的半变异结构特征，分析 T_s 空间依赖性的区域差异。

2.3.2.3 局部双变量莫兰指数

为识别地形因子与 T_s 之间的空间耦合特征，本研究采用局部双变量莫兰指数（Local Bivariate Moran’s I）对海拔与 T_s 的空间依赖关系进行分析。Local Bivariate Moran’s I 能够揭示局部区域内两个变量之间的空间模式，帮助识别空间自相关性的局部特征，进而揭示特定区域的空间热点或冷点。该方法对于研究变量之间的空间交互和区域差异具有重要意义，广泛应用于地理信息科学、环境科学和经济学等领域（Jiang et al. 2025；Zhou et al. 2025）。Local Bivariate Moran’s I 的计算公式如下：

$$I_i=\frac{\sum_{j=1}^{n}w_{ij}(x_i-\bar{x})(y_j-\bar{y})}{\sum_{i=1}^{n}(x_i-\bar{x})^2\sum_{j=1}^{n}(y_j-\bar{y})^2} \tag{1-6}$$

式（2-6）中，I_i 是位置 i 处的局部双变量莫兰指数，x_i 和 y_i 分别是位置 i 上两个变量的观测值，$\bar{x}$ 和 $\bar{y}$ 是变量 x 和 y 的均值，w_{ij} 是空间权重矩阵元素，表示空间位置 i 和 j 之间的邻接关系，n 是样本数量。局部双变量莫兰指数的结果可以用来识别四种典型的空间模式，分别为：

（1）高-高（High-High）：高值区域与高值邻近区域相邻，表明两个变量之间存在强正相关；

（2）低-低（Low-Low）：低值区域与低值邻近区域相邻，表明两个变量之间也存在强正相关；

（3）高-低（High-Low）：高值区域与低值邻近区域相邻，表明两个变量之间存在负相关；

（4）低-高（Low-High）：低值区域与高值邻近区域相邻，表明两个变量之间也存在负相关。

在本研究中，Local Bivariate Moran's I 主要用于检验地形因子与 T_s 空间分布之间的局部关联特征，并判断这种关联是否存在显著的区域差异，从而为空间自适应建模中引入地形变量以及采用局部建模策略提供统计依据。在上述空间权重结构基础上，本研究计算了 GST_Avg（X）与高程（Y）之间的 Local Bivariate Moran's I，并通过置换检验获得相应的 p 值。随后，进一步计算空间滞后辅助变量（Wy），并根据显著性检验结果将各站点划分为四类显著的 LISA 聚集类型（$p < 0.05$）：高—高型（High-High，红色）、高—低型（High-Low，绿色）、低—高型（Low-High，紫色）和低—低型（Low-Low，蓝色）。局部空间关联不显著的站点（$p \geq 0.05$）以灰色表示。结果表明约 64%的站点表现出统计显著的局部空间关联，并且四种聚集类型在中国不同区域均有分布（图 2-4）。这种空间异质性的局部关联格局表明，T_s 与高程之间的关系存在明显的空间非平稳性，即地形对 T_s 空间分布的调节作用在不同区域存在差异。上述结果说明，在中国复杂地形与多气候背景下，采用能够刻画局部空间差异的空间自适应建模框架具有必要性，也为后续旋转四叉树局部建模策略的构建提供了依据。

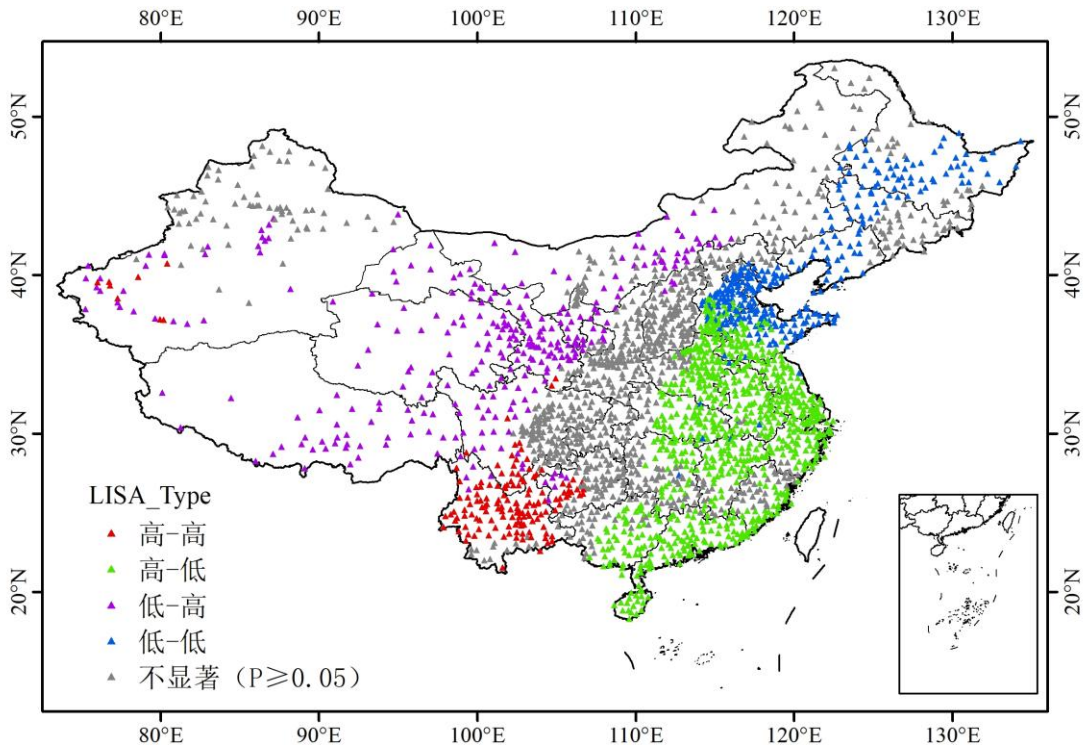


图 2-4 气象观测站点表层 T_s 与高程之间双变量局部 Moran's I 的空间分布图。

Figure 2-4. Spatial patterns of the bivariate Local Moran's I between GST_Avg and elevation at meteorological stations across China.

2.3.3 机器学习方法

为实现多源环境变量驱动下的 T_s 高精度估算，本研究采用极端梯度提升算法（Extreme Gradient Boosting, XGBoost）构建预测模型。XGBoost 是一种基于梯度提升框架的集成学习方法，通过逐步拟合前一轮模型残差构建回归树序列，并在目标函数中引入正则化项以控制模型复杂度，从而在提高预测精度的同时降低过拟合风险（Chen et al. 2016）。与传统线性回归或单一决策树模型相比，XGBoost 在处理非线性关系、变量交互效应及高维特征空间方面具有显著优势。由于 T_s 受气候因子、地形特征、土壤属性及土地覆盖等多源变量的共同影响，其空间分布往往表现出明显的非线性与非平稳特征。因此，能够自适应刻画复杂变量关系的 ML 算法更适用于本研究的建模需求。

XGBoost 的一个关键优势是其能够处理异质性和高维度的特征变量，这在地球科学应用中尤为常见，尤其是在涉及复杂地形、土地覆盖变化和气候梯度的情况下。近期的研究已经证明了 XGBoost 在类似领域中的有效性，包括 LST 重建（Li et al. 2024）、多层 SM 估算（Karthikeyan et al. 2021；Li et al. 2024）、干旱事件归因（Wang et al. 2025）以及作物产量预测（Li et al. 2023）。结合本研究提出的旋转四叉树空间划分模型，XGBoost 被用于各空间子区域内构建局部 T_s 预测模型，以增强模型对空间非平稳性的适应能力并提高区域尺度预测精度。

为进一步解释 ML 模型结果并识别关键驱动因子，本研究引入 SHAP（SHapley Additive exPlanations）方法对模型输出进行解释。SHAP 基于合作博弈论中的 Shapley value 思想，可将模型预测结果分解为各输入变量的边际贡献，从而量化不同变量对单一样本预测结果的正向或负向影响（Lundberg et al. 2017）。与传统变量重要性方法相比，SHAP 不仅能够评估变量的全局相对贡献，还能够揭示变量取值变化对模型输出的非线性影响方向和潜在响应区间，因此适用于复杂 ML 模型的可解释性分析。在 SCDHW 事件影响分析中，本研究采用 XGBoost-SHAP 方法量化事件特征、土壤水热条件、蒸散过程和气象背景变量对玉米 NPP 相对损失的贡献。具体而言，首先基于训练好的模型计算各样本中不同变量的 SHAP 值，并以平均绝对 SHAP 值表征变量的全局重要性；随后，选取贡献较高的关键变量绘制 SHAP 依赖图，以解析主要驱动因子与 NPP 相对损失之间的非线性响应关系。

2.3.4 趋势分析方法

为识别 1980-2020 年期间不同深度 T_s 的长期变化趋势，本研究采用 Mann-Kendall（MK）非参数趋势检验方法（Hamed et al. 1998）。与基于最小二乘法的线性回归相比，MK 检验不依赖于数据分布形式，对异常值和非正态时间序列具有更强的稳健性，因此广泛应用于气象与水文时间序列趋势分析（Nalley et al. 2012；Pingale et al. 2014）。MK 检验首先计算统计量 S：

$$S=\sum_{i-1}^{n-1}\sum_{j=i+1}^{n} sign\left(x_j-x_i\right) \tag{1-7}$$

式（2-7）中，x 为 i 和 j 时间的数值，n 为数据的长度，sign（v）为：

$$sign(v)=\begin{cases} 1 & for \quad v>0 \\ 0 & for \quad v=0 \\ -1 & for \quad v<0 \end{cases} \tag{1-8}$$

假设 x_i 是相互独立和随机排列的，当 $n \geq 8$ 时，S 呈近似正态分布（均值为 0），方差（var）通过下公式获得：

$$var(S)=\frac{n(n-1)(2n+5)}{18} \tag{1-9}$$

最后，计算 MK 统计量 Z 值：

$$Z=\begin{cases}\dfrac{S-1}{\sqrt{var}} & for\ \ S>0\\ 0 & for\ \ S=0\\ \dfrac{S+1}{\sqrt{var}} & for\ \ S<0\end{cases} \tag{1-10}$$

当｜Z｜>1.96 时，在 5%显著性水平下拒绝原假设，表明时间序列存在显著趋势。Z > 0 表示上升趋势，Z < 0 表示下降趋势。在本研究中，MK 检验用于识别不同深度 T_s 的长期变化方向及其显著性，从而为分析气候变化背景下土壤热环境演变特征提供统计依据。

2.3.5 关键土壤热过程识别方法

2.3.5.1 土壤热浪事件识别

本文采用四种再分析产品（ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q）中 10 cm 深度的逐日 T_s 数据识别土壤热浪事件。土壤热浪识别参考 Hobday 等（2016）提出的事件识别框架，采用基于日历日气候态的季节变化阈值进行判定。具体而言，对于每一个日历日，基于 1980-2000 年参考期内以目标日为中心的 11 天滑动窗口样本，即目标日前后各 5 天并涵盖所有基准年份，计算逐日 T_s 的第 90 百分位阈值。同时，采用相同样本计算对应的日历日气候态平均值。随后，对第 90 百分位阈值序列和日历日气候态平均值序列分别采用 31 天窗口的循环滑动平均方法进行平滑处理，即在年积日序列首尾相接的条件下，对每个日历日前后各 15 天的数值进行平均，以降低逐日阈值的随机波动，并保证阈值和气候态背景随季节连续变化。闰日的阈值和气候态平均值由相邻日期线性插值得到。当某日 T_s 高于对应年积日的平滑第 90 百分位阈值时，该日被识别为土壤热浪日。连续超过阈值的日期首先被归并为候选热浪事件；若相邻候选事件之间的间隔不超过 2 天，则进一步合并为同一事件。最终，仅保留持续时间不少于 5 天的事件作为有效土壤热浪事件。

基于保留的有效土壤热浪事件，本文提取四类热浪指标，包括年度发生频次、事件持续时间、峰值强度和累积强度。其中，年度发生频次定义为某一年内识别到的有效土壤热浪事件数量；事件持续时间定义为单个有效热浪事件持续的天数。峰值强度定义为事件期间逐日 T_s 相对于平滑日历日气候态平均值的最大正异常值；累积强度定义为事件持续期间逐日 T_s 相对于平滑日历日气候态平均值的正

异常值之和。最后，在每个格点和再分析产品尺度上对年度土壤热浪特征进行汇总，包括土壤热浪发生频次、平均事件持续时间、平均峰值强度和平均累积强度。

2.3.5.2 土壤冻融状态识别

本文采用四种再分析产品（ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q）中 10 cm 深度的逐日 T_s 识别土壤冻融状态，并进一步提取年度冻结指标。考虑到土壤冻结过程通常跨越自然年，本文将冻结年定义为当年 7 月 1 日至次年 6 月 30 日。逐日土壤热状态采用滞后阈值法进行判定。具体而言，当 $T_s \leq -0.5$ ℃时，该日判定为冻结状态；当 $T_s \geq 0.5$ ℃时，该日判定为融化状态；当 T_s 处于−0.5 ℃至 0.5 ℃的过渡区间时，则继承前一个有效日期的热状态。该处理可降低 0 ℃附近短期温度波动导致的频繁状态切换，提高冻融状态识别的稳定性。

为进一步降低短期噪声影响，本文仅将持续时间不少于 3 天的冻结时段视为有效冻结过程。基于这些有效冻结时段，分别提取年度冻结指标，包括初冻日期、终冻日期、冻结持续期和冻结日数。其中，初冻日期和终冻日期分别定义为一个冻结年内首次和最后一次出现的有效冻结日；冻结持续期定义为初冻日期与终冻日期之间的时间跨度，用于表征冻结季长度；冻结日数则定义为冻结年内实际处于有效冻结状态的总天数。对于某一格点—年份—产品组合，若逐日 T_s 的缺失比例超过 10%，则不计算该年的冻融指标。

基于上述方法，本文分别计算四种再分析产品的多年平均初冻日期、终冻日期和冻结日数，并进一步比较不同产品对中国土壤冻融空间格局的表征一致性。该过程指标体系能够从极端高温事件和冷季冻融转换两个方面评估再分析产品对关键土壤热动态过程的刻画能力。

2.3.6 SCDHW 识别方法

本文采用逐日 T_s 和 SM 数据识别 SCDHW。其中，T_s 采用 10 cm 深度数据，SM 采用与其相匹配的土层数据。选择 10 cm 土层主要是因为该深度既位于作物根系活动较为敏感的浅层土壤范围内，又能相较于地表温度更稳定地反映土壤热环境变化，减少瞬时辐射和地表短期波动对事件识别的干扰。SCDHW 识别基于日历日气候态动态阈值方法，并参考 Hobday 等（2016）的事件识别框架。

具体而言，对于每个日历日，基于 2001-2020 年参考期内以目标日为中心的 11 天滑动窗口样本，即目标日前后各 5 天并涵盖所有基准年份，分别计算 T_s 的第 90 百分位阈值和 SM 的第 10 百分位阈值。其中，第 90 百分位 T_s 阈值用于表征异常高温条件，第 10 百分位 SM 阈值用于表征异常干旱条件。对应的日历日气候态平均值也由相同样本计算得到。随后，分别对温度阈值、水分阈值及其对应的日历日气候态平均值序列进行 31 天循环滑动平均平滑处理，以降低逐日序

列的随机波动，并保证阈值和气候态背景随季节连续变化。闰日的阈值和气候态平均值由相邻日期线性插值得到。当某日的 T_s 高于对应年积日的平滑第 90 百分位阈值，且逐日 SM 低于对应年积日的平滑第 10 百分位阈值时，该日被识别为复合干热日。连续发生的复合干热日被归并为候选 SCDHW；若相邻候选事件之间的间隔不超过 2 天，则进一步合并为同一事件。最终，仅保留持续时间不少于 5 天的事件作为有效 SCDHW 事件。

针对每个有效 SCDHW 事件，本文提取四个事件尺度指标，包括发生频次、持续时间、峰值强度和累积强度。其中，发生频次定义为某一年内识别到的 SCDHW 事件数量；持续时间定义为单个事件持续的天数。需要说明的是，SM 在本文中主要用于识别异常低水分条件，即用于判定高温日是否同时受到干旱胁迫；而事件强度指标仅基于 T_s 的高温超阈值幅度计算。具体而言，对于第 t 日，其逐日高温强度定义为：

$$I_t = T_{s,t} - T_{90,d} \tag{1-11}$$

式（2-11）中，I_t 为第 t 日的逐日高温强度，$T_{s,t}$ 为第 t 日的 T_s，$T_{90,d}$ 为第 t 日对应年积日 d 的平滑第 90 百分位温度阈值。由于有效 SCDHW 事件中的每一天均满足 $T_{s,t} > T_{90,d}$，因此 I_t 表示 T_s 超过高温阈值的幅度，单位为 ℃。对于第 e 个 SCDHW 事件，其峰值强度和累积强度分别定义为：

$$I_{\text{peak},e} = \max\left\{ I_t \mid t \in S_e \right\} \tag{1-12}$$

$$I_{\text{cum},e} = \sum_{t \in S_e} I_t \tag{1-13}$$

式（2-12）和（2-13）中，S_e 表示第 e 个 SCDHW 事件包含的所有复合干热日，$I_{\text{peak},e}$ 表示该事件期间最大的逐日高温超阈值幅度，$I_{\text{cum},e}$ 表示该事件期间逐日高温强度的累积值。最后，在数据源尺度上，对年度 SCDHW 事件特征进行汇总，包括年度 SCDHW 事件发生频次、平均事件持续时间、平均峰值强度和平均累积强度。该方法能够在异常低 SM 条件约束下，刻画土壤高温胁迫事件的发生、持续和强度特征。

2.3.7 广义加性混合模型

为评估不同物候阶段 SCDHW 事件对玉米产量损失的非线性影响，本研究采用广义加性混合模型（Generalized Additive Mixed Model，GAMM）进行分析（Wood 2017）。GAMM 可通过平滑函数刻画事件强度、持续时间及环境因子与产量损失之间的非线性关系，并通过随机效应控制像元和年份尺度上的非独立性。

本研究以玉米产量损失率为响应变量，以 SCDHW 事件强度和持续时间为核心解释变量，同时纳入 SM、T_s、气温、降水和太阳辐射等环境因子作为控制

变量。所有连续变量在建模前均进行标准化处理。为控制像元间稳定的空间异质性和年份间气候背景差异，模型中加入像元随机效应和年份随机效应。统一GAMM模型形式如下：

$$Y_i = \beta_0 + \beta_1 P_i + f_{P_i}(I_i, D_i) + \sum_{k=1}^{m} f_k(X_{ki}) + b_{pixel(i)} + b_{year(i)} + \varepsilon_i \quad (1\text{-}14)$$

式（2-14）中，Y_i为第i个样本的玉米产量损失率；P_i为玉米物候期，包括VGS和RGS阶段；I_i和D_i分别为事件强度和持续时间$f_{P_i}(I_i, D_i)$为随物候阶段变化的强度—持续时间二维平滑交互项，用于分别刻画VGS和RGS阶段的非线性响应面；X_{ki}为第i个样本的第k个环境控制变量，m为环境控制变量总数。本研究中的环境控制变量包括SM、T_s、2m气温、降水量和太阳辐射等，均为与对应SCDHW事件或物候阶段匹配后的聚合变量；$f_k(\cdot)$为环境变量对应的平滑函数；$b_{pixel(i)}$和$b_{year(i)}$分别为像元随机效应和年份随机效应；ε_i为残差项。

模型采用限制最大似然法估计，并基于观测值与预测值关系评价模型表现。为比较不同物候阶段的相对敏感性，基于统一模型在相同事件强度和持续时间组合下分别预测VGS和RGS阶段的产量损失，并计算二者差值。若VGS预测产量损失高于RGS，则表明相同事件条件下VGS阶段响应更强；反之，则表明RGS阶段响应更强。进一步统计差异响应面的方向和显著区域比例，以判断玉米产量损失对不同物候阶段SCDHW事件的敏感性差异。

2.3.8 精度评价方法

模型性能和T_s产品的精度表现是通过RMSE（均方根误差）、MAE（平均绝对误差）、R^2（决定系数）、Bias（偏差）和ubRMSD（无偏均方根误差）进行评估的。RMSE和MAE分别用于测试估计波动性和波动幅度的能力，R^2表示模型解释的方差百分比。Bias用于观察预测值是过高还是过低。这些指标的计算公式如下：

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N}[(x_i - y_i)]^2}{N}} \quad (1\text{-}15)$$

$$MAE = \frac{\sum_{i=1}^{N} | x_i - y_i |}{N} \quad (1\text{-}16)$$

$$\mathrm{Bias} = \frac{1}{N}\sum_{i=1}^{N}\left(x_i - y_i\right) \quad (1\text{-}17)$$

$$R^2 = 1 - \frac{\sum_{i=1}^{N}\left(y_i - x_i\right)^2}{\sum_{i=1}^{N}\left(y_i - \bar{y}\right)^2} \tag{1-18}$$

$$\text{ubRMSD} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}\left[\left(x_i - y_i\right) - \text{Bias}\right]^2} \tag{1-19}$$

其中，N 为样本数量，y_i 是实测值的第 i 个数据点，x_i 是对应的预测值，$\bar{y}$ 是实测值的平均值。

第三章 再分析土壤温度产品的适用性评估

3.1 引言

T_s 是陆面系统中的关键状态变量，对陆气能量交换、地下热量传输、冻融活动以及多种生态和水文过程具有重要调控作用。与近地表气温相比，T_s 能够更直接地反映热信号在地下的传导与储存过程，并因土壤热性质、含水量、植被覆盖和积雪隔热效应等因素的差异而表现出显著的垂向异质性。然而，与全球范围内较为丰富的气温观测记录相比，连续的多层 T_s 原位观测仍然十分有限（Zhang et al. 2022），且许多常规气象站缺乏标准化的 T_s 观测深度（Holmes et al. 2008）。这些限制增加了大尺度可靠刻画多层 T_s 的难度，也制约了对土壤热状态时空差异、长期趋势及其气候响应的系统认识。

为弥补上述原位观测不足，已有研究发展了多种替代方法。热红外遥感产品（如 MODIS LST）和被动微波观测产品（如 AMSR-E/AMSR2）已被广泛用于监测大尺度地表或近地表土壤热状态（Deo et al. 2017；Wu et al. 2022）。然而二者均存在明显局限，前者受到云遮掩和大气条件影响，且通常反演的是辐射 LST，而非实际意义上的 T_s；后者虽然具备全天候观测能力，但通常受到空间分辨率低和探测深度浅的限制（Long et al. 2020；Huang et al. 2020；Gong et al. 2023；丁利荣等 2023）。此外，基于气象因子和地表变量的统计模型和 ML 方法也被用于 T_s 估算（Bayatvarkeshi et al. 2021；Mortier et al. 2024；Azad et al. 2025），但这类方法通常依赖大规模训练样本，且其跨区域迁移能力可能受到限制。在许多实际应用中，近地表气温仍被用作 T_s 的替代指标，然而二者在能量来源、热容量和热传输过程方面存在显著差异，其时空变化也并不同步（Chen et al. 2021）。上述局限表明，亟需能够可靠表征多深度土壤热状态的数据产品。

在现有数据来源中，再分析产品具有独特优势，其通过融合气象强迫、陆面过程表征和长期连续时间序列，能够生成具有垂向分层信息的 T_s 估算结果。ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q 等广泛使用的再分析产品，已成为陆面过程、生态系统、冰冻圈以及气候影响研究中的重要数据来源（Rodell et al. 2004；Muñoz-Sabater et al. 2021；Kosaka et al. 2024）。然而，这些产品对观测 T_s 的再现能力可能会随着区域、环境条件和土壤深度的不同而发生显著变化。更重要的是，其误差可能并非随机分布，而是可能呈现出系统性的垂向组织特征、环境依赖性和过程相关偏差，从而显著影响其在不同科学应用中的适用性。这种潜在的环境依赖性表明，有必要在地理梯度显著、陆面条件复杂的区域对再分析 T_s 产品进行系统评估。

在这一背景下，中国为评估多层 T_s 再分析产品提供了尤为适宜的地理场景，因为其包含北半球最显著的环境梯度之一。中国地形高程从东部低海拔平原过渡到 QTP，气候类型由湿润季风区转变为干旱和半干旱内陆盆地，季节性积雪和冻融过程也随纬度和地形发生显著变化。这些强烈对比可能会放大站点观测与格网再分析数据之间的尺度不匹配，并导致 T_s 估算误差呈现空间组织性。因此，基于中国区域的评估不仅可以提供不同产品的精度信息，也有助于深入理解地形、季节性和土壤深度如何共同调控陆面热状况产品的可靠性。

已有研究已在全球和区域尺度上对再分析及模型驱动的 T_s 产品进行了评估，并为不同产品的性能差异提供了重要证据。现有研究普遍表明，T_s 产品性能会随环境条件变化而改变，包括 SM、植被类型、气候区和海拔等因素（Albergel et al. 2015；Ma et al. 2021；张天鹏等 2022）。在气候敏感区域，尤其是多年冻土区，有研究发现 JRA-3Q 在模拟 T_s 方面优于若干其他再分析产品（Lan et al. 2025）；而在考虑亚格网异质性后，MERRA-2 被认为在泛北极多年冻土区具有最高的总体精度（Li et al. 2026）。尽管已有研究取得了重要进展，但仍存在若干关键不足。首先，多数评估主要关注平均状态精度或单一土层，对多层产品在统一框架下的系统比较仍较为有限。其次，再分析产品再现 T_s 长期变化的能力尚未得到充分关注。最后，更少有研究考察这些产品对关键土壤热过程的表征能力，例如土壤热浪和冻融动态。

为弥补上述不足，本章节的研究系统评估了四套长期再分析 T_s 产品在中国区域表征 T_s 时空格局、长期变暖趋势及关键土壤热过程的能力。研究选取 1980-2020 年四套广泛使用的再分析数据集，包括 ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q。评估重点包括三个方面：（1）不同产品再现 T_s 空间格局的能力，及其在不同深度、不同季节和海拔条件下的精度表现；（2）不同产品刻画多层 T_s 长期变暖趋势的可靠性；（3）不同产品再现关键土壤热动态过程的表现及一致性，包括土壤热浪和冻融过程。本研究结果可为气候变暖背景下再分析 T_s 产品可靠性评估提供基准，也可为其在陆面过程、冰冻圈、生态系统和气候影响研究中的合理选择与应用提供科学依据。

3.2 数据和方法

本章所使用的数据主要包括两类：首先是第 2.2.1 节介绍的长时序（1980-2020）多层 T_s 原位观测数据。其次是第 2.2.3 节介绍的四套长时序再分析多层 T_s 格网产品，包括 ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q。

表 3-1 本研究使用的 T_s 数据集

Table 3-1 Summary of the T_s datasets

数据集 Dataset	T_s 深度（cm） T_s layers (cm)	时间分辨率 Temporal resolution	空间分辨率 Spatial resolution	时间范围 Time coverage
ERA5-Land	skin temperature, 0-7, 7-28, 28-100	Daily	0.1°	1980-2020
GLDAS 2.0	AvgSurfT_inst, 0-10, 10-40, 40-100	Daily	0.25°	1980-1999
GLDAS 2.1	AvgSurfT_inst, 0-10, 10-40, 40-100	Daily	0.25°	2000-2020
JRA-3Q	0, 7, 19, 49	Daily	0.25°	1980-2020
MERRA-2	0, 9.8, 19.5, 38.5	Daily	0.5° × 0.625°	1980-2020
In-situ sites	0, 5, 10, 15, 20, 40	Daily	-	1980-2020

由于不同再分析产品在空间分辨率和土层深度上存在差异，本文首先将各产品逐日 T_s 数据重采样至统一空间分辨率，并根据原位观测站点经纬度提取对应位置的多层 T_s 值。在此基础上，以各产品原始土层代表深度为自变量、对应 T_s 为因变量，采用一维线性插值方法将站点尺度的再分析 T_s 统一插值至 0、5、10、15、20 和 40 cm 深度。该处理保证了不同再分析产品与原位观测数据在空间位置和土层深度上的一致性，为后续产品精度评价、长期趋势分析和关键土壤热过程指标比较提供基础。在此基础上，本章所采用的方法主要包括趋势分析、土壤热浪和冻融过程识别、精度评价三部分。其中趋势分析方法详见第 2.3.4 节，用于计算 1980-2020 年期间近地表气温和多层 T_s 的长期变化趋势及其显著性；精度评价方法详见第 2.3.7 节，用于定量评估四种再分析产品与原位观测之间的一致性、系统偏差和误差水平。

此外，为进一步评估再分析产品对关键土壤热过程的表征能力有何差异，本章还基于逐日 10 cm 深度 T_s 数据，使用 2.3.5 节介绍的方法，识别土壤热浪事件和冻融状态，并构建相应的过程指标。包括土壤热浪持续时间、发生频次、累积强度、峰值强度，以及初冻日期、终冻日期和冻结日数等。在此基础上，采用皮尔森相关系数（Pearson's correlation coefficient，r）定量比较不同再分析产品在这些过程指标的空间一致性，从而评估其对土壤极端高温过程和冷季冻融过程的表征差异。

3.3 再分析产品对多层 Ts 平均状态的表征能力

图 3-1 展示了中国范围内基于站点的原位观测与四种再分析产品在表征长期 T_s 变率方面的一致性空间分布。总体而言，各产品 R^2 值在东部平原、华北和东北地区普遍较高，而在 QTP 东部、我国西南山地以及西北部分地区较低。这表明，再分析产品在地形相对均一、起伏较小的地区表现更可靠，而在高海拔和地形复杂区域的精度有所降低。在四种产品中，JRA-3Q 在所有深度上表现最佳，高 R^2 站点所占比例最高，低 R^2 站点数量最少。ERA5-Land 表现次之，且整体较为稳定，尤其是在 10-40 cm 深度。GLDAS 表现居中，而 MERRA-2 的低 R^2 值分布较广，特别是在西部和复杂地形区域。图 3-1 表明了再分析产品在表征长期、多深度 T_s 时空变化格局时，不同区域和不同产品间显著的差异。

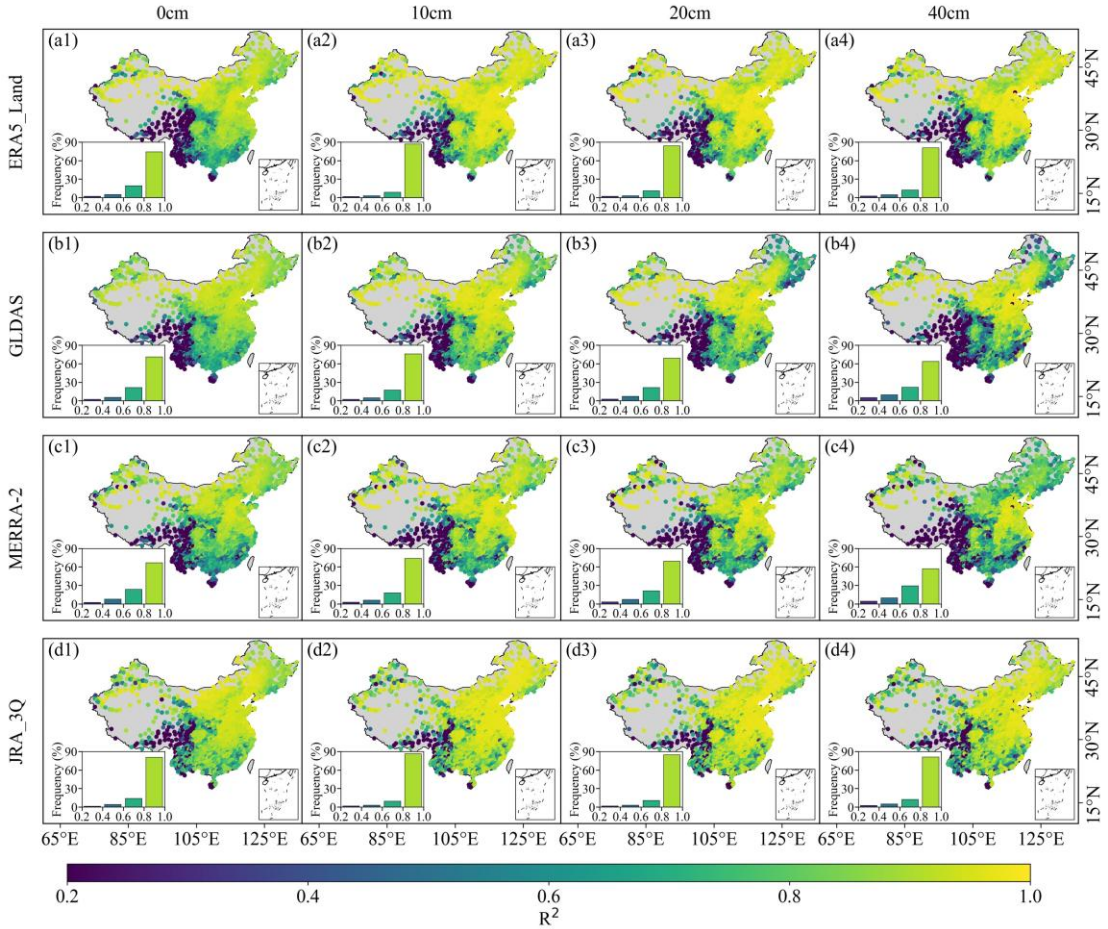


图 3-1 四种再分析产品在表征中国不同深度 T_s 长期变化（1980-2020）的站点一致性空间分布。

Figure 3-1. Spatial distribution of station-level consistency among four reanalysis products in representing long-term T_s changes at different depths across China during 1980-2020.

图 3-2 进一步比较了四种再分析产品在不同深度上再现 T_s 空间格局的能力。总体来看，所有产品均能够捕捉中国范围内 T_s 的宏观空间梯度，这可由散点整

体围绕 1:1 线分布得到体现。然而，大多数散点位于 1:1 线以下，表明四种产品均存在系统性低估 T_s 的现象。在四种产品中，JRA-3Q 的整体一致性最高，在 0-40 cm 土壤剖面内，R^2 范围为 0.68-0.81，偏差范围为−1.70 至−0.72 K。ERA5-Land 也表现较好，尤其在较深土层中表现突出，其 R^2 在 40 cm 深度达到最高值 0.82。GLDAS 的表现居中，而 MERRA-2 始终表现出最低的相关性，并具有最大的 RMSE 和偏差。

不同产品的性能随土壤深度呈现系统性变化。ERA5-Land 和 JRA-3Q 在较深土层中均表现出更高的 R^2 和更小的绝对偏差，表现出与观测结果更好的一致性。GLDAS 随深度增加仅表现出有限改善，而 MERRA-2 在整个土壤剖面内均保持较低相关性，并持续存在低估现象。这些结果表明，四种再分析产品在表征中国多层 T_s 方面存在显著的产品间差异。

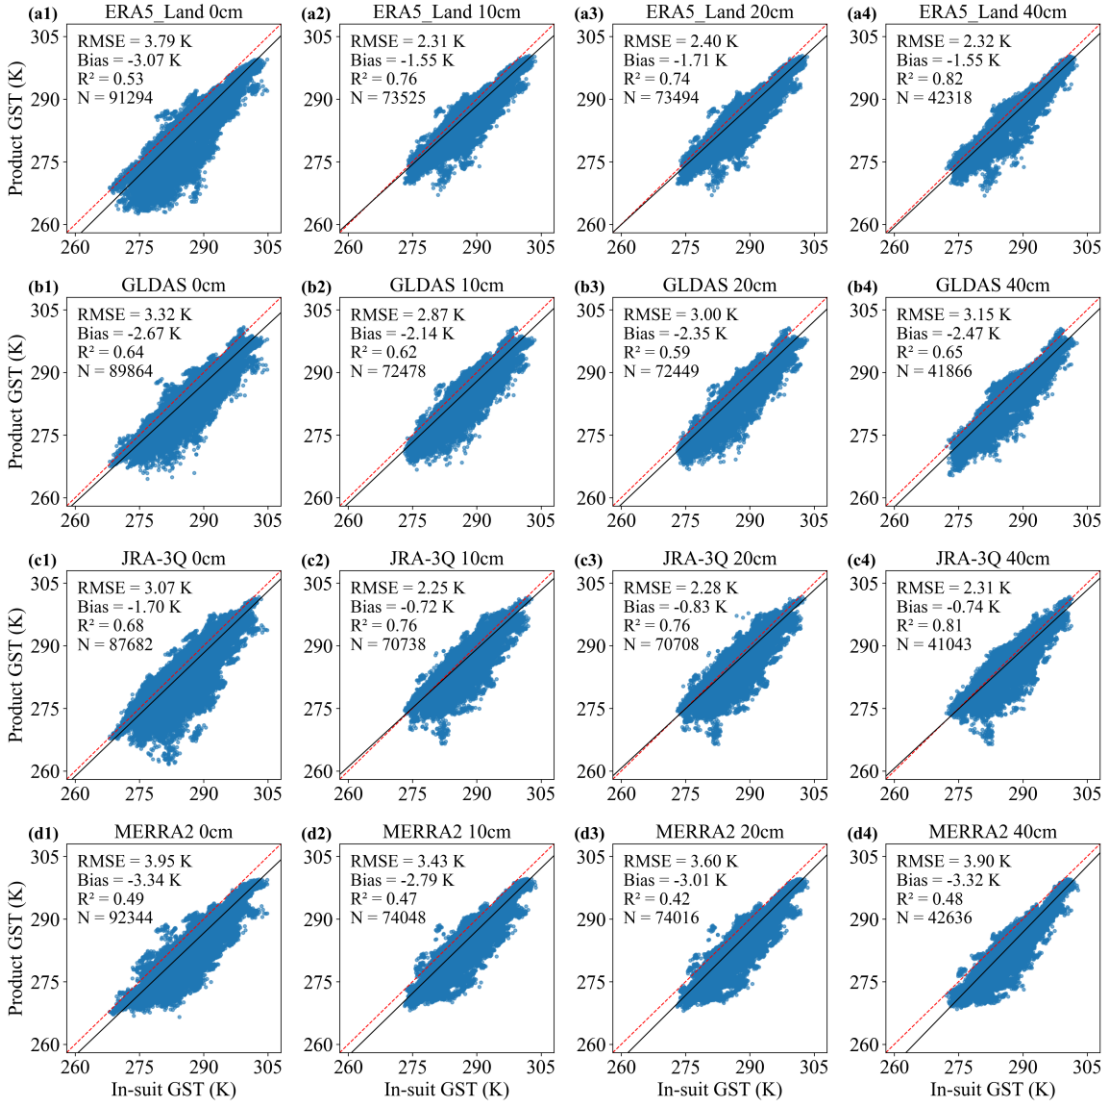


图 3-2 四套再分析产品对中国区域不同深度 T_s 空间分布格局的总体表征能力。

Figure 3-2. Overall performance of four reanalysis products in reproducing the spatial patterns of T_s at different depths across China.

3.4 不同环境背景下再分析 T_s 产品的精度表现

3.4.1 不同季节精度表现

为分析不同再分析 T_s 产品在季节尺度上的模拟能力差异，本文将全年划分为春季（3-5 月）、夏季（6-8 月）、秋季（9-11 月）和冬季（12-2 月），并分别计算 ERA5-Land、MERRA-2、GLDAS 和 JRA-3Q 在不同季节及不同土层深度（0、5 和 15 cm）的 T_s 模拟精度指标。结果表明，不同再分析产品的 T_s 模拟精度具有明显季节差异（图 3-3）。

总体而言，从 R^2 的分布特征来看，四套产品在春季和秋季普遍表现出较高的相关性，而在夏季和冬季明显降低。该趋势在所有深度均较为一致。以 0 cm 深度为例，春季与秋季的 R^2 中位数整体高于夏季和冬季，且箱线图分布更为集中。类似趋势在 10 cm、20 cm 和 40 cm 土层中同样存在。在 ubRMSD 指标上，各产品在夏季和冬季的误差幅度普遍高于春季和秋季，且箱体范围更大，表明误差离散程度增加。整体而言，春秋季节的误差分布更加稳定，而夏冬季节波动幅度更为显著。

从不同产品的对比结果来看，JRA-3Q 在各季节及各深度中均表现出相对较高的 R^2 和较小的 Bias，其模拟结果与观测值的一致性和稳定性整体优于其他再分析产品。GLDAS 和 MERRA-2 在多数季节中取得了较高的 R^2，但其 Bias 和 UBRMSD 在夏季和冬季明显增大，反映出这两套产品在极端气候背景或复杂陆面过程条件下的模拟稳定性仍存在一定不足。相比之下，ERA5-Land 的整体表现处于四套再分析产品的中等水平，其季节间精度变化幅度相对较小，但在部分地区和浅层土壤中仍表现出一定的季节性系统偏差。

从不同土层深度的对比结果来看，R^2 随深度增加整体略有提升或保持稳定，而 ubRMSD 和 Bias 绝对值总体呈下降趋势。具体而言，浅层土壤，尤其是 0 cm 深度，误差幅度和离散程度较大；随着土层加深，误差分布逐渐收窄，20 cm 和 40 cm 深度的模拟结果更加稳定，且季节间差异有所减弱。Bias 结果显示，多数产品在不同季节和土层深度下均表现出一定程度的负偏差，表明其对 T_s 存在系统性低估；该特征在夏季和冬季更为明显，并主要集中于 0 和 10 cm 等浅层土壤。相比之下，JRA-3Q 的 Bias 更接近零，说明其系统偏差相对较小。总体而言，四套再分析产品在季节尺度上的模拟精度存在明显差异，整体呈现春季和秋季精度较高、夏季和冬季精度较低的特征（图 3-3）。同时，误差幅度随深度增加而减小，浅层 T_s 的季节性误差更为突出。产品间比较显示，JRA-3Q 在相关性和系统偏差控制方面整体优于其他产品，而 GLDAS 与 MERRA-2 在夏季和冬季误差波动较大。

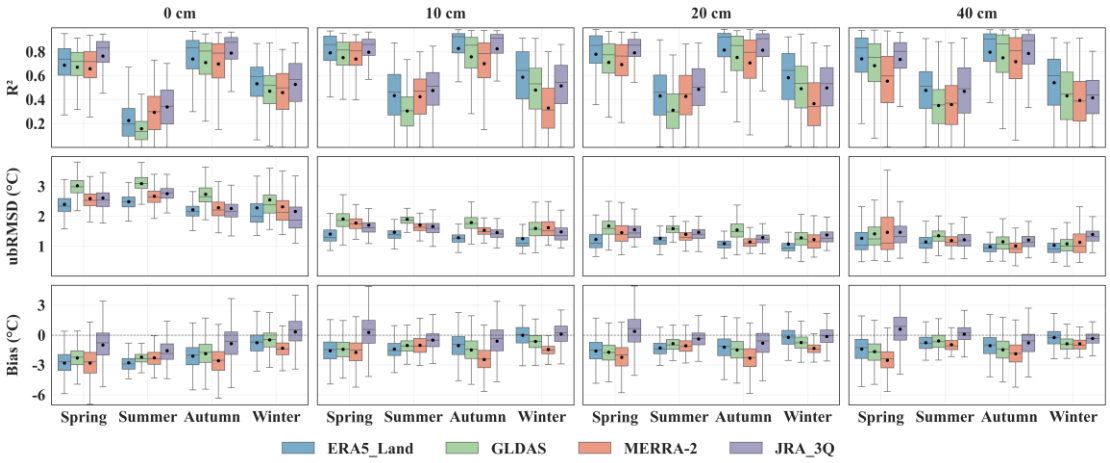


图 3-3 四套再分析 T_s 产品在不同季节的精度比较。

Figure 3-3. Comparison of seasonal accuracy of four reanalysis T_s products.

3.4.2 不同土地类型精度表现

为进一步分析不同下垫面下再分析 T_s 产品精度的差异，本文基于土地利用类型数据将原位观测站点划分为荒地（Barren）、耕地（Cropland）、森林（Forest）和草地（Grassland）四类，并分别评估 ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q 在不同土地利用类型及不同深度（0、5 和 15 cm）下的精度。结果表明，不同土地利用类型下各再分析产品的 R^2、ubRMSD 和 Bias 分布存在明显差异（图 3-4）。

从整体来看，不同土地利用类型下再分析 T_s 产品的精度具有显著差异。荒地的 R^2 整体高于其他三类下垫面类型，同时 ubRMSD 与 Bias 的绝对值普遍较大，且箱线图离散程度更高。相比之下，耕地与草地的 R^2 值整体较高，误差分布相对集中。森林区域的 R^2 最低，但在部分产品中呈现较大的误差波动范围。在产品间比较方面，JRA-3Q 在四类土地利用类型和多数深度中均表现出较高的 R^2 和较小的 Bias，其箱线图中位数整体位于较优区间，且离散程度相对较小。MERRA-2 与 GLDAS 在耕地和森林区域的 R^2 值较高，但在荒地和草地条件下 R^2 明显下降，同时 ubRMSD 与 Bias 波动幅度增加。ERA5-Land 在不同土地利用类型之间的精度变化相对平稳，但在荒地和森林区域的浅层土壤中 ubRMSD 较高。整体来看，JRA-3Q 在不同土地利用类型下表现出较强的一致性，而其他产品在荒地条件下精度下降更为明显。

不同深度对比结果表明，ubRMSD 随深度增加整体呈下降趋势，各土地利用类型间的误差差异在深层土壤中明显减弱。在 40 cm 深度下，各产品在不同土地利用类型间的 R^2 差异幅度缩小，箱线图重叠程度明显增加，表明深层 T_s 模拟结果在不同下垫面条件下趋于一致。浅层土壤（0 cm -10 cm）中，土地利用类型之间的差异最为显著，荒地的误差幅度最大，而耕地和草地的误差相对较小。Bias

指标显示，大多数产品在不同土地利用类型下普遍存在负偏差，且荒地和森林区域的偏差幅度相对较大。耕地和草地中的 Bias 绝对值整体较小，且分布范围更集中。JRA-3Q 的 Bias 在各类土地利用类型下均接近零值，而 GLDAS 和 MERRA-2 在荒地条件下负偏差更为明显。

综上，不同土地利用类型下再分析 T_s 产品的模拟精度存在明显差异，且浅层土壤中的误差差异更为突出。荒地区域整体表现出较低的 R^2 和较高的误差幅度，说明再分析产品在裸露下垫面条件下对 T_s 的模拟不确定性较大；相比之下，耕地和草地条件下的模拟精度相对较高。不同产品中，JRA-3Q 在各类土地利用类型和不同深度下表现较为稳定，综合精度优于其他产品。

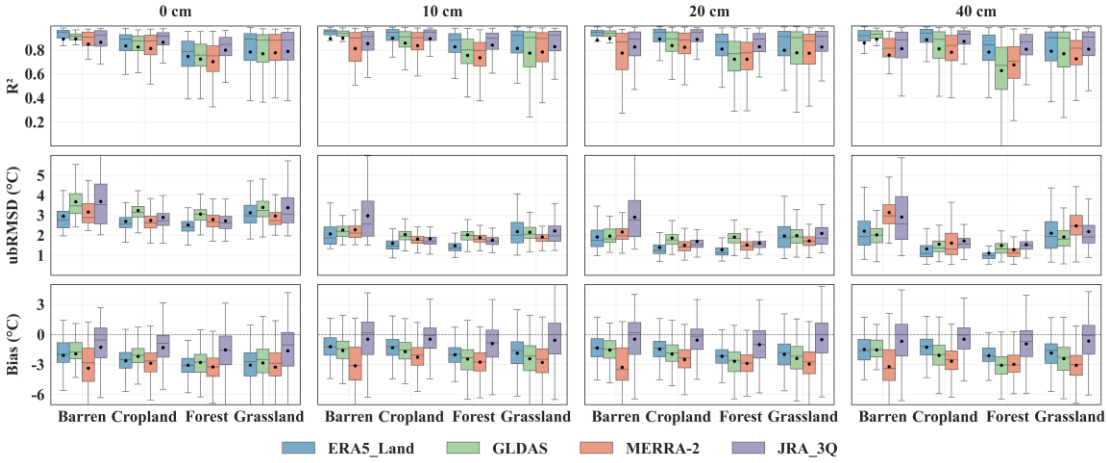


图 3-4 不同土地利用类型下四套再分析 T_s 产品在不同深度的模拟精度。

Figure 3-4. Comparison of simulation accuracy of four reanalysis T_s products under different land-use types at different soil depths.

3.4.3 不同海拔区间精度表现

四套再分析 T_s 产品性能从 DEM-I 到 DEM-IV 呈下降趋势，具体表现为 R^2 值降低，以及 ubRMSD 和偏差分布范围扩大（图 3-5）。这一趋势在浅层土壤中最为明显，尤其是在 0 和 10 cm 深度。在低海拔分组（DEM-I 和 DEM-II）中，多数产品能够取得相对较高的 R^2 值，且分布较为集中；而在高海拔分组（DEM-III 和 DEM-IV）中，相关性明显降低，ubRMSD 和偏差的离散程度增大，表明在复杂地形和高海拔条件下产品不确定性更高。相比之下，在 20 和 40 cm 深度下减弱，说明深层 T_s 对地形条件的敏感性较低。

在四套产品中，JRA-3Q 在多数海拔分组和土壤深度下均保持相对较高的 R^2 值，且偏差接近于零，表明其整体性能最为稳定。ERA5-Land 在低海拔地区表现较好，但在 DEM-III 和 DEM-IV 分组中性能下降更为明显。GLDAS 和 MERRA-2 在低海拔地区也表现出相对较高的 R^2 值。然而在高海拔地区，尤其是浅层土

壤中，二者的 ubRMSD 和偏差分布更加离散。沿垂向剖面来看，R^2 通常随土壤深度增加而升高或保持稳定，而 ubRMSD 和绝对偏差则逐渐降低，表明产品在较深土层中的表现更加一致。总体而言，图 3-5 表明海拔对再分析 T_s 产品性能具有显著调控作用，其误差在高海拔地区和浅层土壤中更大。

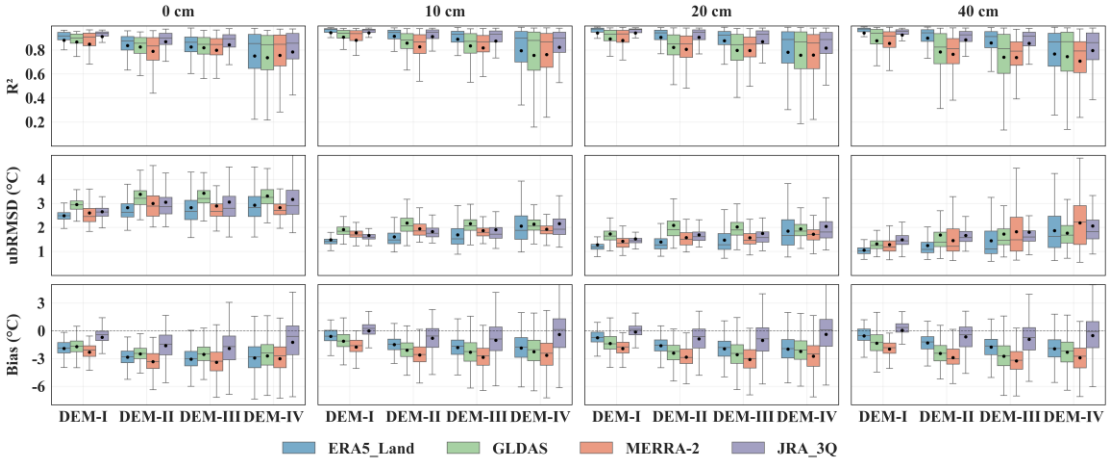


图 3-5 不同海拔梯度下四套再分析 T_s 产品在不同深度的精度表现。

Figure 3-5. Comparison of simulation accuracy of four reanalysis T_s products under different elevation gradients at different soil depths.

3.5 不同数据捕捉长期变暖信号的能力

3.5.1 基于观测数据的变暖信号

1980-2020 年中国区域不同深度站点年均 T_s 的 Theil-Sen 趋势斜率均以正值为主，表明过去四十年中国区域 T_s 整体呈升高趋势（图 3-6）。箱线图结果显示，不同土层的增温幅度存在明显垂向差异。0 cm 深度的增温趋势最强，其趋势斜率的中位数和上四分位数均高于其他土层，且高值端分布范围更宽，说明浅层土壤中较强增温站点占比更高。相比之下，10 cm 和 20 cm 深度的趋势斜率整体降低，分布范围相对收窄，表明增温幅度随土层加深有所减弱。40 cm 深度仍以增温为主，但增温幅度进一步降低，且斜率的空间差异相对更加突出。

空间分布图进一步表明，中国大部分地区的 T_s 趋势以升高为主，但增温幅度及其空间分布特征随土壤深度发生变化。在 0 cm 深度显著增温站点分布最为广泛，主要集中在东北、华北以及西北部分地区。10 和 20 cm 仍以正向增温趋势为主，但显著增温站点的分布范围较 0 cm 有所缩小。相比之下，40 cm 深度的空间格局更加分散，表现为强增温站点数量减少，而弱增温或不显著变化的站点比例增加。总体而言，上述结果表明，中国区域长期土壤增温具有广泛性，但其增温幅度和显著性均随土壤深度增加而减弱。因此，增温信号在近地表最强，且空间连续性最高；而在较深土层中，增温信号相对较弱，并表现出更强的空间

异质性。从区域分布来看，中国较高纬度地区的土壤增温通常更为明显。

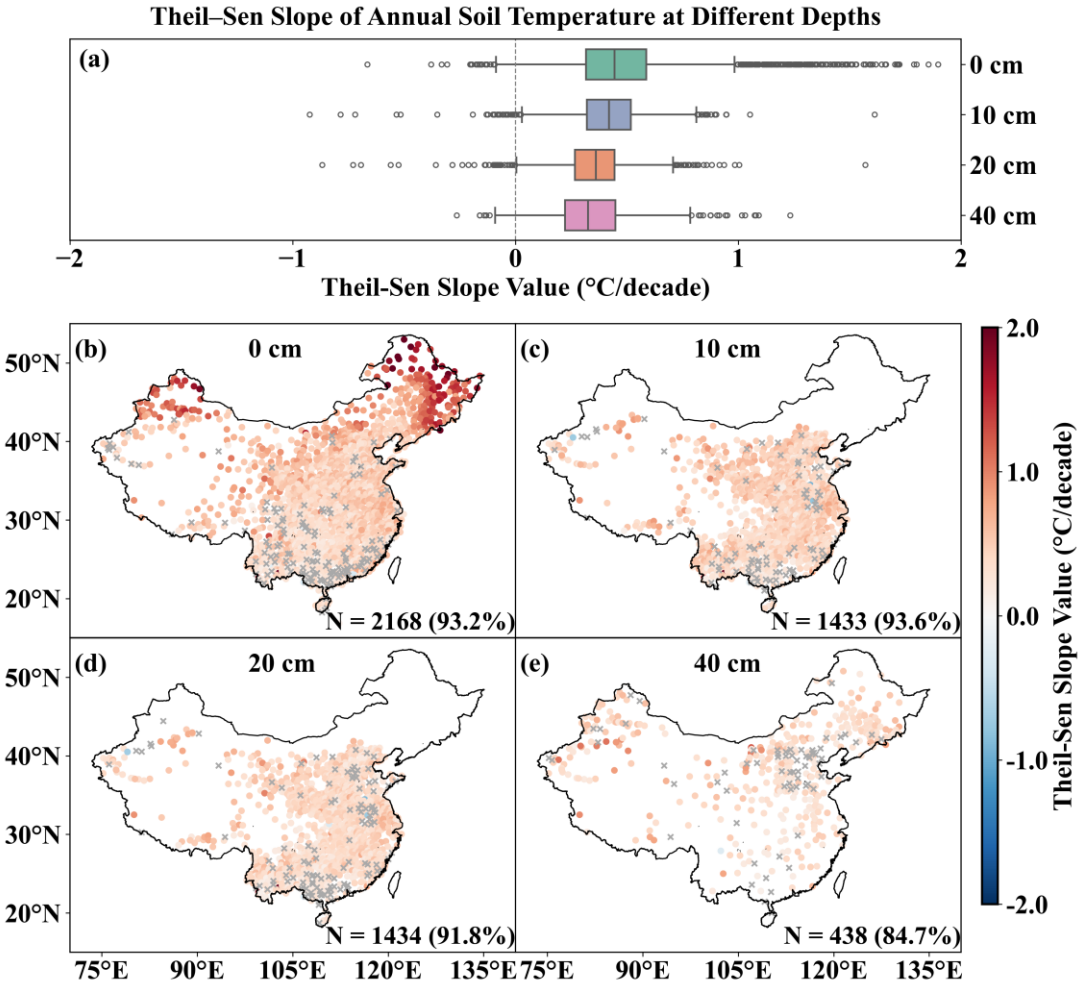


图 3-6 1980-2020 年中国区域基于观测站点的不同深度年均 T_s 变化趋势的垂向与空间格局。颜色表示年均 T_s 变化趋势的大小，单位为°C decade^{-1}；灰色叉号表示基于 Mann-Kendall 检验未通过显著性检验的站点（$p \geq 0.05$）；N 表示各深度参与趋势分析的站点数。

Figure 3-6. Vertical and spatial patterns of observed trends in annual mean T_s across China during 1980-2020. Colors indicate trend magnitude in °C decade^{-1}, and gray crosses denote non-significant trends based on the Mann-Kendall test ($p \geq 0.05$). N denotes the number of valid stations used for trend analysis at each depth.

3.5.2 再分析产品对变暖幅度的表征及其空间格局

四套再分析产品年均 T_s 在不同土层中均表现出以增温为主的变化趋势，说明这些产品能够捕捉中国长期土壤增温的总体方向（图 3-7）。然而，不同产品在增温幅度、空间连续性和区域异质性方面仍存在明显差异。其中，图 3-7（a1-d1）结果显示 ERA5-Land 在多数区域和深度上表现出较为连续的正趋势，其空间格局从地表层到较深土层总体较为一致。JRA-3Q 同样显示出广泛的增温趋势，但局地空间异质性更强，尤其是在中国西部和 QTP 边缘地区，增温与降温斑块交

替分布的特征更加明显。MERRA-2 在各深度中的增温趋势整体较弱，且未通过显著性检验的像元比例较高。相比之下，GLDAS 表现出最强的空间异质性，其中在云贵高原（YGP）及中国东南部部分地区出现了较为明显的降温趋势。

不同产品的增温趋势也表现出一定的深度差异。ERA5-Land 和 JRA-3Q 在不同深度总体保持了相似的增温结构，但增温强度通常随深度增加而减弱。GLDAS 在整个土壤剖面中均表现出较强的空间异质性，不同区域之间增温和降温趋势交替分布明显。总体而言，图 3-7 表明，不同再分析产品在表征土壤增温幅度和空间格局方面存在显著差异：ERA5-Land 和 JRA-3Q 能够更接近地再现大尺度增温结构，MERRA-2 的增温响应相对较弱，而 GLDAS 则表现出最强的空间差异。

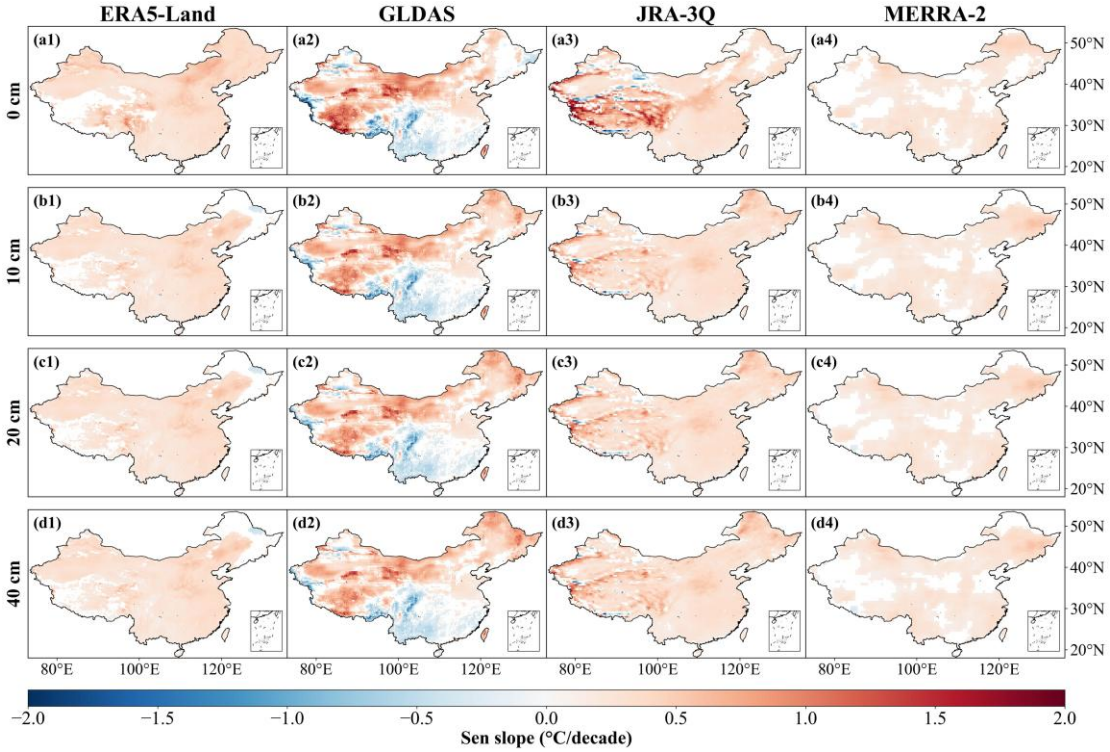


图 3-7 1980-2020 年间，中国区域四种再分析产品不同深度年均 *Ts* 的 Theil-Sen 斜率空间分布图。空白区域表示变化趋势不显著（$p > 0.05$）。

Figure 3-7. Spatial patterns of Theil-Sen slopes in annual mean T_s at four depths derived from the four reanalysis products over China during 1980-2020. Blank areas indicate non-significant trends ($p > 0.05$).

3.6 不同产品热过程指标的一致性

3.6.1 土壤热浪指标的空间格局及产品间一致性

基于四套再分析产品提取的多年平均土壤热浪指标表明，不同产品对中国区域土壤热浪大尺度空间格局的刻画具有一定一致性。持续时间、发生频次、累积强度和峰值强度四类指标的空间分布总体相似，但不同产品在指标数值幅度及空

间异质性刻画方面仍存在明显差异（图 3-8）。

对于持续时间和发生频次而言，土壤热浪指标值总体表现为中国西部较低、东部和东北地区较高，但这一空间梯度的强弱在不同产品之间存在差异。GLDAS 表现出最强的空间异质性，高值区和低值区分布较为破碎；相比之下，MERRA-2 的空间梯度较弱，空间格局更加平滑。ERA5-Land 和 JRA-3Q 则表现出较为连续的区域结构，二者的空间分布总体较为相似，尤其是在持续时间指标上更为明显。对于累积强度和峰值强度而言，所有产品均显示中国北方地区土壤热浪强度较高，尤其集中在东北和华北部分地区，而南方和西南地区的强度相对较低。GLDAS 和 JRA-3Q 在累积强度上表现出更强的空间对比，而 MERRA-2 的空间格局更加平滑，且整体强度偏弱。峰值强度在不同产品之间表现出相对较高的空间一致性，各产品在中国北方均显示出较为相似的高值区，而向南方地区则逐渐过渡为中等或较低值。

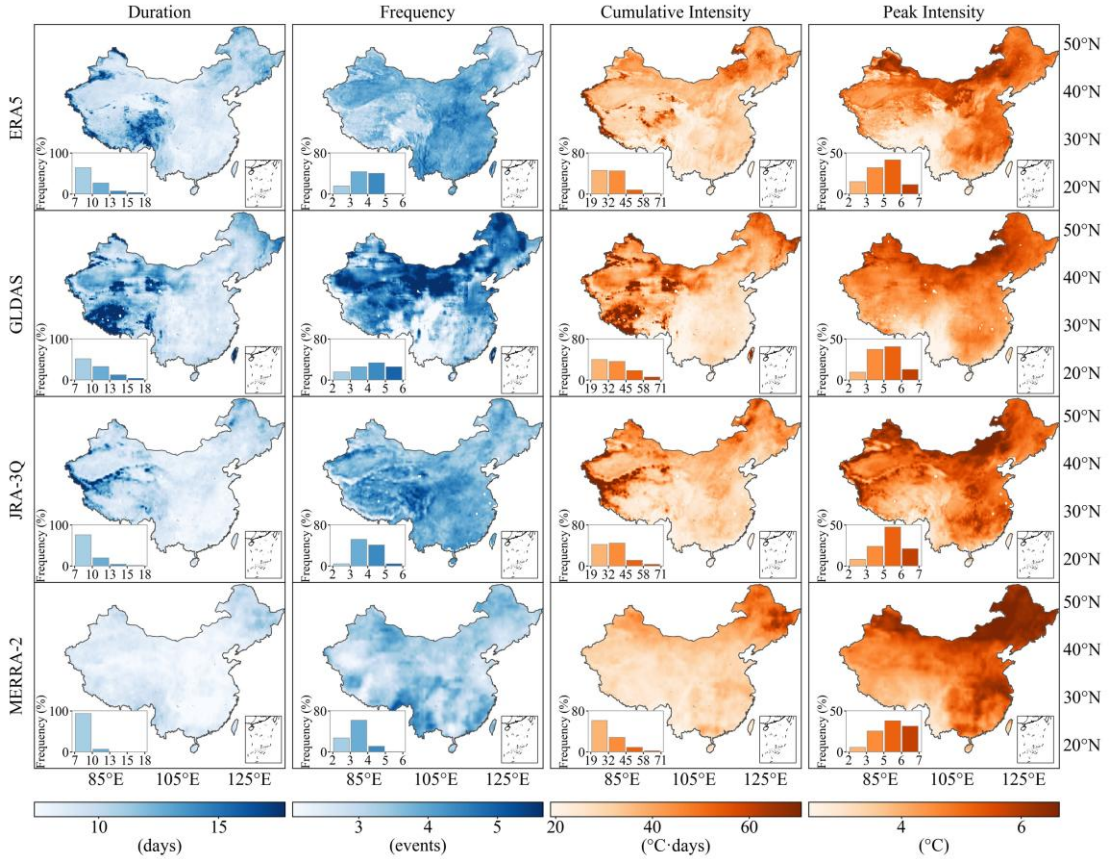


图 3-8 在 10 cm 深度，基于四套再分析产品提取的土壤热浪指标多年平均空间格局。包括平均持续时间、平均发生频次、平均累积强度和平均峰值强度四个指标。

Figure 3-8. Annual mean spatial patterns of four soil heatwave metrics derived from the four reanalysis products at 10 cm depth over China, including mean duration, event frequency, cumulative intensity, and peak intensity.

不同再分析产品之间的两两空间相关分析表明，四类土壤热浪指标的产品间

一致性存在差异。其中，峰值强度表现出最高的一致性，各产品组合均呈较强正相关关系（r=0.69-0.80），表明不同再分析产品对土壤热浪峰值强度空间分布的刻画较为一致（图 3-9）。相比之下，累积强度和持续时间表现为中等程度的一致性，其相关关系总体为正，但相关强度相对较弱，其中较高的相关系数主要出现在 ERA5-Land 与 JRA-3Q 之间。发生频次的产品间一致性最弱，多个产品组合的相关系数接近于零，甚至呈负相关，说明不同产品在表征土壤热浪发生次数方面存在较大不确定性。总体而言，上述结果表明，土壤热浪特征的产品间一致性具有明显的指标依赖性。与强度相关的指标，尤其是峰值强度，在不同产品之间表现出更高的一致性；而与发生过程相关的指标，尤其是发生频次，则更依赖于具体产品，产品间差异更为显著。

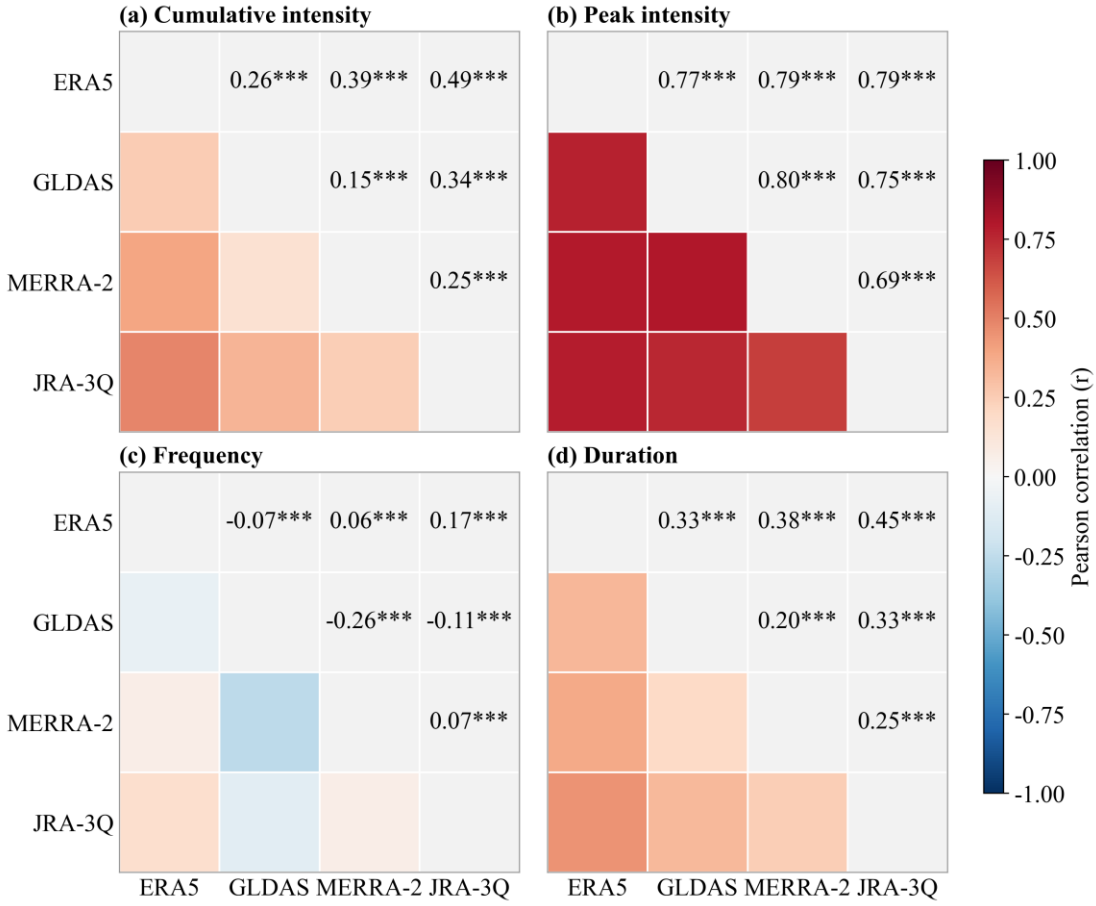


图 3-9 四套再分析产品在中国区域 10 cm 深度土壤热浪指标上的空间一致性。指标包括累积强度、峰值强度、事件频次和持续时间，用于表征不同产品对土壤热浪空间格局识别的一致性。图中数值为 Pearson 相关系数（r），***表示相关性通过 $p < 0.001$ 的显著性检验。

Figure 3-9. Inter-product spatial agreement in soil heatwave metrics among the four products at 10 cm, including cumulative intensity, peak intensity, frequency, and duration. Values indicate Pearson correlation coefficients (r), and *** denotes statistical significance at $p < 0.001$.

3.6.2 土壤冻融指标的空间格局及产品间一致性

基于四套再分析产品提取的多年平均土壤冻融指标显示，初冻日期、终冻日期和冻结日数均呈现出较为一致的大尺度空间格局。总体来看，不同再分析产品对中国区域气候态冻融过程的空间分布具有较强刻画能力，但仍可进一步从局地差异和数值偏差角度评估其产品间差异（图 3-10）。

初冻日期表现出明显的纬度和海拔梯度，即高纬度地区、QTP 以及其他高海拔地区初冻时间较早，而气候较暖的南方地区初冻时间较晚。终冻日期则呈现相反的空间格局，表现为北方和高海拔地区终冻时间较晚，而南方地区终冻时间较早。冻结日数同样表现出显著的南北差异和高低海拔对比，其中东北地区、北疆和 QTP 的冻结持续时间较长，而南方地区的冻结日数几乎为零。尽管不同产品之间仍存在一定的局地差异，但四套产品之间冻融指标的整体空间一致性较高。

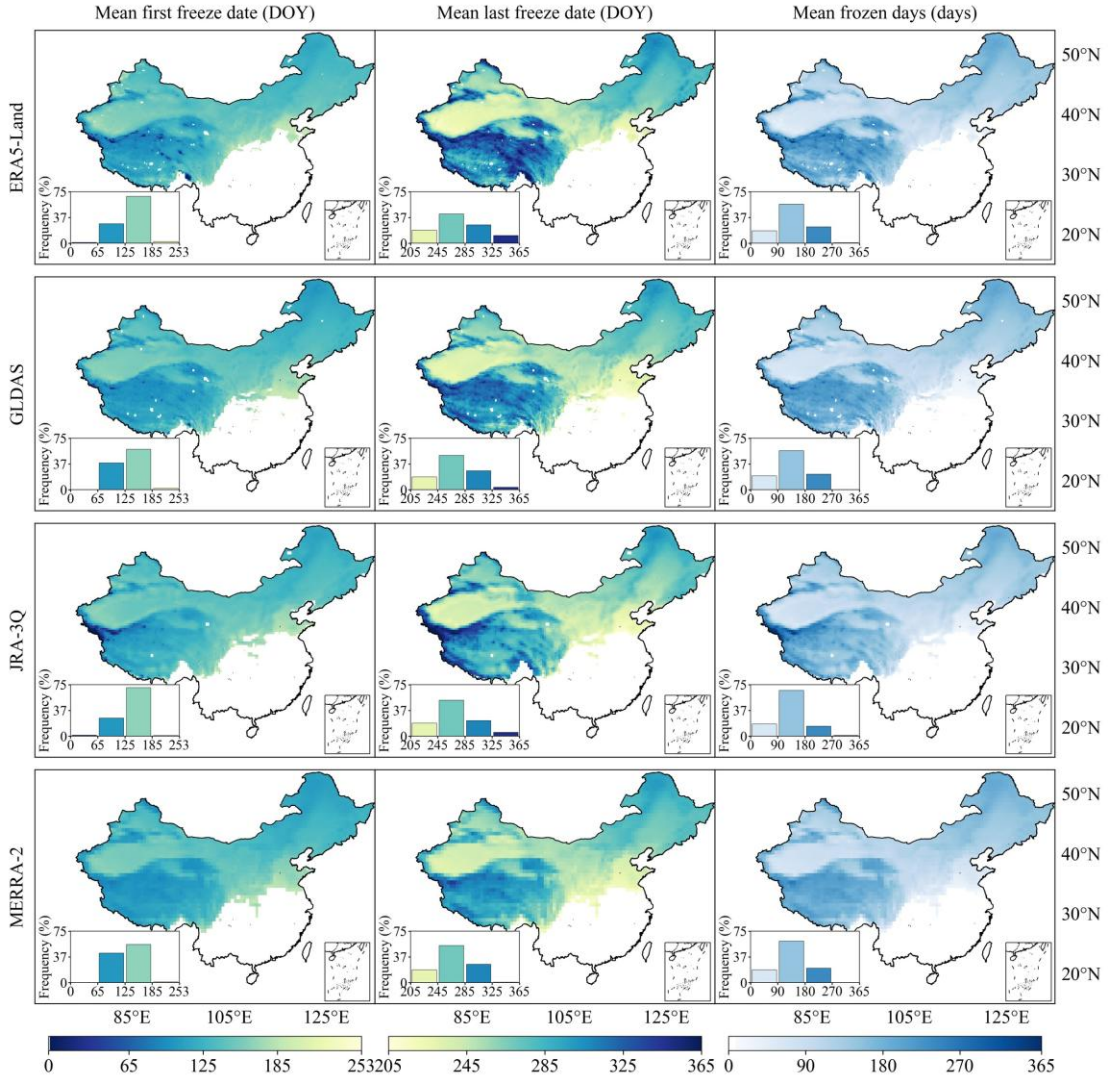


图 3-10 中国区域 10 cm 深度基于四套再分析产品提取的土壤冻融指标多年平均空间格局。三类指标包括平均初冻日期、平均终冻日期和平均冻结天数。

Figure 3-10. Annual mean spatial patterns of three soil freeze-thaw metrics derived from the four reanalysis products at 10 cm depth over China, including mean first freeze date, mean last

freeze date, and mean frozen days.

三类土壤冻融指标的两两空间相关结果显示，不同再分析产品之间总体呈较强正相关关系。其中，初冻日期和终冻日期表现出较高的产品间一致性，相关系数大多介于 0.75-0.93 之间，表明四套产品对中国区域土壤冻融起止时间空间格局的表征较为一致（图 3-11）。冻结日数表现出最高的产品间一致性，各产品组合均保持较强相关关系（r=0.81-0.95），表明与基于冻融时间节点的指标相比，冻结日数在不同再分析产品之间的估算结果更加一致。不同产品在中国区域的有效像元覆盖率总体接近，范围为 72.5%-77.8%。总体而言，上述结果表明，与土壤热浪指标相比，基于再分析产品提取的土壤冻融指标在产品间具有更高的一致性。其中，冻结日数的一致性最高，而初冻日期和终冻日期在不同产品之间也保持较强相关关系。这些结果说明，冷季土壤热状态转换的气候态空间结构在不同再分析系统中相对稳定。

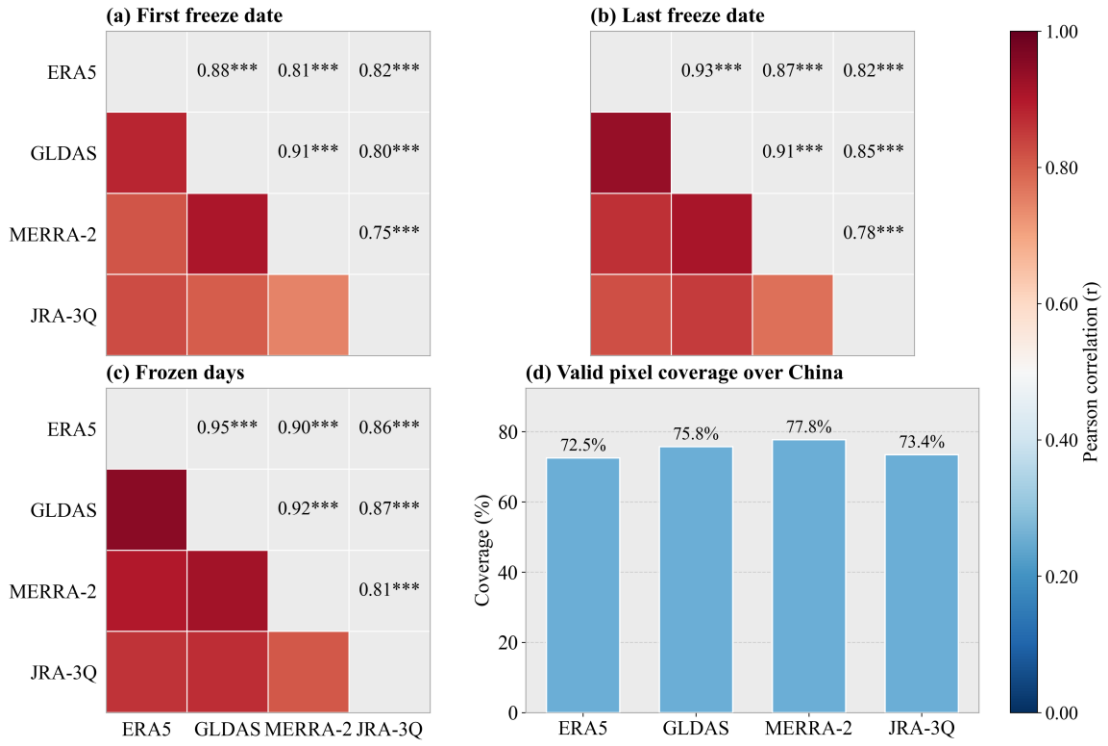


图 3-11 中国区域 10 cm 深度四种再分析产品土壤冻融多年平均指标空间分布的一致性及不同产品冻融有效像元占比。包括初冻日期、终冻日期和冻结日数三个指标。图中数值为 Pearson 相关系数（r），***表示相关性通过 $p < 0.001$ 的显著性检验。

Figure 3-11. Pairwise spatial correlations of annual mean soil freeze-thaw metrics among the four reanalysis products at 10 cm depth, including first freeze date, last freeze date, and frozen days, together with valid pixel coverage over China. Values indicate Pearson correlation coefficients (r), and *** denotes statistical significance at $p < 0.001$.

3.7 讨论

3.7.1 再分析 *Ts* 产品精度表现的垂向分异及环境依赖性

本研究结果表明，再分析 T_s 产品的误差并非随机分布，而是在土壤深度和环境梯度上均呈现出一定的结构性特征，并受到土壤深度和环境条件的共同影响。在四套产品中，误差通常在浅层土壤中较大，并随土壤深度增加而减弱。这种垂向变化特征表明，近地表 T_s 的模拟难度更高，因为其直接响应大气强迫、辐射条件、SM 变化、植被覆盖以及局地地表异质性等多种因素的共同作用（Albergel et al. 2015；Ma et al. 2021；Smith et al. 2022）。相比之下，较深土层主要受热扩散过程控制，并具有更强的热惯性，能够削弱短期波动的影响，因此其模拟结果通常更加稳定（Wang et al. 2024；Li et al. 2026）。

再分析产品精度还沿环境梯度表现出系统性变化。产品不确定性在夏季和冬季相对较大，并在高海拔及地形复杂地区进一步放大。夏季较大的误差可能与强辐射强迫条件下地表能量分配、土壤湿度和温度耦合关系以及蒸散发过程的不确定性有关（Albergel et al. 2015；Ma et al. 2021）。冬季误差则可能与积雪保温效应、冻融转换过程以及冻土热过程的表征有关，这些过程均会强烈调控土壤热状态（Wang et al. 2022；Zhao et al. 2025）。在复杂地形区，较粗分辨率的格网难以准确表征局地海拔、坡度、积雪再分配和土地覆盖异质性，从而导致站点观测与再分析估算之间的尺度不匹配（Koenig et al. 2025；Wang et al. 2026）。

在四套产品中，JRA-3Q 在不同土壤深度和环境条件下总体表现最为稳定，其次为 ERA5-Land。相比之下，GLDAS 和 MERRA-2 在复杂地形和浅层土壤条件下表现出更明显的误差放大现象。这些产品间差异可能源于气象强迫数据、陆面过程参数化方案、空间分辨率以及土层配置等方面的不同（Gelaro et al. 2017；Muñoz-Sabater et al. 2021；Kosaka et al. 2024）。已有针对寒区和多年冻土区的评估研究也表明，由于积雪、土壤和陆面过程表征方式存在差异，不同再分析系统的产品性能可能存在显著差别（Lan et al. 2025）。总体而言，本研究结果表明，再分析 T_s 产品的评估不应局限于总体精度指标；在不同应用场景中，应进一步考虑产品误差随土壤深度和环境条件变化所表现出的结构性差异。

3.7.2 再分析产品表征长期土壤变暖的可靠性

观测结果表明，1980-2020 年中国区域 T_s 呈现出普遍升高的趋势，且变暖幅度在浅层最强，随深度增加逐渐减弱。四套再分析产品总体上能够再现这一大尺度土壤增温方向，但在增温幅度、空间连续性和区域异质性方面存在明显差异。其中，ERA5-Land 和 JRA-3Q 表现出更加连续的增温空间格局，而 MERRA-2 的增温响应相对较弱，GLDAS 则表现出更强的空间破碎性。已有针对区域尺度和多年冻土区的评估研究也表明，不同再分析产品在 T_s 变化趋势表征方面可能存

在显著差异（Lan et al. 2025）。

这些差异说明，产品对长期趋势的表征能力不仅取决于平均状态模拟精度，也受到随时间变化的结构性偏差影响。恒定的平均偏差未必会显著改变趋势斜率，但若偏差随时间、季节、土壤深度或环境条件发生变化，则可能影响长期增温幅度及其空间格局的估计。这类时间依赖性误差可能来源于大气强迫、积雪覆盖、SM、陆气耦合过程以及土壤热参数化方案等方面的不确定性（Zhang et al. 2008；Lyu et al. 2018；Yan et al. 2024）。因此，在 T_s 的平均状态模拟中表现较好的产品，并不一定具有同等稳定的长期增温表征能力。

浅层土壤增温趋势的不确定性较大，这与浅层土壤对外部强迫和局地陆面条件更敏感的物理特征相一致。地表及近地表 T_s 直接受到大气增温、辐射条件、积雪保温、植被变化和 SM 波动等因素影响，因此其趋势估计更容易受到模型结构误差的影响（Smith et al. 2022）。在寒冷和高海拔地区，这种不确定性可能进一步放大，因为积雪和冻土过程对土壤热状况具有重要调控作用（Schaefer et al. 2009；Zhao et al. 2025）。上述结果表明，在开展 T_s 长期趋势分析时，产品的气候态模拟精度并不能完全代表其对长期变化信号的刻画能力。因此，有必要进一步评估不同产品对增温幅度、空间格局及区域差异的再现能力。

3.7.3 关键土壤热动态过程中的过程依赖性表现

基于再分析产品提取的土壤热过程指标表现出明显的产品间一致性差异，这种差异在冻融指标和土壤热浪指标之间尤为突出。冻融指标表现出更高的产品间一致性，尤其是冻结日数，而初冻日期和终冻日期在不同产品之间也保持较强相关关系。相比之下，土壤热浪指标对具体产品更加敏感，尤其是热浪发生频次；而峰值强度则表现出相对较高的一致性。这种差异与已有研究认识一致，即冻融转换过程和热浪事件在主控机制、时间尺度以及指标定义敏感性等方面均存在显著差别（Hobday et al. 2016；Barriopedro et al. 2023）。

冻融指标较强的一致性可能与其主要受冷季大尺度气候梯度控制有关。冻融指标通常基于 0 ℃附近的温度阈值转换确定，并受到海拔、气温、积雪覆盖和 SM 等条件的共同约束（Yi et al. 2019；Jiang et al. 2020）。这些控制因素能够形成较为连续的大尺度空间格局，使冻融指标对不同产品日尺度 T_s 的局地差异相对不敏感。其中，冻结日数综合反映了冻结状态的季节持续性，因此相比初冻日期和终冻日期等基于时间节点的指标，在不同产品之间表现得更加稳定。

相比之下，土壤热浪指标对局地高温异常和事件识别规则更加敏感。热浪发生频次和持续时间强烈依赖百分位阈值、最短持续时间以及事件合并标准，而这些因素通常是热浪识别不确定性的重要来源（Zhang et al. 2022；Barriopedro et al. 2023）。因此，当日尺度 T_s 接近阈值时，不同产品之间的微小差异就可能改变事

件是否被识别，从而导致热浪发生类指标在产品间产生较大差异。相比之下，峰值强度受事件分割方式的影响较小，因为其反映的是已识别事件中的最强异常程度，这也解释了其在不同产品之间相对较高的一致性。因此，在解释基于发生过程的土壤热浪指标时应保持谨慎；在条件允许的情况下，建议结合多产品比较或不确定性范围共同报告相关结果（Perkins-Kirkpatrick et al. 2020）。

3.7.4 产品选择与未来模型发展的启示

本研究对四套再分析 T_s 产品在平均状态表征、长期趋势再现和土壤热过程指标提取方面的性能进行了系统比较，可为中国区域 T_s 数据产品的合理选择和应用提供参考。产品选择不应仅依据单一的总体精度排序，而应根据具体研究目标和应用场景进行判断。对于关注 T_s 平均状态空间格局或多层土壤热结构的研究，JRA-3Q 和 ERA5-Land 在不同土壤深度和环境梯度下表现出更高的整体精度。对于长期增温趋势分析，ERA5-Land 和 JRA-3Q 能够提供更加连续的大尺度增温格局；而基于 GLDAS 得到的趋势结果则需要谨慎解释，因为 GLDAS 2.0 和 GLDAS 2.1 的联合使用可能引入与版本转换相关的不连续性（Qi et al. 2018）。

对于面向土壤热过程的应用，结果可信度取决于具体指标类型。冻融指标，尤其是冻结日数，在不同产品之间表现出较强一致性，因此可相对稳健地用于冷季土壤热状态的大尺度评估。相比之下，土壤热浪发生频次对不同产品的日尺度 T_s 波动和事件识别阈值高度敏感。因此，在研究土壤热浪发生特征时，不宜仅依赖单一产品，而应尽可能采用多产品集合、不确定性范围或敏感性检验来支撑结果解释。本研究结果表明，未来再分析系统的发展应重点改进浅层土壤热动态、积雪保温效应、冻土过程以及地形相关的亚格网异质性表征，尤其是在 QTP、西南山地以及其他环境条件复杂区域。最后，针对当前地形复杂和高寒地区观测约束不足的问题，未来应进一步完善长期原位 T_s 观测网络，并加强观测资料与遥感及再分析系统的融合，从而提升产品评估的可靠性，并为陆面模式改进提供更充分的数据支撑。

3.8 小结

本章基于 1980-2020 年长时序多层 T_s 原位观测资料，系统评估了 ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q 四套再分析产品在中国区域的适用性。评估内容涵盖不同深度 T_s 平均状态及空间格局、不同季节和下垫面背景下的精度表现、长期增温趋势再现能力，以及土壤热浪和冻融等关键土壤热过程指标的产品间一致性。主要结论如下：

（1）四套再分析产品均能够在一定程度上反映中国区域多层 T_s 的空间格局，但不同产品的精度和系统偏差存在明显差异。在 0-40 cm 土层中，JRA-3Q 总体

表现最为稳定，R^2为 0.68-0.81，Bias 为-1.70 到-0.72 K；ERA5-Land 在深层土壤中的表现较好，40 cm 深度 R^2达到 0.82；GLDAS 的 R^2总体为 0.59-0.65，而 MERRA-2 相对较低，为 0.42-0.49，且表现出更明显的负偏差。不同产品的误差总体呈现浅层较大、随深度增加逐渐减小的特征，并在夏季、冬季以及高海拔和复杂地形区域进一步增大。这表明，再分析 T_s 产品的适用性具有明显的条件差异，在复杂地形、高海拔区域和浅层土壤应用中需要更加谨慎。

（2）1980-2020 年原位观测的多层 T_s 总体呈增温趋势，但不同再分析产品对长期增温信号的再现能力存在明显差异。总体上，ERA5-Land 和 JRA-3Q 能够较连续地反映中国区域大尺度土壤增温格局；MERRA-2 的增温响应整体偏弱；GLDAS 的趋势空间分布相对破碎，部分地区甚至出现与观测或其他产品不一致的变化方向。与此同时，原位观测显示增温幅度总体随土层加深而减弱，表明再分析产品对平均 T_s 状态具有较高一致性并不意味着其能够同等可靠地再现长期变化趋势。因此，在基于再分析数据开展 T_s 长期趋势研究时，应同时考虑产品的趋势幅度、空间连续性及时间序列一致性。

（3）不同再分析产品对关键土壤热过程的表征能力具有明显的指标依赖性，且冻融指标的产品间一致性整体高于土壤热浪指标。在四类土壤热浪指标中，峰值强度的一致性最高，不同产品组合的空间相关系数为 0.69-0.80，而发生频次的一致性最低，表明基于事件发生过程的指标对逐日 T_s 波动及事件识别规则更加敏感。相比之下，冻融过程具有更高的产品间一致性：初冻日期和终冻日期的相关系数大多为 0.75-0.93，冻结日数达到 0.81-0.95，且不同产品的冻融有效像元覆盖率总体为 72.5%-77.8%。这些结果说明，大尺度冷季土壤热状态的空间结构在不同再分析系统中相对稳定，而土壤热浪尤其是发生频次等事件型指标的不确定性明显更高，冻融过程主要受大尺度冷季气候背景控制，其空间格局在不同再分析产品中相对稳定；而土壤热浪等极端高温事件指标的不确定性更大，相关结果应结合多产品对比和不确定性分析进行解释。

总体而言，四套再分析 T_s 产品在中国区域均具有一定适用性，但其可靠性受到土层深度、季节、土地覆盖、海拔及研究指标类型的共同影响。JRA-3Q 在多数土层的平均状态模拟中具有较高的综合稳定性，ERA5-Land 在深层 T_s 及长期空间变化表征中具有一定优势，而土壤热浪发生频次等日尺度事件指标表现出较大的产品依赖性。因此，实际应用中应根据具体研究目标选择适宜的数据产品，并在极端事件分析中结合多产品比较或不确定性分析提高结论的稳健性。本章结果为中国区域再分析 T_s 产品选择、长期土壤热状态变化评估和关键土壤热过程研究提供了参考，也进一步说明构建高空间分辨率、多层次 T_s 数据集的必要性。

第四章 基于空间自适应模型的中国逐日多层土壤温度估算

4.1 引言

现有再分析 T_s 产品在中国区域的适用性评估表明，其在高分辨率与多层结构刻画方面仍存在不足，难以满足精细化土壤热过程分析的需求。T_s 作为典型的环境变量，受多种驱动因素共同控制，在大尺度空间上表现出显著的空间异质性。太阳辐射通过调整入射角度和日照时长来改变辐射强度，从而控制地表及近地表土壤的加热过程（Wang et al. 2013）。同时，空气温度的昼夜变化驱动 T_s 的周期性振荡，其振幅和相位受区域气候背景与地形条件的共同制约。地表覆盖物，如植被和积雪均对 T_s 的时空变化具有重要调节作用（Xu et al. 2020；Mortier et al. 2024）。植被冠层能够拦截和散射太阳辐射并通过根系调节 SM 分布，从而增强深层 T_s 的稳定性（Li et al. 2024）。积雪覆盖使地表具有较高的反照率，同时作为有效的隔热层，积雪可以有效减缓冷空气向下传递，在寒冷季节维持较为温暖的土壤热状态（Myers-Smith et al. 2015）。此外，土壤热导率与比热容是控制垂直热传输的重要物理参数。沙质土壤通常具有较低的比热容和较高的热导率，对外界温度变化响应迅速；而黏土因其较高的含水能力与比热容，表现出更强的热稳定性，其温度变化往往具有明显滞后性（Ochsner et al. 2001；Zhao et al. 2022）。理解上述机制是构建精细化 T_s 垂直分布模型并提升 T_s 估算精度的基础。

鉴于上述复杂的物理过程，准确估算不同深度的 T_s 面临较大挑战。迄今为止，已发展出多种 T_s 估算方法。主要包括物理模型、统计或经验模型以及 ML（machine learning, ML）模型（Li et al. 2024；Farhangmehr et al. 2025）。物理模型主要基于土壤热传导定律和能量平衡方程，具有明确的物理机制解释能力，但通常计算复杂，且对多源输入参数（如土壤热物性、气象强迫等）依赖较强（Gao et al. 2008；Hu et al. 2016b；Badache et al. 2016）。统计或经验模型，如自回归积分滑动平均和多元线性回归（Xing et al. 2018），在数据需求和计算复杂度方面具有优势，但其适用范围往往局限于站点以及小范围尺度。近年来，数据驱动的 ML 方法因其在捕捉非线性关系方面的优势，在 T_s 估算中表现出较高的预测精度。例如，在站点尺度上，Feng 等（2019）使用极限学习机（ELM）估算了半小时分辨率的多层 T_s，其 RMSE 范围为 2.26~2.95 K；Li 等（2022b）基于注意力机制的长短期记忆网络（LSTM）实现了对次日 T_s 的预测，RMSE 为 0.74-2.53 K。在区域尺度上，Xu 等（2023）结合卫星遥感与深度学习网络模型，重建了 QTP 5-40 cm 深度范围内的连续 T_s 剖面（$R^2 > 0.836$，MAE < 2.152 °C）；Farhangmehr 等（2025）则提出了混合卷积神经网络–长短期记忆（CNN-LSTM）架构，用于

北美气候区 0-7 cm 深度 T_s 的预测，R^2 值为 0.93-0.99。

尽管上述方法在不同尺度的 T_s 估算中取得了显著进展，但大尺度 T_s 预测和高精度制图仍面临着来自环境复杂性和方法学局限性的关键挑战。首先，T_s 受地形地貌、土壤类型、植被覆盖及局地气候条件的共同影响，表现出显著的空间异质性（Bayatvarkeshi et al. 2021）。这导致 T_s 与解释变量之间的关系具有明显的空间非平稳性，迫切需要根据不同区域定制差异化的建模策略。其次，T_s 观测站点分布稀疏且不均匀，直接采用统一模型对大尺度区域进行建模，往往在观测密集区表现良好，但在样本分布稀疏的区域预测能力显著下降，易产生过拟合问题（Li et al. 2024）。最终，开发能够兼顾大尺度空间可扩展性与局部精度的模型，仍是 T_s 估算研究中的核心难题，这突显了在 T_s 预测方法中平衡普适性与空间适应性精度的持续挑战。

近年来，空间自适应建模方法在处理环境变量的空间非平稳性和不均匀采样问题方面展现出重要潜力。经典的四叉树结构及相关的分层空间数据模型为构建自适应、可变大小的空间划分提供了理论基础，能够通过递归细分高效地组织多尺度空间信息（Samet 1984）。在此基础上，Lagonigro 等（2020）开发了名称为 AQuadtree 的 R 包，该方法提供了一种自适应空间划分框架，能够根据观测值的空间分布生成可变大小的网格单元。这种自适应划分在数据密集区域生成更细密的网格，而在观测稀疏区域生成较粗的网格，从而确保空间结构更好地反映采样异质性，并提高模型捕捉局部空间变异性的能力。基于这一思想，本章节提出了一种旋转四叉树策略，在进行空间划分过程中引入多方向旋转角度，通过对不同旋转结果的集成平均，有效减弱单角度划分网格产生的边界伪影，从多个方向角度捕捉空间异质性，提高局部建模在复杂环境梯度下的鲁棒性。

为了应对大尺度 T_s 估算中常遇到的观测站分布不均和非平稳性问题，我们构建了基于旋转四叉树方法的空间自适应建模框架。在每个子网格单元内，融合多源环境预测因子与原位观测数据，并采用 XGBoost 和层级递进的建模策略对不同深度逐日 T_s 进行估算。基于该框架，本章的目标为：（1）构建一个融合多源数据的空间自适应建模体系；（2）生成 2001-2020 年间中国 1 公里分辨率逐日多层 T_s 数据集；（3）通过独立通量塔观测验证及与主流 T_s 产品的对比评估其性能。所提出的方法为解决由空间非平稳性与观测不均引起的尺度问题提供了一种有效途径，生成的数据集可为高分辨率环境建模、精准农业及气候影响评估提供重要支撑。

4.2 数据和方法

本章所使用的数据包括多层 T_s 原位观测数据、通量站观测数据、遥感数据、再分析气象数据以及辅助地理环境数据。具体而言，多层 T_s 原位观测数据和通量站观测数据的详细介绍见第 2.2.1 节；遥感数据见第 2.2.2 节，包括 LST 和 EVI；ERA5-Land 气温格网产品见第 2.2.3 节；高程、土壤质地等辅助地理环境数据见第 2.2.7 节。本章节使用数据的详细信息见表 4-1。

表 4-1 模型训练使用到的特征变量

Table 4-1 Details of the predictor variables for training the model

数据类型 Type	数据名称 Data	变量名称 Variable	空间分辨率 Spatial resolution	时间分辨率 Temporal resolution	时间范围 Data period
Remotely sensed product	MOD09GA	EVI	500m×500m	Daily	2001-2020
	MOD11A1	LST_Day	1 km×1 km		
	MOD11A1	LST_Night	1 km×1 km		
Climate data	ERA5-Land	Temperature_2m	9 km×9 km	Daily	2001-2020
		Surface_net_solar_radiation			
		Surface_thermal_radiation_downwards			
		Precipitation			
Supplementary data	USGS_SRTM	Elevation	30 m	-	-
		Slope	30 m		
	Soil Texture	Sand, Silt, Clay (0-5, 5-15, 15-30, 30-60 cm)	250m×250m	-	-
In situ sites	T_s	0, 5, 10, 15, 20, 40 cm	-	Daily	2001-2020

本章使用的方法主要包括特征变量筛选、空间分析、ML 建模和精度评价四部分。首先采用 VIF 方法对特征变量进行多重共线性检验，并剔除存在严重共线性的变量，以提高模型训练的稳定性和解释性，相关方法见第 2.3.1.2 节。各变量的 VIF 检验结果见附图 3。空间分析方法主要用于刻画 T_s 原位观测站点的空间自相关特征，并构建 RQ 自适应建模网格，相关方法详见第 2.3.2 节；ML 方法用于训练 T_s 预测模型，相关方法见第 2.3.3 节，模型超参数的表格详见表 4-2；精度评价方法用于定量检验模型预测结果与原位观测之间的一致性，相关方法见第 2.3.8 节。本章节具体的技术路线如下图 4-1 所示。

表 4-2 XGBoost 模型超参数的候选取值

Table 4-2 Candidate values of hyperparameters in XGBoost.

超参数 Hyperparameters	起始值 Start	终止值 End	步长 Step
n_estimators	20	200	20
max_depth	5	15	1
learning rate	0.1	1	0.1

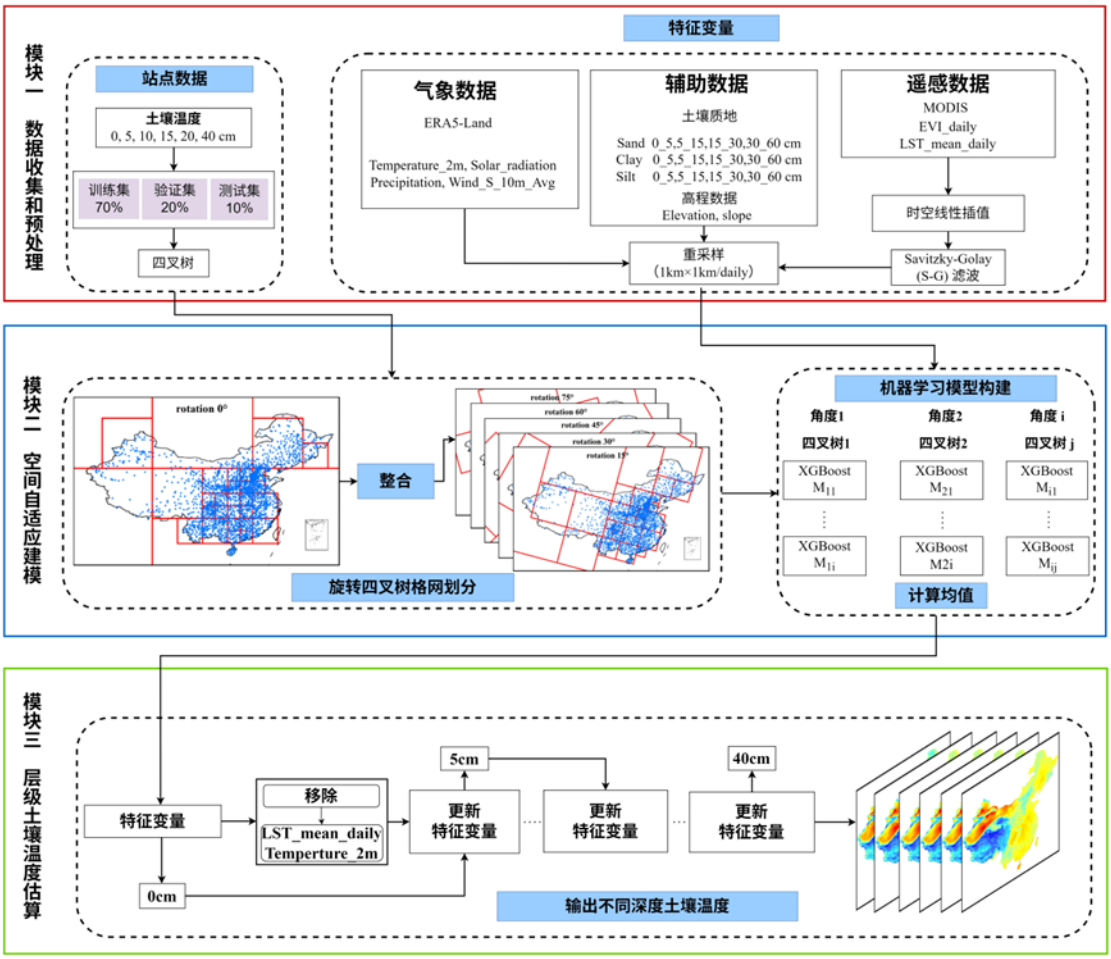


图 4-1 多层 T_s 数据产品重构技术路线图。

Figure 4-1. Workflow of the proposed method to obtain multi-layer T_s over the China.

4.3 空间自适应建模的精度表现

4.3.1 局部自适应建模的多模型精度表现

在不同土壤深度下，基于不同网格和角度构建的局部自适应模型精度表现表明，各模型整体具有较高的精度表现，R^2 中位数主要介于 0.92-0.98，RMSE 中位

数主要介于 1.6-2.4 K（图 4-2）。训练集和测试集的精度分布较为接近，说明模型在保持较高拟合能力的同时具有较好的泛化性能，未表现出过拟合现象。不同土层的比较结果显示，模型在 0 和 40 cm 深度的预测性能略低于中间深度，表明表层和较深层 T_s 的空间建模不确定性相对更高。

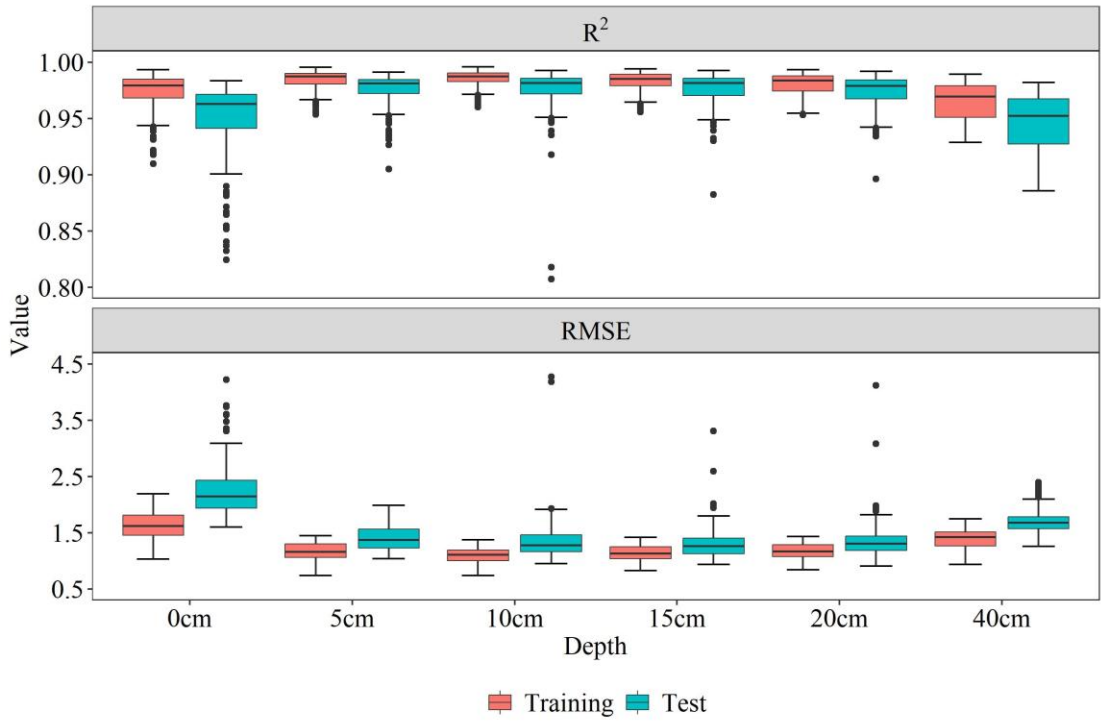


图 4-2 不同深度下局部模型在训练集和测试集上的性能表现。

Figure 4-2. Model performance for training and test sets across different depths.

4.3.2 基于通量站点的精度评估

为进一步检验模型结果的独立适用性，本研究使用 ChinaFLUX 网络中 18 个通量塔站点的逐日 T_s 观测数据对最终数据集进行了验证。为保证不同深度验证结果之间的可比性，仅保留 0、5、10、15、20 和 40 cm 深度的观测数据。通量站点的元数据见表 2-1，对应的逐日尺度验证结果如图 4-3 所示。结果表明，该数据集在独立通量站点上仍保持较高精度，R^2 为 0.78-0.87，RMSE 为 3.89-5.14 K，说明所构建的空间自适应模型具有较好的预测性能和空间泛化能力。

此外，附图 4 进一步展示了不同深度下通量塔 T_s 年均观测值与年均预测值之间的空间一致性。结果显示，年均尺度验证同样具有较高精度，R^2 为 0.70-0.82，RMSE 为 2.93-3.58 K；但各深度普遍存在约+2-+3 K 的系统性正偏差，表明模型在年均尺度上对通量站点 T_s 存在一定程度的高估。

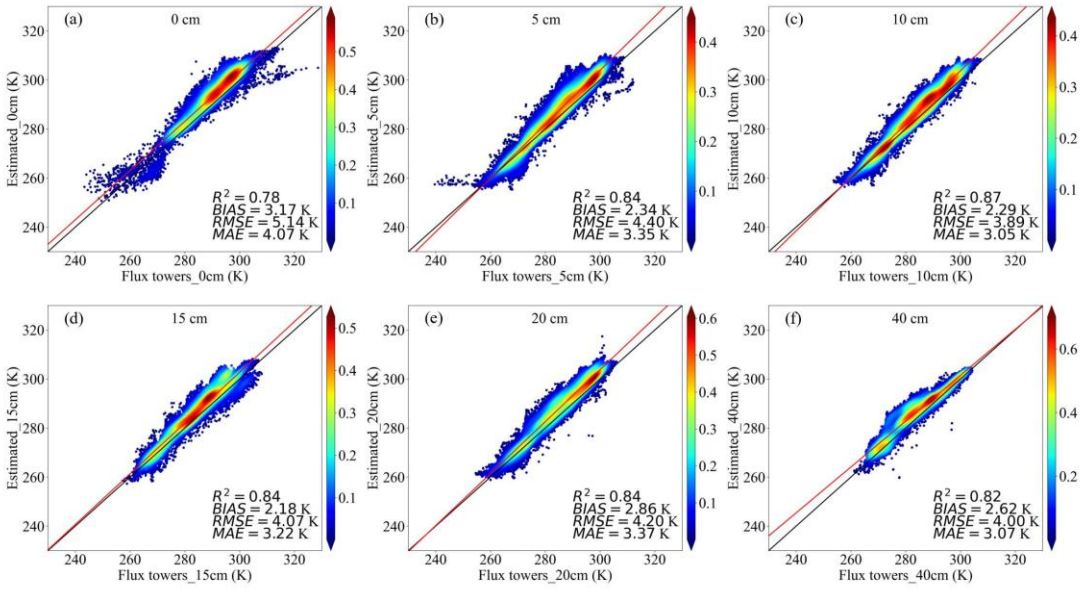


图 4-3 不同深度下逐日 T_s 估算值与通量塔观测值的散点密度对比图。

Figure 4-3. Density scatter plots comparing estimated daily T_s with flux tower observations at different depths.

本研究在站点尺度上计算了不同深度的 R^2 和 RMSE，以进一步评估模型在空间上的预测性能。结果表明，各站点 R^2 值总体介于 0.70-1.00 之间，说明模型在多数站点具有较好的预测能力。图 4-4 显示，大多数站点的 R^2 值高于 0.85，表明模型在全国范围内具有较高的一致性。高精度站点主要分布在西北、东北及中部地区，而预测误差较大的站点则主要集中于 YGP 以及观测站点相对稀疏的 QTP 地区。不同深度 T_s 的 RMSE 分布总体集中在 0.5-3.0 K 之间，表明模型整体预测误差相对较小。从垂向变化来看，RMSE 在 0 cm 深度相对较高，在 5-20 cm 深度明显降低，并在 40 cm 深度略有增加，说明模型预测误差存在一定的深度依赖性（附图 5）。进一步比较测试集中六个深度年均 T_s 观测值与预测值的关系发现，R^2 介于 0.94-0.97 之间，RMSE 为 0.74-1.40 K，且系统性偏差较小（附图 6）。总体来看，站点尺度误差分布和年均尺度验证结果共同说明，空间自适应模型在不同深度 T_s 估算中具有较好的稳定性和适用性，但其在高海拔、复杂地形以及观测站点稀疏区域的预测不确定性仍需进一步关注。

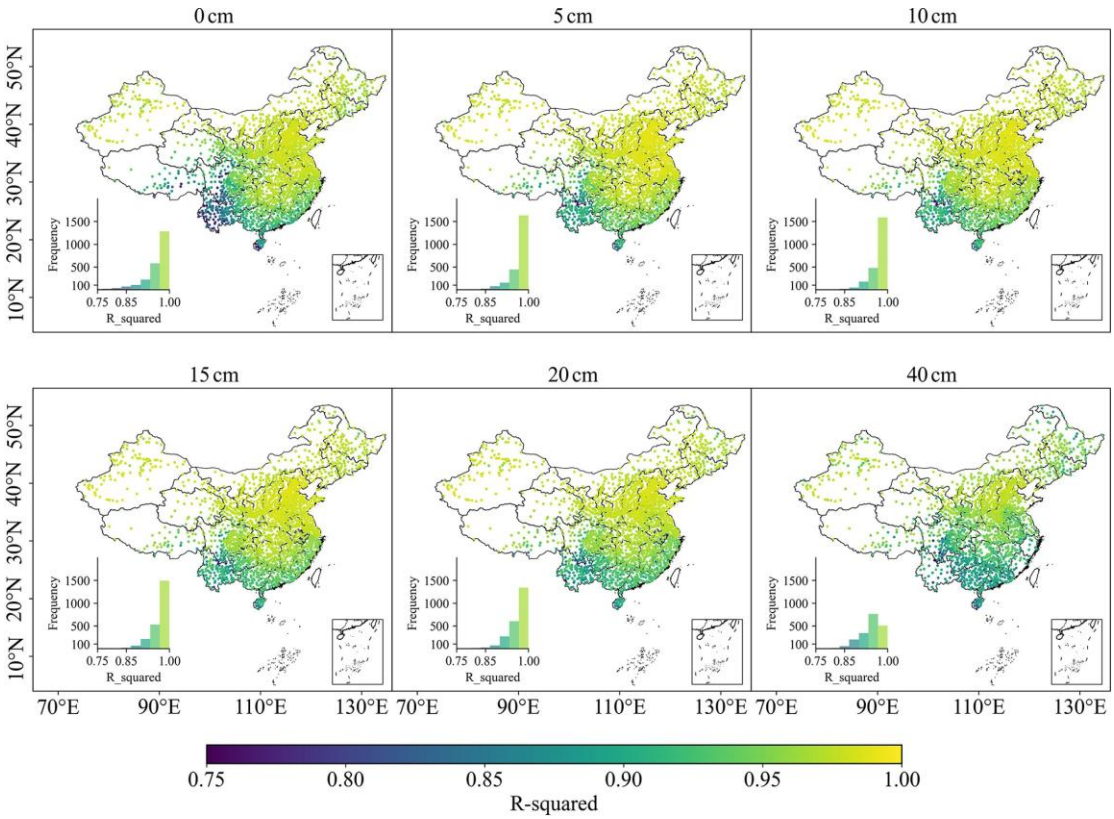


图 4-4 使用 T_s 观测值和预测值计算的各站点 R^2 空间分布图。

Figure 4-4. Goodness of R^2 across China estimated during the model testing phase. Performance metrics are calculated between predicted_T_s and in situ T_s data sets.

4.4 不同土地覆盖类型和季节的精度评估

分组箱线图展示了六个深度（0、5、10、15、20 和 40 cm）下，不同土地覆盖类型（裸地、耕地、森林和草地）的 T_s 预测性能，评价指标包括 R^2 和 RMSE（图 4-5）。总体来看，不同土地覆盖类型和深度下模型均保持较高的预测精度，R^2 中位数主要介于 0.94-0.98，表明模型在不同下垫面条件下具有较好的稳定性。

不同土地覆盖类型比较结果表明，裸地的 R^2 值相对最高，其次为耕地，而森林和草地的 R^2 值略低，说明模型对开阔地表条件下 T_s 变化的相关性刻画更好。RMSE 中位数总体分布在 1.1-1.8 K 之间，其中裸地的 RMSE 相对较高，而耕地、森林和草地的 RMSE 值较低且分布更加集中。这表明，裸地虽然具有较高的相关性，但其 T_s 波动幅度较大，导致绝对误差相对更高。从深度来看，RMSE 在 0 cm 处最大，随后随土层加深逐渐减小，并在 40 cm 略有回升。这一垂向变化特征说明，表层 T_s 更易受到辐射、大气强迫和局地下垫面条件影响，预测不确定性相对较高；而中间层的热状态更稳定，因此模型误差较小。

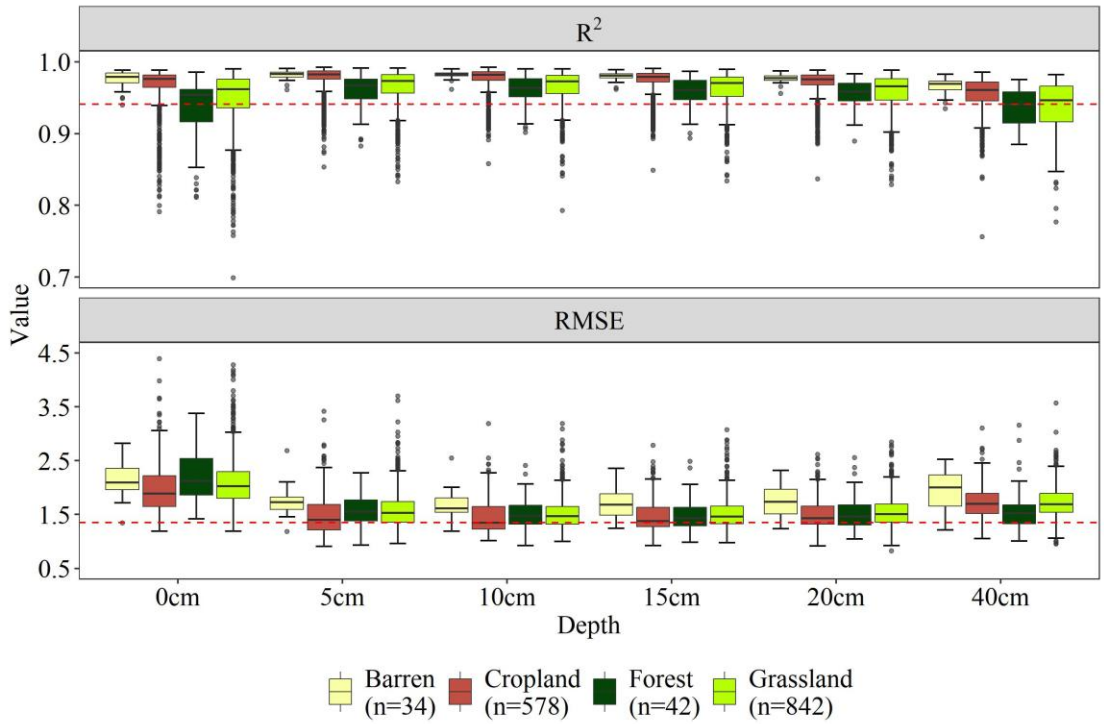


图 4-5 不同土地利用类型（森林、草地、耕地与裸地）条件下，各深度（0、5、10、15、20 和 40 cm）T_s 预测值的精度表现。

Figure 4-5. Evaluation of predicted T_s at different depths (i.e., 0, 5, 10, 15, 20, 40 cm) across various land use types (i.e., Forest, Grassland, Cropland, Barren).

不同季节条件下的 T_s 预测精度存在明显差异。各深度 R^2 中位数介于 0.48-0.98 之间，春季和秋季整体较高，说明模型在过渡季节对 T_s 变化的刻画能力较强；而夏季和冬季 R^2 相对较低，尤其在 20-40 cm 深度下降更为明显，反映出深层 T_s 在极端季节条件下存在更高的不确定性（图 4-6）。RMSE 中位数总体约为 1.3-2.2 K，春季和秋季相对较低，而夏季和冬季较高，其中冬季 40 cm 深度的 RMSE 中位数值最大。从垂向变化来看，RMSE 从 0 cm 到 5-10 cm 深度逐渐减小，随后在 15-40 cm 深度中有所回升。这一结果表明，模型误差不仅受深度影响，也受到季节性热传输过程和地表能量交换条件的共同调控。

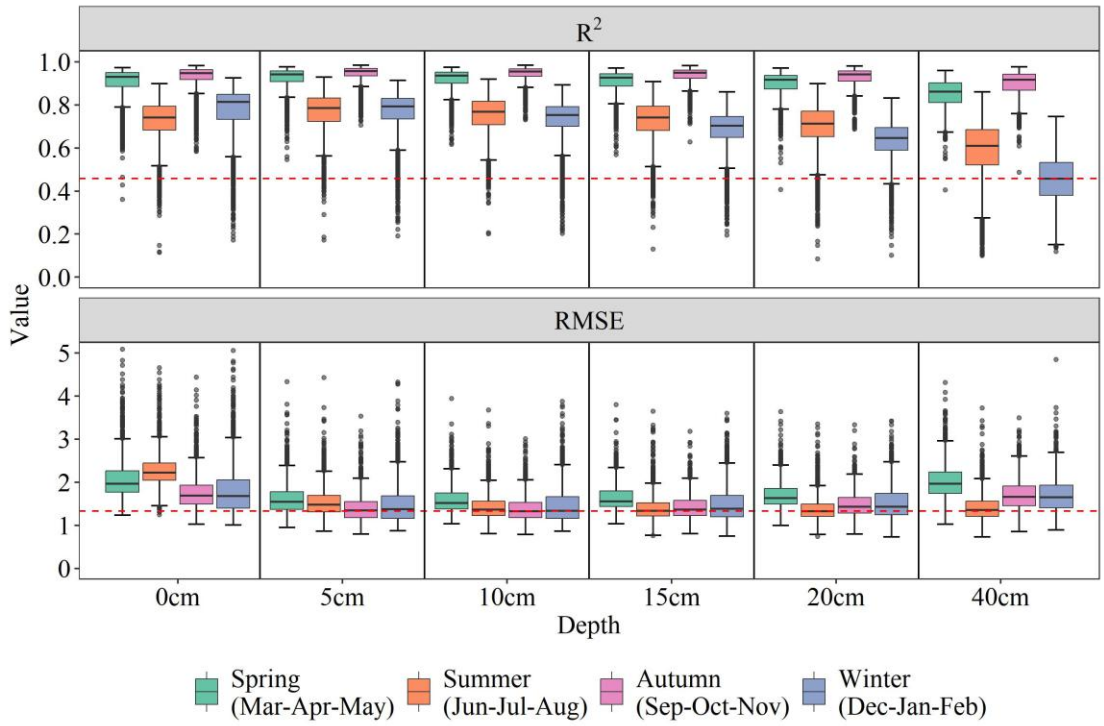


图 4-6 不同深度 T_s 预测值（0-40 cm）在不同季节的精度表现。冬季（12-2 月）、春季（3-5 月）、夏季（6-8 月）、秋季（9-11 月）。

Figure 4-6. Evaluation of the predicted_T_s at different depths (i.e., 0, 5, 10, 15, 20, and 40 cm) at sites with four seasons (i.e., spring, summer, autumn, and winter). Winter is defined as December, January, and February; spring as March, April, and May; summer as June, July, and August; and autumn as September, October, and November.

4.5 不同土壤温度产品比较

为进一步评估本研究生成 T_s 产品的空间表现，将 0 cm 深度下的 T_s 空间分布与 ERA5-Land 和 GLDAS 2.1 再分析产品进行对比。结果包括全国尺度的空间分布特征和典型区域的局部放大差异（图 4-7a-f）。与两套再分析产品相比，本研究生成的 T_s 数据集具有更高的空间分辨率，能够更细致地刻画局地尺度的空间异质性。局部放大结果显示，本研究生成的 T_s 产品较好地反映了地形和海拔变化所导致的温度梯度差异，尤其在四川盆地向 QTP 边缘过渡等地形起伏显著区域表现更为清晰。相比之下，ERA5-Land 和 GLDAS2.1 由于空间分辨率较粗，对细尺度地形效应的刻画能力有限，空间分布结果相对平滑，部分局地温度差异被弱化。

基于站点观测的散点密度图进一步比较了不同 T_s 产品的精度表现（附图 7）。结果表明，相较于 ERA5-Land 和 GLDAS 2.1，本研究生成的 T_s 产品在与站点观测值的一致性更高，说明其在站点尺度上具有更优的模拟精度。具体而言，在 0、10 和 40 cm 深度，本数据集的 R^2 值介于 0.94-0.97，而 ERA5-Land 的 R^2 值为

0.83-0.89，GLDAS 2.1 的 R^2 值为 0.83-0.87。该结果说明，本研究生成的高精度 T_s 数据集不仅能够提升站点尺度的估算精度，也能够更好地表征由地形起伏和海拔差异引起的局地空间变化，而这些细节在粗分辨率再分析产品中往往难以充分体现。总体而言，所提出的空间自适应建模框架能够更精细地刻画 T_s 的空间分布特征，并在地形复杂区域提高区域尺度 T_s 建模的精度和适用性。

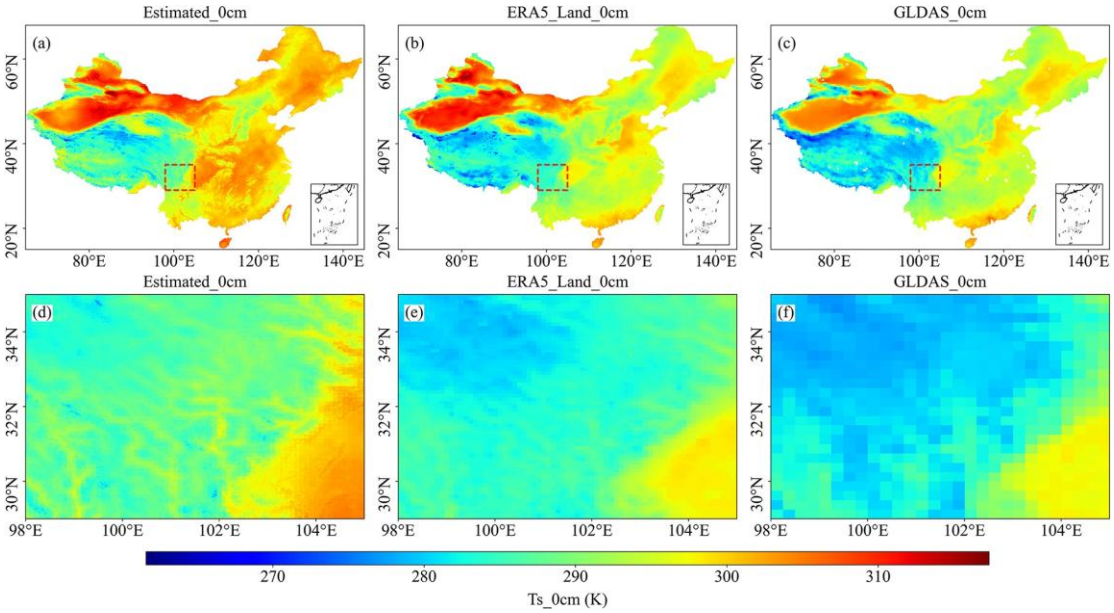


图 4-7 不同 T_s 数据产品比较，以 0 cm 深度 T_s 为例。

Figure 4-7. Comparison of different T_s products (e.g., 0 cm).

4.6 不同深度土壤温度产品时空格局

为分析 T_s 空间分布的季节差异及其垂向变化特征，本研究选取 2020 年 1 月 1 日和 2020 年 7 月 1 日分别代表冬季和夏季，对比中国区域 0、5、10、15、20 和 40 cm 深度 T_s 的空间格局及频率分布特征。2020 年 1 月 1 日的结果表明，冬季不同深度 T_s 的空间分布及频率分布均存在明显差异（图 4-8a-f）。结果表明，冬季中国 T_s 具有明显的南北温度梯度，北方地区，尤其是东北、西北以及 QTP，T_s 整体较低，形成大范围低温区；而南方地区 T_s 相对较高，表现为由北向南逐渐升高的空间格局。从垂向分布来看，较深层的 T_s 整体高于表层，尤其在东北地区和 QTP 等低温区域更为明显，反映出冬季深层土壤对地表冷却过程具有一定的热缓冲作用。

2020 年 7 月 1 日的结果表明，夏季中国区域 T_s 整体高于冬季，东部和南部地区普遍表现为较高温区，北方地区 T_s 也明显升高。随着土层深度增加，T_s 的空间分布趋于平缓，频率分布也相应发生变化，反映出夏季 T_s 具有一定的垂向调节特征（图 4-8g-l）。不同于冬季，夏季 T_s 通常随土层加深而降低，表层温度明

显高于深层，说明夏季热量主要由地表向下传导，地表受太阳辐射和大气强迫影响更为直接。综合比较冬季和夏季结果可以发现，T_s 的垂向结构具有明显的季节反转特征：冬季较深土层温度整体高于表层，而夏季则表现为表层温度高于深层。频率直方图进一步表明，不同深度 T_s 的分布范围存在明显差异，其中表层温度分布更宽，波动幅度更大；而深层 T_s 分布相对集中，说明深层土壤具有更强的热稳定性。总体而言，不同深度 T_s 的时空格局共同反映了纬度位置、地形条件、季节性辐射强迫和地下热传导过程对土壤热状态的综合影响，为进一步理解土壤热过程的季节变化和垂向传输机制提供了依据。

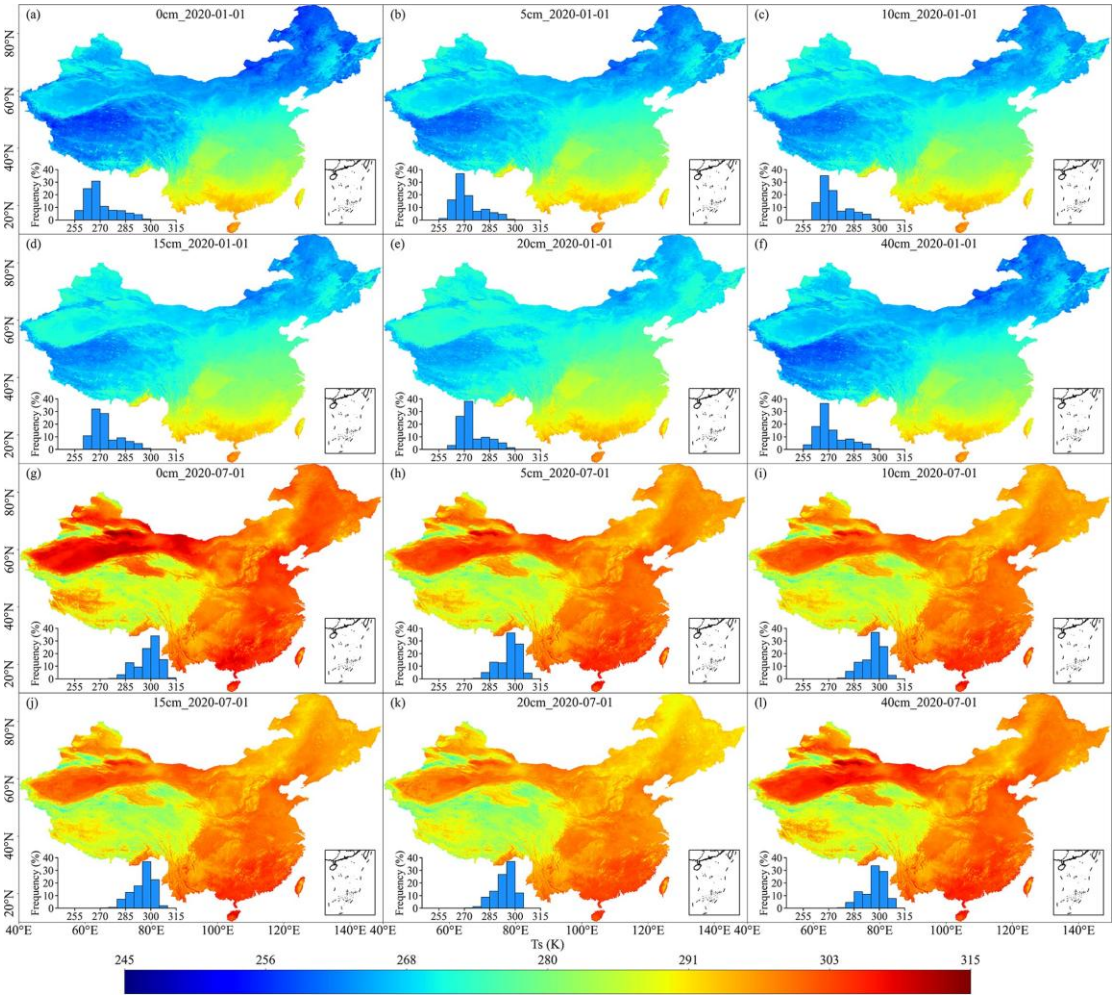


图 4-8 不同深度（0、5、10、15、20 和 40 cm）T_s 估算结果的空间分布图及对应的频率分布直方图，以 2020-01-01 和 2020-07-01 两个日期为例。

Figure 4-8. Spatial patterns and histograms of Estimated T_s at different depths (0, 5, 10, 15, 20, and 40 cm).

为进一步评估 T_s 预测值在时间维度上的表现，选取四个不同区域的站点，对比其在 2018 年 1 月至 2020 年 1 月期间的 T_s 预测值与实测值时间序列，站点

包括 56748（99.18°E，25.12°N）等（图 4-9）。图中分别给出了 0 和 40 cm 两个深度的 T_s 估算值（Estimated_0cm、Estimated_40cm）、T_s 实测值（In-situ_0cm、In-situ_40cm），并同时展示了日均 LST（Daily_mean_LST）和 2 m 气温（Temperature_2m），用于比较不同热状态变量的时间变化特征。结果表明，2 m 气温和 T_s 均呈现明显的季节性变化，即夏季达到高值、冬季降至低值，但 T_s 的时间序列整体较气温更加平滑。不同深度之间的响应特征存在明显差异，具体表现为 0 cm 深度 T_s 对气温和 LST 变化响应更为迅速，日波动幅度较大；而 40 cm 深度的 T_s 变化相对平缓，并表现出一定的时间滞后，反映了土壤热量向下传导过程中对短期温度波动的削弱和缓冲作用。站点尺度精度评估结果显示，两个深度的 RMSE 介于 1.24-2.05 K，说明模型估算值与原位观测值在时间序列上具有较好一致性。

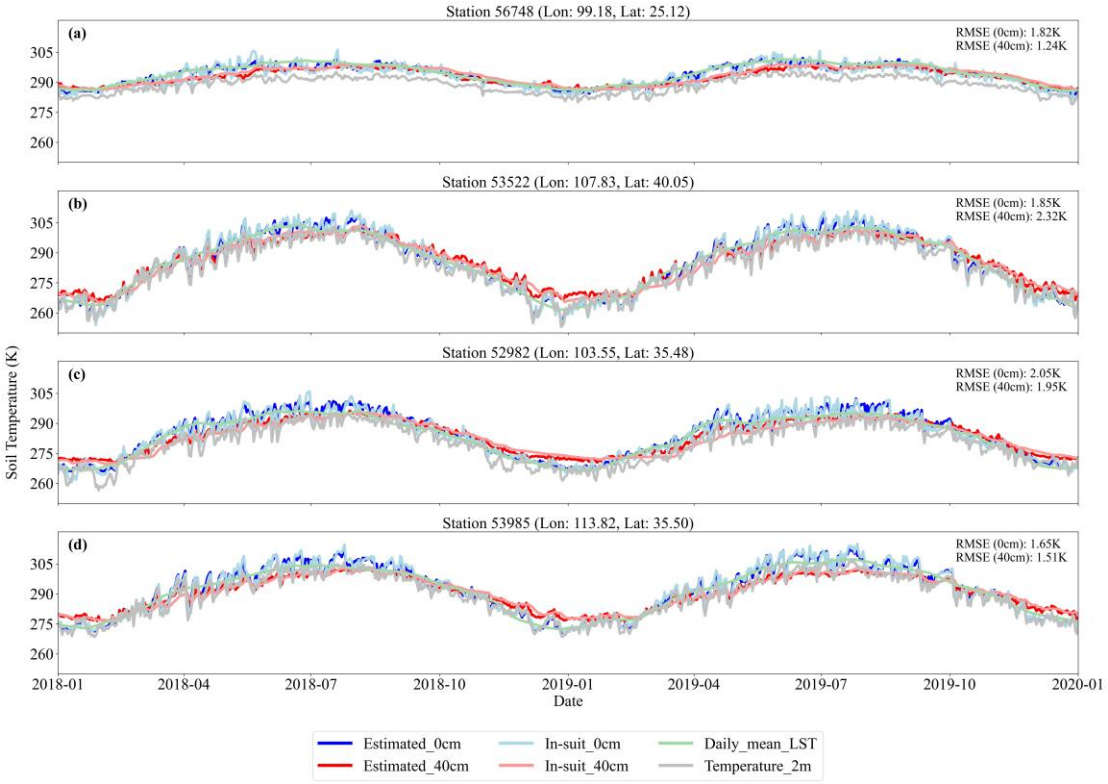


图 4-9 不同区域四个代表性站点在 2018-2019 年期间，0 cm 和 40 cm 深度逐日的 T_s 估算值、LST 以及再分析数据的 2m 气温之间的时间序列图。

Figure 4-9. Time series of the Estimated_0cm, Estimated_40cm, Daily_mean_LST, and Temperature_2m at four sites from different regions between 2018-2019.

4.7 讨论

4.7.1 空间自适应模型的优势

以往研究已探索了多种构建 T_s 数据集的方法。例如，Wang 等（2023）基于 2000 多个地面观测站，采用薄板样条插值和角距离加权插值方法，构建了中国 1980-2010 年、空间分辨率为 0.25°的逐日多层 T_s 数据集。然而，在国家尺度 T_s 数据集构建过程中，一个长期存在的核心问题在于观测站点空间分布极不均匀，具体表现为东部低海拔地区站点密集，而西部及高海拔区域站点稀疏。采用单一全局函数进行建模的方法在空间异质性高的环境中，难以有效刻画 T_s 与其驱动因子之间的非线性和不平稳关系。具体而言，在样本稀疏区域，全局模型缺乏足够数据进行有效学习，导致预测精度偏低；而在样本密集区域，模型又容易发生过拟合，使训练过程过度受这些区域影响。这种样本分布不平衡最终会引入系统性偏差，并限制模型的空间泛化能力。

再分析数据集通过将资料同化系统与数值天气预报和陆面过程模型相结合，为刻画陆气相互作用及地下热传输过程提供了重要信息，在大尺度气候模拟和长期环境评估中具有显著优势。Yang 等（2018）利用中国地面站月均 T_s 观测，对 ERA-Interim/Land、MERRA-2、CFSR 和 GLDAS-2.0 四套再分析 T_s 数据集的精度进行了评估，结果表明以上数据集在全国范围内均系统性低估了 T_s。近年来发布的 ERA5-Land 和 GLDAS 2.1 数据集有较高的时间分辨率（逐小时或 3 小时），但其空间分辨率仍受限于 0.1°或 0.25°。除再分析产品外，部分研究尝试利用 ML 构建 T_s 产品，Lembrechts 等（2022）基于 8519 个全球分布的 T_s 传感器、采用随机森林模型构建的 Global Soil Bioclimatic Variables 数据集，但该数据集仅提供长期气候平均态，而无法满足高分辨率逐日估算的需求。

相比之下，本研究提出的方法框架在精度和空间分辨率方面均有效克服了上述局限。该空间自适应建模策略相较于传统插值方法和全局训练的 ML 具有显著优势，其核心在于局部建模思想，能够充分考虑地形、土壤属性及气候条件在区域尺度上的差异性。如附图 8 所示，旋转四叉树在六个不同角度（0°-75°）下划分子网格，从多个方向刻画空间异质性特征。通过对不同旋转角度下的预测结果进行平均，该方法有效降低了静态网格分区常见的边界伪影问题，使空间分布更加平滑和连续。此外，我们还定量分析了不同旋转角度生成的网格在同一站点上的预测差异。附图 9 结果表明，与其他深度相比，0 cm 深度的不确定性较高，且高不确定性区域主要集中在 YGP 和四川盆地部分区域。

此外，1 km 的精细空间分辨率使模型能够解析对植被动态和土壤生物地球化学过程具有重要意义的局地热分布特征。我们进一步评估了卫星反演的 LST 对模型性能的贡献。如附图 10 和附图 11 所示，与仅使用气温作为输入变量相

比，引入 LST 能显著提升整体建模精度，并在不同土地覆盖类型站点上均表现出性能提升，其中在裸地区域的改进尤为明显。这一结果凸显了在观测数据相对稀缺条件下，多源数据融合对提升空间自适应模型性能的重要作用。综上所述，本研究提出的空间自适应局地建模方法为在观测站点分布不均、环境条件复杂的情景下开展大尺度 T_s 估算提供了一种更加稳健且具备良好扩展性的解决方案。

4.7.2 土壤温度产品的潜在应用

基于空间自适应估算方法生成的高时空分辨率多层 T_s 数据集，有效填补了我国在连续、系统性 T_s 剖面数据方面的长期空缺。作为关键的生物物理变量，T_s 能够反映土壤大气相互作用过程中的热力学特征，而这些信息往往无法仅通过气温加以准确刻画。在农业生态系统中，T_s 贯穿作物生长全过程，从播种与萌发到营养生长及最终产量形成均发挥着基础性调控作用（Rahman et al. 2019）。多层 T_s 数据可用于优化积温模型，提高播期判定的科学性，并为精准农业管理和可持续耕作措施提供重要支撑。此外，T_s 通过调控养分分解速率和 SM 在剖面中的迁移过程（Jebamalar et al. 2012），直接影响土壤肥力维持、水分保持能力以及农业生态系统的整体运行效率。

除农业应用外，T_s 正逐渐被视为评估生态系统对极端气候事件响应的重要指标。Fan 等（2024）提出了土壤复合干旱热浪指数，用于量化干旱与热浪并发事件的严重程度。然而，其研究表明，相较于地面观测记录，现有再分析数据集普遍低估了此类极端事件的强度，这进一步凸显了对精细化 T_s 数据的迫切需求。在全球变暖背景下，极端高温和干旱事件发生频率和强度持续增加，获取可靠的 T_s 数据对于提升环境胁迫的监测与预测能力至关重要。这不仅有助于深化对陆地生态系统响应机制的认识，也为区域乃至国家尺度的气候适应与风险管理提供关键的数据支撑。

此外，T_s 在生态与水文模型中具有核心作用，相较于气温，其能够更加直接地表征陆地表层过程，是生物地球化学循环和物候变化的敏感指示因子（Lembrechts et al. 2022）。例如，Liu 等（2024）的研究表明，T_s 是驱动我国森林春季物候变化的主导因子之一。在寒区环境中，T_s 控制着冻融循环过程，而冻融状态变化对径流形成、地下水补给以及多年冻土稳定性具有重要影响（Smith et al. 2022；Xu et al. 2022）。同时，T_s 也是土壤呼吸的重要驱动因子，直接影响 CO_2 排放通量和陆地生态系统碳循环过程（Lloyd et al. 1994；Hursh et al. 2017）。因此，高精度 T_s 产品的构建能够显著提升生态系统碳动态模拟和区域碳收支评估的准确性，从而加深对气候反馈机制的理解。

4.7.3 局限性与未来展望

尽管本研究提出的空间自适应 T_s 估算框架整体表现良好，但仍存在若干需

要进一步讨论的局限性。如图 4-4 所示，站点尺度的验证结果表明模型预测精度在空间上存在明显差异，其中 YGP 和 QTP 区域的预测性能相对较低。一方面，如图 4-7 所示，本研究构建的多源数据融合的空间自适应模型在刻画不同海拔和地貌条件下的 T_s 变化方面明显优于现有数据集；另一方面，YGP 和 QTP 地形起伏剧烈、海拔高、气候变化快，使得土壤热状况的形成机制更加复杂，从而显著增加了 T_s 估算的不确定性。这一结果与已有研究结论一致，即在高海拔地区，气温与 LST 之间的耦合关系减弱，从而加大了建模的不确定性（Mo et al. 2025）。

MODIS LST 是本研究建模框架中的关键输入变量。然而，作为光学热红外遥感产品，其对云覆盖极为敏感，常导致观测数据缺失。尽管本研究通过时空插值和 S-G 滤波对 LST 进行了重建和平滑处理，但重建结果中仍不可避免地残留一定不确定性。未来 T_s 重建工作的改进可从两个主要方向展开。首先，可引入更加具有物理约束的 LST 重建方法，例如结合地表能量平衡模型和日变化温度循环模型（Hong et al. 2022；Firozjaei et al. 2024；Wang et al. 2024），通过能量守恒原理在缺测或不可靠观测时段估算地表热状态，从而获得更符合物理过程的温度结果。其次，融合时间分辨率更高的遥感观测数据亦有助于弥补 MODIS 的局限性。例如，被动微波卫星可提供全天候观测，对云干扰不敏感（Duan et al. 2017；Wu et al. 2022）；同时，新一代静止轨道卫星（如 Himawari-8）具备 10 分钟级别的观测能力，可显著提升 LST 估算的时间连续性和质量（Yamamoto et al. 2022；You et al. 2024）。上述改进方向有望显著提高 T_s 监测的精度和时间连续性。

本研究结果表明，模型预测精度在不同深度之间存在显著差异，且进一步受到季节变化和土地利用类型的影响（图 4-5 和 4-6）。总体而言，0 cm 预测精度相对较低，在 5-10 cm 显著提升，而在 20-40 cm 又有所下降。这种随深度变化的精度特征可从土壤剖面的物理特性加以解释。表层 T_s 对短期气象因子（如太阳辐射、降水和蒸散作用）响应敏感，导致其时空波动性较强，从而增加了预测误差。相比之下，中间土层通过热扩散过程和较高的热容量对高频温度扰动具有缓冲作用，使 T_s 表现出更高的稳定性和更低的变率，因此在该深度范围内模型 RMSE 较低、R^2 较高。

在更深土层中，预测精度下降的主要原因在于表层误差在层间级联的建模过程中向下传播，同时土壤质地等输入变量的不确定性随深度逐渐累积；在夏季和冬季等极端气候条件下，这些不确定性可能进一步放大。短期尺度上的 SM 变化会显著改变土壤的基本热学性质，包括热容量、热导率和热扩散率，从而影响热量传输过程及亚日尺度 T_s 动态（Abu-Hamdeh 2003；Subin et al. 2013）。因此，在当前建模框架中未显式引入 SM，可能在日尺度乃至亚日尺度 T_s 模拟中引入额外不确定性，尤其在深层土壤中更为明显。未来若能引入高分辨率 SM 数据，将

有助于更真实地表征土壤水热耦合过程，并进一步提升 T_s 估算精度。

季节变化及土地覆盖差异同样对模型性能的时空分布产生重要影响。如图 4-6 所示，模型在春季和秋季的预测表现相对较优，而在夏季和冬季精度有所下降。夏季植被生长旺盛、冠层闭合度提高，会显著改变地表—大气之间的能量交换过程，并削弱冠层温度与地下 T_s 之间的耦合关系，从而降低 LST 作为近地表 T_s 代理变量的有效性（Kropp et al. 2020；Cui et al. 2022）。此外，由于卫星传感器测量的是辐射温度，在高覆盖植被区，LST 往往更接近冠层顶部温度而非真实 0cm 处的 T_s，这会进一步引入不确定性。冬季条件下，积雪使土壤热过程更加复杂：雪的高反照率降低了净辐射通量（Loranty et al. 2014；Li et al. 2018），其隔热效应削弱了土壤对冷空气波动的响应（Zhang 2005；Myers-Smith et al. 2015）。同时，SM 冻结会改变土壤的热导率和热容量，频繁的冻融循环使 T_s 呈现显著的非线性特征，从而增加建模不确定性（Li et al. 2023；Imanian et al. 2024）。尽管本研究提出的 T_s 空间自适应建模框架在不同深度和环境条件下表现出较强的稳健性，但其尚未显式刻画垂向热传输的物理机制。未来研究可引入能够更好地捕捉复杂时空依赖关系的深度学习模型，以增强对 T_s 时空和深度变化过程的物理可解释性。

4.8 小结

本章针对中国区域观测站点空间分布不均和 T_s 空间非平稳性问题，构建了基于旋转四叉树、XGBoost 和层级递进策略的空间自适应建模框架，并生成了 2001-2020 年中国逐日 1 km 分辨率、多层（0、5、10、15、20 和 40 cm）T_s 数据集。主要结论如下：

（1）空间自适应建模框架在不同土层均获得了较高的预测精度，并表现出较好的空间泛化能力。不同网格和旋转角度下局部模型训练集与测试集的 R^2 中位数总体为 0.92-0.98，RMSE 中位数为 1.6-2.4 K，且训练集与测试集精度分布较为接近，说明模型未表现出明显过拟合。在 18 个独立 ChinaFLUX 通量站的逐日验证中，不同土层 R^2 为 0.78-0.87，RMSE 为 3.89-5.14 K；年均尺度 R^2 仍达到 0.70-0.82，RMSE 为 2.93-3.58 K，但存在约 2-3 K 的系统性正偏差。上述结果表明，空间自适应建模能够较稳定地实现中国区域多层 T_s 的空间扩展，但高海拔、复杂地形和观测稀疏区域仍是主要不确定性来源。

（2）模型在不同土地覆盖和季节条件下总体保持较高精度，但预测性能具有明显的下垫面和季节依赖性。不同土地覆盖类型下各深度 R^2 中位数为 0.94-0.98，RMSE 中位数约为 1.1-1.8 K，表明模型在耕地、森林、草地和裸地等不同下垫面具有较好的整体稳定性。相比之下，季节差异更加明显，不同季节和深度

的 R^2 中位数为 0.48-0.98，RMSE 约为 1.3-2.2 K，其中春季和秋季整体精度高于夏季和冬季，20-40 cm 深层土壤在极端季节的预测不确定性相对较高。不同深度的站点 R^2 总体介于 0.70-1.00，且多数站点高于 0.85；对应 RMSE 主要集中在 0.5-3.0 K，进一步表明模型具有较好的区域适用性。

（3）与 ERA5-Land 和 GLDAS 2.1 相比，本研究生成的 1 km T_s 数据集在站点一致性和局地空间细节刻画方面均具有明显优势。在 0、10 和 40 cm 三个代表性深度，本数据集与站点观测的 R^2 达到 0.94-0.97，高于 ERA5-Land 的 0.83-0.89 和 GLDAS 2.1 的 0.83-0.87。同时，1 km 空间分辨率能够更清晰地刻画四川盆地—青藏高原边缘等复杂地形区域由地形和海拔变化导致的细尺度温度梯度，而较粗分辨率再分析产品的空间分布相对平滑。生成的多层 T_s 产品还较好再现了土壤温度的季节性垂向反转特征，即冬季深层 T_s 总体高于表层，而夏季表层 T_s 高于深层，反映了土壤热传导对地表温度波动的缓冲及滞后作用。

总体而言，本章构建的空间自适应建模框架能够有效提升中国区域多层 T_s 的估算能力，所生成的逐日 1 km 多层 T_s 数据集可为农业生产管理、生态系统过程模拟、极端气候事件监测、寒区水文过程以及冻融研究提供重要数据支撑。同时，本章结果也表明，模型在高海拔复杂地形区、夏冬季以及部分深层土壤中的预测不确定性仍需关注。未来研究可进一步引入高质量 SM 信息，改进 LST 反演精度，并增强模型对土壤热传导、积雪保温和冻融过程的物理约束，从而进一步提升高精度 T_s 产品在复杂环境区域的可靠性。

第五章 土壤复合干热事件时空变化及其对玉米的影响

5.1 引言

在全球变暖背景下，极端事件的频率与强度持续上升，并以空间与时间上的相互关联方式出现，形成复合型极端事件（Zscheischler et al. 2018）。其中，干旱与热浪叠加的复合高温干旱事件呈现更频繁、更持久、更强烈的协同增强趋势（Dannenberg et al. 2022；Hao 2022；Zhang et al. 2023），并通过陆面能量与水分过程的耦合放大对农业系统的胁迫，从而显著提高减产风险并加剧粮食安全压力（Hameed et al. 2020；IPCC 2021；Shi et al. 2025）。

从生态过程机制来看，CDHW 对作物系统的影响并非仅体现为气温升高本身，而是表现为冠层—土壤连续体中的水热失衡。高温和高 VPD 会增强大气蒸发需求，而降水不足和 SM 亏缺则限制作物生长土层的水分供给（He et al. 2022；Chen et al. 2026）。当大气需水增加与土壤供水受限同步发生时，作物气孔调节增强，蒸腾冷却能力下降，冠层能量分配由潜热通量向感热通量转移，进而加剧冠层和近地表热胁迫（张更喜等 2024；Wang et al. 2025）。与此同时，SM 亏缺会削弱土壤蒸发冷却作用并降低土壤热容量，使浅层土壤对外界热强迫更加敏感，从而促进土壤增温异常的形成和维持。持续的地表增温可进一步通过热扩散过程向下传递，使土壤高温异常与水分亏缺在作物生长土层中相互叠加，形成土壤复合干热胁迫（Hao et al. 2022）。在这一过程中，T_s 并非仅是大气增温的被动响应变量，而是调控土壤水热微环境和作物生理过程的重要状态变量。T_s 升高与 SM 亏缺的耦合可能产生协同胁迫效应：一方面，高 T_s 可能降低根系活性、扰动细胞膜稳定性，并抑制作物对水分和养分的吸收；另一方面，SM 亏缺会削弱作物对热胁迫的缓冲能力，使高温不利影响进一步放大（Guo et al. 2026）。此外，T_s 升高还可能增强土壤微生物呼吸和作物呼吸消耗，加速碳释放并降低净碳积累（Davidson et al. 2006）。因此，在土壤高温与水分亏缺共同作用下，土壤水热胁迫可通过限制根系吸水、降低蒸腾冷却和削弱光合碳同化等过程向冠层传导，最终导致作物生产力下降。

尽管 CDHW 事件的生态影响已受到广泛关注，现有识别与评估框架仍主要基于气温、降水或干旱指数构建（Jiang et al. 2025；Yan et al. 2025）。该框架在气象学意义上能够刻画大气层面热异常与水分亏缺的协同增强特征。然而，当其进一步用于评估植被生产力或碳损失影响时，其过程表征能力可能存在局限。当水分供应相对充足时，作物可通过蒸腾冷却缓解冠层热胁迫，高温并不必然引发光合下降；而在干旱背景下，土壤热惯性与水分恢复滞后使 T_s 异常更易累积并

延迟恢复，从而形成持续的水热复合胁迫（Song et al. 2022）。另外已有研究指出，土壤极端高温事件的强度与频次的上升速度可能快于气温（García-García et al. 2023），且土壤中激增的 SCDHW 被严重低估（Fan et al. 2024）。因此，若在高温胁迫评估中忽略 T_s，可能系统性低估热风险对农业生产与生态过程的真实影响。基于此，有必要构建能够显式表征水热耦合约束的新型评估框架。

在全球气候变暖驱动复合极端事件增强的背景下，中国农业系统正面临日益严峻的复合干热风险（董勤各等 2026）。东北、华北及黄淮海平原等粮食主产区近年来高温与干旱叠加事件显著增加，表现出频率提升、持续时间延长与峰值强度增加的特征，对粮食安全与农业稳定性构成系统性压力（Liu et al. 2025；Lin et al. 2026）。玉米作为中国种植面积最大、空间分布最广的粮食作物，其生产稳定性不仅关系国家粮食安全，也影响畜牧业与区域经济结构（李少昆 等，2017；Wu et al. 2023）。玉米生长发育对水热条件高度敏感，尤其在拔节、抽雄等关键阶段，水分供应不足与热胁迫叠加可能显著抑制作物生长和产量形成（白莉萍等 2004）。已有研究表明，全球平均气温每升高 1 ℃，玉米产量可能下降约 7.4%（Zhao et al. 2017），而干旱和热胁迫的协同效应会显著加剧这种损失（Guo et al. 2022）。更重要的是，相较于气温升高，土壤增温对玉米根际微环境及根冠协调性的影响可能更为直接和持续（Xia et al. 2021b；Zhang et al. 2023a）。田间试验显示，T_s 仅升高 0.6 ℃即可导致玉米产量下降 6.3%（Hu et al. 2020）。这表明，在评估玉米对复合干热胁迫的响应时，仅依赖气温等大气指标可能难以充分刻画作物实际经历的土壤水热环境。将 T_s 与 SM 共同纳入事件识别框架，有助于从土壤水热耦合角度更准确地识别玉米生长季复合干热风险。

基于此，本研究提出 SCDHWs 识别框架，以 T_s 升高与 SM 亏缺的同步发生，刻画玉米生长季的水热胁迫情景，重点回答以下三个问题：（1）中国 2001-2020 年 SCDHWs 的时空分布特征如何，不同农业区事件频次、持续时间和强度是否呈现差异化变化趋势？（2）不同物候阶段发生的 SCDHWs 是否会造成不同程度的玉米生产力损失，其主导驱动因子是否存在阶段性差异？（3）玉米产量损失对不同物候阶段 SCDHWs 事件的强度和持续时间的敏感性是否存在差异？围绕上述问题，本研究在像元尺度上识别了 SCDHWs 的时空变化特征，比较了不同农业区复合干热事件的变化趋势，并量化了 SCDHWs 对不同物候阶段玉米生产力和产量损失的影响。研究结果有助于从土壤水热耦合视角完善农业复合干热风险评估框架，并为玉米主产区生产力损失识别和产量风险预警提供依据。

5.2 数据和方法

本章所使用的数据主要包括两类，首先是 SCDHW 识别用到的 T_s 和 SM 数

据集。具体为第四章生成的 2001-2020 年中国逐日 1 km 分辨率多层（0、5、10、15、20 和 40 cm）T_s 数据集，以及 2.2.4 节介绍的 SM 数据集 SMCI1.0。其次是第 2.2.5 节介绍的玉米物候和产量格网数据集。本章节使用的数据详见表 5-1。

表 5-1 本章节使用的数据集

Table 5-1 Summary of the datasets

数据名称 Dataset	变量名称 Name	时间分辨率 Temporal resolution	空间分辨率 Spatial resolution	时间范围 Time coverage
SMCI1.0	10 cm	Daily	1 km	2001-2020
T_s	10 cm	Daily	1 km	2001-2020
NPP	-	Daily	8 km	2001-2019
PML-V2.2a	ET、Ec、Es、PET	8-Days	500 m	2001-2020
玉米物候	VGS、RGS	Year	30 m	2001-2020
玉米产量	-	Year	10 km	2001-2015

为保证多源数据在空间尺度上的一致性，并支撑后续 SCDHWs 识别、NPP 损失及产量损失分析，本章首先将玉米物候、产量格网、T_s、SM 等数据重采样统一到 NPP 数据的空间分辨率，并以统一后的像元作为基本分析单元。在此基础上，基于玉米物候和产量格网数据提取有效玉米像元，并将其与中国农业区划数据进行空间叠加，统计不同农业区内玉米像元的数量。农业区划使用中科院资源环境科学平台（https://www.resdc.cn/）下载的农业区划数据，具体包括东北平原（A）、北方干旱半干旱区（B）、黄淮海平原（C）、黄土高原（D）、青藏高原（E）、长江中下游平原（F）、四川盆地及周边地区（G）、云贵高原（I）和华南地区（H）共九个农业区。图 5-1 展示了玉米像元在不同农业区内的空间分布及数量统计。可以看出，玉米像元主要分布在东北平原、黄淮海平原、北方干旱半干旱区、长江中下游平原和云贵高原等区域，而青藏高原和华南地区玉米像元相对较少。该空间分布结果为后续不同农业区内 SCDHWs 事件特征、NPP 损失及产量损失响应差异分析提供了样本基础。研究区详见图 5-1。

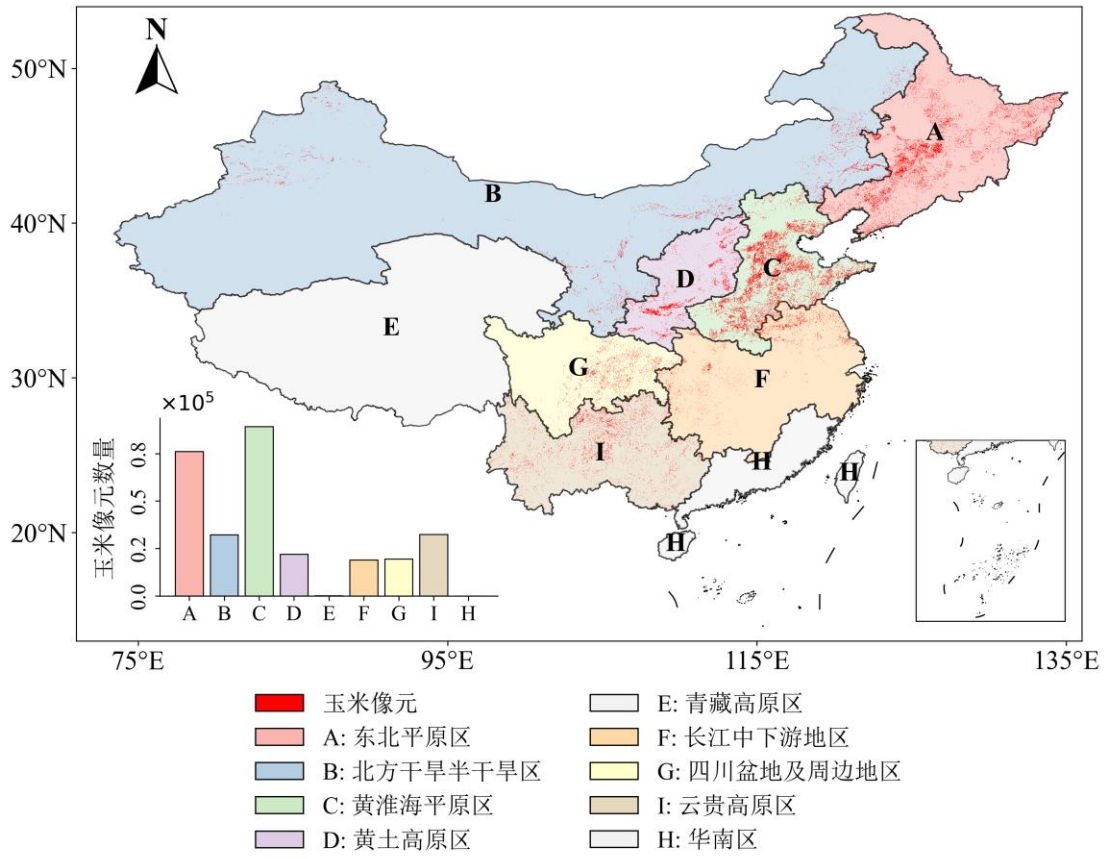


图 5-1 中国不同农业区玉米像元的空间分布及数量统计。

Figure 5-1. Spatial distribution and count of maize pixels across agricultural regions in China.

本章主要采用三类方法开展分析。首先，基于 10 cm 深度的逐日 T_s 和 SM 数据识别 SCDHWs，并提取事件频次、持续时间、峰值强度和累积强度等事件特征指标，具体方法见第 2.3.6 节。其次，采用 ML 结合 SHAP 方法分析 SCDHWs 期间玉米 NPP 相对损失的关键驱动因子及其非线性响应关系，相关方法见第 2.3.3 节。最后，采用 GAMM 模型进一步检验玉米产量损失对不同物候阶段 SCDHWs 的敏感性差异。该模型通过引入事件强度、持续时间及其与物候阶段的交互项，刻画产量损失对 SCDHWs 的非线性响应；同时加入像元随机效应和年份随机效应，以控制空间异质性和年份背景差异，具体方法见第 2.3.7 节。

5.3 SCDHWs 的时空趋势

5.3.1 SCDHWs 的空间格局

基于 2001-2020 年逐日 T_s 和 SM 数据，本研究进一步计算了中国区域土壤 SCDHWs 的多年平均频次、持续时间、峰值强度和累积强度，以揭示 SCDHWs 的空间分布特征（图 5-2）。总体来看，SCDHWs 呈现明显的空间异质性，不同事件指标在空间格局上具有一定一致性，但其高值区分布也存在差异。从事件频

次来看，SCDHWs 在中国东部、华中、华南、西南以及部分东北地区发生较为频繁，而青藏高原、西北干旱区及部分高海拔地区事件频次相对较低。多年平均频次整体以中低频次为主，大部分地区低于 0.5 events yr^{-1}，说明 SCDHWs 虽然并非每年普遍发生，但在我国主要农业区具有较广泛分布。频次高值区主要集中在水热条件变化较强、T_s 升高与 SM 亏缺容易同步发生的区域，表明这些地区更容易出现土壤热胁迫与干旱胁迫叠加的极端事件。从事件持续时间来看，其空间格局与频次分布总体相似。持续时间较长的区域主要位于中国东部、华中、华南及西南部分地区，而青藏高原和西北地区持续时间较短。多数区域多年平均持续时间集中在 1-4 days yr^{-1}，表明 SCDHWs 通常表现为短期或阶段性事件，但在部分区域可形成相对持续的土壤水热胁迫过程。持续时间的空间差异说明，不同区域不仅在事件发生概率上存在差别，在事件维持能力和累积胁迫程度上也存在明显区域分异。

事件峰值强度反映了 SCDHWs 期间 T_s 异常升高的最大幅度。从图 5-2c 可以看出，峰值强度在我国中东部、华南、西南和东北部分区域相对较高，而青藏高原和西北部分区域强度较低。与频次和持续时间相比，峰值强度的高值区更集中于热量条件较充足、土壤增温明显的区域，说明这些地区在发生 SCDHWs 时更容易达到较强的土壤热异常水平。累积强度综合反映了事件持续时间和强度的共同作用，其空间分布与频次、持续时间和峰值强度均具有一定对应关系。高累积强度主要分布在华中、华南、西南及东北部分地区，说明这些区域不仅事件发生较多或持续时间较长，而且事件期间的土壤热异常累积效应更强。

总体而言，2001-2020 年中国 SCDHWs 多年平均特征表现出由西北和青藏高原低值向东部、南部及西南地区高值增强的空间格局。我国主要玉米种植区中，东北平原、黄淮海平原、长江中下游平原、四川盆地及周边地区和云贵高原等区域均存在不同程度的 SCDHWs 分布，该空间格局为后续分析 SCDHWs 对玉米 NPP 损失和产量损失的影响提供了基础。

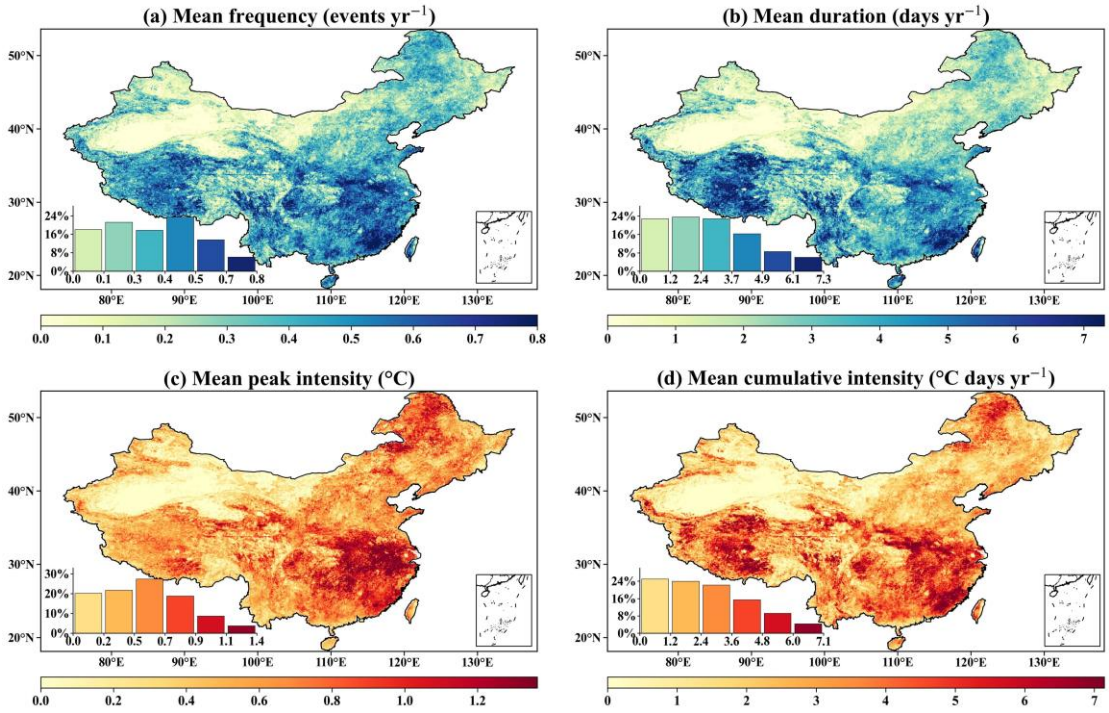


图 5-2 2001-2020 年中国 SCDHWs 多年平均频次、持续时间、峰值强度和累积强度的空间分布。

Figure 5-2. Spatial patterns of multi-year mean frequency, duration, and intensity of SCDHW in China during 2001-2020.

5.3.2 SCDHWs 的变化趋势

通过 2001-2020 年中国 SCDHWs 各指标的年际变化可以看出，事件持续时间、发生频次、峰值强度和累积强度均呈现不同程度的上升趋势（图 5-3）。其中，事件持续时间增加趋势最为明显，线性趋势为+2.40 d decade^{-1}，表明 SCDHWs 在研究期内不仅发生更加频繁，而且单次或年度事件的持续影响时间也在延长。事件发生频次呈现较弱但持续的增加趋势，变化速率为+0.13 events decade^{-1}，说明 SCDHWs 的发生概率整体有所提高。

从事件强度来看，峰值强度和累积强度均表现出上升特征。峰值强度的增加速率为 0.34 °C decade^{-1}，表明事件发生期间土壤热异常的极端程度有所增强。累积强度的增加幅度更为突出，达到 3.89 °C·days decade^{-1}，说明在持续时间延长和强度增强的共同作用下，SCDHWs 的综合胁迫程度明显加重。相较于单一峰值强度，累积强度同时反映了事件持续时间和强度的叠加效应，因此其上升趋势更能体现 SCDHW 对生态系统和作物生长潜在影响的增强。

同时，各指标在年际尺度上存在明显波动，说明 SCDHWs 的发生和发展受到年际气候条件变化的显著调控。部分年份事件持续时间、频次和累积强度明显偏高，表明这些年份可能出现了更强或更持久的土壤水热复合胁迫。图中误差线

显示，不同年份 SCDHWs 指标均存在较大的空间离散性，说明 SCDHWs 的年际变化不仅表现为全国平均水平的增加，也伴随着显著的区域差异。总体而言，2001-2020 年中国 SCDHWs 呈现持续时间延长、发生频次增加、峰值强度增强和累积强度升高的综合变化特征。这表明在研究期内，中国 SCDHWs 的风险总体增强，尤其是累积胁迫效应的增加可能对玉米生长过程中的水分利用、光合生产力和最终产量形成产生更强影响。

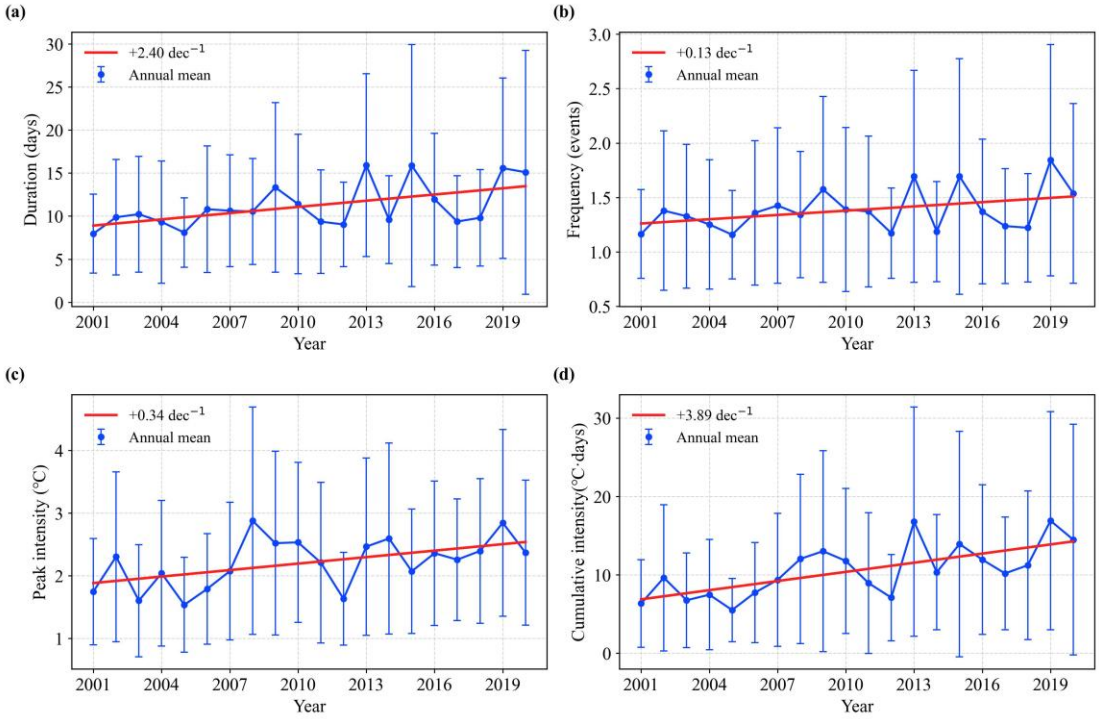


图 5-3 2001-2020 年中国 SCDHWs 频次、持续时间和强度的年际变化及趋势。

Figure 5-3. Interannual variations and trends in the frequency, duration, and intensity of SCDHWs in China during 2001-2020.

5.4 SCDHW 期间玉米 NPP 损失的物候期差异及驱动机制

5.4.1 不同农业区玉米关键物候期 NPP 损失的分布差异

为揭示 SCDHWs 影响下玉米生产力损失在不同物候阶段和农业区之间的差异，本研究统计了各农业区 VGS 和 RGS 阶段的 NPP 相对损失率分布（图 5-4）。总体来看，SCDHWs 发生期间玉米 NPP 相对损失率存在明显的区域差异和物候期差异，不同农业区内 VGS 和 RGS 阶段的损失水平及离散程度均表现出较强异质性。

从区域差异来看，东北平原（A）、黄淮海平原（C）、黄土高原（D）以及北方干旱半干旱区（B）的 NPP 相对损失率整体较高，说明这些区域玉米生产力对 SCDHWs 的响应较为明显。其中，B 区在 VGS 和 RGS 阶段均表现出较高的损

失水平，表明干旱半干旱背景下玉米生产力可能更容易受到土壤高温与水分亏缺共同作用的影响。相比之下，四川盆地及周边地区（G）和云贵高原（I）的 NPP 相对损失率整体较低，但不同物候阶段之间仍存在一定差异。

从物候期差异来看，不同农业区内 VGS 和 RGS 阶段的 NPP 损失表现差异显著。在 A、B、C 和 D 等玉米主要种植区，VGS 阶段的 NPP 相对损失率通常高于 RGS 阶段。在 F、G 和 I 等南方或西南农业区，RGS 阶段的 NPP 相对损失率高于 VGS，尤其在云贵高原（I）表现较为明显。此外，各农业区箱线图的整体离散程度表明，不同农业区玉米 NPP 相对损失率仍存在较大差异，反映出 SCDHWs 对玉米生产力的影响具有明显异质性。这种差异可能与局地土壤水热条件、气象背景、地形特征及农田管理措施等因素有关。总体而言，SCDHWs 影响下玉米 NPP 相对损失率表现出显著的区域分异和物候期差异。北方及黄淮海等主要玉米种植区 VGS 阶段 NPP 相对损失率较高。

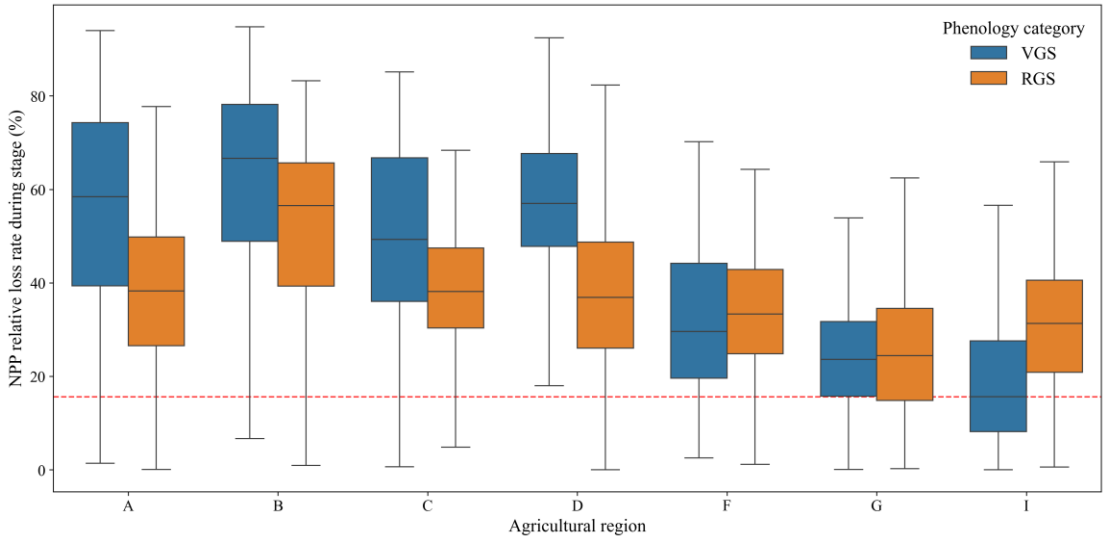


图 5-4 不同农业区玉米 VGS 和 RGS 阶段 NPP 相对损失率的差异。

Figure 5-4. Differences in NPP relative loss rate between VGS and RGS across agricultural regions.

5.4.2 玉米 NPP 损失的关键驱动因子及非线性响应

为进一步揭示 SCDHWs 影响下玉米 NPP 相对损失的主导机制，本研究结合 XGBoost-SHAP 方法，分别识别 VGS 和 RGS 阶段关键变量的相对贡献及其非线性响应特征。VGS 阶段玉米 NPP 相对损失的 SHAP 分析结果表明模型在测试集上取得了较好的预测性能（R^2=0.732，RMSE=11.627），说明所选变量能够较好表征 VGS 阶段 NPP 相对损失的变化（图 5-5）。变量重要性结果表明，植被蒸腾异常是贡献最高的单一变量，其次为 SM 最小值、平均太阳净辐射、潜在蒸散异常、平均降水量和总降水量。变量类别统计结果进一步显示，蒸散过程因子贡献最高，占 36.6%；气象条件因子和土壤水热条件因子分别占 33.3%和 24.7%；SCDHWs

事件特征因子贡献相对较低，仅占 5.3%。这一结果表明，VGS 阶段玉米 NPP 相对损失主要受蒸散过程和水分供给条件控制，而事件自身强度和持续时间等特征的直接贡献相对有限。

从主要特征变量的 SHAP 依赖图看，不同变量对 VGS 阶段 NPP 相对损失的影响方向存在明显差异。植被蒸腾异常与 SHAP 值呈明显负向非线性关系，随着植被蒸腾异常增加，其对 NPP 相对损失的正向贡献逐渐减弱，并在较高取值区间转为负向贡献，表明较高的植被蒸腾水平有助于缓解 SCDHWs 对玉米 NPP 的不利影响。SM 最小值也表现出负向响应特征，即 SM 较低时对应较高的 SHAP 值，而随着 SM 条件改善，SHAP 值逐渐降低，说明 SM 亏缺会加剧 NPP 相对损失。相比之下，平均太阳净辐射和潜在蒸散异常均表现出正向响应，二者增加时 SHAP 值整体升高，表明较强的辐射输入和较高的大气蒸发需求会增强 SCDHWs 对 NPP 的负面影响。平均降水量和总降水量整体呈负向响应，随着降水增加，SHAP 值下降，说明降水补给能够在一定程度上缓解事件期间的水分胁迫。上述结果表明，VGS 阶段玉米 NPP 相对损失主要受植被蒸腾、SM 状况、太阳辐射、潜在蒸散发需求和降水条件共同影响，其中水分供给与蒸散过程的调节作用最为突出。

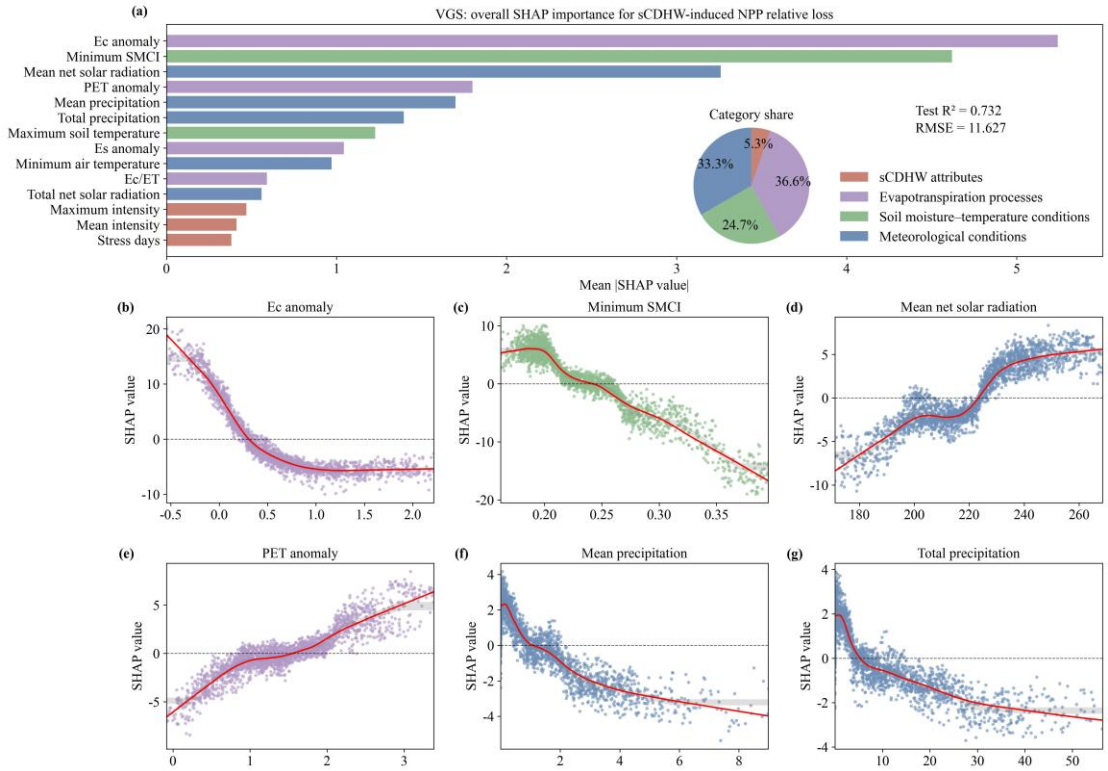


图 5-5 VGS 阶段 SCDHWs 影响下玉米 NPP 相对损失的驱动因子重要性及响应关系。

Figure 5-5. Driver importance and response relationships for SCDHW-induced NPP relative loss during the maize VGS.

RGS 阶段玉米 NPP 相对损失的 SHAP 分析结果表明模型在测试集上的 R^2 为 0.615，RMSE 为 10.345，所选变量对 RGS 阶段 NPP 相对损失具有一定解释能力（图 5-6）。变量重要性结果显示，平均太阳净辐射的平均绝对 SHAP 值最高，是 RGS 阶段 NPP 相对损失的最主要驱动因子；其次为 T_s 最高值、SM 最小值、植被蒸腾异常、潜在蒸散异常、最低气温和总降水量。变量类别统计结果显示，气象条件因子贡献最高，占 33.6%；蒸散过程因子和土壤水热条件因子分别占 30.6%和 25.8%；SCDHWs 事件特征因子贡献相对较低，占 10.0%。

从主要变量的 SHAP 依赖关系来看，RGS 阶段 NPP 相对损失同时受到热量条件、水分供给和蒸散过程的共同调控。平均太阳净辐射与 SHAP 值呈明显正向非线性关系，随着太阳辐射增强，SHAP 值整体升高，表明较强辐射输入会加剧 NPP 相对损失。T_s 最高值表现出先升高后降低的非线性响应，其 SHAP 值在中等偏高 T_s 范围内较高，说明 T_s 对 NPP 损失的影响并非简单线性增强。SM 最小值与 SHAP 值整体呈负向关系，即 SM 较低时对应较高的 SHAP 值，而随着 SM 增加，SHAP 值逐渐下降，表明 SM 亏缺会放大 RGS 阶段的生产力损失。植被蒸腾异常同样表现为负向响应，随着植被蒸腾异常增加，SHAP 值逐渐降低并趋于稳定，说明较高蒸腾水平可能反映作物水分利用和生理活性维持能力较强。潜在蒸散异常整体呈正向响应，表明较高的大气蒸发需求会增强水分胁迫效应。总体而言，RGS 阶段玉米 NPP 相对损失主要受太阳辐射、T_s、SM、蒸散过程和气温条件共同影响，其中热量条件增强与水分亏缺的叠加作用较为突出。

综合 VGS 和 RGS 两个阶段的 SHAP 分析结果可知，SCDHWs 影响下玉米 NPP 相对损失的主导驱动因子具有明显的物候阶段差异。VGS 阶段以蒸散过程因子贡献最高，其中植被蒸腾异常和 SM 最小值的重要性较高，而最高 T_s 的贡献相对较低，说明营养生长期玉米生产力损失主要受水分供给不足和蒸散过程异常控制。进入 RGS 阶段后，气象条件因子的贡献升高，平均太阳净辐射成为最重要变量，同时最高 T_s 和 SM 最小值分别位列第二和第三，表明生殖生长期玉米 NPP 损失对热量条件增强和 SM 亏缺的共同作用更加敏感。总体来看，VGS 阶段更突出水分过程对生产力损失的调节作用，而 RGS 阶段则表现出更强的土壤高温、太阳辐射和水分亏缺协同影响。

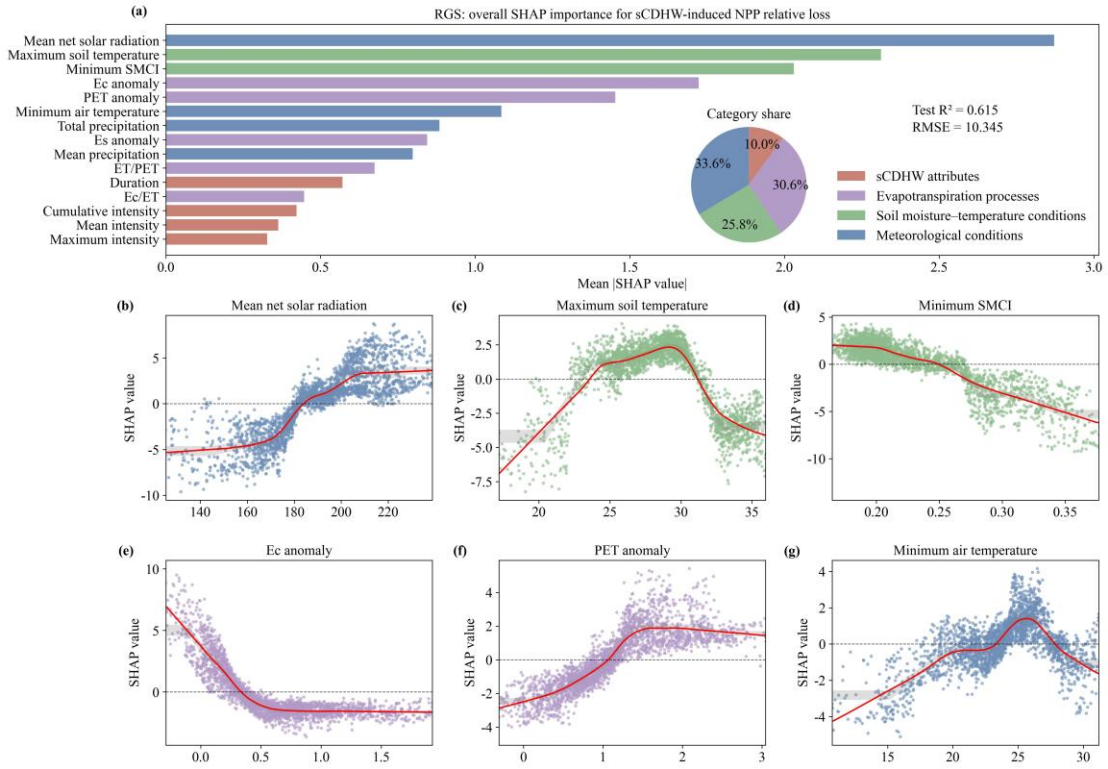


图 5-6 RGS 阶段 SCDHWs 影响下玉米 NPP 相对损失的驱动因子重要性及 SHAP 依赖关系。

Figure 5-6. Driver importance and response relationships for SCDHW-induced NPP relative loss during the maize RGS.

5.5 不同物候期 SCDHWs 对玉米产量损失的敏感性

本研究比较了统一 GAMM 模型与分阶段 GAMM 模型对玉米产量损失率的预测能力（图 5-7）。其中，统一 GAMM 模型是同时纳入 VGS 和 RGS 样本构建的单一模型，图 5-7a 和图 5-7b 分别表示该模型在 VGS 和 RGS 样本中的分组预测表现；图 5-7c 和图 5-7d 则分别表示基于 VGS 和 RGS 样本独立构建的分阶段 GAMM 模型结果。总体来看，两类模型的预测值与观测值均呈正相关关系，高密度样本主要分布在 1:1 线附近，说明 GAMM 模型能够刻画 SCDHWs 事件特征与玉米产量损失率之间的总体关系。然而，预测值的分布范围整体小于观测值，表明模型对极端产量损失样本的刻画能力仍然有限。

从预测性能来看，统一 GAMM 模型在两个物候期中的表现整体优于分阶段 GAMM 模型。对于 VGS 样本，统一模型的 R^2 为 0.370，高于分阶段模型的 0.319；RMSE 和 MAE 分别由分阶段模型的 9.14 pp 和 6.89 pp 降至 8.84 pp 和 6.61 pp。对于 RGS 样本，统一模型的 R^2 为 0.354，高于分阶段模型的 0.316；RMSE 和 MAE 分别由分阶段模型的 8.40 pp 和 6.47 pp 降至 8.17 pp 和 6.34 pp。上述结果表明，将 VGS 和 RGS 样本纳入统一 GAMM 框架后，模型的解释能力和预测误

差均有所改善，说明统一模型能够更稳定地表征不同物候期 SCDHWs 事件特征与玉米产量损失率之间的关系。因此，后续不同物候期产量损失敏感性差异分析基于统一 GAMM 模型开展。

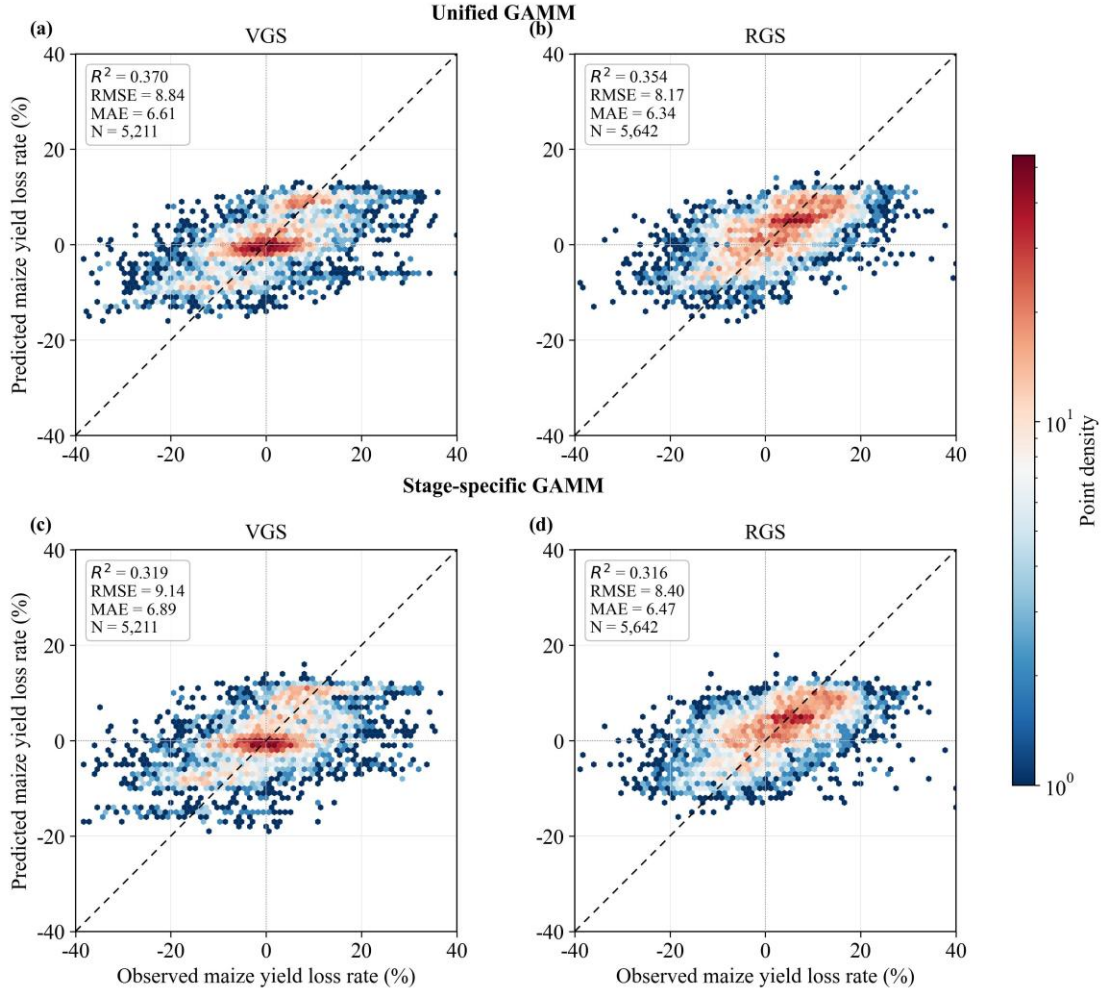


图 5-7 不同 GAMM 建模策略下玉米产量损失率的预测性能。（a，b）分别表示统一 GAMM 模型在 VGS 和 RGS 样本中的预测表现；（c，d）分别表示 VGS 和 RGS 分阶段 GAMM 模型的预测表现。黑色虚线表示 1:1 参考线，颜色表示样本点密度。R^2、RMSE、MAE 和 N 分别表示模型性能指标和样本数量。

Figure 5-7. Predictive performance of maize yield loss rate under different GAMM strategies. Panels (a, b) show the prediction performance of the unified GAMM for VGS and RGS samples, respectively; panels (c, d) show the performance of stage-specific GAMMs for VGS and RGS samples, respectively. The black dashed line indicates the 1:1 reference line, and colors indicate point density. R^2, RMSE, MAE, and N denote model performance metrics and sample size.

基于统一 GAMM 模型进一步计算了 VGS 与 RGS 阶段预测玉米产量损失率的差异，并在由 SCDHWs 平均强度和持续时间构成的二维预测域中展示（图 5-8）。其中，VGS−RGS 为正表示 VGS 阶段预测产量损失率高于 RGS 阶段，负值

则表示 RGS 阶段预测产量损失率高于 VGS 阶段。需要说明的是，该图反映的是不同强度—持续时间组合下的模型预测差异，而非地理空间分布。

从预测差异分布来看，图 5-8a 中负值区域占据主体，说明在多数 SCDHWs 强度和持续时间组合下，RGS 阶段对应的预测玉米产量损失率高于 VGS 阶段。尤其在事件持续时间较长时，差异面大范围表现为负值，表明 RGS 阶段玉米产量对持续性 SCDHWs 更为敏感。图 5-8b 进一步量化了不同差异方向及显著性在强度—持续时间预测域中的占比。RGS 阶段预测产量损失率高于 VGS 阶段的网格占比为 74.7%，其中显著区域占 54.0%；VGS 阶段预测产量损失率高于 RGS 阶段的网格占比为 25.3%，其中显著区域仅占 16.1%。所有显著差异区域合计占 70.1%。差异统计结果显示，VGS−RGS 的平均差异为−1.38 pp，中位数为−1.83 pp，5%-95%范围为−4.97 至 3.52 pp，进一步表明在模型预测层面，RGS 阶段 SCDHWs 对玉米产量损失的影响整体强于 VGS 阶段。综合图 5-7 和图 5-8 可知，统一 GAMM 模型具有相对更稳定的预测能力，并揭示了玉米产量损失对 SCDHWs 响应的明显物候阶段差异。总体而言，RGS 阶段是玉米产量对 SCDHWs 更敏感的关键时期。

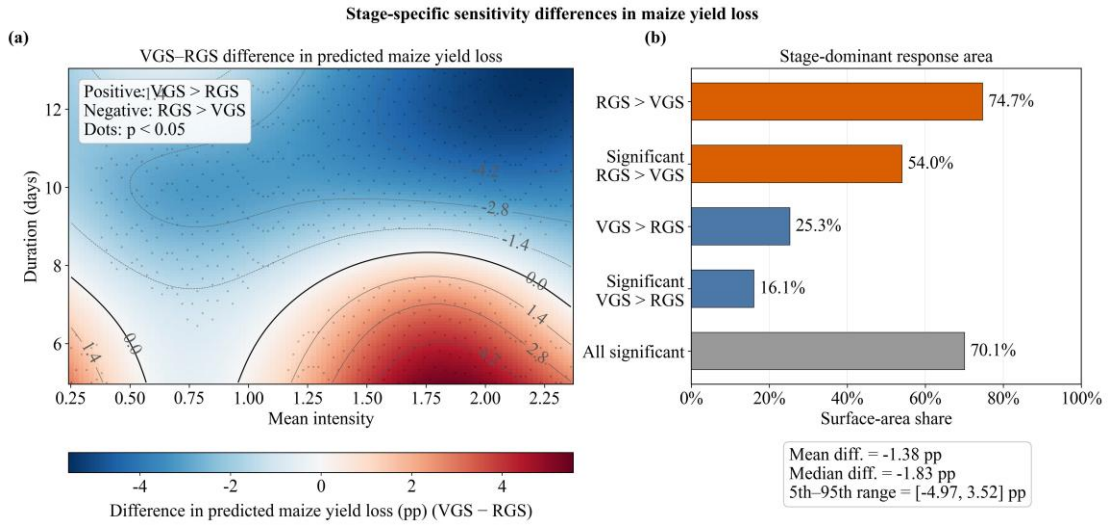


图 5-8 不同物候期 SCDHWs 对玉米产量损失敏感性的预测差异及显著性分布。（a）VGS 与 RGS 阶段预测玉米产量损失率的差异，计算方式为 VGS−RGS；正值表示 VGS 阶段高于 RGS 阶段，负值表示 RGS 阶段高于 VGS 阶段，灰色点表示差异显著（p< 0.05）。（b）不同差异方向及显著性类别在强度和持续时间预测网格中的占比。

Figure 5-8. Predicted differences and significance patterns in maize yield loss sensitivity to SCDHWs across phenological stages. (a) Difference in predicted maize yield loss rate between VGS and RGS, calculated as VGS − RGS; positive and negative values indicate higher predicted losses during VGS and RGS, respectively, and gray dots denote significant differences ($p < 0.05$). (b) Prediction-grid shares of different difference directions and significance categories within the intensity-duration domain.

5.6 讨论

5.6.1 SCDHWs 的时空分布特征及区域差异

本研究基于高精度逐日 T_s 和 SM 数据，识别了 2001-2020 年中国区域 SCDHWs 事件的时空分布特征。结果表明，SCDHWs 在空间上具有显著异质性，其多年平均频次、持续时间、峰值强度和累积强度均表现出明显区域分异。这说明 SCDHWs 并非传统意义上高温区或干旱区的简单叠加，而是由 T_s 和 SM 相对于当地气候态的同步异常共同决定。因此，SCDHWs 的空间分布更能反映作物土壤复合异常暴露，而不是单一气候因子的空间分布。已有研究也表明，复合土壤干热事件在不同气候区之间存在明显空间差异，且其高值区会受到变量选择、时间尺度和阈值定义的影响（Zhao et al. 2025）。这进一步说明，SCDHWs 的空间格局应结合事件定义和区域气候背景进行解释。

不同 SCDHWs 指标所表征的风险含义并不完全相同。发生频次主要反映事件发生可能性，持续时间反映事件对作物耕层环境的连续影响时长，峰值强度代表最强瞬时胁迫程度，而累积强度综合了事件强度和持续时间，更能反映作物在事件过程中承受的总胁迫负荷。本研究发现，持续时间和累积强度增加较为明显，说明中国区域土壤复合干热风险的增强不仅表现为事件发生概率上升，也表现为事件持续影响时间延长和综合胁迫负荷增加。Lin 等（2026）同样发现，中国不同深度土壤热浪的频次、持续时间和强度均呈增强趋势，且东北平原、黄淮海平原等粮食主产区农田暴露风险明显上升。Chen 等（2024）也指出，全球农田生长季 GPP 暴露于热浪的风险将持续增加，且主要由热浪频次和累积幅度增强驱动。也有研究表明未来全球农田暴露于极端复合干旱—热浪事件的风险将显著增加（Wang et al. 2023）。这些结果共同表明，在农业气候风险评估中，仅关注事件峰值可能低估 SCDHWs 的实际影响，而持续时间和累积强度应作为评价 SCDHWs 风险的重要指标。

值得注意的是，西北干旱半干旱地区并未表现为全国最高的 SCDHWs 暴露区。这并不意味着该区域不存在干旱或热胁迫，而是与相对阈值识别方法有关。本研究强调 T_s 和 SM 相对于当地多年气候态的同步异常，而非绝对干旱或绝对高温状态。长期处于干旱背景的西北地区 SM 本身较低，相对异常事件的识别频次可能受到限制；而在季节性水分波动较强的区域，T_s 升高与 SM 下降更容易同时越过相对阈值。因此，SCDHWs 的空间格局应理解为区域气候态、SM 背景、土壤热环境、阈值定义和时间尺度共同作用的结果。本研究识别的 SCDHWs 可进一步表明，中国玉米主产区面临的农业气候风险正在从单一高温或干旱胁迫转向土壤复合异常暴露，其增强趋势需要在生产力影响和产量风险评估中予以重点关注。

5.6.2 SCDHWs 对玉米生产力影响的物候差异

NPP 表征植被在扣除自身呼吸消耗后的净碳积累，能够反映作物可用于生长和干物质形成的实际生产力水平（Cramer et al. 1999）。因此，本研究采用 NPP 相对损失率刻画 SCDHWs 发生期间玉米生产力的下降程度，以揭示土壤复合干热胁迫对玉米生长过程和产量形成潜力的影响。结果表明，SCDHWs 对玉米生产力的影响具有明显的农业区和物候期差异，其中东北平原、黄淮海平原、黄土高原以及北方干旱半干旱区的 NPP 相对损失率整体较高，说明这些区域玉米生产力对土壤复合干热胁迫更为敏感。已有研究也表明，复合土壤干热事件会显著削弱植被生产力。Zhao 等（2025）发现，中国大部分地区在复合土壤干热事件期间出现生产力负异常，且 2000 年后这种负响应的强度和空间范围进一步扩大。该结果与本研究中 SCDHWs 期间玉米 NPP 相对损失增加的现象一致，进一步说明土壤复合干热胁迫能够通过抑制作物净碳积累影响农田生产力。

不同物候期的分析结果显示，在东北平原、黄淮海平原、黄土高原和北方干旱半干旱区，VGS 阶段 NPP 相对损失通常高于 RGS 阶段，表明玉米 VGS 阶段生产力损失对 SCDHWs 更为敏感。基于模型解释结果发现，VGS 阶段 NPP 损失主要受植被蒸腾异常、SM 最小值、太阳净辐射、潜在蒸散异常和降水等因子控制，其中与水分供应、蒸腾调节和蒸散需求相关的变量贡献较高。该结果说明，VGS 阶段 SCDHWs 对玉米生产力的影响主要体现为水分限制主导的短期净碳积累下降。VGS 阶段是叶面积扩展、根系建成和冠层光合能力形成的重要时期，SM 亏缺会限制根系吸水和冠层蒸腾，削弱叶片扩展和光合能力形成（Huang et al. 2023）。同时，较高的蒸散需求会增强土壤—植物—大气连续体中的水分消耗压力，当根系吸水难以满足冠层蒸腾需求时，作物通常通过气孔调节降低水分损失，但这也会抑制光合作用和叶面积发育，从而加剧事件期 NPP 相对损失（Hsiao et al. 2019；Koehler et al. 2023）。Wei 等（2026）指出，玉米干旱胁迫不仅取决于 SM 供应，也受大气水分需求调节；VPD 升高会增强蒸腾需求、加速 SM 消耗，并通过气孔关闭抑制碳同化。也有研究指出，复合热干事件下作物会通过气孔关闭减少水分损失，但同时会抑制光合碳吸收并降低产量潜力（Tabari et al. 2023；Sutanto et al. 2024）。因此，本研究中 VGS 阶段水分供应和蒸散相关因子贡献较高，说明 VGS 阶段 SCDHWs 对玉米生产力的影响主要通过 SM 亏缺和蒸散需求增强共同实现。

相比之下，RGS 阶段 NPP 损失的主导因子发生明显转变。模型解释结果显示，RGS 阶段贡献较高的变量主要包括平均太阳净辐射、最高 T_s、SM 最小值、植被蒸腾异常和潜在蒸散异常，其中太阳辐射和 T_s 等能量与热量相关因子的作用明显增强。该结果表明，RGS 阶段 SCDHWs 对玉米生产力的影响不再主要表

现为水分供应不足单独主导，而是体现为土壤高温、水分亏缺和能量输入共同作用下的复合胁迫。已有研究表明，玉米在开花、授粉和灌浆期对高温和水分亏缺尤为敏感，高温可通过降低花粉活力、影响授粉受精、减少籽粒数和缩短灌浆持续时间等途径削弱产量形成（Niu et al. 2021；Mirosavljević et al. 2024）。同时，T_s变化会影响作物根系生长、吸水能力和地上部生长表现，土壤热胁迫可能通过根—冠协同过程影响作物生产力（Calleja-Cabrera et al. 2020；Zhao et al. 2025）。Lu 等（2026）进一步发现，将 T_s 纳入复合干旱—高温事件指数后，可显著提高其对玉米产量损失的解释能力，说明土壤热异常能够提供单纯气象高温指标难以表征的胁迫信息。总体来看，VGS 阶段 SCDHWs 对玉米 NPP 的影响主要表现为水分供应不足和蒸散异常引起的短期净碳积累下降，而 RGS 阶段则更多体现为土壤高温、水分亏缺和辐射增强共同作用下的复合胁迫。这种阶段性转换说明，SCDHWs 对玉米生产力的影响不能仅从损失大小进行比较，还应结合不同物候期的生理敏感性和主导胁迫路径进行解释。

5.6.3 生产力与产量损失的差异及风险启示

本研究发现，在相同 SCDHWs 平均强度和持续时间组合下，RGS 阶段对应的玉米产量损失率整体高于 VGS 阶段，且这种差异在事件持续时间较长时更加明显。这表明，SCDHWs 对玉米最终产量的影响并不完全取决于事件期生产力损失大小，而与事件发生的物候阶段及其是否作用于产量形成关键过程密切相关。具体而言，VGS 阶段较高的 NPP 相对损失主要反映事件发生期间净碳积累受到抑制，而 RGS 阶段虽然 NPP 损失不一定最高，但由于其更接近籽粒形成和产量决定过程，持续性久的 SCDHWs 更容易转化为最终产量损失。

这种差异说明，NPP 损失和产量损失表征的是两个相关但并不等同的过程。NPP 相对损失主要刻画事件期作物生产力的即时响应，而产量损失则是整个生长季碳累积、同化物分配、籽粒形成和灌浆过程综合作用后的最终结果（Wang et al. 2019；Ren et al. 2022）。因此，事件期 NPP 损失较高并不必然意味着最终产量损失也最高；相反，如果胁迫发生在产量形成敏感阶段，即使短期生产力下降幅度有限，也可能通过影响籽粒数、灌浆速率或同化物转运效率而放大最终产量损失。已有研究表明，玉米产量对大气干旱存在明显非线性阈值响应，超过关键阈值后产量损失会快速增加，且土壤和大气耦合的差异会调节这种敏感性（Wei et al. 2026）。结合本研究结果，RGS 阶段 SCDHWs 对产量损失的影响可能并非简单的线性累积过程，而更可能表现为关键生育阶段胁迫超过作物耐受范围后的非线性放大。换言之，事件发生时间决定其是否作用于产量形成敏感窗口，而事件持续时间和累积强度则决定胁迫是否超过作物可补偿范围。

基于上述认识，玉米主产区农业气候风险评估应区分生产力风险和产量风险。

不同物候期 NPP 相对损失的差异，能够表征 SCDHWs 对玉米生长过程和碳积累即时影响的阶段性差异；而最终产量风险则不仅取决于事件是否发生在产量形成敏感窗口，还取决于 T_s 升高与 SM 亏缺是否形成持续性复合胁迫，并超过作物可补偿范围。因此，未来玉米干热风险预警不宜仅依据整个生长季平均暴露或单一指标，而应综合考虑物候阶段、土壤水热状态、事件持续时间、累积强度以及关键胁迫阈值。由此，农业气候风险评估应从是否发生复合干热事件的识别，进一步转向事件发生在何时、土壤水热胁迫持续多久、是否作用于产量形成敏感窗口的综合评估。

5.7 小结

本章基于重构的 T_s 数据、SM 数据、玉米物候数据、NPP 数据和产量格网数据，构建了面向玉米生长季土壤水热胁迫的 SCDHW 识别框架，并进一步分析了 SCDHWs 的时空变化特征及其对玉米生产力和产量损失的影响。主要结论如下：

（1）2001-2020 年中国 SCDHWs 的持续时间、发生频次和强度均呈增加趋势，其中持续性和累积性胁迫的增强最为突出。研究期间，SCDHWs 持续时间以 2.40 d decade^{-1}的速率增加，发生频次增加 0.13 events decade^{-1}，峰值强度增加 0.34 ℃ decade^{-1}，累积强度增加 3.89 °C·d decade^{-1}。不同指标的空间高值区并不完全重合，其中黄土高原和北方干旱半干旱农业区等玉米主要种植区域表现出较高的土壤复合干热风险。四类指标同步增加表明，研究期内 SCDHWs 不仅发生概率有所提高，而且单次事件持续时间延长、热异常增强，其风险正由短期事件暴露向持续性和累积性胁迫转变。

（2）SCDHWs 对玉米 NPP 损失的驱动机制具有明显的物候阶段差异，VGS 阶段以水分和蒸散过程为主，而 RGS 阶段热量相关因素的重要性明显增强。在东北平原、北方干旱半干旱区、黄淮海平原和黄土高原等主要玉米种植区，VGS 阶段 NPP 相对损失总体高于 RGS 阶段。XGBoost-SHAP 模型在 VGS 阶段测试集上的 R^2 达到 0.732，RMSE 为 11.627；变量类别贡献中，蒸散过程因子占 36.6%，气象条件因子占 33.3%，土壤水热条件因子占 24.7%，而 SCDHWs 事件自身的强度和持续时间等特征仅占 5.3%，说明 VGS 阶段生产力损失更多受水分供应与蒸散状态调控。进入 RGS 阶段后，气象条件因子的贡献升至首位，占 33.6%，平均太阳净辐射、最高 T_s 和 SM 最小值成为最重要的三个变量，表明玉米生殖生长期对土壤高温、辐射增强和水分亏缺的协同作用更加敏感。

（3）基于 GAMM 模型的产量损失敏感性分析表明，在相同 SCDHWs 平均强度和持续时间组合下，RGS 阶段对应的玉米产量损失率整体高于 VGS 阶段，且这种差异在事件持续时间较长时更加明显。预测结果显示，RGS 阶段产量损失

率高于 VGS 阶段的预测网格占 74.7%，其中显著区域占 54.0%。上述结果表明，玉米产量损失对 RGS 阶段长持续时间 SCDHWs 更为敏感，持续性土壤水热复合胁迫更容易由阶段性生产力损失转化为最终产量损失。因此，面向玉米产量损失的复合干热风险评估应重点关注 RGS 阶段 SCDHWs 的持续时间、累积强度及其与产量形成关键窗口的重合程度。

总体而言，本章从土壤水热耦合视角完善了复合干热事件识别框架，揭示了中国农业区 SCDHWs 的时空变化趋势及其对玉米生产力和产量损失的阶段性影响。研究结果表明，将 T_s 和 SM 共同纳入农业气候风险评估，有助于更准确刻画玉米生长过程中实际承受的土壤复合胁迫，并为玉米主产区干热风险预警、物候期差异化管理和粮食安全适应策略制定提供科学依据。

第六章 结论与展望

6.1 主要结论

本研究围绕“基于中国高精度土壤温度数据的土壤复合干热事件识别及其对玉米的影响研究”这一主题展开。首先，基于多层原位 T_s 观测数据，系统评估了主流再分析 T_s 产品在中国区域的适用性与局限性；其次，融合地面观测、遥感、再分析气象资料以及地形和土壤属性数据，构建空间自适应建模框架，生成中国区域逐日多层 T_s 数据集。最后，将 T_s 数据与 SM、玉米物候、NPP 和产量数据相结合，从土壤水热耦合视角识别 SCDHWs，并分析其对玉米生产力和产量损失的阶段性影响。主要结论如下。

（1）再分析 T_s 产品在总体空间格局表征上具有可用性，但长期趋势和土壤热浪与冻融指标存在明显不确定性。

四套再分析产品总体能够反映中国区域 T_s 的宏观空间格局，但其整体精度存在明显产品差异。JRA-3Q 和 ERA5-Land 在多数土层和环境条件下表现较为稳定，能够较好刻画 T_s 的空间分布特征；GLDAS 和 MERRA-2 在复杂地形区、浅层土壤及部分极端季节条件下不确定性相对较高。再分析产品误差具有明显的垂向结构和环境依赖性，通常表现为浅层误差较大、深层误差较小，并在夏季、冬季、高海拔区和复杂地形区进一步放大。在长期变化表征方面，四套产品总体能够捕捉中国多层 T_s 的增温方向，但对增温幅度及其空间分布的刻画能力存在差异。ERA5-Land 和 JRA-3Q 对大尺度增温格局的表征较为连续，而 GLDAS 和 MERRA-2 在部分区域的趋势幅度和空间一致性上存在较大不确定性。在关键土壤热过程表征方面，不同指标的产品间一致性存在明显差异。土壤热浪指标对产品选择更为敏感，其中峰值强度的一致性相对较高，而发生频次的一致性最低，说明事件发生类指标更易受逐日温度波动、阈值设定和事件合并规则影响。相比之下，土壤冻融指标在不同产品之间具有更高一致性，尤其是冻结日数，表现出较稳定的纬度和海拔梯度。

（2）基于空间自适应建模重构中国 2001-2020 年 1 km 逐日多层 T_s 数据集。

针对中国区域 T_s 观测站点分布不均、环境异质性强和全局模型泛化能力不足的问题，本研究构建了基于旋转四叉树和 XGBoost 的空间自适应局部建模框架。该框架通过自适应空间划分和多角度旋转集成，兼顾了局地环境差异与模型稳定性，并降低了单一空间分区可能产生的边界效应。基于该框架，本研究融合地面观测、卫星遥感、再分析气象资料以及地形和土壤属性变量，生成了中国 1 km 分辨率、逐日多层（0、5、10、15、20 和 40 cm）T_s 数据集。验证结果表明，

该数据集在训练集、测试集和独立通量站点中均表现出较高精度，能够较好刻画不同土层、土地覆盖类型和季节条件下的 T_s 变化。与 ERA5-Land 和 GLDAS 等再分析产品相比，本研究生成的数据集在空间分辨率和站点一致性方面均有所提升，并能够更细致地表征复杂地形区的局地温度梯度和空间异质性。

（3）基于高精度 T_s 和 SM 协同识别的 SCDHWs 在中国农业区表现出增强趋势和区域分异特征。

基于上一章节重构的高精度 T_s 数据集，并结合已有的高精度 SM 数据集，本研究从作物生长季土壤水热耦合视角构建了 SCDHWs 识别框架。该框架以 10 cm T_s 异常升高和 SM 异常亏缺的同步发生作为事件判定依据，能够更直接地刻画玉米生长过程中承受的土壤复合水热胁迫过程。基于该框架的识别结果表明，2001-2020 年期间，中国多数农业区 SCDHWs 呈增强趋势，主要表现为事件持续时间延长和累积强度增加，说明玉米主产区土壤复合干热风险正在由短期暴露向持续性、累积性胁迫转变。不同农业区 SCDHWs 的发生特征存在明显差异，北方玉米主产区和干旱半干旱农业区通常表现出更高的复合水热胁迫风险。

（4）VGS 阶段 SCDHWs 更易导致玉米 NPP 损失，而 RGS 阶段 SCDHWs 更易转化为最终产量损失。

结合玉米物候、NPP 和产量数据，本研究量化了 VGS 和 RGS 阶段 SCDHWs 对玉米生产力及产量损失的影响。结果表明，在东北平原、黄淮海平原、黄土高原和北方干旱半干旱区等玉米主要产区，VGS 阶段玉米 NPP 相对损失通常高于 RGS 阶段。XGBoost-SHAP 分析进一步表明，VGS 阶段生产力损失主要受植被蒸腾异常、SM 亏缺和降水等水分过程控制；而 RGS 阶段土壤高温、太阳辐射等热量相关因子的作用增强，表明生殖生长期玉米生产力响应对土壤高温和热量条件更加敏感。基于 GAMM 模型的产量损失敏感性分析表明，在相同 SCDHWs 强度和持续时间条件下，RGS 阶段对应的玉米产量损失率整体高于 VGS 阶段，且这种差异在长持续时间事件下更加明显。该结果说明，VGS 阶段 SCDHWs 更容易造成事件期 NPP 损失，而 RGS 阶段持续时间久的 SCDHWs 更容易转化为最终产量损失。

6.2 创新点

（1）提出了面向多层结构、长期趋势与关键热过程的再分析 T_s 产品综合评估框架。

已有再分析 T_s 产品评估多侧重平均状态或单一土层精度，对不同产品在多层土壤结构、长期变化趋势及关键土壤热过程表征方面的综合适用性认识不足。针对这一问题，本研究构建了涵盖从平均状态精度、长期趋势可靠性以及土壤热

浪与冻融过程表征能力的综合评估框架，系统比较 ERA5-Land、GLDAS、MERRA-2 和 JRA-3Q 四类再分析产品在中国复杂地理环境下的适用性。该创新不仅突破了传统产品评估中以单一精度指标为主的局限，也为不同应用场景下 T_s 产品的合理选择提供了更具过程意义的依据。

（2）构建了中国 2001-2020 年 1 km 分辨率逐日多层（0、5、10、15、20 和 40 cm）T_s 数据集。

针对中国区域 T_s 观测站点分布不均、地形和下垫面异质性强、传统全局模型难以兼顾局地差异与空间泛化能力的问题，本研究提出了基于旋转四叉树空间划分和 XGBoost 局部建模的空间自适应估算框架，并进一步引入层级递进策略以增强多层 T_s 估算的垂向一致性。该方法能够根据观测样本密度和区域环境差异自适应调整建模单元，有效缓解全局建模对空间非平稳关系刻画不足的问题。基于该方法生成的 2001-2020 年中国逐日 1 km 分辨率多层 T_s 数据集，为土壤热环境监测、生态过程模拟和农业气候风险分析提供了高时空分辨率数据基础。

（3）揭示了基于土壤水热状态识别的 SCDHWs 对玉米生产力和产量影响的物候阶段差异。

现有复合干热事件研究多基于气温、降水或大气干旱指标，难以直接刻画作物生长过程中土壤高温与水分亏缺同步发生所形成的水热复合胁迫。针对这一不足，本研究将高精度 T_s 数据与 SM 数据相结合，从土壤水热耦合视角识别 SCDHWs，并进一步结合玉米物候、NPP 和产量数据，揭示了 SCDHWs 对玉米生产力损失和最终产量损失影响的阶段性差异。结果表明，VGS 阶段 SCDHWs 更容易表现为事件期 NPP 损失，而 RGS 阶段 SCDHWs 更容易转化为最终产量损失，说明土壤复合干热胁迫对玉米的影响不仅取决于事件强度和持续时间，还与事件发生的物候阶段密切相关。该认识推动了农业复合干热风险研究从传统大气暴露指标向土壤水热复合胁迫过程拓展，也为区分玉米生产力风险与产量风险提供了新的科学依据。

6.3 研究不足和展望

尽管本研究围绕中国区域多层 T_s 数据构建及其农业气候风险应用开展了较为系统的分析，但受限于模型结构、过程刻画和多源数据不确定性等因素，仍存在一些不足。后续研究可从以下几个方面进一步完善。

（1）遥感输入数据的不确定性仍可能影响 T_s 估算结果。

MODIS LST 和植被指数是本研究 T_s 估算的重要输入变量，但光学遥感数据易受云、气溶胶和观测角度影响，尤其在南方多云湿润区和复杂山地环境中存在较多缺测和噪声。尽管本研究通过时空插值和平滑处理提高了数据连续性，但重

建过程仍可能引入不确定性，并进一步传递至深层 T_s 估算结果。未来可融合被动微波遥感、静止气象卫星高频热红外观测和多源 LST 重建产品，提高地表热状态输入变量的时间连续性和物理可靠性；同时开展输入变量不确定性传播分析，明确遥感变量、气象变量和静态环境变量对 T_s 估算误差的相对贡献。

（2）多层 T_s 重构模型仍需增强物理过程约束。

本研究主要采用数据驱动方法刻画 T_s 与多源环境变量之间的非线性关系，能够取得较高估算精度，但对土壤热传导、土壤水热耦合、积雪隔热和冻融相变等物理过程的显式约束仍然有限。尤其在夏季强蒸散、冬季积雪覆盖和冻融频繁条件下，土壤热过程受多种非线性机制共同影响，仅依赖统计关系可能难以充分刻画其过程机理。未来可在空间自适应框架基础上，引入积雪和冻融状态，发展物理机制与 ML 相结合的混合建模方法，以提高多层 T_s 估算的物理一致性和跨区域泛化能力。

（3）农业应用仍可扩展至多作物、多管理情景和未来气候风险评估。

本研究重点分析了玉米系统中 SCDHWs 对 NPP 和产量损失的影响，但不同作物类型、品种、种植制度和农田管理措施对根区水热胁迫的敏感性存在差异。未来可将该框架扩展至小麦、水稻和大豆等主要粮食作物，比较不同作物对 SCDHWs 的响应差异。同时，可结合灌溉、播期调整、品种熟制和耕作方式等管理信息，分析农业适应措施对根区复合水热胁迫风险的缓解作用。在气候变化背景下，还可进一步耦合未来气候情景和作物模型，预测不同升温路径下中国主要粮食产区 SCDHWs 风险的演变趋势，为农业气候风险预警和适应策略制定提供支撑。

参考文献

白莉萍,隋方功,孙朝晖,葛体达,吕银燕,周广胜.2004.土壤水分胁迫对玉米形态发育及产量的影响[J].生态学报(7):1556-1560.

丁利荣,周纪,张晓东,王韶飞,唐文彬,王子卫,马晋,艾丽皎,李明松,王伟.2023.全天候地表温度遥感获取进展与挑战[J].遥感学报,27(7):1534-1553.

董勤各,何建强,李毅,姚宁,李想,张浩磊,王胜楠,蒋腾聪,陈柏青,高春瑞,梁超,张桂源,宫蕾,赵金璇,于强,冯浩.2026.气候变化对西北地区粮食生产的影响及应对策略[J].中国科学院院刊,41(4):673-685.

胡金鹏,何研,史培军.2025.复合干热事件对小麦产量影响的研究进展与展望全文替换[J].气候变化研究进展,21(5):625-640.

黄茂伟,章红颖,陈一鸣,梁航琪,丛楠,赵红芳,黎夏.2025.干热复合事件对北半球植被的影响及时滞效应[J].地理学报,80(11):3058-3071.

李少昆,赵久然,董树亭,赵明,李潮海,崔彦宏,刘永红,高聚林,薛吉全,王立春,王璞,陆卫平,王俊河,杨祁峰,王子明.2017.中国玉米栽培研究进展与展望[J].中国农业科学,50(11):1941-1959.

李召良,段四波,唐伯惠,吴骅,任华忠,阎广建,唐荣林,冷佩.2016.热红外地表温度遥感反演方法研究进展[J].遥感学报,20(5):899-920.

刘纯,包雯慧,吴骅,段四波,曹彪,殷志祥,吴鹏海.2025.1985 年—2023 年遥感地表温度研究进展与展望[J].遥感学报,29(7):2328-2344.

刘玉洁,葛全胜,戴君虎.2020.全球变化下作物物候研究进展[J].地理学报,75(1):14-24.

莫兴国,李宏轩,刘苏峡,林忠辉.2002.用土壤温度估算表层土壤导温率与热通量的研究[J].中国生态农业学报(1):66-68.

彭琼艳,沈若缺,刘玉洁.2024.2001-2020 年中国玉米物候期数据集[DS/OL].国家生态科学数据中心.https://cstr.cn/31253.11.sciencedb.16127.

任余龙,李振朝,蒋俊霞,高晓清,周甘霖,芦亚玲.2022.三种土壤导热率模型对中国北方地表温度的模拟[J].高原气象,41(5):1315-1324.

徐俊杰,于一雷,杨丽虎,李文彦,吕翠翠,韦欣.2025.六种机器学习算法对西藏那曲草甸土土壤剖面温度的模拟效果对比[J].中国农业气象,46(6):781-795.

佚名.2006.土壤物理学[M].高等教育出版社.

张更喜,王慧敏,粟晓玲,方红远,章数语,黄金柏,冯凯.2024.复合干热胁迫下黄土高原夏季植被脆弱性评估[J].农业工程学报,40(6):339-346.

张慧智,史学正,于东升,王洪杰,赵永存,孙维侠,黄宝荣.2009.中国土壤温度的空间预测研究[J].土壤学报,46(1):1-8.

张建彬,高志球,童兵,王琳琳.2023.土壤温度预报方程研究进展[J].土壤学报,60(3):599-609.

张天鹏,保万魁,雷秋良,刘笑彤,杜新忠,周脚根,罗加法,刘宏斌.2022.1951—2010 年中国土壤温度时空变化特征及其影响因素[J].地理学报,77(3):589-602.

周广胜.2015.气候变化对中国农业生产影响研究展望[J].气象与环境科学,38(1):80-94.

Abbas G, Younis H, Naz S, Fatima Z, Atique-ur-Rehman, Hussain S, Ahmed M, Ahmad S. 2019. Effect of Planting Dates on Agronomic Crop Production[M]. In: Hasanuzzaman M (editor), Agronomic Crops: Volume 1: Production Technologies.

Singapore: Springer, pp. 131-147.
Abu-Hamdeh NH. 2003. Thermal properties of soils as affected by density and water content[J]. Biosystems engineering, 86(1): 97-102.
Adopted I. 2014. Climate change 2014 synthesis report[J]. IPCC: Geneva, Szwitzerland: 1059-1072.
Akinwande MO, Dikko HG, Samson A. 2015. Variance inflation factor: As a condition for the inclusion of suppressor variable(s) in regression analysis[J]. Open Journal of Statistics, 5(7): 754-767.
Albergel C, Dutra E, Muñoz-Sabater J, Haiden T, Balsamo G, Beljaars A, Isaksen L, de Rosnay P, Sandu I, Wedi N. 2015. Soil temperature at ECMWF: An assessment using ground-based observations[J]. Journal of Geophysical Research: Atmospheres, 120(4): 1361-1373.
Alexandrov VA, Hoogenboom G. 2000. The impact of climate variability and change on crop yield in Bulgaria[J]. Agricultural and Forest Meteorology, 104(4): 315-327.
Araghi A, Mousavi-Baygi M, Adamowski J. 2017. Detecting soil temperature trends in northeast iran from 1993 to 2016[J]. Soil and Tillage Research, 174: 177-192.
Azad N, He H. 2025. Generalization of multiple depths soil temperature estimation using LSTM and CNN[J]. Journal of Hydrology, 661: 133687.
Badache M, Eslami-Nejad P, Ouzzane M, Aidoun Z, Lamarche L. 2016. A new modeling approach for improved ground temperature profile determination[J]. Renewable Energy, 85: 436-444.
Barriopedro D, García-Herrera R, Ordóñez C, Miralles DG, Salcedo-Sanz S. 2023. Heat waves: Physical understanding and scientific challenges[J]. Reviews of Geophysics, 61(2): e2022RG000780.
Bayatvarkeshi M, Bhagat SK, Mohammadi K, Kisi O, Farahani M, Hasani A, Deo R, Yaseen ZM. 2021. Modeling soil temperature using air temperature features in diverse climatic conditions with complementary machine learning models[J]. Computers and Electronics in Agriculture, 185: 106158.
Belghit A, Benyaich M. 2014. Numerical Study of Heat Transfer and Contaminant Transport in an Unsaturated Porous Soil[J]. Journal of Water Resource and Protection, 6(13): 1238-1247.
Bilgili M. 2010. Prediction of soil temperature using regression and artificial neural network models[J]. Meteorol Atmos Phys, 110(1): 59-70.
Bond-Lamberty B, Wang C, Gower ST. 2005. Spatiotemporal measurement and modeling of stand-level boreal forest soil temperatures[J]. Agricultural and Forest Meteorology, 131(1): 27-40.
Borisova T. 1991. Effect of exogenous factors on water relations in maize roots[M]. In: Developments in Agricultural and Managed Forest Ecology:Vol. 24. Elsevier, pp. 9-16.
Bu L duo, Zhu L, Liu J liang, Luo S sha, Chen X ping, Li S qing. Source–sink capacity responsible for higher maize yield with removal of plastic film[J].
Burgess T, Webster R. 1980. Optimal interpolation and isarithmic mapping of soil properties: I the semi-variogram and punctual kriging[J]. Journal of soil science, 31(2): 315-331.
Calleja-Cabrera J, Boter M, Oñate-Sánchez L, Pernas M. 2020. Root growth adaptation to climate change in crops[J]. Front Plant Sci, 11: 544.
Cao J, Zhang Z, Luo X, Luo Y, Xu J, Xie J, Han J, Tao F. 2025. Mapping global yields of four major crops at 5-minute resolution from 1982 to 2015 using multi-source data and machine learning[J]. Scientific Data, 12(1): 357.

Cao R, Chen Y, Shen M, Chen J, Zhou J, Wang C, Yang W. 2018. A simple method to improve the quality of NDVI time-series data by integrating spatiotemporal information with the Savitzky-Golay filter[J]. Remote Sensing of Environment, 217: 244-257.

Chen L, Aalto J, Luoto M. 2021. Observed Decrease in Soil and Atmosphere Temperature Coupling in Recent Decades Over Northern Eurasia[J]. Geophysical Research Letters, 48(6): e2021GL092500.

Chen T, Guestrin C. 2016. Xgboost: A scalable tree boosting system[C]. Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining, pp. 785-794.

Chen W, Ju H, Liang XZ, Batchelor WD, Wang X. 2026. Rising vapor pressure deficit threatens maize water productivity in the yellow river basin under climate warming[J]. Agricultural Water Management, 331: 110430.

Chen X, Long D, Hong Y, Zeng C, Yan D. 2017. Improved modeling of snow and glacier melting by a progressive two-stage calibration strategy with GRACE and multisource data: How snow and glacier meltwater contributes to the runoff of the U pper B rahmaputra R iver basin?[J]. Water Resources Research, 53(3): 2431-2466.

Chen Y, Cao R, Chen J, Liu L, Matsushita B. 2021. A practical approach to reconstruct high-quality Landsat NDVI time-series data by gap filling and the Savitzky–Golay filter[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 180: 174-190.

Chen Y, Zhang W, Zhou T. 2024. Increasing exposure of global croplands productivity to growing season heatwaves under climate warming[J]. Environ Res Lett, 19(10): 104073.

Chenoweth M.1992.A Possible Discontinuity in the U.S. Historical Temperature Record[J].Journal of Climate,5(10):1172-1179.

Citakoglu H. 2017. Comparison of artificial intelligence techniques for prediction of soil temperatures in Turkey[J]. Theor Appl Climatol, 130(1): 545-556.

Côté J, Konrad JM. 2005. A generalized thermal conductivity model for soils and construction materials[J]. Canadian Geotechnical Journal, 42(2): 443-458.

Cramer W, Kicklighter DW, Bondeau A, Iii BM, Churkina G, Nemry B, Ruimy A, Schloss AL, Intercomparison TPOTPNM. 1999. Comparing global models of terrestrial net primary productivity (NPP): Overview and key results[J]. Global change biology, 5(S1): 1-15.

Crowther TW, Todd-Brown KEO, Rowe CW, Wieder WR, Carey JC, Machmuller MB, Snoek BL, Fang S, Zhou G, Allison SD, Blair JM, Bridgham SD, Burton AJ, Carrillo Y, Reich PB, Clark JS, Classen AT, Dijkstra FA, Elberling B, Emmett BA, Estiarte M, Frey SD, Guo J, Harte J, Jiang L, Johnson BR, Kröel-Dulay G, Larsen KS, Laudon H, Lavallee JM, Luo Y, Lupascu M, Ma LN, Marhan S, Michelsen A, Mohan J, Niu S, Pendall E, Peñuelas J, Pfeifer-Meister L, Poll C, Reinsch S, Reynolds LL, Schmidt IK, Sistla S, Sokol NW, Templer PH, Treseder KK, Welker JM, Bradford MA. 2016. Quantifying global soil carbon losses in response to warming[J]. Nature, 540(7631): 104-108.

Cui X, Xu G, He X, Luo D. 2022. Influences of seasonal soil moisture and temperature on vegetation phenology in the Qilian Mountains[J]. Remote Sensing, 14(15): 3645.

Dannenberg MP, Yan D, Barnes ML, Smith WK, Johnston MR, Scott RL, Biederman JA, Knowles JF, Wang X, Duman T, Litvak ME, Kimball JS, Williams AP, Zhang Y. 2022. Exceptional heat and atmospheric dryness amplified losses of primary production during the 2020 U.S. Southwest hot drought[J]. Global Change

Biology, 28(16): 4794-4806.
Davidson EA, Janssens IA. 2006. Temperature sensitivity of soil carbon decomposition and feedbacks to climate change[J]. Nature, 440(7081): 165-173.
Davidson EA, Janssens IA, Luo Y. 2006. On the variability of respiration in terrestrial ecosystems: moving beyond Q10[J]. Global change biology, 12(2): 154-164.
De Frenne P, Lenoir J, Luoto M, Scheffers BR, Zellweger F, Aalto J, Ashcroft MB, Christiansen DM, Decocq G, De Pauw K, Govaert S, Greiser C, Gril E, Hampe A, Jucker T, Klinges DH, Koelemeijer IA, Lembrechts JJ, Marrec R, Meeussen C, Ogée J, Tyystjärvi V, Vangansbeke P, Hylander K. 2021. Forest microclimates and climate change: Importance, drivers and future research agenda[J]. Global Change Biology, 27(11): 2279-2297.
De Vries D.1958.Simultaneous transfer of heat and moisture in porous media[J].Eos, Transactions American Geophysical Union,39(5):909-916.
Deo RC, Şahin M. 2017. Forecasting long-term global solar radiation with an ANN algorithm coupled with satellite-derived (MODIS) land surface temperature (LST) for regional locations in queensland[J]. Renewable and Sustainable Energy Reviews, 72: 828-848.
Dorau K, Bamminger C, Koch D, Mansfeldt T. 2022. Evidences of soil warming from long-term trends (1951–2018) in North Rhine-Westphalia, Germany[J]. Climatic Change, 170(1): 9.
Du E, Terrer C, Pellegrini AFA, Ahlström A, van Lissa CJ, Zhao X, Xia N, Wu X, Jackson RB. 2020. Global patterns of terrestrial nitrogen and phosphorus limitation[J]. Nat Geosci, 13(3): 221-226.
Duan SB, Li ZL, Leng P. 2017. A framework for the retrieval of all-weather land surface temperature at a high spatial resolution from polar-orbiting thermal infrared and passive microwave data[J]. Remote Sensing of Environment, 195: 107-117.
Fan X, Zhang Y, Shi K, Peng J, Liu Yongwei, Zhou Y, Liu Yuanbo, Zhu Q, Song C, Wan R, Zhao X, Woolway RI. 2024. Surging compound drought–heatwaves underrated in global soils[J]. Proceedings of the National Academy of Sciences, 121(42): e2410294121.
Fang X, Luo S, Lyu S, Cheng C, Li Z, Zhang S. 2021. Numerical modeling of the responses of soil temperature and soil moisture to climate change over the Tibetan Plateau, 1961–2010[J]. International Journal of Climatology, 41(8): 4134-4150.
Farhangmehr V, Imanian H, Mohammadian A, Cobo JH, Shirkhani H, Payeur P. 2025. A spatiotemporal CNN-LSTM deep learning model for predicting soil temperature in diverse large-scale regional climates[J]. Science of The Total Environment, 968: 178901.
Farr TG, Rosen PA, Caro E, Crippen R, Duren R, Hensley S, Kobrick M, Paller M, Rodriguez E, Roth L, Seal D, Shaffer S, Shimada J, Umland J, Werner M, Oskin M, Burbank D, Alsdorf D. 2007. The Shuttle Radar Topography Mission[J]. Reviews of Geophysics, 45(2).
Feng Y, Cui N, Hao W, Gao L, Gong D. 2019. Estimation of soil temperature from meteorological data using different machine learning models[J]. Geoderma, 338: 67-77.
Firozjaei MK, Mijani N, Kiavarz M, Duan SB, Atkinson PM, Alavipanah SK. 2024. A novel surface energy balance-based approach to land surface temperature downscaling[J]. Remote Sensing of Environment, 305: 114087.
Frossard JS, Crocombette M. 1985. Effet de la température des racines sur leur respiration et sur la croissance des plantules de deux hybrides de maïs[J]. Agronomie, 5(8): 719-725.

Gan Y, Siddique KHM, Turner NC, Li XG, Niu JY, Yang C, Liu L, Chai Q. 2013. Chapter Seven - Ridge-Furrow Mulching Systems—An Innovative Technique for Boosting Crop Productivity in Semiarid Rain-Fed Environments[M]. In: Sparks DL (editor), Advances in Agronomy:Vol. 118. Academic Press, pp. 429-476.

Gao Yan, Fan R, Li H, Liu R, Lin X, Guo H, Gao YuTing. 2016. Thermal performance improvement of a horizontal ground-coupled heat exchanger by rainwater harvest[J]. Energy and Buildings, 110: 302-313.

Gao Z, Fan X, Bian L. 2003. An analytical solution to one-dimensional thermal conduction-convection in soil[J]. Soil Science, 168(2): 99-107.

Gao Z, Lenschow DH, Horton R, Zhou M, Wang L, Wen J. 2008. Comparison of two soil temperature algorithms for a bare ground site on the Loess Plateau in China[J]. Journal of Geophysical Research: Atmospheres, 113(D18).

García-García A, Cuesta-Valero FJ, Miralles DG, Mahecha MD, Quaas J, Reichstein M, Zscheischler J, Peng J. 2023. Soil heat extremes can outpace air temperature extremes[J]. Nat Clim Chang: 1-5.

Geiger R, Aron RH, Todhunter P. 2009. The Climate Near the Ground[M]. Rowman & Littlefield.

Gelaro R, McCarty W, Suárez MJ, Todling R, Molod A, Takacs L, Randles CA, Darmenov A, Bosilovich MG, Reichle R. 2017. The modern-era retrospective analysis for research and applications, version 2 (MERRA-2)[J]. Journal of climate, 30(14): 5419-5454.

Gong Y, Li H, Shen H, Meng C, Wu P. 2023. Cloud-covered MODIS LST reconstruction by combining assimilation data and remote sensing data through a nonlocality-reinforced network[J]. International Journal of Applied Earth Observation and Geoinformation, 117: 103195.

Greaves JA. 1996. Improving suboptimal temperature tolerance in maize- the search for variation[J]. Journal of Experimental Botany, 47(3): 307-323.

Guga S, Bole Y, Riao D, Bilige S, Wei S, Li K, Zhang J, Tong Z, Liu X. 2025. The challenge of chilling injury amid shifting maize planting boundaries: A case study of northeast China[J]. Agricultural Systems, 222: 104166.

Guo X, Du L, Tian Q, Tian J. 2026. Disentangling the effects of vapor pressure deficit and soil moisture on gross primary productivity in semi-arid grassland ecosystem of northern China[J]. Ecological Indicators, 188: 114997.

Guo Y, Lu X, Zhang J, Li K, Wang R, Rong G, Liu X, Tong Z. 2022. Joint analysis of drought and heat events during maize (zea mays L.) growth periods using copula and cloud models: A case study of songliao plain[J]. Agricultural Water Management, 259: 107238.

Haldimann P. 1998. Low growth temperature-induced changes to pigment composition and photosynthesis in Zea mays genotypes differing in chilling sensitivity[J]. Plant, Cell & Environment, 21(2): 200-208.

Ham JM, Senock RS. 1992. On the Measurement of Soil Surface Temperature[J]. Soil Science Society of America Journal, 56(2): 370-377.

Hamed KH, Rao AR. 1998. A modified mann-kendall trend test for autocorrelated data[J]. Journal of hydrology, 204(1-4): 182-196.

Hameed M, Ahmadalipour A, Moradkhani H. 2020. Drought and food security in the middle east: An analytical framework[J]. Agricultural and Forest Meteorology, 281: 107816.

Hansen G, Cramer W. 2015. Global distribution of observed climate change impacts[J]. Nature Clim Change, 5(3): 182-185.

Hansen J, Lebedeff S. 1987. Global trends of measured surface air temperature[J].

Journal of Geophysical Research: Atmospheres, 92(D11): 13345-13372.
Hao Z.2022.Compound events and associated impacts in China[J].iScience,25(8):104689.
Hao Z, Hao F, Xia Y, Feng S, Sun C, Zhang X, Fu Y, Hao Y, Zhang Y, Meng Y. 2022. Compound droughts and hot extremes: Characteristics, drivers, changes, and impacts[J]. Earth-Science Reviews, 235: 104241.
He B, Chen C, Lin S, Yuan W, Chen HW, Chen D, Zhang Y, Guo L, Zhao X, Liu X, Piao S, Zhong Z, Wang R, Tang R. 2022. Worldwide impacts of atmospheric vapor pressure deficit on the interannual variability of terrestrial carbon sinks[J]. Natl Sci Rev, 9(4): nwab150.
Herb WR, Janke B, Mohseni O, Stefan HG. 2008. Ground surface temperature simulation for different land covers[J]. Journal of Hydrology, 356(3): 327-343.
Hobday AJ, Alexander LV, Perkins SE, Smale DA, Straub SC, Oliver ECJ, Benthuysen JA, Burrows MT, Donat MG, Feng M, Holbrook NJ, Moore PJ, Scannell HA, Sen Gupta A, Wernberg T. 2016. A hierarchical approach to defining marine heatwaves[J]. Progress in Oceanography, 141: 227-238.
Holmes T, Owe M, De Jeu R, Kooi H. 2008. Estimating the soil temperature profile from a single depth observation: A simple empirical heatflow solution[J]. Water Resources Research, 44(2).
Hong F, Zhan W, Göttsche FM, Liu Z, Dong P, Fu H, Huang F, Zhang X. 2022. A global dataset of spatiotemporally seamless daily mean land surface temperatures: Generation, validation, and analysis[J]. Earth System Science Data, 14(7): 3091-3113.
Honma T, Tsuchida T, Ishii K, Mizuno T, Ishigooka Y, Takimoto T, Kuwagata T. 2022. New estimation model for paddy soil temperature in early growth stage, and its application to estimate nitrogen mineralization of organic fertilizer[J]. Soil Science and Plant Nutrition, 68(2): 295-304.
Hou P, Liu Y, Xie R, Ming B, Ma D, Li S, Mei X. 2014. Temporal and spatial variation in accumulated temperature requirements of maize[J]. Field Crops Research, 158: 55-64.
Hsiao J, Swann AL, Kim SH. 2019. Maize yield under a changing climate: The hidden role of vapor pressure deficit[J]. Agricultural and Forest Meteorology, 279: 107692.
Hu G, Zhao L, Wu X, Li R, Wu T, Xie C, Qiao Y, Shi J, Cheng G. 2016a. An analytical model for estimating soil temperature profiles on the Qinghai-Tibet Plateau of China[J]. J Arid Land, 8(2): 232-240.
Hu G, Zhao L, Wu X, Li R, Wu T, Xie C, Qiao Y, Shi J, Li W, Cheng G. 2016b. New Fourier-series-based analytical solution to the conduction–convection equation to calculate soil temperature, determine soil thermal properties, or estimate water flux[J]. International Journal of Heat and Mass Transfer, 95: 815-823.
Hu Q, Feng S. 2003. A Daily Soil Temperature Dataset and Soil Temperature Climatology of the Contiguous United States[J]. Journal of Applied Meteorology and Climatology, 42(8): 1139-1156.
Hu Q,Feng S.2004.A role of the soil enthalpy in land memory[J].Journal of Climate,17(18):3633-3643.
Hu Y, Ma P, Duan C, Wu S, Feng H, Zou Y. 2020. Black plastic film combined with straw mulching delays senescence and increases summer maize yield in northwest China[J]. Agricultural Water Management, 231: 106031.
Huang B, Xu Q. 2000. Root growth and nutrient element status of creeping bentgrass cultivars differing in heat tolerance as influenced by supraoptimal shoot and root

temperatures[J]. Journal of Plant Nutrition, 23(7): 979-990.
Huang C, Qin A, Gao Y, Ma S, Liu Z, Zhao B, Ning D, Zhang K, Gong W, Sun M, others. 2023. Effects of water deficit at different stages on growth and ear quality of waxy maize[J]. Frontiers in Plant Science, 14: 1069551.
Huang R, Huang J xi, Zhang C, Ma H yuan, Zhuo W, Chen Y yi, Zhu D hai, Wu Q, Mansaray LR. 2020. Soil temperature estimation at different depths, using remotely-sensed data[J]. Journal of Integrative Agriculture, 19(1): 277-290.
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[J]. Remote Sensing of Environment, 83(1): 195-213.
Hursh A, Ballantyne A, Cooper L, Maneta M, Kimball J, Watts J. 2017. The sensitivity of soil respiration to soil temperature, moisture, and carbon supply at the global scale[J]. Global Change Biology, 23(5): 2090-2103.
Imanian H, Mohammadian A, Farhangmehr V, Payeur P, Goodarzi D, Hiedra Cobo J, Shirkhani H. 2024. A comparative analysis of deep learning models for soil temperature prediction in cold climates[J]. Theoretical and Applied Climatology, 155(4): 2571-2587.
IPCC.2019.IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems[J].IPCC Summary for Policymalers:1-472.
IPCC. 2021. Chapter 3: Human Influence on the Climate System[EB/OL]. https://www.ipcc.ch/report/ar6/wg1/chapter/chapter-3/.
Jebamalar AS, Raja SAT, Bai SJS. 2012. Prediction of annual and seasonal soil temperature variation using artificial neural network[J]. Indian Journal of Radio & Space Physics, 41(1): 48-57.
Jiang H, Yi Y, Zhang W, Yang K, Chen D. 2020. Sensitivity of soil freeze/thaw dynamics to environmental conditions at different spatial scales in the central tibetan plateau[J]. Science of The Total Environment, 734: 139261.
Jiang L, Zhang J, Bai L, Han J, Meng X, Cao D, Al-Sakkaf AS. 2025. Increased frequency and severity of global compound dry and heat wave events in a daily scale[J]. Journal of Hydrology, 654: 132857.
Jiang S, Feng F, Zhang X, Xu C, Jia B, Lafortezza R. 2025. Driving factors of fragmentation in urban landscapes: Local contributions, spatial relationships, and causal effects[J]. Ecological Indicators, 174: 113454.
Johansen O. 1977. Thermal conductivity of soils[R].
Kang S, Kim S, Oh S, Lee D. 2000. Predicting spatial and temporal patterns of soil temperature based on topography, surface cover and air temperature[J]. Forest Ecology and Management, 136(1): 173-184.
Karthikeyan L, Mishra AK. 2021. Multi-layer high-resolution soil moisture estimation using machine learning over the United States[J]. Remote Sensing of Environment, 266: 112706.
Katan J.1981.Solar Heating (Solarization) of Soil for Control of Soilborne Pests[J].Annual Review of Phytopathology,19(1):211-236.
Kath J, Pembleton KG. 2019. A soil temperature decision support tool for agronomic research and management under climate variability: Adapting to earlier and more variable planting conditions[J]. Computers and Electronics in Agriculture, 162: 783-792.
Kim S, Singh VP. 2014. Modeling daily soil temperature using data-driven models and spatial distribution[J]. Theor Appl Climatol, 118(3): 465-479.
Kisi O, Tombul M, Kermani MZ. 2015. Modeling soil temperatures at different depths

by using three different neural computing techniques[J]. Theor Appl Climatol, 121(1): 377-387.

Kleber M.2010.What is recalcitrant soil organic matter?[J].Environmental Chemistry,7(4):320-332.

Koehler T, Wankmüller FJ, Sadok W, Carminati A. 2023. Transpiration response to soil drying versus increasing vapor pressure deficit in crops: Physical and physiological mechanisms and key plant traits[J]. Journal of Experimental Botany, 74(16): 4789-4807.

Koenig CEM, Hilbich C, Hauck C, Arenson LU, Wainstein P. 2025. Thermal state of permafrost in the central andes (27–34° S)[J]. The Cryosphere, 19(7): 2653-2676.

Kong D, Zhang Y, Gu X, Wang D. 2019. A robust method for reconstructing global MODIS EVI time series on the Google Earth Engine[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 155: 13-24.

Kosaka Y, Kobayashi S, Harada Y, Kobayashi C, Naoe H, Yoshimoto K, Harada M, Goto N, Chiba J, Miyaoka K, others. 2024. The JRA-3Q reanalysis[J]. Journal of the Meteorological Society of Japan Ser II, 102(1): 49-109.

Kropp H, Loranty MM, Natali SM, Kholodov AL, Rocha AV, Myers-Smith I, Abbot BW, Abermann J, Blanc-Betes E, Blok D, Blume-Werry G, Boike J, Breen AL, Cahoon SMP, Christiansen CT, Douglas TA, Epstein HE, Frost GV, Goeckede M, Høye TT, Mamet SD, O'Donnell JA, Olefeldt D, Phoenix GK, Salmon VG, Sannel ABK, Smith SL, Sonnentag O, Vaughn LS, Williams M, Elberling B, Gough L, Hjort J, Lafleur PM, Euskirchen ES, Heijmans MM, Humphreys ER, Iwata H, Jones BM, Jorgenson MT, Grünberg I, Kim Y, Laundre J, Mauritz M, Michelsen A, Schaepman-Strub G, Tape KD, Ueyama M, Lee BY, Langley K, Lund M. 2020. Shallow soils are warmer under trees and tall shrubs across arctic and boreal ecosystems[J]. Environ Res Lett, 16(1): 015001.

Kurylyk BL, MacQuarrie KTB, McKenzie JM. 2014. Climate change impacts on groundwater and soil temperatures in cold and temperate regions: Implications, mathematical theory, and emerging simulation tools[J]. Earth-Science Reviews, 138: 313-334.

Lagonigro R, Oller R, Martori J. 2020. AQuadtree: An R package for quadtree anonymization of point data[J]. The R Journal.

Lan S, Cao B, Li X, Sun W, Wang S, Ma R, Sun Z, Guo X. 2025. Improved JRA-3Q soil temperature in permafrost regions[J]. Journal of Climate.

Lembrechts JJ, Lenoir J. 2020. Microclimatic conditions anywhere at any time![J]. Global Change Biology, 26(2): 337-339.

Lembrechts JJ, Lenoir J, Roth N, Hattab T, Milbau A, Haider S, Pellissier L, Pauchard A, Ratier Backes A, Dimarco RD, Nuñez MA, Aalto J, Nijs I. 2019. Comparing temperature data sources for use in species distribution models: From in-situ logging to remote sensing[J]. Global Ecology and Biogeography, 28(11): 1578-1596.

Lembrechts JJ, van den Hoogen J, Aalto J, Ashcroft MB, De Frenne P, Kemppinen J, Kopecký M, Luoto M, Maclean IMD, Crowther TW, Bailey JJ, Haesen S, Klinges DH, Niittynen P, Scheffers BR, Van Meerbeek K, Aartsma P, Abdalaze O, Abedi M, Aerts R, Ahmadian N, Ahrends A, Alatalo JM, Alexander JM, Allonsius CN, Altman J, Ammann C, Andres C, Andrews C, Ardö J, Arriga N, Arzac A, Aschero V, Assis RL, Assmann JJ, Bader MY, Bahalkeh K, Barančok P, Barrio IC, Barros A, Barthel M, Basham EW, Bauters M, Bazzichetto M, Marchesini LB, Bell MC, Benavides JC, Benito Alonso JL, Berauer BJ, Bjerke JW, Björk RG, Björkman MP,

Björnsdóttir K, Blonder B, Boeckx P, Boike J, Bokhorst S, Brum BNS, Brůna J, Buchmann N, Buysse P, Camargo JL, Campoe OC, Candan O, Canessa R, Cannone N, Carbognani M, Carnicer J, Casanova-Katny A, Cesarz S, Chojnicki B, Choler P, Chown SL, Cifuentes EF, Čiliak M, Contador T, Convey P, Cooper EJ, Cremonese E, Curasi SR, Curtis R, Cutini M, Dahlberg CJ, Daskalova GN, de Pablo MA, Della Chiesa S, Dengler J, Deronde B, Descombes P, Di Cecco V, Di Musciano M, Dick J, Dimarco RD, Dolezal J, Dorrepaal E, Dušek J, Eisenhauer N, Eklundh L, Erickson TE, Erschbamer B, Eugster W, Ewers RM, Exton DA, Fanin N, Fazlioglu F, Feigenwinter I, Fenu G, Ferlian O, Fernández Calzado MR, Fernández-Pascual E, Finckh M, Higgens RF, Forte TGW, Freeman EC, Frei ER, Fuentes-Lillo E, García RA, García MB, Géron C, Gharun M, Ghosn D, Gigauri K, Gobin A, Goded I, Goeckede M, Gottschall F, Goulding K, Govaert S, Graae BJ, Greenwood S, Greiser C, Grelle A, Guénard B, Guglielmin M, Guillemot J, Haase P, Haider S, Halbritter AH, Hamid M, Hammerle A, Hampe A, Haugum SV, Hederová L, Heinesch B, Helfter C, Hepenstrick D, Herberich M, Herbst M, Hermanutz L, Hik DS, Hoffrén R, Homeier J, Hörtnagl L, Høye TT, Hrbacek F, Hylander K, Iwata H, Jackowicz-Korczynski MA, Jactel H, Järveoja J, Jastrzębowski S, Jentsch A, Jiménez JJ, Jónsdóttir IS, Jucker T, Jump AS, Juszczak R, Kanka R, Kašpar V, Kazakis G, Kelly J, Khuroo AA, Klemedtsson L, Klisz M, Kljun N, Knohl A, Kobler J, Kollár J, Kotowska MM, Kovács B, Kreyling J, Lamprecht A, Lang SI, Larson C, Larson K, Laska K, le Maire G, Leihy RI, Lens L, Liljebladh B, Lohila A, Lorite J, Loubet B, Lynn J, Macek M, Mackenzie R, Magliulo E, Maier R, Malfasi F, Máliš F, Man M, Manca G, Manco A, Manise T, Manolaki P, Marciniak F, Matula R, Mazzolari AC, Medinets S, Medinets V, Meeussen C, Merinero S, Mesquita R de CG, Meusburger K, Meysman FJR, Michaletz ST, Milbau A, Moiseev D, Moiseev P, Mondoni A, Monfries R, Montagnani L, Moriana-Armendariz M, Morra di Cella U, Mörsdorf M, Mosedale JR, Muffler L, Muñoz-Rojas M, Myers JA, Myers-Smith IH, Nagy L, Nardino M, Naujokaitis-Lewis I, Newling E, Nicklas L, Niedrist G, Niessner A, Nilsson MB, Normand S, Nosetto MD, Nouvellon Y, Nuñez MA, Ogaya R, Ogée J, Okello J, Olejnik J, Olesen JE, Opedal ØH, Orsenigo S, Palaj A, Pampuch T, Panov AV, Pärtel M, Pastor A, Pauchard A, Pauli H, Pavelka M, Pearse WD, Peichl M, Pellissier L, Penczykowski RM, Penuelas J, Petit Bon M, Petraglia A, Phartyal SS, Phoenix GK, Pio C, Pitacco A, Pitteloud C, Plichta R, Porro F, Portillo-Estrada M, Poulenard J, Poyatos R, Prokushkin AS, Puchalka R, Puşcaş M, Radujković D, Randall K, Ratier Backes A, Remmele S, Remmers W, Renault D, Risch AC, Rixen C, Robinson SA, Robroek BJM, Rocha AV, Rossi C, Rossi G, Roupsard O, Rubtsov AV, Saccone P, Sagot C, Sallo Bravo J, Santos CC, Sarneel JM, Scharnweber T, Schmeddes J, Schmidt M, Scholten T, Schuchardt M, Schwartz N, Scott T, Seeber J, Segalin de Andrade AC, Seipel T, Semenchuk P, Senior RA, Serra-Diaz JM, Sewerniak P, Shekhar A, Sidenko NV, Siebicke L, Siegwart Collier L, Simpson E, Siqueira DP, Sitková Z, Six J, Smiljanic M, Smith SW, Smith-Tripp S, Somers B, Sørensen MV, Souza JJLL, Souza BI, Souza Dias A, Spasojevic MJ, Speed JDM, Spicher F, Stanisci A, Steinbauer K, Steinbrecher R, Steinwandter M, Stemkovski M, Stephan JG, Stiegler C, Stoll S, Svátek M, Svoboda M, Tagesson T, Tanentzap AJ, Tanneberger F, Theurillat JP, Thomas HJD, Thomas AD, Tielbörger K, Tomaselli M, Treier UA, Trouillier M, Turtureanu PD, Tutton R, Tyystjärvi VA, Ueyama M, Ujházy K, Ujházyová M, Uogintas D, Urban AV, Urban J, Urbaniak M, Ursu TM, Vaccari FP, Van de Vondel S, van den Brink L, Van Geel M, Vandvik V, Vangansbeke P, Varlagin A, Veen GF, Veenendaal E, Venn

SE, Verbeeck H, Verbrugggen E, Verheijen FGA, Villar L, Vitale L, Vittoz P, Vives-Ingla M, von Oppen J, Walz J, Wang R, Wang Y, Way RG, Wedegärtner REM, Weigel R, Wild J, Wilkinson M, Wilmking M, Wingate L, Winkler M, Wipf S, Wohlfahrt G, Xenakis G, Yang Y, Yu Z, Yu K, Zellweger F, Zhang J, Zhang Z, Zhao P, Ziemblińska K, Zimmermann R, Zong S, Zyryanov VI, Nijs I, Lenoir J. 2022. Global maps of soil temperature[J]. Global Change Biology, 28(9): 3110-3144.

Li B, Liang S, Ma H, Dong G, Liu X, He T, Zhang Y. 2024. Generation of global 1 km all-weather instantaneous and daily mean land surface temperatures from MODIS data[J]. Earth System Science Data, 16(8): 3795-3819.

Li Q, Ma M, Wu X, Yang H. 2018. Snow cover and vegetation-induced decrease in global albedo from 2002 to 2016[J]. Journal of Geophysical Research: Atmospheres, 123(1): 124-138.

Li Q, Shi G, Shangguan W, Nourani V, Li J, Li L, Huang F, Zhang Y, Wang C, Wang D, Qiu J, Lu X, Dai Y. 2022a. A 1 km daily soil moisture dataset over China using in situ measurement and machine learning[J]. Earth System Science Data, 14(12): 5267-5286.

Li Q, Zhu Y, Shangguan W, Wang X, Li L, Yu F. 2022b. An attention-aware LSTM model for soil moisture and soil temperature prediction[J]. Geoderma, 409: 115651.

Li X, Jiang D, Liu F. 2016. Winter Soil Warming Exacerbates the Impacts of Spring Low Temperature Stress on Wheat[J]. Journal of Agronomy and Crop Science, 202(6): 554-563.

Li X, Zhang L, Wang X, Liang B. 2024. Forecasting greenhouse air and soil temperatures: A multi-step time series approach employing attention-based LSTM network[J]. Computers and Electronics in Agriculture, 217: 108602.

Li X, Zhu Y, Li Q, Zhao H, Zhu J, Zhang C. 2023. Interpretable spatio-temporal modeling for soil temperature prediction[J]. Frontiers in Forests and Global Change, 6: 1295731.

Li Y, Hou R, Tao F. 2020. Interactive effects of different warming levels and tillage managements on winter wheat growth, physiological processes, grain yield and quality in the North China Plain[J]. Agriculture, Ecosystems & Environment, 295: 106923.

Li Y, Zeng H, Zhang M, Wu B, Zhao Y, Yao X, Cheng T, Qin X, Wu F. 2023. A county-level soybean yield prediction framework coupled with XGBoost and multidimensional feature engineering[J]. International Journal of Applied Earth Observation and Geoinformation, 118: 103269.

Li Yanjie, Wang L, Zhao L, Hu G, Wu Y, Li Yan, Li X, Wang M, Zhao J, Li Z. 2026. Assessment of reanalysis soil temperature products over the pan-arctic permafrost region with consideration of sub-grid heterogeneity[J]. CATENA, 262: 109587.

Lin L, Wu S, Shi M, Tang Y, Luo M. 2026. Accelerating increases in soil heatwaves and cropland exposure in China[J]. Environ Res Lett, 21(1): 014024.

Liu BC, Liu W, Peng SW. 2005. Study of heat and moisture transfer in soil with a dry surface layer[J]. International Journal of Heat and Mass Transfer, 48(21): 4579-4589.

Liu F, Wu H, Zhao Y, Li D, Yang JL, Song X, Shi Z, Zhu AX, Zhang GL. 2022. Mapping high resolution National Soil Information Grids of China[J]. Science Bulletin, 67(3): 328-340.

Liu Y, Liu X, Fu Z, Zhang D, Liu L. 2024. Soil temperature dominates forest spring phenology in China[J]. Agricultural and Forest Meteorology, 355: 110141.

Liu Y, von Wirén N. 2017. Ammonium as a signal for physiological and morphological responses in plants[J]. Journal of Experimental Botany, 68(10): 2581-2592.

Liu Z, Jiao L, Lian X. 2025. Changes in compound extreme events and their impacts on cropland productivity in China, 1985–2019[J]. Earth's Future, 13(3): e2024EF005038.

Lloyd J, Taylor JA. 1994. On the temperature dependence of soil respiration[J]. Functional ecology: 315-323.

Long D, Yan L, Bai L, Zhang C, Li X, Lei H, Yang H, Tian F, Zeng C, Meng X, Shi C. 2020. Generation of MODIS-like land surface temperatures under all-weather conditions based on a data fusion approach[J]. Remote Sensing of Environment, 246: 111863.

Loranty MM, Berner LT, Goetz SJ, Jin Y, Randerson JT. 2014. Vegetation controls on northern high latitude snow-albedo feedback: Observations and CMIP 5 model simulations[J]. Global change biology, 20(2): 594-606.

Lu S, Ren T, Gong Y, Horton R. 2007. An improved model for predicting soil thermal conductivity from water content at room temperature[J]. Soil Science Society of America Journal, 71(1): 8-14.

Lu X, Wei S, Guo Y, Ersi C, Chen D, Zhou Z, Li Y, Dong Y, Tong Z, Liu X, Zhang J, Zhao C, Zhao Y. 2026. Dynamic hazard assessment of compound drought and heat events in maize based on a soil-temperature-integrated index in songliao plain[J]. European Journal of Agronomy, 175: 127984.

Lundberg SM, Lee SI. 2017. A unified approach to interpreting model predictions[J]. Advances in neural information processing systems, 30.

Lyu Z, Zhuang Q. 2018. Quantifying the effects of snowpack on soil thermal and carbon dynamics of the arctic terrestrial ecosystems[J]. Journal of Geophysical Research: Biogeosciences, 123(4): 1197-1212.

Ma H, Zeng J, Zhang X, Fu P, Zheng D, Wigneron JP, Chen N, Niyogi D. 2021. Evaluation of six satellite- and model-based surface soil temperature datasets using global ground-based observations[J]. Remote Sensing of Environment, 264: 112605.

Mahanama SPP, Koster RD, Reichle RH, Suarez MJ. 2008. Impact of Subsurface Temperature Variability on Surface Air Temperature Variability: An AGCM Study[J]. Journal of Hydrometeorology, 9(4): 804-815.

Masson-Delmotte V, Zhai P, Pirani A, Connors SL, Péan C, Berger S, Caud N, Chen Y, Goldfarb L, Gomis MI, others. 2021. Climate change 2021: The physical science basis[J]. Contribution of working group I to the sixth assessment report of the intergovernmental panel on climate change, 2(1): 2391.

Mihalakakou G.2002.On estimating soil surface temperature profiles[J].Energy and Buildings,34(3):251-259.

Mirosavljević M, Mikić S, Župunski V, Abdelhakim L, Trkulja D, Zhou R, Špika AK, Ottosen CO. 2024. Effects of heat stress during anthesis and grain filling stages on some physiological and agronomic traits in diverse wheat genotypes[J]. Plants, 13(15): 2083.

Mo Y, Pepin N, Lovell H. 2025. Understanding temperature variations in mountainous regions: The relationship between satellite-derived land surface temperature and in situ near-surface air temperature[J]. Remote Sensing of Environment, 318: 114574.

Mortier S, Hamedpour A, Bussmann B, Wandji RPT, Latré S, Sigurdsson BD, De Schepper T, Verdonck T. 2024. Inferring the relationship between soil temperature and the normalized difference vegetation index with machine learning[J].

Ecological Informatics, 82: 102730.
Muñoz-Sabater J, Dutra E, Agustí-Panareda A, Albergel C, Arduini G, Balsamo G, Boussetta S, Choulga M, Harrigan S, Hersbach H, Martens B, Miralles DG, Piles M, Rodríguez-Fernández NJ, Zsoter E, Buontempo C, Thépaut JN. 2021. ERA5-Land: a state-of-the-art global reanalysis dataset for land applications[J]. Earth System Science Data, 13(9): 4349-4383.
Myers-Smith IH, Elmendorf SC, Beck PSA, Wilmking M, Hallinger M, Blok D, Tape KD, Rayback SA, Macias-Fauria M, Forbes BC, Speed JDM, Boulanger-Lapointe N, Rixen C, Lévesque E, Schmidt NM, Baittinger C, Trant AJ, Hermanutz L, Collier LS, Dawes MA, Lantz TC, Weijers S, Jørgensen RH, Buchwal A, Buras A, Naito AT, Ravolainen V, Schaepman-Strub G, Wheeler JA, Wipf S, Guay KC, Hik DS, Vellend M. 2015. Climate sensitivity of shrub growth across the tundra biome[J]. Nature Climate Change, 5(9): 887-891.
Nalley D, Adamowski J, Khalil B. 2012. Using discrete wavelet transforms to analyze trends in streamflow and precipitation in Quebec and Ontario (1954–2008)[J]. Journal of Hydrology, 475: 204-228.
Niu S, Du X, Wei D, Liu S, Tang Q, Bian D, Zhang Y, Cui Y, Gao Z. 2021. Heat stress after pollination reduces kernel number in maize by insufficient assimilates[J]. Frontiers in Genetics, 12: 728166.
Ochsner TE, Horton R, Ren T. 2001. A new perspective on soil thermal properties[J]. Soil science society of America Journal, 65(6): 1641-1647.
Opedal ØH, Armbruster WS, Graae BJ. 2015. Linking small-scale topography with microclimate, plant species diversity and intra-specific trait variation in an alpine landscape[J]. Plant Ecology & Diversity, 8(3): 305-315.
Ozturk M, Salman O, Koc M. 2011. Artificial neural network model for estimating the soil temperature[J]. Can J Soil Sci, 91(4): 551-562.
Perkins-Kirkpatrick SE, Lewis SC. 2020. Increasing trends in regional heatwaves[J]. Nat Commun, 11(1): 3357.
Pingale SM, Khare D, Jat MK, Adamowski J. 2014. Spatial and temporal trends of mean and extreme rainfall and temperature for the 33 urban centers of the arid and semi-arid state of Rajasthan, India[J]. Atmospheric Research, 138: 73-90.
Poorter H, Niklas KJ, Reich PB, Oleksyn J, Poot P, Mommer L. 2012. Biomass allocation to leaves, stems and roots: Meta-analyses of interspecific variation and environmental control[J]. New phytologist, 193(1): 30-50.
Pramanik P, Bandyopadhyay K, Bhaduri D, Bhattacharyya R, Aggarwal P. 2015. Effect of mulch on soil thermal regimes-a review[J]. International Journal of Agriculture, Environment and Biotechnology, 8(3): 645-658.
Qi W, Liu J, Chen D. 2018. Evaluations and improvements of GLDAS2. 0 and GLDAS2. 1 forcing data's applicability for basin scale hydrological simulations in the tibetan plateau[J]. Journal of Geophysical Research: Atmospheres, 123(23): 13-128.
Qian B, Gregorich EG, Gameda S, Hopkins DW, Wang XL. 2011. Observed soil temperature trends associated with climate change in Canada[J]. Journal of Geophysical Research: Atmospheres, 116(D2).
Quayle RG, Easterline DR, Karl TR, Hughes PY. 1991. Effects of Recent Thermometer Changes in the Cooperative Station Network[J]. Bulletin of the American Meteorological Society, 72(11): 1718-1724.
Rahman MH ur, Ahmad A, Wajid A, Hussain M, Rasul F, Ishaque W, Islam MdA, Shelia V, Awais M, Ullah A, Wahid A, Sultana SR, Saud S, Khan S, Fahad S, Hussain M, Hussain S, Nasim W. 2019. Application of CSM-CROPGRO-cotton model for

cultivars and optimum planting dates: Evaluation in changing semi-arid climate[J]. Field Crops Research, 238: 139-152.

Ren H, Zhao M, Zhou B, Zhou W, Li K, Qi H, Jiang Y, Li C. 2022. Understanding physiological mechanisms of variation in grain filling of maize under high planting density and varying nitrogen applicate rate[J]. Frontiers in Nutrition, 9: 998946.

Roberts PA, Van Gundy SD, McKinney HE. 1981. Effects of Soil Temperature and Planting Date of Wheat on Meloidogyne incognita Reproduction, Soil Populations, and Grain Yield[J]. J Nematol, 13(3): 338-345.

Rodell M, Houser PR, Jambor U, Gottschalck J, Mitchell K, Meng CJ, Arsenault K, Cosgrove B, Radakovich J, Bosilovich M, Entin JK, Walker JP, Lohmann D, Toll D. 2004. The Global Land Data Assimilation System[J]. Bulletin of the American Meteorological Society, 85(3): 381-394.

Rouse Jr JW, Haas RH, Schell JA, Deering DW. 1974. Monitoring vegetation systems in the great plains with ERTS[C]. NASA. Goddard Space Flight Center 3d ERTS-1 Symp., Vol. 1, Sect. A.

Russelle MP, Bolton FE. 1980. Soil Temperature Effects on Winter Wheat and Winter Barley Emergence in the Field [1][J]. Agronomy Journal, 72(5): 823-827.

Ruter JM, Ingram DL. 1990. 14Carbon-labeled Photosynthate Partitioning in Ilex crenata `Rotundifolia' at Supraoptimal Root-zone Temperatures[J]. Journal of the American Society for Horticultural Science, 115(6): 1008-1013.

Sadras V, Calderini D. 2009. Crop Physiology: Applications for Genetic Improvement and Agronomy[M]. Academic Press.

Samet H. 1984. The quadtree and related hierarchical data structures[J]. ACM Computing Surveys (CSUR), 16(2): 187-260.

Sanikhani H, Deo RC, Yaseen ZM, Eray O, Kisi O. 2018. Non-tuned data intelligent model for soil temperature estimation: A new approach[J]. Geoderma, 330: 52-64.

Schaefer K, Zhang T, Slater AG, Lu L, Etringer A, Baker I. 2009. Improving simulated soil temperatures and soil freeze/thaw at high-latitude regions in the simple biosphere/carnegie-ames-stanford approach model[J]. Journal of Geophysical Research: Earth Surface, 114(F2).

Shati F, Prakash S, Norouzi H, Blake R. 2018. Assessment of differences between near-surface air and soil temperatures for reliable detection of high-latitude freeze and thaw states[J]. Cold Regions Science and Technology, 145: 86-92.

Shi R, Liu Yi, Zhu Y, Ren L, Liu Yu, Zhang X, Zhang L. 2025. Impact of flash droughts on global crop yields considering crop phenology and irrigation conditions[J]. Agricultural and Forest Meteorology, 373: 110763.

Sierra J.2002.Nitrogen mineralization and nitrification in a tropical soil: effects of fluctuating temperature conditions[J].Soil Biology and Biochemistry,34(9):1219-1226.

Smith SL, O'Neill HB, Isaksen K, Noetzli J, Romanovsky VE. 2022. The changing thermal state of permafrost[J]. Nat Rev Earth Environ, 3(1): 10-23.

Song Y, Huang A, Chen H. 2022. The Persistence and Reemergence of Atmospheric Anomaly Signals in Soil Temperature[J]. Journal of Geophysical Research: Atmospheres, 127(19): e2022JD037218.

Soong JL, Phillips CL, Ledna C, Koven CD, Torn MS. 2020. CMIP5 Models Predict Rapid and Deep Soil Warming Over the 21st Century[J]. Journal of Geophysical Research: Biogeosciences, 125(2): e2019JG005266.

Stone PJ, Sorensen IB, Jamieson PD. 1999. Effect of soil temperature on phenology, canopy development, biomass and yield of maize in a cool-temperate climate[J].

Field Crops Research, 63(2): 169-178.
Streletskiy DA, Sherstiukov AB, Frauenfeld OW, Nelson FE. 2015. Changes in the 1963–2013 shallow ground thermal regime in Russian permafrost regions[J]. Environmental Research Letters, 10(12): 125005.
Subin ZM, Koven CD, Riley WJ, Torn MS, Lawrence DM, Swenson SC. 2013. Effects of soil moisture on the responses of soil temperatures to climate change in cold regions[J]. Journal of climate, 26(10): 3139-3158.
Sutanto SJ, Zarzoza Mora SB, Supit I, Wang M. 2024. Compound and cascading droughts and heatwaves decrease maize yields by nearly half in sinaloa, mexico[J]. npj Nat Hazards, 1(1): 26.
Tabari H, Willems P. 2023. Global risk assessment of compound hot-dry events in the context of future climate change and socioeconomic factors[J]. Npj Climate and Atmospheric Science, 6(1): 74.
Thoma E, Tsiros IX, Lykoudis S, Psiloglou BE. 2013. Applications of Semi-Analytical Models for Estimating Soil Temperature[C]. Advances in Meteorology, Climatology and Atmospheric Physics, pp. 757-763.
Ulrich R, Seifert J. 1978. Effect of soil-temperature on nitrification rate[J]. Rostlinna vyroba, 24(1): 1-8.
Valdés A, Marteinsdóttir B, Ehrlén J. 2019. A natural heating experiment: Phenotypic and genotypic responses of plant phenology to geothermal soil warming[J]. Global Change Biology, 25(3): 954-962.
van den Hoogen J, Geisen S, Routh D, Ferris H, Traunspurger W, Wardle DA, de Goede RGM, Adams BJ, Ahmad W, Andriuzzi WS, Bardgett RD, Bonkowski M, Campos-Herrera R, Cares JE, Caruso T, de Brito Caixeta L, Chen X, Costa SR, Creamer R, Mauro da Cunha Castro J, Dam M, Djigal D, Escuer M, Griffiths BS, Gutiérrez C, Hohberg K, Kalinkina D, Kardol P, Kergunteuil A, Korthals G, Krashevska V, Kudrin AA, Li Q, Liang W, Magilton M, Marais M, Martín JAR, Matveeva E, Mayad EH, Mulder C, Mullin P, Neilson R, Nguyen TAD, Nielsen UN, Okada H, Rius JEP, Pan K, Peneva V, Pellissier L, Carlos Pereira da Silva J, Pitteloud C, Powers TO, Powers K, Quist CW, Rasmann S, Moreno SS, Scheu S, Setälä H, Sushchuk A, Tiunov AV, Trap J, van der Putten W, Vestergård M, Villenave C, Waeyenberge L, Wall DH, Wilschut R, Wright DG, Yang J in, Crowther TW. 2019. Soil nematode abundance and functional group composition at a global scale[J]. Nature, 572(7768): 194-198.
Vose RS, Easterling DR, Gleason B. 2005. Maximum and minimum temperature trends for the globe: An update through 2004[J]. Geophysical Research Letters, 32(23).
Wan Z, Dozier J. 1996. A generalized split-window algorithm for retrieving land-surface temperature from space[J]. IEEE Transactions on geoscience and remote sensing, 34(4): 892-905.
Wang A, Tao H, Ding G, Zhang B, Huang J, Wu Q. 2023. Global cropland exposure to extreme compound drought heatwave events under future climate change[J]. Weather and Climate Extremes, 40: 100559.
Wang C, Ning P. 2019. Post-silking phosphorus recycling and carbon partitioning in maize under low to high phosphorus inputs and their effects on grain yield[J]. Frontiers in plant science, 10: 784.
Wang D, Wang A, Wang Z. 2023. A multilayer daily high-resolution gridded homogenized soil temperature over continental China[J]. International Journal of Climatology, 43(5): 2015-2030.
Wang K, Dickinson RE. 2013. Contribution of solar radiation to decadal temperature variability over land[J]. Proceedings of the National Academy of Sciences,

110(37): 14877-14882.
Wang L, Gao Z, Horton R, Lenschow DH, Meng K, Jaynes DB. 2012. An Analytical Solution to the One-Dimensional Heat Conduction–Convection Equation in Soil[J]. Soil Science Society of America Journal, 76(6): 1978-1986.
Wang L, Henderson M, Liu B, Shen X, Chen X, Lian L, Zhou D. 2018. Maximum and Minimum Soil Surface Temperature Trends Over China, 1965–2014[J]. Journal of Geophysical Research: Atmospheres, 123(4): 2004-2016.
Wang M, Wang Y, Liu X, Hou W, Wang J, Li S, Zhao L, Hu Z. 2025. Vapor pressure deficit dominates vegetation productivity during compound drought and heatwave events in China's arid and semi-arid regions: Evidence from multiple vegetation parameters[J]. Ecological Informatics, 88: 103144.
Wang Q, Tang Y, Tong X, Atkinson PM. 2024. Filling gaps in cloudy landsat LST product by spatial-temporal fusion of multi-scale data[J]. Remote Sensing of Environment, 306: 114142.
Wang X, Chen R. 2022. Influence of snow cover on soil freeze depth across China[J]. Geoderma, 428: 116195.
Wang X, Chen R. 2024. Freezing and thawing characteristics of seasonally frozen ground across China[J]. Geoderma, 448: 116966.
Wang X, He L, Li P, Ma J, Shi Y, Tian Q, Zhao G, He J, Feng H, Shi H, Yu Q. 2026. Spatially adaptive estimation of multi-layer soil temperature at a daily time-step across China during 2010–2020[J]. Earth System Science Data, 18(1): 97-116.
Wang Y, Chen W, Zhang J, Nath D. 2013. Relationship between soil temperature in may over Northwest China and the East Asian summer monsoon precipitation[J]. Acta Meteorol Sin, 27(5): 716-724.
Wei D, Zhang Y, Zhao Y, Sun Q. 2026. Nonlinear maize yield responses to drought drive escalating regional vulnerabilities under climate change in China[J]. Journal of Environmental Management, 412: 130233.
Wood SN. 2017. Generalized additive models: An introduction with R[M]. chapman and hall/CRC.
Wu G, Ling J, Liu ZX, Xu YP, Chen XM, Wen Y, Zhou SL. 2022. Soil warming and straw return impacts on winter wheat phenology, photosynthesis, root growth, and grain yield in the North China Plain[J]. Field Crops Research, 283: 108545.
Wu L, Zhang J. 2014. Strong subsurface soil temperature feedbacks on summer climate variability over the arid/semi-arid regions of East Asia[J]. Atmospheric Science Letters, 15(4): 307-313.
Wu P, Su Y, Duan S bo, Li X, Yang H, Zeng C, Ma X, Wu Y, Shen H. 2022. A two-step deep learning framework for mapping gapless all-weather land surface temperature using thermal infrared and passive microwave data[J]. Remote Sensing of Environment, 277: 113070.
Wu X, Jiang D, Zhang F. 2023. Increasing impact of compound agricultural drought and hot events on maize yield in China[J]. Climate Research, 90: 17-29.
Xia Z, Zhang G, Zhang S, Wang Q, Fu Y, Lu H. 2021a. Efficacy of root zone temperature increase in root and shoot development and hormone changes in different maize genotypes[J]. Agriculture, 11(6): 477.
Xia Z, Zhang S, Wang Q, Zhang G, Fu Y, Lu H. 2021b. Effects of root zone warming on maize seedling growth and photosynthetic characteristics under different phosphorus levels[J]. Frontiers in Plant Science, 12: 746152.
Xing L, Li L, Gong J, Ren C, Liu J, Chen H. 2018. Daily soil temperatures predictions for various climates in United States using data-driven model[J]. Energy, 160: 430-440.

Xu C, Liao S, Huang L, Xia J. 2023. Soil temperature estimation at different depths over the central Tibetan Plateau integrating multiple Digital Earth observations and geo-computing[J]. International Journal of Digital Earth, 16(2): 4023-4043.

Xu C, Qu JJ, Hao X, Zhu Z, Gutenberg L. 2020. Surface soil temperature seasonal variation estimation in a forested area using combined satellite observations and in-situ measurements[J]. International Journal of Applied Earth Observation and Geoinformation, 91: 102156.

Xu S, Fu Q, Li T, Meng F, Liu D, Hou R, Li M, Li Q. 2022. Spatiotemporal characteristics of the soil freeze-thaw state and its variation under different land use types - A case study in Northeast China[J]. Agricultural and Forest Meteorology, 312: 108737.

Xue Y, Vasic R, Janjic Z, Liu YM, Chu PC. 2012. The impact of spring subsurface soil temperature anomaly in the western U.S. on North American summer precipitation: A case study using regional climate model downscaling[J]. Journal of Geophysical Research: Atmospheres, 117(D11).

Yamamoto Y, Ichii K, Ryu Y, Kang M, Murayama S. 2022. Uncertainty quantification in land surface temperature retrieved from Himawari-8/AHI data by operational algorithms[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 191: 171-187.

Yan H, You Y, Jiao W, Pan N. 2025. Intensifying impacts of compound drought and heatwave events on water use efficiency in U.S. corn and soybeana[J]. Agricultural and Forest Meteorology, 375: 110873.

Yan S, Chen Y, Hou Y, Liu K, Li X, Xing Y, Wu D, Cui J, Zhou Y, Pu W, Wang X. 2024. Which global reanalysis dataset has better representativeness in snow cover on the tibetan plateau?[J]. The Cryosphere, 18(9): 4089-4109.

Yang K, Zhang J. 2018. Evaluation of reanalysis datasets against observational soil temperature data over China[J]. Clim Dyn, 50(1): 317-337.

Yang Q, Xu M, Liu H, Wang J, Liu L, Chi Y, Zheng Y. 2011. Impact factors and uncertainties of the temperature sensitivity of soil respiration[J]. Shengtai Xuebao/Acta Ecologica Sinica, 31(8): 2301-2311.

Yi Y, Kimball JS, Chen RH, Moghaddam M, Miller CE. 2019. Sensitivity of active-layer freezing process to snow cover in arctic alaska[J]. The Cryosphere, 13(1): 197-218.

You W, Huang C, Hou J, Zhang Y, Dou P, Han W. 2024. Reconstruction of MODIS LST Under Cloudy Conditions by Integrating Himawari-8 and AMSR-2 Data Through Deep Forest Method[J]. IEEE Trans Geosci Remote Sensing, 62: 1-17.

Zellweger F, De Frenne P, Lenoir J, Vangansbeke P, Verheyen K, Bernhardt-Römermann M, Baeten L, Hédl R, Berki I, Brunet J, Van Calster H, Chudomelová M, Decocq G, Dirnböck T, Durak T, Heinken T, Jaroszewicz B, Kopecký M, Máliš F, Macek M, Malicki M, Naaf T, Nagel TA, Ortmann-Ajkai A, Petřík P, Pielech R, Reczyńska K, Schmidt W, Standovár T, Świerkosz K, Teleki B, Vild O, Wulf M, Coomes D. 2020. Forest microclimate dynamics drive plant responses to warming[J]. Science, 368(6492): 772-775.

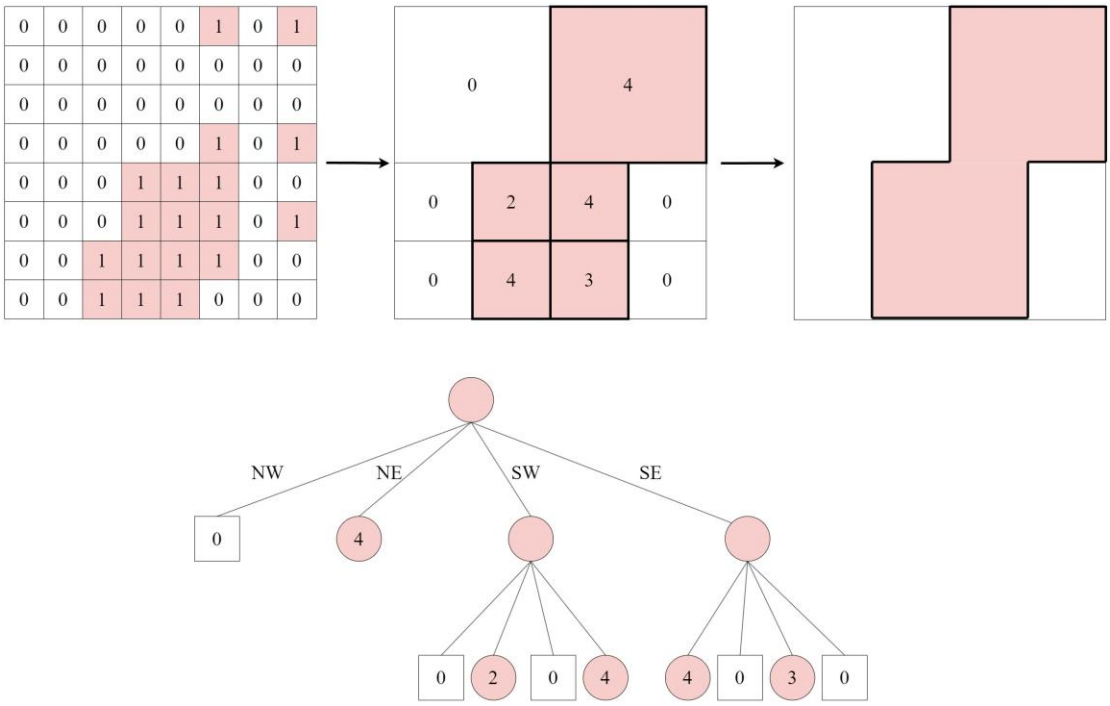
Zhang H, Wang E, Zhou D, Luo Z, Zhang Z. 2016. Rising soil temperature in China and its potential ecological impact[J]. Sci Rep, 6(1): 35530.

Zhang S, Bai J, Zhang G, Xia Z, Wu M, Lu H. 2023a. Negative effects of soil warming, and adaptive cultivation strategies of maize: A review[J]. Science of The Total Environment, 862: 160738.

Zhang S, Xia Z, Wang Q, Fu Y, Zhang G, Lu H. 2023b. Soil cooling can improve maize root-shoot growth and grain yield in warm climate[J]. Plant Physiology and

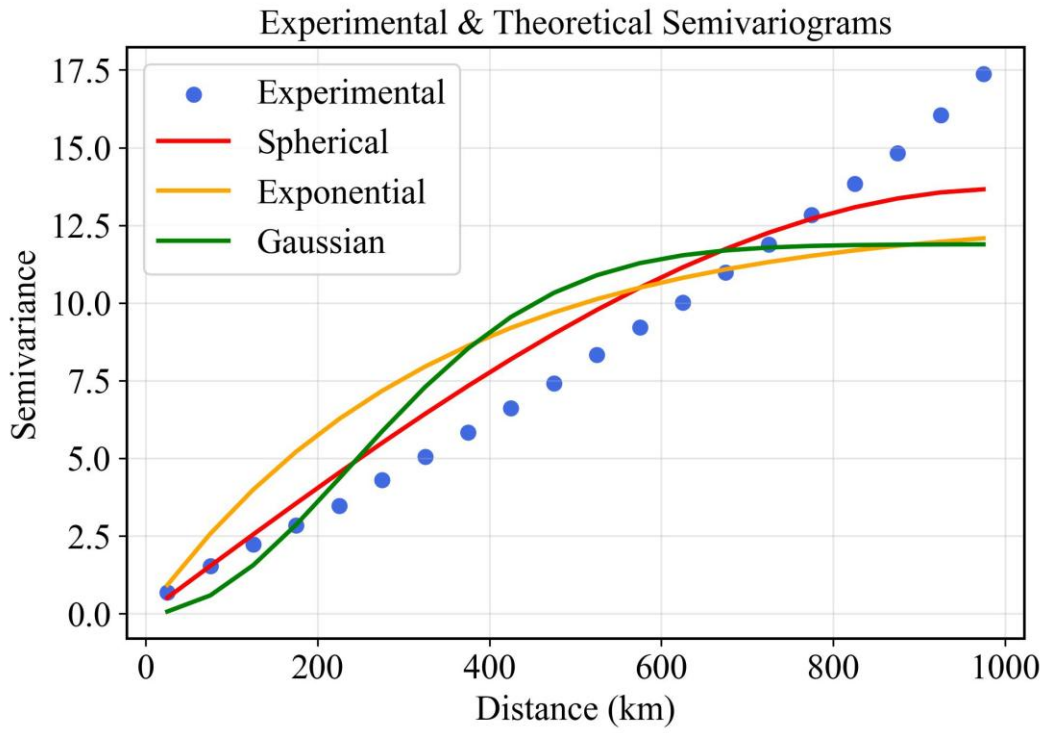
Biochemistry, 200: 107762.
Zhang T. 2005. Influence of the seasonal snow cover on the ground thermal regime: An overview[J]. Reviews of Geophysics, 43(4).
Zhang T, Huang JC, Lei Q, Liang X, Lindsey S, Luo J, Zhu AX, Bao W, Liu H. 2022. Empirical estimation of soil temperature and its controlling factors in Australia: Implication for interaction between geographic setting and air temperature[J]. CATENA, 208: 105696.
Zhang Y, Chen W, Smith SL, Riseborough DW, Cihlar J. 2005. Soil temperature in canada during the twentieth century: Complex responses to atmospheric climate change[J]. Journal of Geophysical Research: Atmospheres, 110(D3).
Zhang Y, Kong D, Gan R, Chiew FHS, McVicar TR, Zhang Q, Yang Y. 2019. Coupled estimation of 500 m and 8-day resolution global evapotranspiration and gross primary production in 2002–2017[J]. Remote Sensing of Environment, 222: 165-182.
Zhang Y, Liu X, Jiao W, Wu X, Zeng X, Zhao L, Wang L, Guo J, Xing X, Hong Y. 2023. Spatial Heterogeneity of Vegetation Resilience Changes to Different Drought Types[J]. Earth's Future, 11(4): e2022EF003108.
Zhang Y, Wang S, Barr AG, Black TA. 2008. Impact of snow cover on soil temperature and its simulation in a boreal aspen forest[J]. Cold Regions Science and Technology, 52(3): 355-370.
Zhao C, Liu B, Piao S, Wang X, Lobell DB, Huang Y, Huang M, Yao Y, Bassu S, Ciais P, others. 2017. Temperature increase reduces global yields of major crops in four independent estimates[J]. Proceedings of the National Academy of sciences, 114(35): 9326-9331.
Zhao J, Zhao L, Sun Z, Hu G, Zou D, Xiao M, Liu G, Pang Q, Du E, Li Z, Wu X, Xiao Y, Wang L, Zhang W. 2025. The thermal state of permafrost under climate change on the qinghai–tibet plateau (1980–2022): A case study of the west kunlun[J]. The Cryosphere, 19(10): 4211-4236.
Zhao T, Liu S, Xu J, He H, Wang D, Horton R, Liu G. 2022. Comparative analysis of seven machine learning algorithms and five empirical models to estimate soil thermal conductivity[J]. Agricultural and Forest Meteorology, 323: 109080.
Zhao Y, Wang L, Jiang Q, Wang Z, Guo X. 2025. Spatiotemporal evolution of compound soil drought-heat events and their impact mechanisms on ecosystem productivity across China[J]. Journal of Environmental Management, 395: 127981.
Zhou LM, Jin SL, Liu CA, Xiong YC, Si JT, Li XG, Gan YT, Li FM. 2012. Ridge-furrow and plastic-mulching tillage enhances maize–soil interactions: Opportunities and challenges in a semiarid agroecosystem[J]. Field Crops Research, 126: 181-188.
Zhou R, Chen J, Cui S, Li L, Qian J, Zhao H, Huang G. 2025. A data-driven framework to identify influencing factors for soil heavy metal contaminations using random forest and bivariate local moran's I: A case study[J]. Journal of Environmental Management, 375: 124172.
Zimmermann A, Webber H, Zhao G, Ewert F, Kros J, Wolf J, Britz W, de Vries W. 2017. Climate change impacts on crop yields, land use and environment in response to crop sowing dates and thermal time requirements[J]. Agricultural Systems, 157: 81-92.
Zscheischler J, Westra S, van den Hurk BJJM, Seneviratne SI, Ward PJ, Pitman A, AghaKouchak A, Bresch DN, Leonard M, Wahl T, Zhang X. 2018. Future climate risk from compound events[J]. Nature Clim Change, 8(6): 469-477.

附录



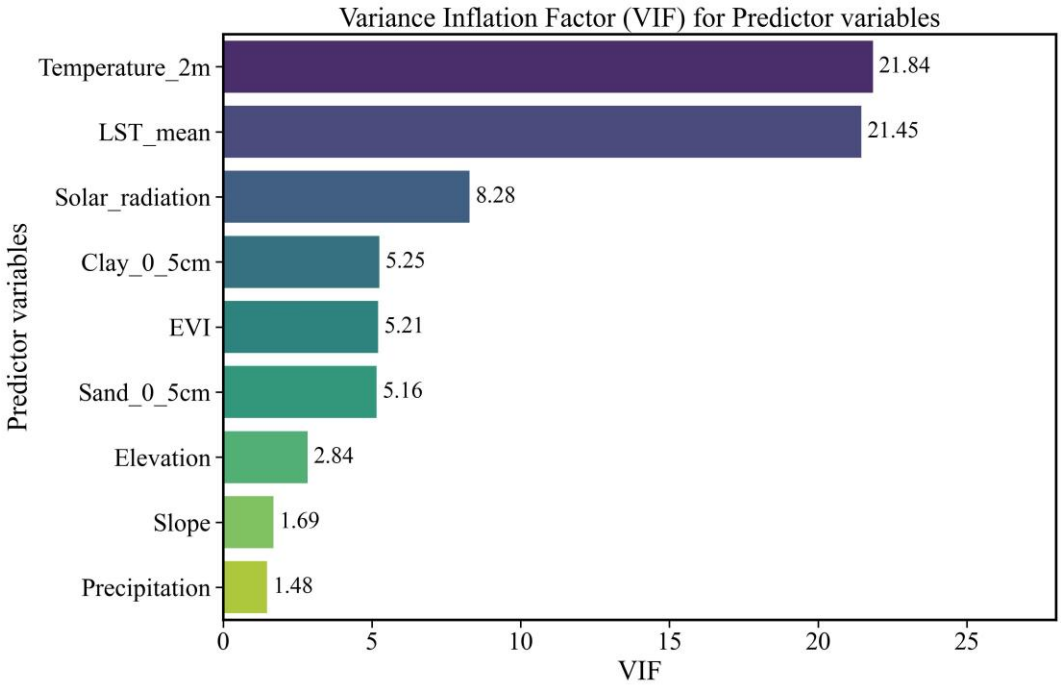
附图 1 四叉树空间索引原理。西北（NW）、东北（NE）、西南（SW）和东南（SE）分别表示四叉树对二维空间划分形成的四个象限。

Figure S1. Quadtree spatial index principle. (Northwest (NW), Northeast (NE), Southwest (SW), Southeast (SE) refer to the four quadrants into which the quadtree divides the two-dimensional space).



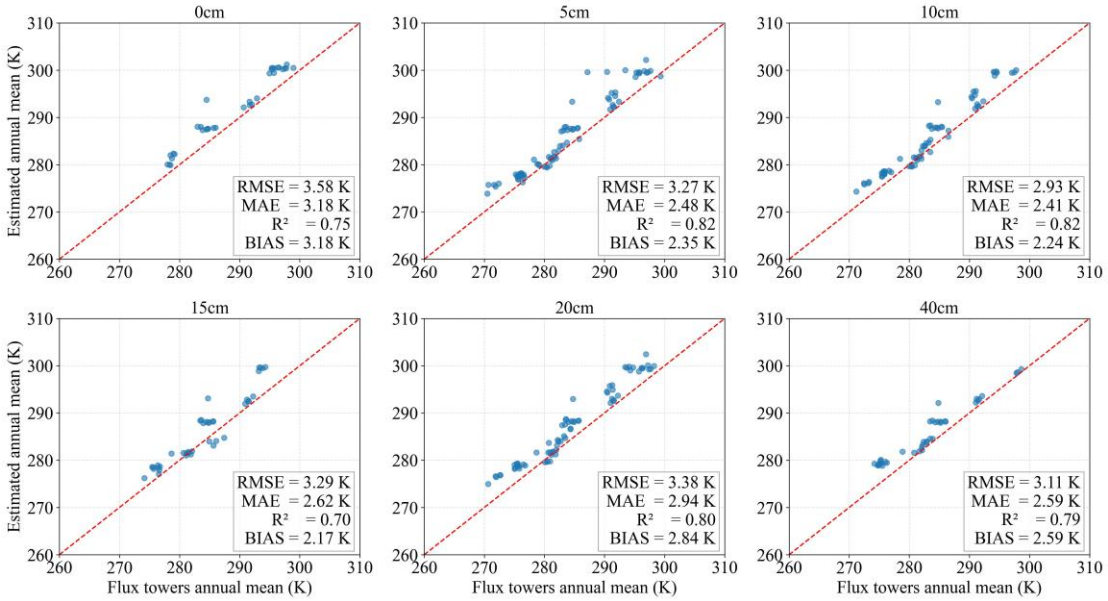
附图 2 2020 年 0 cm 深度年均 T_s 的半变异函数拟合结果。（使用球状模型、指数模型和高斯模型三种拟合模型的结果对比）。

Figure S2. Experimental and theoretical semivariograms of annual mean T_s in 2020 at 0 cm (The spherical, exponential, and Gaussian models are fitted for comparison).



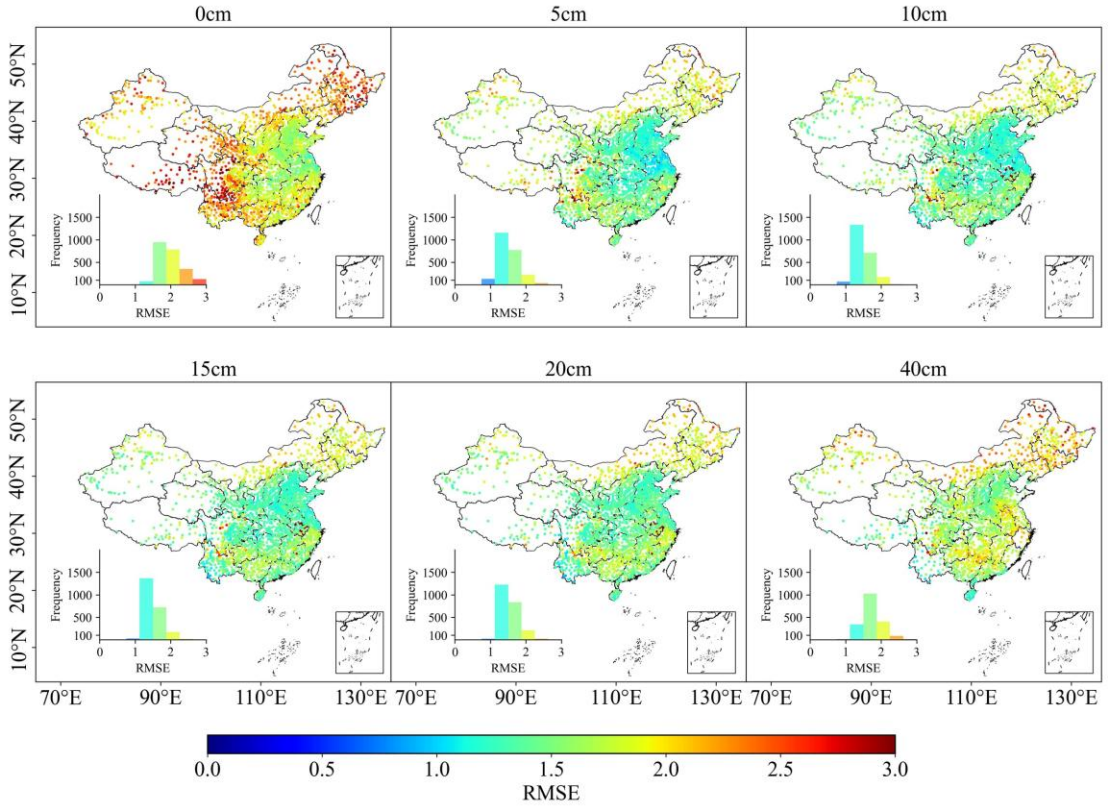
附图 3 所有特征变量的 VIF 结果。

Figure S3. Variance Inflation Factor (VIF) of predictor variables.



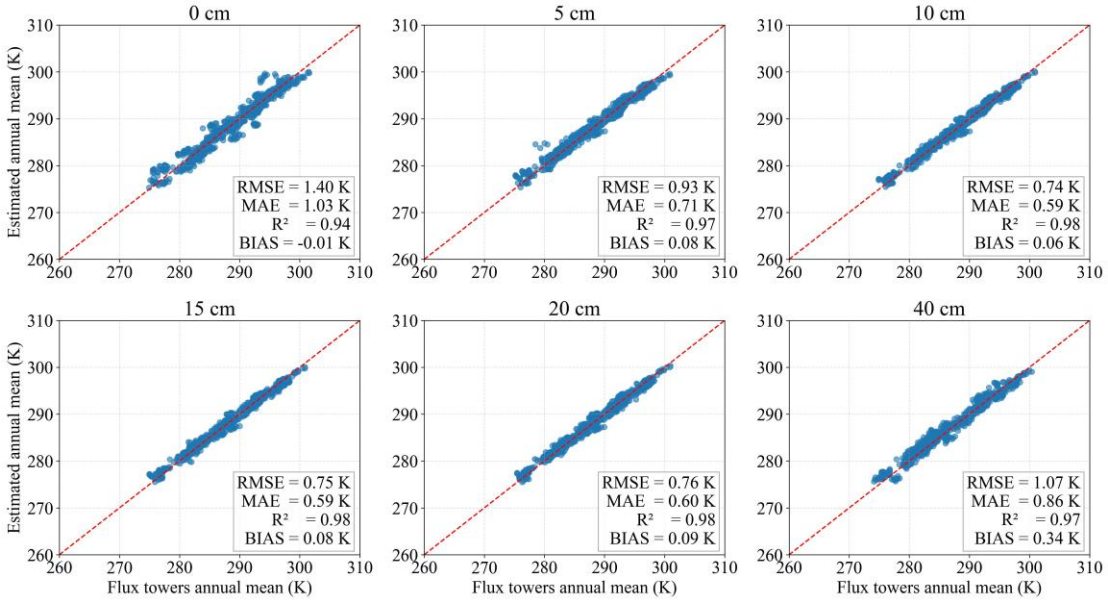
附图 4 不同深度（0-40 cm）T_s 年均预测值与 FLUX 通量塔年均观测值的精度分析。

Figure S4. Comparison between estimated and FLUX towers annual mean T_s across six depths (0-40 cm).



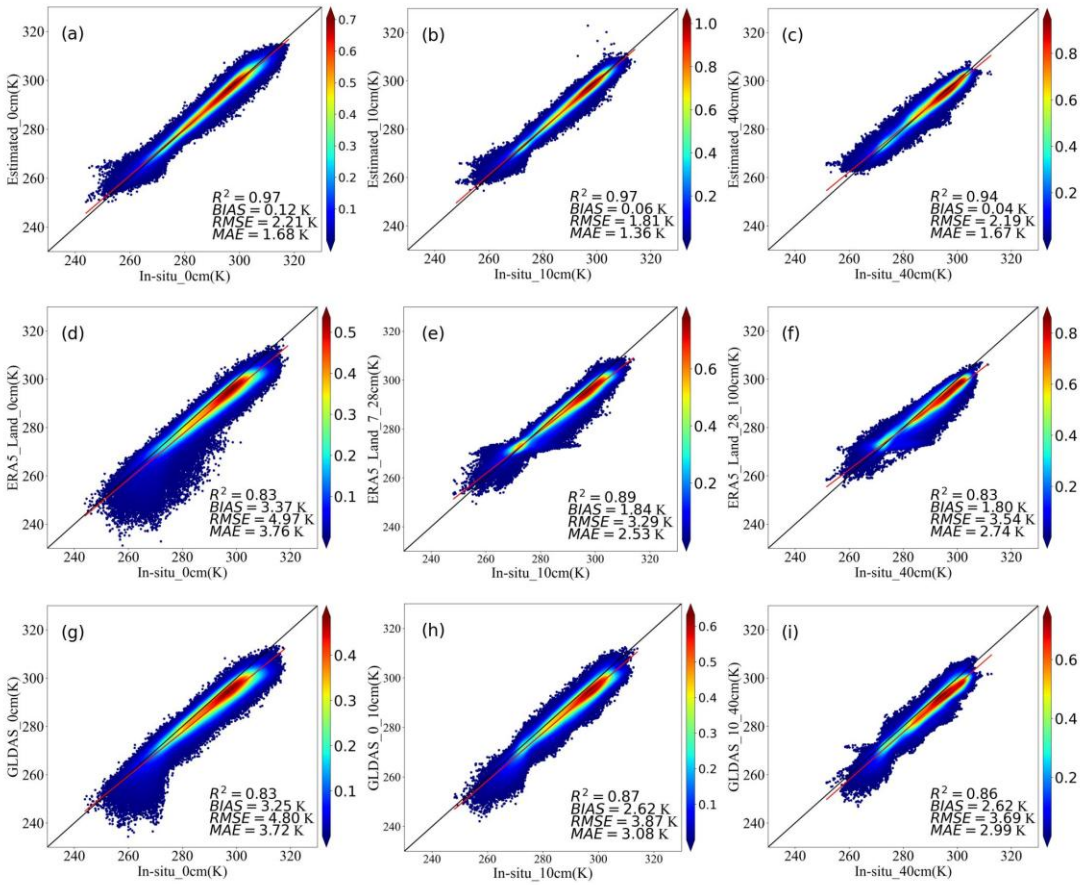
附图 5 基于各站点 T_s 观测值和预测值计算的 RMSE 空间分布图。

Figure S5. Goodness of RMSE across China estimated during the model testing phase. Perfrmance metrics are calculated between predicted T_s and in-situ T_s data sets.



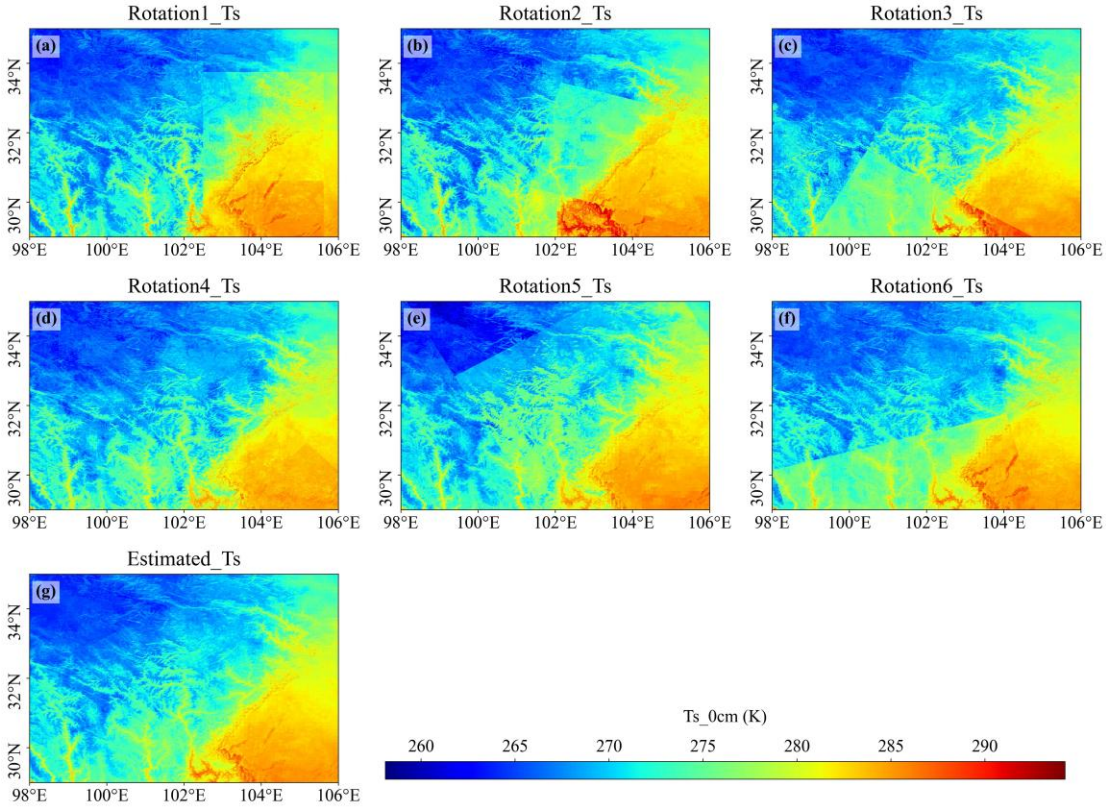
附图 6 不同深度（0-40 cm）年均 T_s 预测值与观测值的对比。

Figure S6. Comparison between estimated and observed annual mean T_s across six soil depths (0-40 cm).



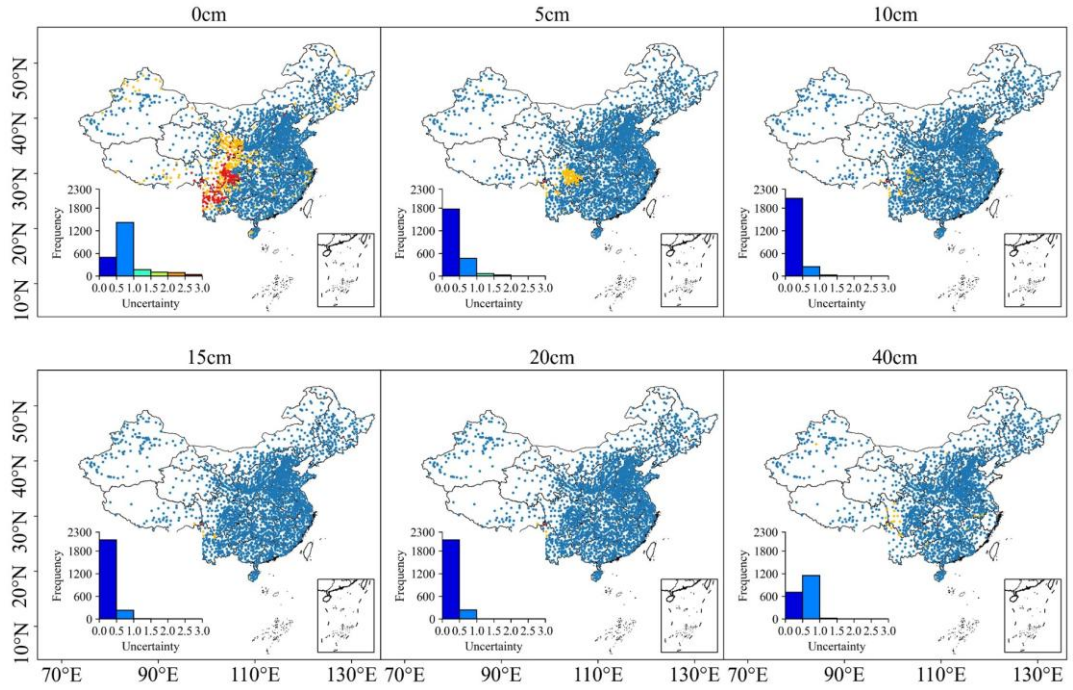
附图 7 不同 T_s 产品精度对比的散点密度图（以 0、10 和 40 cm 深度为例）。

Figure S7. Scatter density plot comparing the accuracy of different products (i.e., 0, 10, and 40 cm).



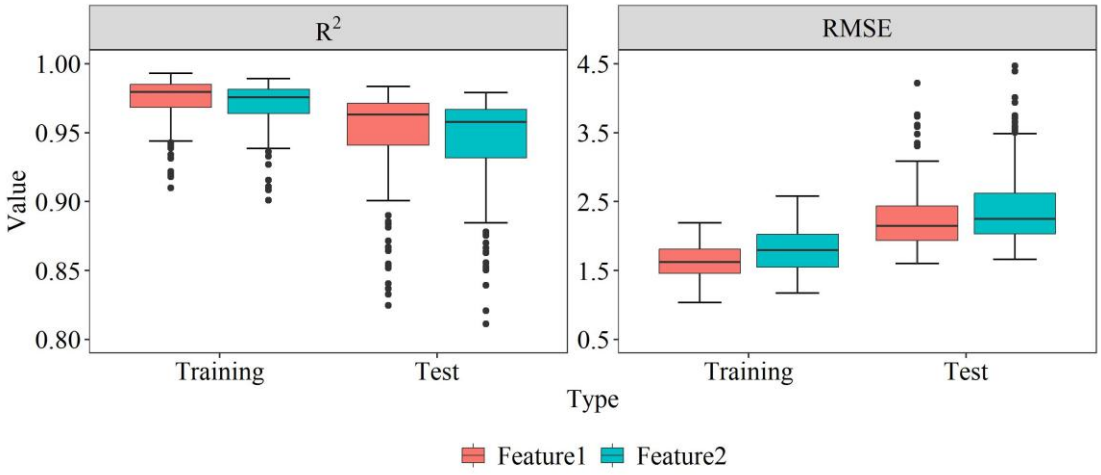
附图 8 同一区域内（29°N-35°N，98°E-106°E）不同旋转角度与多次平均结果的空间细节差异。Rotation 1-Rotation 6 表示不同旋转角度建模的结果，Estimated_Ts 表示所有旋转角度的平均结果。

Figure S8. The difference in spatial performance after modeling different rotations separately (Rotation1-Rotation 6) and the average value of all different rotations (Estimated_T_s) within the same sub-region (29°N–35°N, 98°E–106°E).



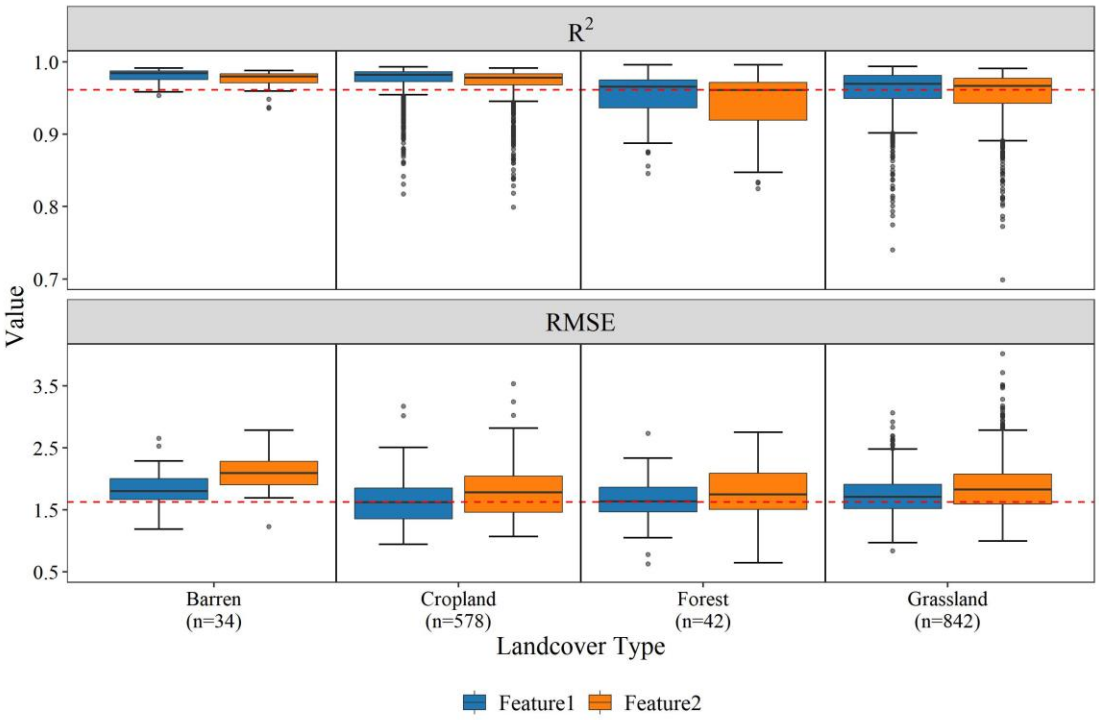
附图 9 基于旋转四叉树的站点尺度 T_s 预测结果不确定性空间分布图（0-40 cm）。

Figure S9. Spatial patterns of prediction uncertainty at six depths (0-40 cm) based on the rotated-quadtree ensemble.



附图 10 不同特征变量组合下的模型精度对比。（Feature 1 表示在其他特征变量基础上同时引入气温和 LST，Feature 2 表示在其他特征变量基础上仅引入气温）。

Figure S10. Comparison of Modeling Accuracy with Different Feature Variables (Feature1 represents using both air temperature and LST together with other feature variables, while Feature 2 represents using only air temperature together with other feature variables).



附图 11 不同特征变量组合及不同土地覆盖类型下的模型精度差异。（Feature 1 表示在其他特征变量基础上同时引入气温和 LST，Feature 2 表示在其他特征变量基础上仅引入气温）。

Figure S11. Differences in model accuracy across land cover types under different feature variable combinations. (Feature1 represents using both air temperature and LST together with other feature variables, while Feature 2 represents using only air temperature together with other feature variables).

致谢

拿到硕士录取通知书的那个夏天，我一直沉浸在喜悦之中，满怀期待地憧憬着即将开始的新生活，那是 2020 年的夏天。时光飞逝，转眼六年过去，我即将结束自己的博士生涯。站在这段求学旅程的终点回望，许多往事再次涌上心头。

当时正值疫情初期，那一年的研究生面试也是线上进行的。与课题组结缘，始于面试后于强老师打来的一通电话，接通电话后于老师先做了自我介绍和关于课题组的基本情况，随后他让我考虑一下是否愿意加入他课题组，接到电话的我受宠若惊。后来，我们又通了几次电话，最终我有幸加入生态模拟团队跟着于老师学习。

于老师带学生算是很宽松的放养吧。这些年，我和于老师的交流多是在线上，汇报频率很低。我一度感觉这样可太滋润了，因为不用频繁的应付组会，可以有大把的时间搞学习之外的事情。那段时间我迷恋上了电脑 DIY 装机和骑行，花了很多时间去不务正业。进组后的很长一段时间我都没有一个固定的研究方向。一方面，是我自己本就知识匮乏，根本谈不上有什么自己的想法和兴趣点，东一榔头，西一棒槌，很多东西都是浅尝辄止。非要再找一个理由，那可以归咎于导师没有在我一进组的时候就给我指定一个明确的研究方向。其实，于老师很强调因材施教，并且他一直以来也是这样践行的。他鼓励学生广泛的涉猎，积极的交流并寻求合作伙伴，从来没有把他的意愿强加在我身上，对于具体的研究方向和需要做决策的时刻，他多是和我平等的讨论并提出自己的意见供我参考。我在很长一段时间觉得老师这样是不是太“客气”了。

转博后的第二年春天，我还是没有任何成果产出。但是看到组里好几个师兄师姐都陆续申请了 CSC 出国联培。我还是鼓起勇气找到于老师，表达了自己也想尝试的想法。没想到于老师很支持，他积极的帮我联系外导并顺利拿到了邀请信。不过遗憾的是我自身实力不足，最终没有通过基金委审核，浪费了这次宝贵的机会。后来，国家气象中心的何亮师兄招收客座学生，我又跑去找于老师看是否可以跟着何师兄做一些工作，于老师依然给予了充分支持，随后我开启了在北京为期一年半的学习。这段经历后来成为我博士阶段十分重要的一部分，也让我获得了接触不同研究环境、研究资源和合作伙伴的机会。

承蒙整个课题组的厚爱，我度过了美好且难忘的一段求学时光。首先，由衷的感谢我的导师于强研究员，感谢您六年来给予我的包容、信任、支持与鼓励。作为我学术道路上的启蒙者和领路人，总能在关键的时刻给予我无条件的帮助与支持，您对科学问题的认识和宏观的把控总能让我从中受益匪浅。感谢靳宁师兄，在我硕士阶段给予我细致的指导，带我一步步迈入科研的大门。其次，感谢何亮

师兄，在国家气象中心客座期间，你为我提供了很高的合作平台和极为丰富的数据资源，支持我参加学术会议和交流活动，让我有机会接触不同的研究工作和科研同行，极大地拓宽了我的学术视野。另外，感谢石浩师兄，你总能一针见血地指出我论文和研究中的不足，并及时与我讨论、寻找解决方案，让我在一次次修改和讨论中收获良多。

感谢课题组刘亚东师兄，赵杰师兄，施宇师兄、田琪师兄、谭姣姣师姐、牛文浩师弟等。在杨凌相处的有限时间里，我们有机会坐在一起畅所欲言，开怀畅饮。你们总是不遗余力的解答我的困惑，在学习和生活中都无私的给予我很多帮助，让我尤为感动。感谢任凯师兄和同门李鹏，我们一起到新疆出差，在伽师县一望无际的棉田第一次见识到气势磅礴的机械播种，也曾在胡杨河市骑着电瓶车追赶下午十一点的夕阳，那次略显仓促的新疆之行，现在回想起来却也难得的自由与快乐。感谢杨晶晶师姐、同门姚林佳和陈彬师弟，大家跟着于老师到陕北和陕南安装调试二氧化碳通量观测站，有幸领略沿途的风景，品尝各地的美食。那些在野外奔波、调试设备的经历，如今都成为博士生涯中格外宝贵而鲜活的记忆。

感谢学习室的陈森师妹、魏英楠师妹、范馨逸师妹、蒋昆昊师弟、蒋露师妹等。同窗共处的日子里，总少不了欢声笑语。大家一起讨论问题、分享经验，在一次次交流中彼此帮助、共同进步，让原本漫长且偶有枯燥的科研生活多了许多轻松与温暖。感谢好友樊凯、苏艳丽、岳程瑜、陈晓凯、史博太、丁二卯、王诗晨。感谢你们陪我一起分担焦虑，也陪我一起吐槽、八卦和欢笑。科研之外的这些日常看似琐碎，却构成了这几年生活中十分重要的一部分。过往的点滴都是珍贵的回忆。

感谢我的女友王咪。那个接纳我所有不完美，陪伴我整个青春的人。我们之间早已没有了花前月下的浪漫，多的只是鸡零狗碎的日常。这一路走来历经挫折跌跌撞撞，却也是你一次次的帮我重拾已经丧失的勇气，给我重新出发的力量。六年的求学生活里有太多不确定，而你的坚守与陪伴，是其中最确定的部分。感谢我的父母和所有亲人，你们永远是我最坚实的后盾，最大的避风港。能够心无旁骛地读书多年，本身就是一种幸运，而这份幸运，很大程度上来自你们长久以来默默的托举。

最后，感谢许守华老师、姚宁老师、何建强老师、赵刚老师、吴耕泓老师、冯璞玉老师、赵福年老师等，感谢各位老师在我的日常生活以及博士学位论文撰写过程中给予的帮助与指导。

山水一程，幸得相逢。谨以此文，感谢所有曾经给予我帮助、理解、支持与陪伴的人。此去经年，愿我们各自珍重，也愿前路依然有值得奔赴的远方。

作者简介

王雪彤，男，中共党员，山西朔州人。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，研究方向为农业遥感与农业气象学。

一、主要学习经历

2015.09-2019.07，山西农业大学资源环境学院，地理信息科学专业，攻读学士学位；

2020.09-2022.07，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，攻读硕士学位。

2022.09-2026.07，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，攻读博士学位。

二、发表论文

[1] **Wang, X.T**., He, L.*, Li, P., Ma, J.G., Shi, Y., Tian, Q., Zhao, G., He, J.Q., Feng, H., Shi, H.*, Yu, Q.*, 2026. Spatially adaptive estimation of multi-layer soil temperature at a daily time-step across China during 2010-2020. *Earth System Science Data.* (第一作者/IF 11.6/中科院 1 区 Top)

[2] Li, P. He, L.*, **Wang, X.T**., Ding, E.M., Yu, Q.*, 2025. How reliable are long time-series reanalysis and model-based soil moisture products for agricultural soil water stress monitoring? Insights from a five-dataset evaluation across China. *Agricultural Water Management.* (第三作者/IF 6.5/中科院 1 区 Top)

[3] Wang, M., Hu, Z.*, **Wang, X**., Li, X., Wang, Y., Liu, H., Han, C., Cai, J., Zhao, W., 2023. Spatio-temporal variation of carbon sources and sinks in the loess plateau under different climatic conditions and land use types. *Forests*. (第三作者/IF 2.9/中科院 2 区)

三、数据产品

[1] **王雪彤**,何亮,石浩,于强.(2025).中国 1 千米分辨率逐日多层土壤温度数据集(2010-2020). 国家青藏高原科学数据中心. https://doi.org/10.11888/Terre.tpdc.302333.

四、学术交流

2025 年 01 月，参加首届全国气候资源论坛

2024 年 10 月，参加第二届气候变化科学大会

2024 年 06 月，参加第四届植被动力学暑期学校