doi:10.6041/j.issn.1000-1298.2026.17.004

融合物候趋势特征与时序感知网络的冬小麦种植区提取方法

曹　培[1,2]　赵豪雨[1]　韩文霆[2,3]

(1.西北农林科技大学机械与电子工程学院,陕西杨凌 712100;2.西北农林科技大学旱区农业节水研究院,陕西杨凌 712100;3.旱区作物高效用水国家工程实验室,陕西杨凌 712100)

摘要:为提高冬小麦种植区空间分布信息提取精度,针对现有方法在多时相物候信息利用不足、显式物候趋势特征融合效率不高以及复杂农业景观下局部结构恢复能力有限等问题,本文提出一种融合物候趋势特征的时序感知网络 ST-EdgeNet(Spatial-temporal edge-aware network)。以关中平原冬小麦关键生育阶段为对象,基于 2025 年 3—5 月 Sentinel-2 月尺度合成影像,选取 7 个原始波段和 7 个植被指数构建三时相基础光谱特征,并依据冬小麦在返青、抽穗和灌浆阶段的时序变化规律,构建包含旺盛期高值、峰值突出度、返青速率、峰后变化及软先验约束在内的 9 维物候趋势特征。在模型设计上,构建物候感知时序融合模块(PhAT)以增强三时相特征的自适应交互能力,设置趋势特征独立编码支路(TrendEncoder)以提高显式物候特征的有效表达,并结合局部结构增强与解码精化策略改善复杂地块区域恢复效果。基于关中平原 9 个县区构建县级空间分离数据集,其中训练集、验证集和测试集分别来自 6 个、1 个和 2 个县区,并与 PSPNet、FCN 和 SegFormer 等主流语义分割模型进行对比。结果表明:融合物候趋势特征的 ST-EdgeNet 在空间独立测试区取得最优识别效果,总体精度(OA)、F1 分数和平均交并比(mIoU)分别达到 98.53%、97.60% 和 96.61%,较最优对比模型 SegFormer 的平均交并比提高 10.25 个百分点;引入物候趋势特征后,ST-EdgeNet 的平均交并比由 95.32% 提升至 96.61%,分割错误率相对降低 27.6%。研究表明,物候趋势特征与时序感知网络的协同设计能够显著提升冬小麦种植区提取精度,所提方法可为冬小麦种植区高精度遥感制图与智能化调查提供方法参考。

关键词:冬小麦;种植区提取;物候趋势特征;时序感知网络;Sentinel-2 影像

中图分类号:S127　　**文献标识码**:A　　**文章编号**:1000-1298(2026)17-0042-12　　**OSID**:

Method for Extracting Winter Wheat Planting Area Integrating Phenological Trend Features and Temporal-Aware Networks

Cao Pei[1,2]　Zhao Haoyu[1]　Han Wenting[2,3]

(1. *College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi* 712100, *China*
2. *Institute of Water Saving Agriculture in Arid Regions, Northwest A&F University, Yangling, Shaanxi* 712100, *China*
3. *National Engineering Laboratory for Arid-region Crop High-efficiency Water Use, Yangling, Shaanxi* 712100, *China*)

Abstract: A spatial-temporal edge-aware network, ST-EdgeNet, integrated with phenological trend features, was proposed to improve the extraction accuracy of winter wheat planting areas. The method aimed to address three limitations of existing methods: insufficient utilization of multi-temporal phenological information, low efficiency in fusing explicit phenological trend features, and limited capability for local structure recovery in complex agricultural landscapes. Focusing on the key growth stages of winter wheat in the Guanzhong Plain, monthly composite Sentinel-2 imagery from March to May 2025 was used. Seven original spectral bands and seven vegetation indices were selected to construct three-phase basic spectral features. According to the temporal variation characteristics of winter wheat during the green-up, heading, and grain-filling stages, a 9-dimensional phenological trend feature set was further developed, including vigorous-growth high-value response, peak prominence, green-up rate, post-

收稿日期:2026-05-03　修回日期:2026-05-29

基金项目:国家自然科学基金青年基金项目(32301698)、陕西省重点研发计划项目(2024NC-ZDCYL-05-01)、陕西省"四链"融合项目(2025CY-JJQ-21)和云南省重点研发计划项目(202402AE090005)

作者简介:曹培(1989—),女,副教授,博士,主要从事农情信息获取研究,E-mail:caopei2020@nwafu.edu.cn

peak variation, and soft-prior constraints. In terms of model design, a phenology-aware temporal fusion module (PhAT) was constructed to enhance the adaptive interaction among multi-temporal features; an independent TrendEncoder branch was introduced to improve the representation of explicit phenological trend features; and local structure enhancement and decoder refinement strategies were incorporated to improve recovery performance in complex field regions. A county-level spatially separated dataset covering nine counties in the Guanzhong Plain was established, in which the training, validation, and test sets were derived from six, one, and two counties, respectively. The proposed method was compared with mainstream semantic segmentation models, including PSPNet, FCN, and SegFormer. The results showed that ST-EdgeNet with phenological trend features achieved the best recognition performance in spatially independent test areas, with overall accuracy (OA), F1-score, and mean intersection over union (mIoU) reaching 98.53%, 97.60%, and 96.61%, respectively. Its mIoU was 10.25 percentage points higher than that of the best comparative model, SegFormer. After phenological trend features were introduced, the mIoU of ST-EdgeNet was increased from 95.32% to 96.61%, while the segmentation error rate was reduced by 27.6%. These results indicated that the synergistic design of phenological trend features and a temporal-aware network was effective in improving the accuracy of winter wheat planting area extraction, providing methodological support for high-precision remote sensing mapping and intelligent surveying of winter wheat planting areas.

Key words: winter wheat; planting area extraction; phenological trend features; temporal-aware network; Sentinel-2 imagery

0　引言

冬小麦是我国重要的主粮作物之一,其种植面积与空间分布信息的准确获取对于粮食安全评估、农业资源优化配置以及种植结构调整具有重要意义[1]。小麦面积调查主要依赖统计报表、样方抽样和人工核查等方式,存在时效性不足、空间精度有限和调查成本较高等问题[2]。随着 Sentinel-2 等中高分辨率遥感数据的持续开放,以及深度学习语义分割方法在地表覆盖制图中的广泛应用,利用多时相卫星影像开展冬小麦种植区高精度自动提取,已成为农业遥感领域研究热点[3-5]。

相较于单时相遥感识别,冬小麦提取更依赖关键物候阶段的时序差异表达[6-7]。以关中平原为例,冬小麦通常在 3—5 月依次经历返青、拔节抽穗和灌浆成熟等关键阶段,其植被指数和红边响应往往表现为“前期快速上升—中期达到峰值—后期逐步回落”的典型变化过程[8]。该时序规律为冬小麦与裸地、建设用地、常绿林地以及部分春季作物的区分提供了重要依据。因此,如何在深度学习框架中有效利用多时相物候信息,是提升冬小麦遥感提取精度的关键问题[9-12]。

已有研究表明,基于关键生育期植被指数构建物候特征,能够在一定程度上提高冬小麦识别效果[13-14]。然而,现有方法仍存在两方面不足:多时相光谱信息的融合方式仍以通道拼接、时序堆叠或通用序列建模为主[15-16],难以突出不同物候阶段在分类判别中的差异性作用,特别是在仅有 3 个关键时相的短时序条件下,时序信息利用效率仍有提升空间;已有研究虽构建了 NDVI 差值、EVI 变化幅度等趋势特征,但这类特征若直接拼接到输入通道中,往往在浅层卷积学习中被高维原始光谱特征所淹没,导致其显式引入后的增益有限[17-18]。这说明,物候特征能否真正服务于作物识别,不仅取决于特征本身是否具有判别意义,还取决于网络是否具备与之相匹配的编码与融合机制。

针对冬小麦种植区遥感提取中多时相物候信息利用不足、显式物候趋势特征融合效率不高以及复杂农业景观下局部结构恢复能力有限等问题,本文开展以下研究:基于 3—5 月 Sentinel-2 多时相影像构建能够表征冬小麦关键生育阶段变化的 9 维物候趋势特征;设计融合物候感知时序融合模块和趋势特征独立编码支路的 ST-EdgeNet 网络,提高短时序物候信息表达与融合效率;基于县级空间分离数据集开展对比、消融和补充公平性实验,验证方法在典型农业景观样区中的有效性与跨县迁移能力,为冬小麦种植区高精度遥感提取及典型农业区作物空间分布制图提供方法参考。

1　材料与方法

1.1　研究区与数据来源

1.1.1　研究区概况

研究区位于陕西省关中平原(33°35′~35°51′N,106°19′~110°36′E,如图 1 所示),涵盖西安市、咸阳市、宝鸡市、铜川市和渭南市 5 个地级市。关中地区年降水量为 500~700 mm,年均气温 12~14℃。研究区内冬小麦通常于 10 月中下旬播种,翌年 6 月上旬收获;其中 3—5 月经历返青、拔节、抽穗、灌浆

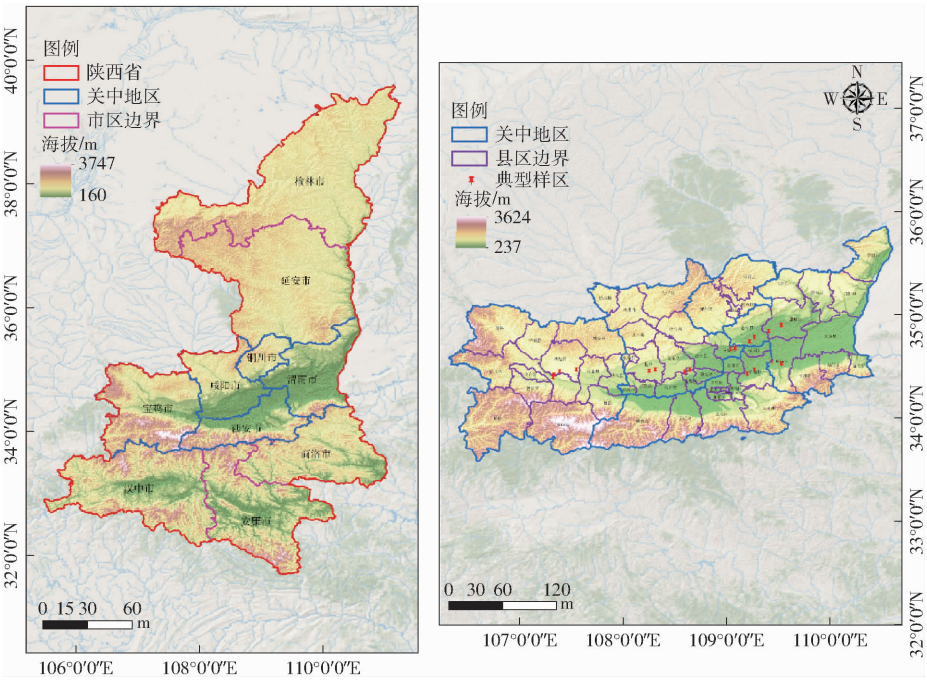

图 1 研究区位置与样本县区分布

Fig. 1 Location of study area and distribution of sampled counties

等关键物候阶段,是开展多时相遥感识别的关键窗口期。

1.1.2 遥感数据及预处理

本文采用欧洲空间局(European Space Agency, ESA)发布的 Sentinel-2A/B 多光谱卫星影像作为主要遥感数据源。Sentinel-2 多光谱成像仪(Multispectral instrument, MSI)共提供 13 个光谱波段,其中可见光与近红外波段空间分辨率为 10 m,红边与短波红外波段空间分辨率为 20 m。结合冬小麦物候识别需求及不同波段对植被长势、叶绿素变化、水分状态和冠层结构的表征能力,本文选取 B2(蓝)、B3(绿)、B4(红)、B5(红边)、B8(近红外)、B11(短波红外 1)和 B12(短波红外 2)共 7 个原始波段作为基础光谱变量。

影像获取与预处理在 Google Earth Engine 平台完成。考虑关中平原冬小麦在 3—5 月依次经历返青、拔节抽穗和灌浆成熟等关键生育阶段,本文分别选取 2025 年 3 月、4 月和 5 月的 Sentinel-2 Level-2A 地表反射率产品构建三时相输入数据。冬小麦返青、拔节、抽穗和灌浆并非严格按照自然月离散分布,不同县区受气温、品种和管理措施影响会存在一定时间差异。本文采用 3 月、4 月和 5 月月尺度中值合成影像,并不将 3 个时相与 4 个生育期作机械一一对应,而是将其作为冬小麦关键生育阶段连续变化过程的代表观测。其中,3 月影像主要反映返青至拔节初期的冠层恢复和快速生长起点,4 月影像主要反映拔节、抽穗及旺盛生长期的高植被覆盖状态,5 月影像主要反映灌浆至成熟阶段的冠层衰减和水分变化。

为降低云、薄雾及局部异常观测的影响,首先依据质量波段进行云和云影剔除,再在月尺度内对可用观测进行中值合成,生成各月份代表性影像。为保证多波段空间一致性,将 20 m 波段重采样至 10 m 后统一参与后续分析;同时,在样本裁剪前完成空间配准和边界一致性检查。

在特征构建方面,除 7 个原始波段外,本文进一步计算 NDVI、EVI2、SAVI、GNDVI、NDRE、LSWI 和 NDWI 7 个常用植被指数,分别从植被活力、冠层结构、土壤背景、叶绿素响应和水分状态等方面补充表征冬小麦关键生育阶段的光谱特征,为后续物候趋势特征构建提供基础变量[19-21]。

因此,每个时相形成 7 个原始波段与 7 个植被指数共 14 个通道,三时相共构成 42 维基础光谱输入。为减弱不同变量量纲和数值范围差异对模型训练的影响,本文在样本构建阶段对所有输入特征进行统一归一化处理;对云掩膜后残留的无效像元及少量缺测值,采用掩膜剔除方式处理,以保证输入数据质量的一致性和可用性。

1.1.3 标签制作与质量控制

为兼顾研究的可操作性与区域代表性,在关中平原五市范围内选取 9 个具有代表性的县区作为样本来源,每个县区布设 2 个 1 024 像素×1 024 像素的采样区(约 10.24 km×10.24 km),共形成 18 个采样区,总覆盖面积约 1 887 km^2,约占关中平原总

面积的 4.8%。样本区并非以面积比例覆盖整个关中平原为目标，而是面向冬小麦主要种植区及典型农业景观类型进行布设，如表 1 所示。因此，该数据集可用于验证模型在代表性场景下的有效性与跨县迁移能力，但尚不足以支持对关中平原全部地貌组合条件的充分泛化结论。

表 1　县级空间分离样本区基本信息

Tab.1　Basic information of sample areas under county-level spatial separation

县区	所属市	地貌特征	数据集类型
陈仓	宝鸡	山前冲积扇	训练集
凤翔	宝鸡	西部平原	训练集
乾县	咸阳	渭北旱塬	训练集
富平	渭南	渭北台塬	训练集
蒲城	渭南	渭河平原灌区	训练集
临渭	渭南	渭河谷地	训练集
三原	咸阳	渭北平原	验证集
渭城	咸阳	城郊混合区	测试集
临潼	西安	秦岭北麓过渡带	测试集

外业调查分 2 个时段进行：第 1 时段为 2025 年 3 月 7—9 日，对应冬小麦返青期；第 2 时段为 2025 年 5 月 22—30 日，对应冬小麦灌浆成熟期。两个时段的调查时间与本文所用 3 月和 5 月遥感合成影像的代表时相，即 2025 年 3 月 13 日和 2025 年 5 月 24 日主景影像，在物候阶段上具有较好的对应性。每个采样区开展系统性实地调查，记录约 20 个均匀分布的核查点，覆盖冬小麦及典型非冬小麦地物；18 个采样区共形成约 360 个采样区内核查点，平均调查密度约为 0.19 个/km^2。同时，在驱车前往各采样区的沿途中，同步记录部分冬小麦集中种植区的空间位置，形成补充观测记录。上述外业调查覆盖 9 个样本县区及其典型采样区，可为冬小麦标签制作与遥感判读结果复核提供依据。

受调查条件限制，本次外业调查未在 4 月开展专项实地记录。4 月标签主要依据 4 月 12 日前后的 Sentinel－2 合成影像，结合返青期（3 月）和成熟期（5 月）的外业核查点，通过以下两种方式加以弥补：对 3 月和 5 月均确认为冬小麦的地块，4 月以高概率认定为冬小麦，地物类型在短期内不会发生根本性改变；对两时段核查结果存在差异的地块，利用 4 月 NDVI 高值和峰值突出度特征（F3）进行辅助判读，并结合耕地矢量数据和相邻像元的时序一致性进行修正。上述处理方式使得 4 月标签具有较高的可信度，但其精度仍受限于非直接外业核查，这是本文标签体系的局限性。

1.1.4　数据集构建与划分

本文采用县级行政区空间分离方式划分训练集、验证集和测试集，以降低空间邻近样本带来的自相关影响。样本裁剪尺寸统一为 256 像素 ×256 像素，训练集采用步长 128 像素的 50% 重叠滑窗裁剪，验证集和测试集采用步长 256 像素的无重叠裁剪，以保证测试阶段每个像素仅参与一次评价，降低重叠样本对精度统计的影响。其中，训练集包括 6 个县区、12 个采样区，共生成 588 个影像样本块（patch）；验证集包括 1 个县区、2 个采样区，共生成 32 个影像样本块；测试集包括渭城和临潼 2 个县区、4 个采样区，共生成 64 个影像样本块。

1.2　物候趋势特征构建

1.2.1　冬小麦物候规律与特征设计依据

冬小麦在关中平原 3—5 月的生长过程具有较稳定的阶段性遥感响应特征。受区域气候条件与种植制度影响，冬小麦通常于 3 月进入返青拔节阶段，冠层叶面积和叶绿素含量快速增加，近红外反射率及相关植被指数同步升高；4 月前后进入抽穗扬花和旺盛生长期，冠层覆盖度、叶面积指数和叶绿素水平普遍达到较高值；5 月进入灌浆成熟阶段后，植株逐渐衰老，叶片失绿、含水率下降，部分植被指数开始回落[22]。整体上，冬小麦在 3—5 月通常表现为“前期快速上升—中期达到峰值—后期逐步回落”的单峰型时序变化[23]。本文通过返青速度、峰值突出度和峰后变化等趋势特征，将返青、拔节、抽穗和灌浆等连续生育过程压缩表达于 3 个关键时相之间的变化关系中，从而在短时序条件下保留主要物候判别信息。

与冬小麦相比，果园、部分春季蔬菜、油菜及常绿林地等强混淆地物虽然在局部时相上可能具有相近的高植被覆盖度，但其时序变化过程并不一致。已有研究表明，冬小麦识别的关键不在于单一时相高值本身，而在于对关键物候阶段时序轨迹的有效刻画，即通过峰值位置、增长速率、峰后变化及水分响应等特征表征其独特物候过程[24]。因此，仅依赖单时相光谱或单一植被指数高值容易导致误分，而构建物候趋势特征有助于增强对不同地物物候差异的表达能力。

基于上述认识，本文在特征设计中遵循以下原则：优先保留能够直接表征冬小麦关键生育阶段状态的高判别力特征，突出旺盛生长期高值和阶段性峰值信息；兼顾冠层生长、叶绿素变化和水分响应等不同维度，提高物候表达的互补性；同时控制特征规模，避免大量同质化线性差值叠加，以减小冗余信息对模型训练稳定性的干扰。基于此，本文构建了 9 维物候趋势特征，如表 2 所示。上述特征可归纳为关键时期绝对水平特征、峰值突出度特征、返青增速

与峰后变化特征以及季节水分变化特征 4 类，用于从不同层面描述冬小麦关键生育阶段的时序响应特征。

表 2 物候趋势特征定义与物理意义

Tab. 2 Definitions and physical meanings of phenological trend features

编号	名称	计算公式	物理意义
F1	4 月 NDVI 原值	$NDVI_4$	关键旺盛期绝对植被活力水平
F2	NDVI 高值软判别	clip((NDVI$_4$ − 0.66)/0.30, 0, 1)	将冬小麦旺盛期高值经验转化为连续软约束
F3	NDVI 峰值突出度	$2NDVI_4 - NDVI_3 - NDVI_5$	4 月是否为 NDVI 时序峰值
F4	EVI2 峰值突出度	$2EVI2_4 - EVI2_3 - EVI2_5$	抗饱和的冠层峰值检测
F5	NDRE 峰值突出度	$2NDRE_4 - NDRE_3 - NDRE_5$	红边波段叶绿素峰值响应
F6	EVI2 返青速度	$EVI2_4 - EVI2_3$	返青拔节期至抽穗期的冠层增长幅度
F7	NDRE 返青速度	$NDRE_4 - NDRE_3$	叶绿素快速积累速率
F8	EVI2 峰后变化率	$EVI2_5 - EVI2_4$	抽穗期至灌浆成熟期的冠层衰减幅度
F9	LSWI 季节变化	$LSWI_5 - LSWI_3$	全生长季水分状态变化

表 2 中 9 维物候趋势特征均以逐像素方式计算。对于影像中每一个空间位置，分别提取其 3 月、4 月和 5 月对应像元的植被指数值，并依据表 2 所列公式计算该像元的趋势响应。由此得到的趋势特征图与原始 Sentinel－2 影像严格空间对齐，空间分辨率保持为 10 m，数据形式为 $H \times W \times 9$。

1.2.2 特征相关性与互补性分析

为评估 9 维物候趋势特征之间的信息冗余程度与互补关系，本文基于训练样本计算 Pearson 相关系数矩阵。如图 2 所示，9 维物候趋势特征并非简单重复叠加，而是在关键时期状态、峰值形态、增长速率等不同层面共同表征冬小麦物候过程。这种“组内适度冗余、组间相对互补”的结构，有利于模型在训练过程中自动筛选高价值信息，并增强对复杂农业景观中强混淆地物的区分能力。

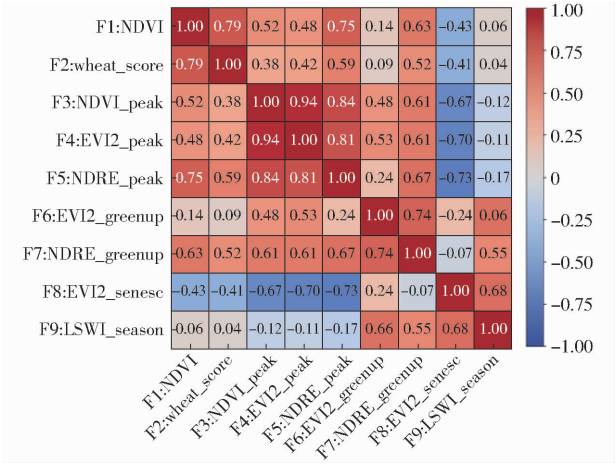

图 2 物候趋势特征相关系数矩阵

Fig. 2 Correlation matrix of phenological trend features

1.3 ST－EdgeNet 模型架构

1.3.1 网络总体框架

本文构建了融合物候趋势特征的时序感知网络 ST－EdgeNet，其整体框架如图 3 所示。模型以两类信息作为输入：由 2025 年 3—5 月 Sentinel－2 多时相影像构成的三时相基础光谱特征；依据冬小麦关键生育阶段构建的 9 维物候趋势特征。

网络首先利用物候感知时序融合模块对三时相基础光谱特征进行自适应加权与交互，以增强模型对关键物候阶段差异的表达能力；随后，通过趋势特征独立编码支路（TrendEncoder）对 9 维物候趋势特征进行单独表征，并在解码阶段与主干特征逐尺度融合，以提高显式物候特征的利用效率；在此基础上，结合局部结构增强与解码精化策略，进一步改善

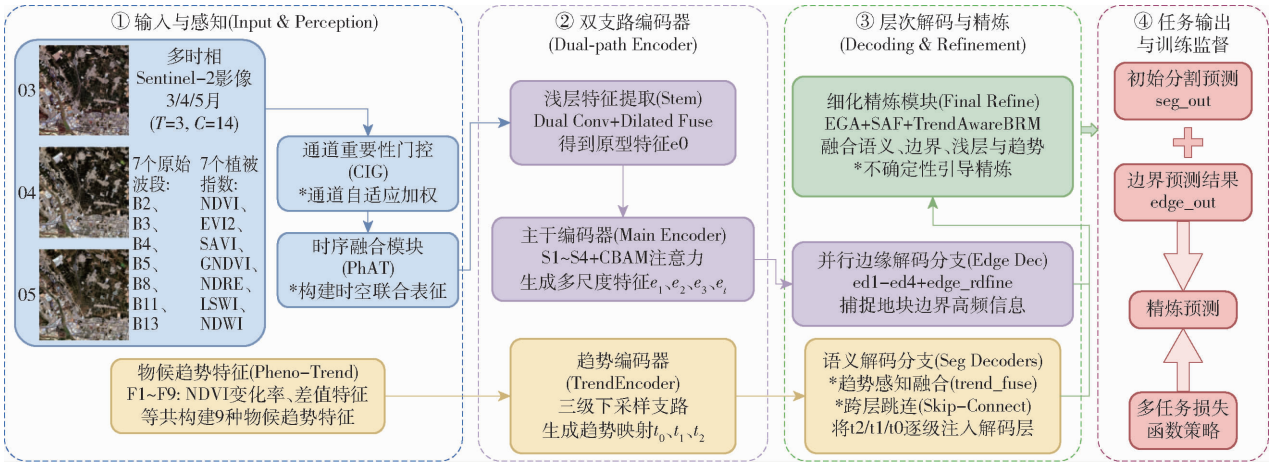

图 3 ST－EdgeNet 总体框架图

Fig. 3 Overall framework of ST－EdgeNet

复杂农业景观下的区域恢复效果。整体上，ST-EdgeNet 通过三时相光谱信息与显式物候趋势信息的协同建模，实现冬小麦种植区的高精度提取。

1.3.2　物候感知时序融合模块

冬小麦在 3—5 月具有明显的阶段性遥感响应，若直接将多时相特征进行通道拼接，难以突出不同物候阶段对分类判别的差异贡献。为此，本文设计了物候感知时序融合模块（PhAT），以实现对关键月份信息的自适应加权。设三时相输入特征为

$$X = \{X_3, X_4, X_5\} \tag{1}$$

其中　　$X_m \in \mathbf{R}^{C\times H\times W}$

式中 $m \in \{3,4,5\}$，$C = 14$，H、W 表示输入影像块的空间高度和宽度。首先，对每个时相特征进行线性映射并展平为空间 Token 序列

$$T_m = \mathrm{Proj}(X_m) + E_m \tag{2}$$

其中，Proj 表示线性投影操作，E_m 表示月份位置编码。进一步地，利用趋势特征 z 生成调制参数，对时序特征进行先验调制

$$T'_m = \gamma(z) \odot T_m + \beta(z) \tag{3}$$

式中，调制参数 $\gamma(z)$ 和 $\beta(z)$ 由 9 维物候趋势特征（$z \in \mathbf{R}^{C\times H\times W}$）生成。具体而言，首先对 z 进行空间全局平均池化，得到 9 维全局描述向量；随后经两层全连接层（分别含 ReLU 激活和线性变换）映射为与时序 Token 通道数匹配的 C 维向量；最后将其广播至空间维度，得到逐通道（而非逐像素）的调制参数（$\gamma(z)$、$\beta(z) \in \mathbf{R}^{C}$）。这种全局池化后全连接的调制方式能够捕获趋势特征的全局物候统计信息，以较小的参数规模实现对多时相特征的全局物候调制，使不同物候背景下的影像在进入注意力机制前获得先验对齐。之后通过注意力机制实现多时相信息交互，即

$$\mathrm{Attention}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V}) = \mathrm{Softmax}((\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}})/\mathrm{sqrt}(d))\boldsymbol{V} \tag{4}$$

式中，$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 分别为调制后时序特征生成的查询矩阵、键矩阵和值矩阵；d 为特征通道维度。最终输出融合特征 F_{phat}，供后续主干网络进行空间特征提取。PhAT 的作用在于增强模型对“返青—抽穗—灌浆”阶段差异的感知能力，从而提高多时相信息利用效率。

1.3.3　趋势特征独立编码支路

物候趋势特征具有明确的农学含义[25-26]，但若仅以通道拼接方式直接输入主干网络，容易在浅层卷积过程中被高维光谱特征淹没。为此，本文构建趋势特征独立编码支路，对 9 维趋势特征进行单独表征，并在解码阶段与主干特征进行逐尺度融合。

TrendEncoder 以 $H \times W \times 9$ 的像元级趋势特征图为输入，采用全卷积结构进行编码，不进行全局展平或对象级统计。其输出的 t_0、t_1 和 t_2 分别对应原始分辨率、1/2 分辨率和 1/4 分辨率，即空间尺寸分别为 $H \times W$、$H/2 \times W/2$ 和 $H/4 \times W/4$，并与主干解码器对应层级的特征图在空间尺寸上保持一致。

设趋势特征图为 z，则其多尺度编码过程可表示为

$$\begin{cases} t_0 = f_0(z) \\ t_1 = f_1(t_0) \\ t_2 = f_2(t_1) \end{cases} \tag{5}$$

其中，t_0、t_1 和 t_2 分别为不同尺度下的趋势特征表示。融合前通过 1×1 卷积完成通道对齐，随后采用残差式注入方式引入对应层级，从而实现空间一致的逐尺度融合

$$F^{l}_{\mathrm{out}} = F^{l}_{\mathrm{dec}} + \alpha_l \varphi_l(t_l) \tag{6}$$

式中　l——解码阶段的尺度层级索引

F^{l}_{dec}——第 l 层未融合趋势特征前的解码器特征图

F^{l}_{out}——融合趋势特征后的第 l 层输出特征图

α_l——可学习融合系数

φ_l——通道对齐映射

下角 out 表示融合输出特征，dec 表示解码特征。该支路的核心作用是为物候趋势信息建立独立的梯度传播路径，从而提高趋势特征对冬小麦识别的实际贡献。

1.3.4　编码器结构设计

编码器由 4 层卷积下采样模块构成，通道维度依次为 64→128→256→512→512。每层卷积后接 CBAM（Convolutional block attention module）注意力模块[27]，依次执行通道注意力和空间注意力两步操作。通道注意力通过全局平均池化和全局最大池化提取通道描述符，经共享全连接层生成通道权重向量，实现对不同光谱波段和植被指数的自适应加权。空间注意力通过对通道维度的平均和最大操作生成空间描述图，经卷积层输出逐像素的注意力权重，使编码器能够聚焦地块内部纹理和边界过渡区域。

1.4　对比实验设置

为系统验证模型架构设计与物候趋势特征引入对冬小麦种植区提取性能的影响，本文设计了 A、B、C、D 共 4 组对比实验，具体设置见表 3。A、B 组用于评估通用语义分割模型在是否引入物候趋势特征条件下的性能变化，C、D 组用于分析本文模型在相同条件下对物候趋势特征的利用效果。其中，对比模型选 FCN[28]、PSPNet[29] 和 SegFormer[30]，分别代表经典全卷积分割框架、多尺度上下文聚合分割框

架和基于 Transformer 的分割框架,具有较好的代表性。

表 3 对比实验设置

Tab. 3 Settings of comparative experiments

实验组	模型	输入特征	融合方式
A	PSPNet/FCN/SegFormer	42 维光谱	无物候趋势特征
B	PSPNet/FCN/SegFormer	42 维光谱 + 9 维物候	输入端直接通道拼接
C	ST - EdgeNet	42 维光谱	PhAT 时序融合
D	ST - EdgeNet	42 维光谱 + 9 维物候	TrendEncoder 独立编码 + 逐尺度融合

本文未开展“SegFormer + TrendEncoder”实验,主要原因在于 TrendEncoder 并非简单的输入端拼接模块,而是与 ST - EdgeNet 的多尺度解码结构和残差式注入机制相结合。若直接移植至 SegFormer,需要重新设计尺度对齐、融合接口和特征注入位置,已超出本文研究范围。A→B 与 C→D 的对比已能够说明不同融合方式对物候趋势特征利用效率的影响,后续研究将进一步验证 TrendEncoder 在其他分割主干中的可迁移性。

1.5 训练策略

所有实验均基于 PyTorch 框架实现,在 NVIDIA GeForce RTX 3070 Ti GPU 上完成训练与推理。输入样本尺寸为 256 像素 ×256 像素,批处理大小设为 8。训练阶段采用自动混合精度加速,推理阶段采用 float32 精度以保证计算稳定性。

A、B 组中的 PSPNet、FCN 和 SegFormer 采用统一训练配置,A 组采用 SGD 优化器,初始学习率为 0.01,学习率调度采用 StepLR,损失函数为交叉熵与 Dice 损失加权组合。B 组在 A 组模型参数基础上进行微调,将输入层由 42 通道扩展至 51 通道,学习率设为 0.003。其余训练设置与 A 组保持一致。该设置用于评估通用分割模型在简单通道拼接条件下对物候趋势特征的响应情况。

C、D 组采用两阶段训练策略,优化器为 AdamW,初始学习率为 2×10^{-4},权重衰减为 5×10^{-5},学习率调度采用 OneCycleLR 结合余弦退火策略,D 组额外引入 TrendEncoder 辅助损失,各组训练阶段均采用随机翻转、随机旋转和随机仿射变换等数据增强方式。

需要指出的是,A、B 组与 C、D 组在优化器(SGD 与 AdamW)和学习率调度策略(StepLR 与 OneCycleLR)上存在差异。上述差异是基于两类模型的参数规模、结构特性和任务适应性而分别设定的:SGD 在中小规模 CNN 模型(FCN 约 2.6×10^6、PSPNet 约 3.1×10^6)上具有更好的收敛稳定性,而 AdamW 更适合包含 Transformer 结构和多任务损失(物候辅助、边缘监督)的大结构模型(ST - EdgeNet 约 9.1×10^6)。

1.6 评价指标

为定量评价不同模型在冬小麦种植区提取任务中的分类与分割性能,本文采用总体精度(OA)、精确率(Precision)、召回率(Recall)、F1 分数、冬小麦交并比(IoU_w)、非冬小麦交并比(IoU_n)和平均交并比(mIoU)等常用语义分割评价指标进行综合评价。上述指标均基于像素级混淆矩阵计算。

2 结果与分析

2.1 总体精度评价

图 4 给出了 4 组实验在空间独立测试区上的定量评价结果。总体来看,D 组(ST - EdgeNet + 物候趋势特征)取得了最优识别效果,总体精度、精确率、召回率、F1 分数和平均交并比分别达到 98.53%、99.37%、95.89%、97.60% 和 96.61%,均优于其余模型。说明本文方法在冬小麦种植区识别精度、区域完整性和边界恢复质量方面具有明显优势。

从组间对比结果看,A 组和 B 组为通用分割模型对比实验,C 组和 D 组为本文模型实验。A 组中,SegFormer 取得最佳结果,平均交并比为 86.36%,优于 PSPNet 和 FCN,表明基于全局依赖建模的分割框架在农田地块识别中具有一定优势。相比之下,本文模型在未引入物候趋势特征时即达到 95.32% 的平均交并比,引入趋势特征后进一步提升至 96.61%,分别较 A 组最优模型提高 8.96、10.25 个百分点,表明 ST - EdgeNet 在多时相信息建模与边界精细恢复方面具有更强的任务适应能力。

2.2 多时相与物候特征融合效果分析

A 组结果表明,3 种对比模型的平均交并比介于 78.27% ~ 86.36% 之间,其中 SegFormer 表现最优,PSPNet 与 FCN 结果相近。说明在冬小麦种植区提取任务中,引入全局上下文建模能力有助于提高农田地块的空间识别效果,但通用分割架构在复杂边界恢复和物候信息利用方面仍存在局限。

B 组在 A 组基础上进一步引入相同的 9 维物候趋势特征,但采用输入通道直接拼接的方式进行融合。结果显示,3 种对比模型的平均交并比平均仅提升 0.13 个百分点,如图 5 所示,其中 SegFormer 由 86.36% 提升至 86.68%,PSPNet 和 FCN 提升更为有限。该结果表明,物候趋势特征本身具有一定判别价值,但若缺乏与之匹配的特征表达与融合机制,

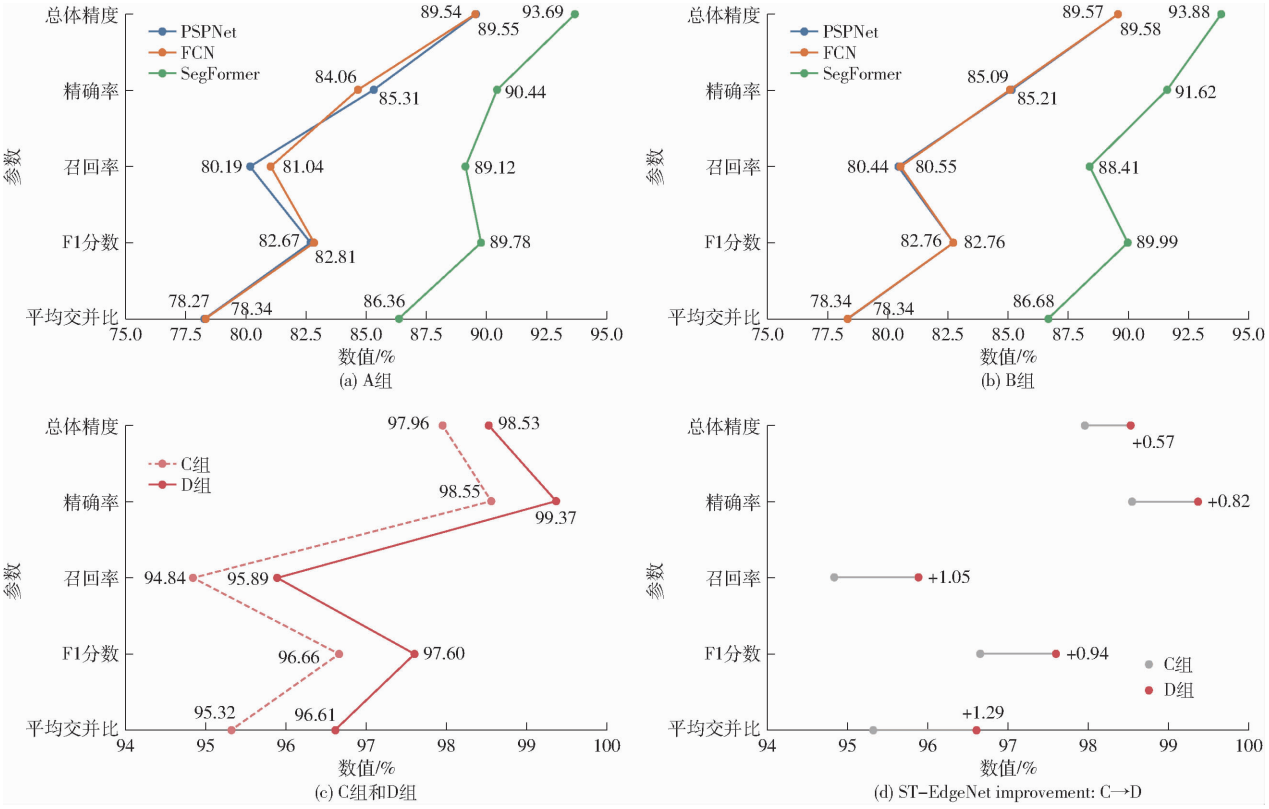

图 4　各实验组在空间独立测试区的定量评价结果

Fig. 4　Quantitative evaluation results of different experimental groups in spatially independent test areas

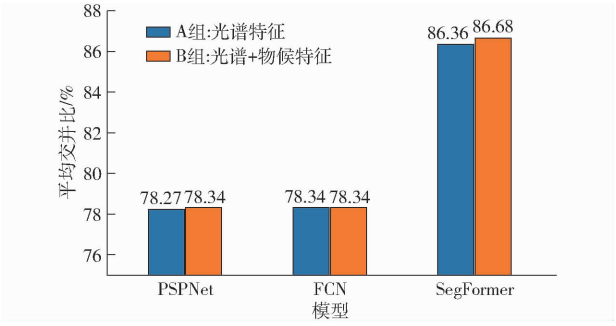

图 5　A、B 组模型平均交并比对比

Fig. 5　Comparison of mIoU values of baseline models in groups A and B

其增益难以有效释放。

A、B 组实验说明(SegFormer 模型在测试集识别效果如图 6 所示),误差分析图中绿色表示正确识别的冬小麦像素,红色表示误检像素,蓝色表示漏检像素。该图为局部典型样块的高对比可视化结果,主要用于展示不同模型在复杂地块边界和破碎耕地中的识别差异,整体精度评价以图 4 及测试区定量指标统计结果为准,物候信息能否转化为稳定的精度提升,关键不在于是否额外增加趋势特征,而在于网络是否为该类特征提供了相对独立且有效的学习路径。对于通用分割模型而言,简单拼接方式难以避免趋势特征在浅层表示中被高维光谱特征淹没,从而限制了其实际贡献。

C 组中,ST－EdgeNet 在仅使用 42 维多时相光谱特征条件下即取得 95.32% 的平均交并比,明显优于 A 组最优模型 SegFormer(86.36%)。说明即使不显式引入物候趋势特征,本文模型仍能够依托针对性的时序融合与边界恢复结构,更充分地挖掘多时相影像中的判别信息。

在此基础上,D 组进一步引入 9 维物候趋势特征后,平均交并比由 95.32% 提升至 96.61%,总体精度由 97.96% 提升至 98.53%,F1 分数由 96.66% 提升至 97.60%,精确率和召回率也同步提高,对比如图 7 所示,表明物候趋势特征不仅增强了冬小麦区域识别的整体准确性,同时改善了误检与漏检控制效果。

从误差变化看,模型分割错误率由 4.68% 降至 3.39%,相对降低 27.6%,说明物候趋势特征对整体测试区分割质量具有稳定增益。进一步比较可知,ST－EdgeNet 引入趋势特征后的平均交并比提升 1.29 个百分点,而对比模型平均仅提升 0.13 个百分点,前者约为后者的 9.9 倍。该结果表明,物候趋势特征的有效利用并不取决于特征是否被附加输入,而取决于模型是否能够建立针对性的编码与融合机制,模型识别效果如图 6 所示。

2.3　物候趋势特征贡献分析

为定量分析 9 维物候趋势特征在本文模型中的实际作用,以 C 组为基线、D 组为完整模型,考察趋

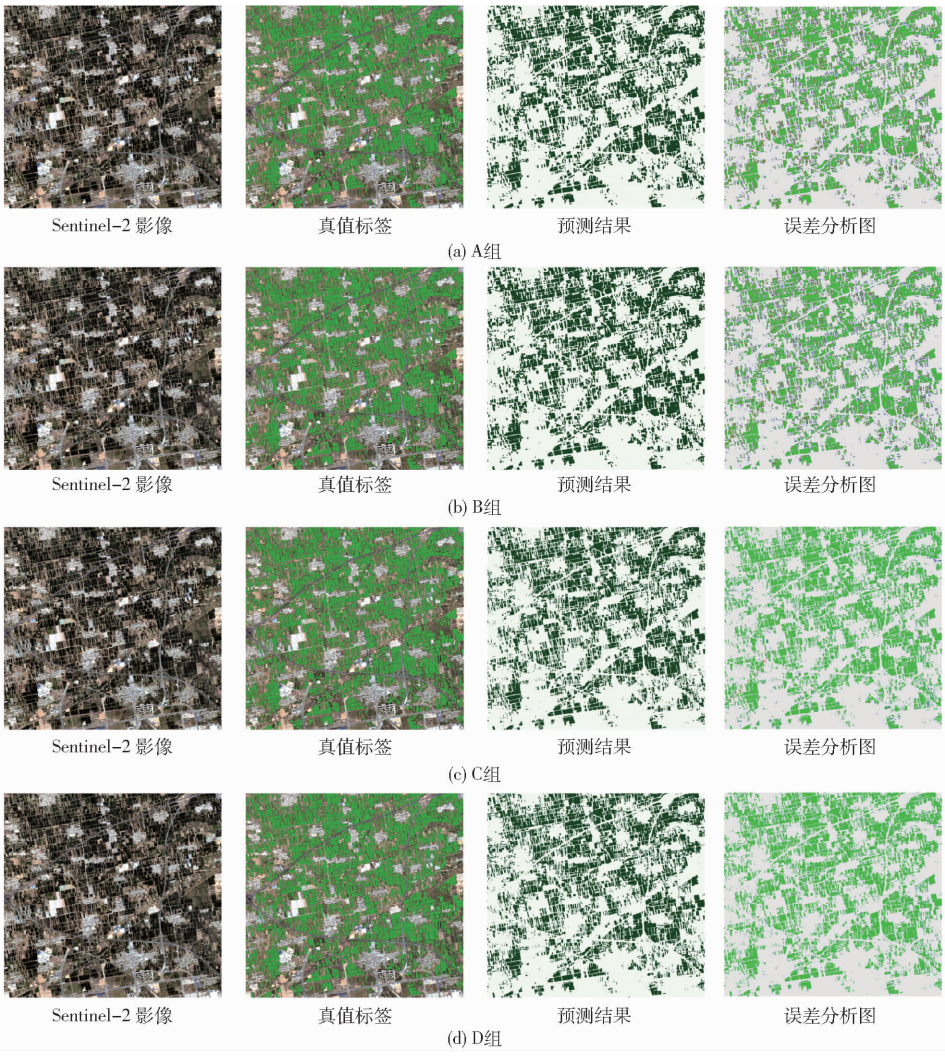

图 6 A、B、C、D 组模型在测试集识别结果

Fig. 6 Recognition results of models in groups A, B, C and D in test area

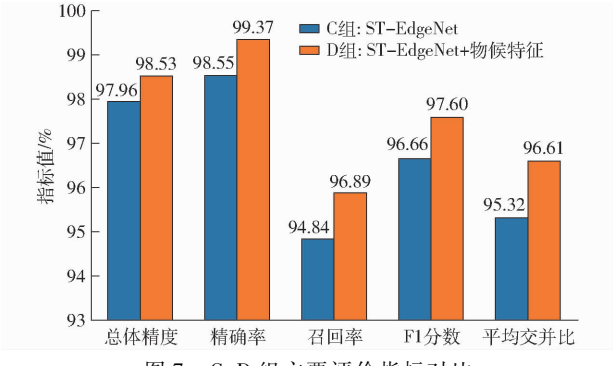

图 7 C、D 组主要评价指标对比

Fig. 7 Comparison of major evaluation metrics between groups C and D

势特征引入后的性能变化。结果表明,ST - EdgeNet 引入物候趋势特征后,平均交并比由 95.32% 提升至 96.61%,说明趋势特征能够稳定提升模型识别精度。

图 8 进一步表明,不同趋势特征的贡献并不均衡。其中,4 月高值水平、红边峰值响应及返青—灌浆阶段的时序变化特征贡献较大,说明冬小麦识别不仅依赖旺长期高值信息,还依赖关键生育阶段的峰值形态与变化过程。相较于简单拼接方式,TrendEncoder 通过独立编码和逐尺度融合,提高了高价值趋势特征的利用效率。

F7(NDRE 返青速度,-0.95%)、F3(NDVI 峰值突出度,-0.37%)和 F9(LSWI 季节变化,-0.36%)在单独置零后反而引起平均交并比轻微上升。这并不意味着上述特征无效,而说明多特征协同编码过程中存在一定交互效应。当部分冗余通道被移除后,模型注意力可重新分配至信息量更高的同类特征,从而减少噪声干扰。总体而言,物候趋势特征在模型中的作用呈现出“核心特征主导、辅助特征补充”的层次化结构,表明作物识别中的特征工程应强调物候机理与融合方式的协同设计。

2.4 模块消融实验

为验证 ST - EdgeNet 各核心模块的独立贡献,并排除训练策略差异对实验结论的潜在影响,本文在保持训练配置一致的条件下开展模块消融实验,结果如图 9 所示。消融实验以 C 组完整 ST -

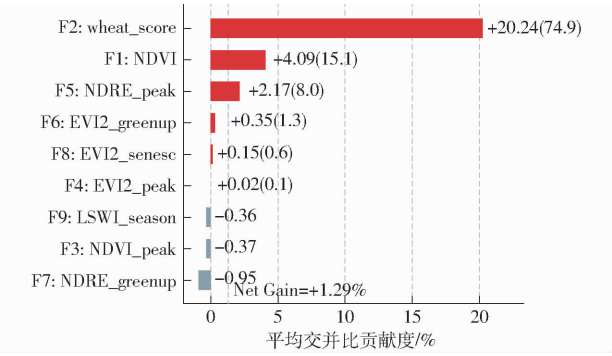

图 8　物候趋势特征逐特征贡献度分析

Fig. 8　Feature-wise contribution analysis of phenological trend features

EdgeNet 为基准，并设置 3 组对照变体：C－a 组将整体网络架构替换为 SegFormer，但采用与 C 组完全相同的 AdamW 优化器、OneCycleLR 学习率调度策略和训练轮次，用于检验训练策略差异对模型性能比较的影响；C－b 组将 PhAT 模块替换为 3 个时相特征的简单平均融合，并去除月份编码和 FiLM 调制，用于分析物候感知时序融合模块的作用；C－c 组将编码器中的 CBAM 注意力模块替换为恒等映射，用于评估通道–空间注意力机制对多光谱特征表达的贡献。D 组则在 C 组基础上进一步引入 TrendEncoder 支路，用于验证 9 维物候趋势特征独立编码与逐尺度融合的增益。

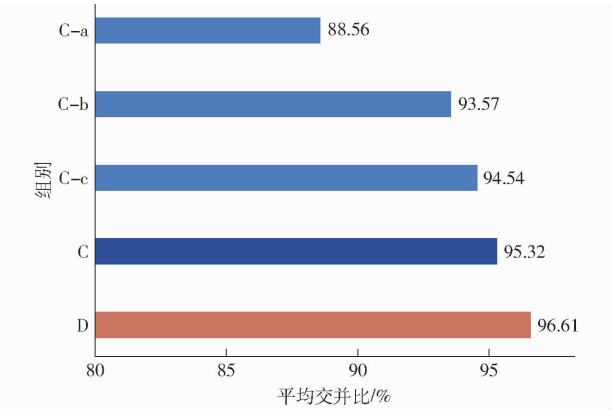

图 9　模块消融实验结果

Fig. 9　Results of ablation experiments

结果表明，C－a 组平均交并比为 88.56%，较 A 组中 SGD 配置下的 SegFormer（86.36%）提高 2.20 个百分点，但仍低于本文模型 C 组的 95.32%，说明统一优化策略虽能一定程度提升对比模型性能，但不足以解释 ST－EdgeNet 的整体优势。由此可见，本文方法的性能提升主要来源于面向冬小麦物候识别任务的架构设计，而非训练策略差异。完整模型始终优于各消融变体，进一步表明 PhAT、CBAM 及 TrendEncoder 等模块对提升冬小麦种植区识别精度均具有积极作用。

具体而言，在训练策略一致的前提下，ST－EdgeNet 仍明显优于通用分割架构，表明模型性能提升主要来源于结构设计而非单纯训练轮次差异。若以简单时序平均替代 PhAT，平均交并比下降 1.75 个百分点，说明物候阶段感知的时序融合对冬小麦识别具有关键作用；移除编码器注意力后，平均交并比下降 0.78 个百分点，说明多光谱特征的通道与空间联合注意力机制同样具有积极贡献。

综合来看，ST－EdgeNet 的性能提升来源于多个模块的协同作用：PhAT 主要负责增强关键物候阶段的时序感知与多时相信息利用效率，CBAM 主要提升多光谱特征的通道与空间表达能力，而 TrendEncoder 则进一步强化显式物候趋势特征的表达与融合效果。上述模块共同作用，使模型在空间独立测试区取得了更高的冬小麦种植区识别精度和更稳定的区域恢复能力。

3　讨论

3.1　物候特征增益与融合方式

本文结果表明，物候趋势特征能否转化为稳定的精度提升，关键不在于特征本身的设计，而在于模型是否为其提供了独立且有效的编码与融合路径。

A、B 组实验表明，3 个对比模型在引入相同 9 维物候趋势特征后平均增益极为有限，这源于通道拼接方式下通道数量占比约为 17.6%，其梯度贡献易受高维光谱特征主导，从而限制了显式物候特征的利用效率。相比之下，TrendEncoder 通过为物候特征建立独立梯度传播路径与专属编码空间，使其能够在相对独立的路径中参与分割决策。该结果从实验层面证明：对于具有明确农学意义的物候先验，仅在数据层面附加输入往往不足以形成稳定提升，仍需与之匹配的融合架构设计加以支撑。

3.2　物候特征贡献的层次性

逐特征贡献分析表明，9 维物候趋势特征对模型性能的影响存在明显差异，其中 F2（高值软判别）、F1（4 月 NDVI 原值）和 F5（NDRE 峰值突出度）贡献较大，是趋势增益的主要来源；F6 和 F8 则起到辅助判别作用；部分特征的独立贡献较弱，甚至在置零后出现轻微正向波动。

这一现象说明，物候特征并非“维度越多越好”，而是存在核心特征与辅助特征并存的层次化结构。结合相关性分析可以看出，F3、F4 和 F5 均用于刻画峰值突出度，组内相关性较强，其中 F5 基于红边波段构建，对叶绿素变化更敏感，因此表现出更高的判别价值。由此可见，部分低贡献特征并非完全无效，而是其信息已被同类更优特征覆盖。在模

型自动筛选机制作用下,保留一定冗余特征仍有助于提高复杂场景下的稳定性与鲁棒性。

3.3 各模块的协同作用

消融实验表明,ST - EdgeNet 的性能优势来源于多模块的协同作用,而非单一结构改进。C - a 实验中,在保持训练策略一致的条件下,以 SegFormer 替代本文整体结构后,平均交并比下降 6.76 个百分点,说明本文模型的提升主要来自结构设计本身。进一步分析可知,PhAT 替换为简单时序平均后,平均交并比下降 1.75 个百分点,表明关键物候阶段的差异化建模对于冬小麦识别具有重要作用;移除 CBAM 后,平均交并比下降 0.78 个百分点,说明通道与空间注意力机制有助于提升多光谱特征表达质量;引入 TrendEncoder 后,平均交并比进一步提高 1.29 个百分点,验证了独立趋势分支的有效性。

4 结论

(1)基于关中平原冬小麦 3—5 月关键生育阶段的 Sentinel - 2 多时相影像,构建了 9 维物候趋势特征。该特征体系从旺盛期高值、峰值突出度、返青速率、峰后变化及季节水分变化等方面表征冬小麦短时序物候变化过程,能够为冬小麦种植区识别提取提供有效先验信息。

(2)构建了融合物候趋势特征的时序感知网络 ST - EdgeNet。模型通过 PhAT 模块增强 3 个关键时相之间的物候信息交互,通过 TrendEncoder 支路实现 9 维趋势特征的独立编码与多尺度融合,避免了趋势特征在直接通道拼接中被高维光谱特征弱化的问题。实验结果表明,相比简单拼接方式,独立趋势编码与时序感知融合机制更有利于发挥显式物候特征在冬小麦种植区提取中的作用。

(3)在县级空间独立测试条件下,所提方法在典型农业景观样区中取得较高识别精度,表明其具有较好的跨县迁移能力。但由于样本覆盖比例和年份范围有限,模型在更大区域和多年份条件下的稳定性仍需进一步验证。

参 考 文 献

[1] Yang G X, Li X R, Liu P Z, et al. Automated in-season mapping of winter wheat in China with training data generation and model transfer[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023,202:422 - 438.

[2] 陈仲新, 任建强, 唐华俊, 等. 农业遥感研究应用进展与展望[J]. 遥感学报, 2016,20(5):748 - 767.
Chen Zhongxin, Ren Jianqiang, Tang Huajun, et al. Progress and perspectives on agricultural remote sensing research and applications in China[J]. National Remote Sensing Bulletin, 2016,20(5):748 - 767. (in Chinese)

[3] 刘哲, 刘帝佑, 朱德海, 等. 作物遥感精细识别与自动制图研究进展与展望[J]. 农业机械学报, 2018,49(12):1 - 12.
Liu Zhe, Liu Diyou, Zhu Dehai, et al. Review on crop type fine identification and automatic mapping using remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018,49(12):1 - 12. (in Chinese)

[4] Gomez C, White J C, Wulder M A. Optical remotely sensed time series data for land cover classification: a review[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016,116:55 - 72.

[5] Sun C K, Tao Y, Liu S L, et al. Automatic mapping of winter wheat planting structure and phenological phases using time-series Sentinel data[J]. Scientific Reports, 2024,14:17886.

[6] Dong Q, Chen X H, Chen J, et al. Mapping winter wheat in North China using Sentinel - 2A/B data: a method based on phenology-time weighted dynamic time warping[J]. Remote Sensing, 2020,12(8):1274.

[7] Zhang D Y, Fang S M, She B, et al. Winter wheat mapping based on Sentinel - 2 data in heterogeneous planting conditions [J]. Remote Sensing, 2019,11(22):2647.

[8] Song Y, Wang J. Mapping winter wheat planting area and monitoring its phenology using Sentinel - 1 backscatter time series [J]. Remote Sensing, 2019,11(4):449.

[9] Wang L M, Jin G W, Xiong X, et al. Object-based automatic mapping of winter wheat based on temporal phenology patterns derived from multitemporal Sentinel - 1 and Sentinel - 2 imagery[J]. ISPRS International Journal of Geo-Information, 2022, 11(8):424.

[10] 田欣媛, 张永红, 刘睿, 等. 考虑植被红边信息的多时相 Sentinel - 2 大范围冬小麦提取研究[J]. 遥感学报, 2022, 26(10):1988 - 2000.
Tian Xinyuan, Zhang Yonghong, Liu Rui, et al. Winter wheat planting area extraction over wide area using vegetation red edge information of multi-temporal Sentinel - 2 images[J]. National Remote Sensing Bulletin, 2022,26(10):1988 - 2000. (in Chinese)

[11] Liu X Y, Li X H, Gao L X, et al. Early-season and refined mapping of winter wheat based on phenology algorithms: a case of Shandong, China[J]. Frontiers in Plant Science, 2023,14:1016890.

[12] 冯权泷, 任燕, 姚晓闯, 等. 基于多源光学雷达数据融合的黄淮海平原冬小麦识别[J]. 农业机械学报, 2023,54(2): 160 - 168.
Feng Quanlong, Ren Yan, Yao Xiaochuang, et al. Identification of winter wheat in Huang - Huai - Hai Plain based on multi-source optical radar data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(2):160 - 168.

(in Chinese)

[13] 宋德娟，张承明，杨晓霞，等. 高分二号遥感影像提取冬小麦空间分布[J]. 遥感学报，2020,24(5):596－608.
Song Dejuan, Zhang Chengming, Yang Xiaoxia, et al. Extracting winter wheat spatial distribution information from GF－2 image[J]. National Remote Sensing Bulletin, 2020,24(5):596－608. (in Chinese)

[14] 郭交，王鹤颖，项诗雨，等. 基于多特征优化的 PolSAR 数据农作物精细分类方法[J]. 农业机械学报，2024,55(9):275－285.
Guo Jiao, Wang Heying, Xiang Shiyu, et al. Crop classification based on PolSAR data using multiple feature optimization[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(9):275－285. (in Chinese)

[15] Belgiu M, Csillik O. Sentinel－2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis[J]. Remote Sensing of Environment, 2018,204:509－523.

[16] Belgiu M, Bijker W, Csillik O, et al. Phenology-based sample generation for supervised crop type classification[J]. International Journal of Applied Earth Observation and Geoinformation, 2021,95:102264.

[17] Feng F, Gao M, Liu R, et al. A deep learning framework for crop mapping with reconstructed Sentinel－2 time series images[J]. Computers and Electronics in Agriculture, 2023,213:108227.

[18] Mohammadi S, Belgiu M, Stein A. Improvement in crop mapping from satellite image time series by effectively supervising deep neural networks[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023,198:272－283.

[19] Tucker C J. Red and photographic infrared linear combinations for monitoring vegetation[J]. Remote Sensing of Environment, 1979,8(2):127－150.

[20] Huete A R. A soil-adjusted vegetation index(SAVI)[J]. Remote Sensing of Environment, 1988,25(3):295－309.

[21] Jiang Z Y, Huete A R, Didan K, et al. Development of a two-band enhanced vegetation index without a blue band[J]. Remote Sensing of Environment, 2008,112(10):3833－3845.

[22] Harfenmeister K, Itzerott S, Weltzien C, et al. Detecting phenological development of winter wheat and winter barley using time series of Sentinel－1 and Sentinel－2[J]. Remote Sensing, 2021,13(24):5036.

[23] Cai W X, Tian J Y, Li X J, et al. A new multiple phenological spectral feature for mapping winter wheat[J]. Remote Sensing, 2022,14(18):4529.

[24] Liu M, He W, Zhang H Y. WPS: a whole phenology-based spectral feature selection method for mapping winter crop from time-series images[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2024,210:141－159.

[25] Li G, Cui J W, Han W T, et al. Crop type mapping using time-series Sentinel－2 imagery and U－Net in early growth periods in the Hetao irrigation district in China[J]. Computers and Electronics in Agriculture, 2022,203:107478.

[26] Li G, Han W T, Dong Y X, et al. Multi-year crop type mapping using Sentinel－2 imagery and deep semantic segmentation algorithm in the Hetao irrigation district in China[J]. Remote Sensing, 2023,15(4):875.

[27] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision(ECCV). Springer, 2018:3－19.

[28] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017,39(4):640－651.

[29] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). IEEE, 2017:6230－6239.

[30] Xie E Z, Wang W H, Yu Z D, et al. SegFormer: simple and efficient design for semantic segmentation with transformers[C]// Advances in Neural Information Processing Systems, 2021: 12077－12090.