

# 基于生长率编码器的作物时序广义分类研究

郭威, 马圣洁, 马兴录

(青岛科技大学 信息科学技术学院, 山东 青岛 266061)

**摘要:** 作物分类是农业遥感工作的基础任务之一; 在实际应用场景中, 作物的生育期会由于不同地区的气候、种植习惯等因素不同而出现较大差异; 现有的分类方法在跨地域、跨年份的数据上分类效果不佳, 模型的推广效果有限; 因此文章对地块级的卫星图像时间序列作物广义分类工作展开了研究, 提出了一种基于注意力机制的生长率编码器, 采用了积温映射生长率的方法, 将日历时间替换为归一化生长进度进行时序位置编码, 提升时序分类模型在跨地域、跨年份数据上的适应性; 通过对4个研究区的小麦、大豆、玉米等7种作物的数据集进行推理测试, 该方法整体准确率OA和F1分数分别达到了91.22%和83.47%, 证明该方法可以应对更复杂的数据, 能够显著提高分类模型的泛化能力。

**关键词:** 卫星遥感; 作物分类; SITS; 生长率; 注意力机制

## Research on Generalized Classification of Crop Time Series Based on Growth Rate Encoders

GUO Wei, MA Shengjie, MA Xinglu

(College of Information Science and Technology, Qingdao University of Science and Technology,  
Qingdao 266061, China)

**Abstract:** Crop classification is a fundamental task in agricultural remote sensing, but in practical applications, the growth period of crops has a great difference due to factors such as climate and cultivation practices in different regions. Existing methods have poor classification effects on the data across regions and years and limited model generalization effects. Therefore, research is conducted on the generalized classification of time-series crops for plot-level satellite images, and an attention-based growth-rate encoder for plot-level satellite time-series classification is proposed. The thermal-time mapping growth rate method is used to replace the calendar time with the normalized growth progress for temporal position encoding, enhancing the adaptability of temporal classification models across regions and years. Through reasoning tests on datasets of seven crops including wheat, soybeans, and corn in four regions, the results show that the approach achieves the overall accuracy (OA) and F1-score by 91.22% and 83.47%, respectively, demonstrating that this method can handle more complex data and significantly improve the generalization ability of classification models.

**Keywords:** satellite remote sensing; crop classification; satellite image time series (SITS); growth rate; attention mechanism

## 0 引言

近年来, 遥感技术与GIS (Geographic Information System) 被广泛应用于农业, 对地区农业生产的决策支持、宏观规划起到的指导作用愈发显著<sup>[1]</sup>。卫星遥感凭借其大范围观测的优势, 为农业生产的作物分类工作提

供了规模庞大的数据<sup>[2]</sup>。面对海量的遥感数据, 如何有效利用其时间、空间、光谱等特征信息提高作物分类算法的精度和可移植性, 成为了当前农业领域的研究问题<sup>[3-4]</sup>。

深度学习和计算机视觉技术在卫星遥感领域已实现成熟应用。鉴于作物生长具有显著的时序特性, 构

收稿日期: 2025-03-20; 修回日期: 2025-05-12。

基金项目: 国家自然科学基金面上项目(22374086); 山东省教育厅本科教改项目重点项目(Z2023152)。

作者简介: 郭威(2000-), 男, 硕士。

通讯作者: 马兴录(1970-), 男, 教授, 硕士。

引用格式: 郭威, 马圣洁, 马兴录. 基于生长率编码器的作物时序广义分类研究[J]. 计算机测量与控制, 2026, 34(3): 186-193.

建卫星图像时间序列 SITS (Satellite Image Time Series) 可以有效表示多时相卫星图像的时序演变特征。因此, 基于 SITS 的时序作物分类方法同样成为了研究的主流<sup>[5-7]</sup>。

时序分类模型的核心在于提取时间维度的特征关联性, 如局部特征分布和全局的特征变化趋势。模型需要在预处理阶段将数据按一定规律和顺序进行采样, 对数据进行分析。

本文针对 SITS 数据的常见问题设计了数据处理及增强方法, 并提出了一种基于注意力机制的生长率编码器 (GRE, growth rate encoder), 利用温度模型映射作物的生长进度, 将归一化的生长进度代替日历时间对时序信息进行位置编码, 实现了利用气象信息和作物的生长规律对跨地域、跨年份的作物分类。经实验验证, 本文提出的方法有效提高了农作物 SITS 分类模型的泛化能力。

## 1 国内外研究现状

为了对作物地块的特征在时间维度发生的变化进行学习, 国内外研究人员针对侧重于时间序列的深度学习模型展开了研究。在卷积神经网络的基础上提出的 3D-CNN 模型, 增加了时间维度的卷积, 同时捕捉多时相遥感图像空间和时间上的特征, 分类精度较二维的卷积神经网络更高, 并且在应对作物生长周期较长或生长变化较为复杂的区域时更加稳定<sup>[7]</sup>。

基于循环神经网络的时序特征提取研究, 将多时相卫星遥感图像进行序列化, 并利用循环神经网络 (RNN, recurrent neural network)、长短时记忆网络 (LSTM, long-short time memory) 等时序循环层对序列中每幅图像的时序变化特征进行分析, 进而对图像中每个像素进行分类<sup>[9-11]</sup>。

结合两种模型的优势, 利用卷积神经网络 (CNN, convolutional neural network) 提取每一幅卫星遥感图像的空间特征, 并在时间维度利用 LSTM 对每个时间点的空间特征进行分析, 可以实现对多时相卫星图像的视觉和时序特征的提取<sup>[8]</sup>。

但是时序卷积的卷积核只能提取局部特征, 难以捕捉序列中全局的时间依赖性, 无法有效理解时间序列中的先后顺序。时序 RNN 则是由于整幅遥感图像的信息过于复杂, 基于语义的时序模型训练复杂度过高, 对运算资源的消耗过大。RNN 普遍存在记忆长度的限制, 难以处理特征复杂的长序列数据。

随着 Transformer<sup>[12]</sup> 的提出, 注意力机制的全局上下文建模能力及其并行化计算优势引起了研究人员的广泛关注, 为 SITS 分类任务带来了全新的研究角度。基于注意力机制对 SITS 的日历时间进行编码, 可以实现

SITS 的全局时序特征提取<sup>[13-15]</sup>。结合注意力机制和轻量化时序卷积, GL-TAE 模型则可以同时进行全局和局部时序特征建模的<sup>[16]</sup>。

## 2 研究内容

### 2.1 问题分析

首先, 由于卫星传感器状况异常和多云天气等问题, 异常、极端的光谱信息对模型提取关键生育期光谱特征产生严重干扰, 因此需要对无法正常表示作物波段值的遥感数据进行清理。通常的清理方法为, 先检测地块的归一化植被指数 (NDVI, normalized difference vegetation index) 平均值, 将明显不属于裸土、植被覆盖的遥感影像从 SITS 中删除, 从而确保 SITS 数据的质量。

这种数据清洗方法会导致序列中的数据缺失, 使得序列的采样频率和长度存在很大差异, 传统的时序模型难以对时间维度尺度不一致的序列数据进行位置编码。同时, 由于时序注意力机制中每个序列的位置编码是固定的, 模型难以推广到数据集中没有出现过的序列类型, 导致模型的泛化能力难以提高<sup>[17]</sup>。

作物的生长过程可能呈现出相对一致的时序变化, 理论上在同一个地区或时期训练的模型有向不同地区或时期推广的可能性。但是由于不同地区在地理和气候上存在显著差异, 导致分类任务中的时序数据分布发生变化。例如, 不同地区分别种植春小麦与冬小麦, 种植季存在较大偏移, 由种植春小麦的场景下训练的分类模型并不能很好地应用到种植冬小麦的场景, 时序模型泛化能力较为有限。

其次, 由于不同地域气候存在差异, 时间序列整体会出现不同幅度的时间偏移。例如不同气候地区会分别种植春小麦和冬小麦, 春小麦的播种时间在 3 月至 5 月之间, 冬小麦的播种时间则在 10 月至 11 月, 且冬小麦的生育期较长, 通常到次年才会采收。这种现象使得忽略作物本身的生长特点的方法不利于分类模型向更多地区的进一步推广。

本文针对以上两个问题展开了研究, 并提出了改进方案。

针对 SITS 采样不规律、时序数据因筛选而缺失的问题<sup>[23-24]</sup>, 设计了针对时间序列的填充、对齐的数据预处理方法, 使输入的时序数据保持相同的尺度与采样频率, 并在此基础上设计了时序数据增强方法。

针对时序分类模型对不同地区农作物卫星图像时间序列分类精度差的问题, 设计了一种基于农业温度模型的时序编码方法, 使时序注意力模型中的位置编码具有农作物的生长规律特征, 从而实现分类模型的跨地域推广应用。

### 2.2 时序数据处理

针对 SITS 采样不规律的特点，时序数据预处理的过程中需要进行重采样和填充操作。

重采样操作需要设置固定起始日期、采样频率和目标序列最大长度，以这三项参数创建时序数据填充容器，并标注容器内每个元素的时间戳。对待处理的时序数据每个采样点的真实日历时间与目标时间戳计算时间差，选择时间差最小的采样点置入容器对应时间戳位置。此过程重复至时序数据全部置入容器。

此时，容器中可能存在未填入时序数据的位置。参考 Transformer<sup>[12]</sup> 的序列数据处理方法，为了保持输入的序列尺度一致，在预处理阶段会对序列填充常数或预测值。因此时序数据预处理可以通过向采样缺失的位置填充零向量，将序列填充至目标序列最大长度。该方法可以保证模型输入数据的尺度一致，并使原本采样不规律的 SITS 数据可以应用统一的时序位置编码规则。

针对 SITS 数据增强操作可以从图像和时序两个角度进行，本文主要探讨时间维度的数据增强方法。在训练集中引入更多时序种类，可以有效提高模型的分类精度，本文的数据重采样和填充操作可以使 SITS 数据具有一定的时序差异。现有的时序增强方法包括在时间维度的插值、遮挡、变形等操作，但大多集中于语音、医疗等领域，缺乏与农业生产特征的结合，难以适配作物 SITS 数据。例如动态时间规整 (DTW, dynamic time wrapping) 方法，对时间序列进行拉伸、收缩操作，虽然可以改变序列的尺度，但是破坏了作物生育期之间的实际依赖关系，导致模型提取到不可能存在的时序特征。

不同地域作物的种植季存在差异，导致 SITS 数据在时间维度发生偏移。如呼伦贝尔与华北地区，大豆、玉米等作物的种植季相差 30 天左右。为了解决目标数据与训练集数据之间存在不同幅度时序偏移的问题，通常采用 TimeMatch 方法对覆盖全年的 SITS 数据进行偏移预估和调整。TimeMatch 方法整体调整不同地域 SITS 数据的日历时间，使其在时间维度上全局固定对齐，实现对跨地域 SITS 数据的时序特征提取<sup>[20]</sup>。

基于 TimeMatch 方法，本文提出了针对填充 SITS 数据的数据增强技术：ShiftAug 和 ShakeAug。如图 1 所示。

由于不同年份和地域在同一时期的天气状况无法确定，当生育期内的气温或降水发生变化时，作物的生育期存在 5~30 天不等的偏差。本文提出的 ShiftAug 方法可以对时间序列进行适当幅度的偏移，调整序列中某一时刻之后数据的相对位置，模拟时序数据日历时间的整体偏差。该方法有助于模型学习 SITS 数据在时间维度的平

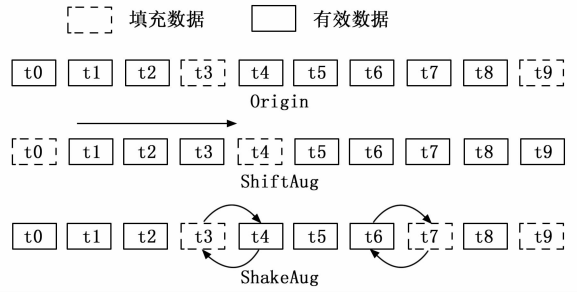


图 1 ShiftAug 方法和 ShakeAug 方法

移不变性特征，使模型适应具有时间偏移特征的 SITS 数据，提升模型鲁棒性。

由于序列数据存在缺失，数据往往无法完整表示作物的生育期，导致模型学习到的生育期依赖关系较为单一。ShakeAug 方法通过调换有效数据和填充数据位置，对数据的日历时间进行单位采样间隔的调整。在不影响生育期长期依赖关系的情况下，增加了关键生育期的有效数据在时序维度的分布，模拟作物关键生育期的局部波动，使训练出的模型更具鲁棒性。

### 2.3 像素集—生长率编码器 PSE-GRE

本文基于 PSE-TAE<sup>[13]</sup> 模型的编码器—解码器结构提出了 PSE-GRE 模型，模型结构如图 2 所示，主要包括数据读取和预处理模块、像素集编码器 (PSE, pixel-set encoder)、生长率编码器 (GRE, growth rate encoder) 和分类解码器。

PSE-GRE 网络的默认配置如表 1 所示，其中，像素集编码器由两个多层感知机和池化层构成，激活函数为 ReLU。

表 1 PSE-GRE 模型参数设置

模型	默认参数
PSE	
n	64
MLP <sub>1</sub>	4,32,64
MLP <sub>2</sub>	132,128
GRE	
de, dk, H	128,8,16
FC <sub>1</sub>	128,(32 × 2)
FC <sub>2</sub>	32,32
MLP <sub>3</sub>	128,128




图 2 PSE-GRE 结构图

在卫星遥感影像数据经过预处理之后, PSE 会提取采样天数  $T$  个地块图像通道数  $C$  中的  $N$  个有效像素, 形成地块随机像素集合  $S \in R^{C \times T \times N}$ 。随后对每幅影像的获取时间、地块的地理几何特征 (如地块周长、像素数等) 以及地域的气象信息进行标注, 再将得到的数据和标注作为原始数据  $x_0$ 。

PSE 将先从原始数据  $x_0$  中随机抽取  $n$  个像素, 在时间维度进行  $T$  次采样得到输入数据  $x_s \in R^{C \times T \times n}$ , 并将输入数据  $x_s$  通过多层感知机  $MLP_1$  提取特征  $\hat{e}_s^{(t)}$ :

$$\hat{e}_s^{(t)} = MLP_1[x_s^{(t)}] \quad (1)$$

为了实现地块内视觉特征的提取, PSE 将像素集的平均值和标准差作为全局像素特征, 对  $\hat{e}_s^{(t)}$  进行池化操作。随后将池化输出向量与地块的地理几何特征  $f$  进行拼接, 并通过多层感知机  $MLP_2$  嵌入, 最后输出该地块的像素特征编码的特征序列  $e^{(t)}$ :

$$e^{(t)} = MLP_2([\text{pooling}(\{\hat{e}_s^{(t)}\}_{s \in S}), f]) \quad (2)$$

生长率编码器基于时序注意力机制, 需要向每个元素添加位置编码向量作为输入序列的顺序信息。

本文根据农艺学中积温的相关理论<sup>[21]</sup>, 提出了一种通过作物所在地区的活动积温映射作物的生长进度的方法, 并设计了将日历时间替换为归一化生长率的生长率编码器。经实验验证, 这种方法对生育期差异较大的作物的分类精度显著提高。

关于温度与生长率的关系存在多种模型, 本文选取基于三基点原则的正弦温度模型来映射作物的生长进度<sup>[21]</sup>。其中  $T_{avg}$  为每日平均气温,  $T_b$  为生长限制温度。将每日的有效积温代入正弦温度模型并累加得到作物随时间推移和温度变化而生长的程度的  $Gsin(t)$ 。其中,  $d_e$  是像素特征序列  $e^{(t)}$  的维度,  $i$  是位置编码的坐标,  $T$  是 SITS 的最大长度:

$$AT = \sum_{i=1}^t \max(T_{avg} - T_b, 0) \quad (3)$$

$$Gsin = \sum_{i=1}^t AT \times \sin\left(\frac{\pi \times AT}{T_a - T_b}\right) \quad (4)$$

$$p^{(t)} = \left[ \sin\left(\frac{Gsin(t)}{Gsin(T)} \setminus \tau^{2i/d_e}\right) \right]_{i=1}^d \quad (5)$$

与 Transformer 将位置编码嵌入预训练的词作为输入类似, GRE 向 PSE 所输出的像素特征序列  $e^{(t)}$  嵌入位置编码  $p^{(t)}$  用作注意力机制的输入  $v^{(t)}$ , 再通过全连接层  $FC_1$  生成对应的查询键对:

$$v^{(t)} = e^{(t)} + p^{(t)} \quad (6)$$

$$q^{(t)}, k^{(t)} = FC_1^{(h)}[e^{(t)} + p^{(t)}] \quad (7)$$

将所有日期的查询在时间  $T$  维度的平均值通过全连接层  $FC_2$  进行处理, 构建为每个头的主查询  $\hat{q}_h$ :

$$\hat{q}_h = FC_2^{(h)}\{\text{mean}[(\hat{q}_h^{(t)})_{t=1}^T]\} \quad (8)$$

将每个头的主查询  $\hat{q}_h$  与序列中所有元素的键相乘

得到维度为  $T$  的注意力掩码  $a_h$ , 进而对嵌入的输入序列进行加权而得到输出  $o_h$ 。再通过多层感知机  $MLP_3$  将每个头的输出进行处理得到输入数据的时序特征向量:

$$o_h = \sum_{t=1}^T a_h[t] v^{(t)} \quad (9)$$

$$o = MLP_3[(o_1, \dots, o_h)] \quad (10)$$

## 2.4 可学习的位置编码

研究表明, 传统的位置编码方法限制了时序模型的泛化能力, 因此一些方法采用循环神经网络学习位置编码的序列特征, 并将其作为新的位置编码进行嵌入<sup>[22]</sup>。本文基于这种方法对生长率位置编码进行建模, 提取不同地区作物生长率的变化特征, 并与 PSE 输入的像素特征进行嵌入。通过加入对生长率编码学习的步骤, 模型可以有效结合作物的生长规律对 SITS 进行时序特征提取。

由于本文的 SITS 进行过填充, 基本的循环神经网络会受到零向量填充的影响。因此, 本文选用更适合处理缺失数据的  $\gamma$ LSTM<sup>[23]</sup> 对生长率编码进行处理, 其结构如图 3 所示。




图 3  $\gamma$ LSTM 结构图

$\gamma$ LSTM 在 LSTM 模型的基础上引入了衰减机制, 利用衰减系数对每个输入序列中的填充数据进行衰减。其中,  $r^{(t)}$  为衰减系数, 且  $r^{(t)} \in [0, 1]$ 。  $\delta^{(t)}$  为序列缺失标注, 由注意力机制的输入  $v^{(t)}$  确定填充观测值的位置及连续填充长度, 并由公式 (11) 确定衰减系数  $r^{(t)}$ :

$$r^{(t)} = e^{-\max(w_r \delta^{(t)} + b_r, o)} \quad (11)$$

$$\hat{C}^{(t-1)} = r^{(t)} C^{(t-1)} \quad (12)$$

$$\hat{h}^{(t-1)} = r^{(t)} h^{(t-1)} \quad (13)$$

$\gamma$ LSTM 利用衰减系数对输入的位置编码  $p^{(t)}$  进行修正, 结合缺失向量  $m^{(t)}$  对输入的的进行标注, 得到  $\hat{p}^{(t)}$ 。中间值  $\tilde{p}^{(t)}$  的求解如 (15), 为第  $n$  个变量的观测均值:

$$\hat{p}^{(t)} = m^{(t)} p^{(t)} + [1 - m^{(t)}] \tilde{p}^{(t)} \quad (14)$$

$$\tilde{p}^{(t)} = r_n^{(t)} p^{(t-1)} + [1 - r_n^{(t)}] \tilde{p}_n \quad (15)$$

$$\tilde{p}_n = \frac{\sum_{t=1}^T m_n^{(t)} p_n^{(t)}}{\sum_{t=1}^T m_n^{(t)}} \quad (16)$$

此时  $\gamma$ LSTM 的计算过程表示为:

$$i^{(t)} = \sigma\{W[\hat{p}^{(t)}, \hat{h}^{(t-1)}, m^{(t)}] + b_i\} \quad (17)$$

$$f^{(i)} = \sigma\{W[\hat{p}^{(i)}, \hat{h}^{(i-1)}, m^{(i)}] + b_f\} \quad (18)$$

$$\hat{C}^{(i)} = \tanh\{W[\hat{p}^{(i)}, \hat{h}^{(i-1)}, m^{(i)}] + b_c\} \quad (19)$$

$$C^{(i)} = f^{(i)} \hat{C}^{(i-1)} + i^{(i)} \hat{C}^{(i)} \quad (20)$$

$$o^{(i)} = \sigma\{W[\hat{p}^{(i)}, \hat{h}^{(i-1)}, m^{(i)}] + b_o\} \quad (21)$$

$$h^{(i)} = o^{(i)} \tanh[C^{(i)}] \quad (22)$$

通过  $\gamma$ LSTM 的学习之后, 将得到的输出  $o^{(i)}$  作为公式(6)中的位置编码  $p^{(i)}$  与空间特征  $e^{(i)}$  进行嵌入。

同样的, 本文在种植了不同品种作物的研究区上也进行了推理实验, 如春小麦与冬小麦, 证明了通过学习生长率的特征并嵌入时序特征的方法可以有效提高模型对不同品种作物时序特征的提取能力, 并在填充数据的场景下保持了较好的分类效果。

### 3 实验与结果分析

#### 3.1 数据采集与处理

为了评估 PSE-GRE 模型在不同地域的泛用性, 本文选择位于内蒙古自治区呼伦贝尔岭南和岭北共 23 个农场(北纬  $47^{\circ}05' \sim 53^{\circ}20'$ , 东经  $115^{\circ}13' \sim 126^{\circ}04'$ , 位于寒温带, 年活动积温在  $2\ 200 \sim 2\ 800$  之间)、河南省安阳市内黄县(北纬  $35^{\circ}39'$  至  $36^{\circ}09'$ , 东经  $114^{\circ}35'$  至  $114^{\circ}59'$ , 位于温带, 年活动积温在  $5\ 200 \sim 5\ 700$  之间)以及河北省雄安新区(北纬  $38^{\circ}43' \sim 39^{\circ}10'$ , 东经  $115^{\circ}38' \sim 116^{\circ}20'$ , 位于暖温带, 年活动积温在  $5\ 000 \sim 5\ 200$  之间)作为研究区。

由于这三个研究区处于不同的温度带内, 因此作物品种的生育期存在一定的差异。呼伦贝尔地区的小麦为春小麦, 与玉米、大豆的生育期同处于 5 月至 10 月; 内黄县的小麦品种为冬小麦, 生育期于 10 月至次年 6 月, 玉米和大豆与小麦轮作, 生育期于 7 月至 10 月; 雄安新区的小麦同样为冬小麦, 生育期于 10 月至次年 6 月, 玉米生育期于 6 月至 10 月。

将采集到的数据按研究区划分为呼伦贝尔岭南 LN, 呼伦贝尔岭北 LB, 内黄县 NH, 以及雄安新区 XA。LN 包含的主要作物为大豆、玉米, LB 包含的主要作物为小麦、油菜、油菜、甜菜、水飞蓟和马铃薯, NH 包含的主要作物为小麦、大豆和玉米, XA 包含的主要作物为小麦和玉米。

本文实验将各研究区的数据整合在一起形成数据集, 并按年份进行划分, 将 2023 年的数据作为模型的训练集, 将 2022 年的数据作为测试集, 以此来证明提出的同时具有时间和地域的推广能力。

数据采集选用 Sentinel-2 (哨兵 2 号高分辨率多光谱成像卫星) 进行遥感数据获取, Sentinel-2 拥有 A、B 两颗卫星, 自 2015 年升空便持续不断地提供地表遥感影像并广泛应用于土地覆盖检测工作。选择研究区内于 2022 和 2023 年每 5 天拍摄的 10 米分辨率的遥感影像作

为原始数据(部分地区包含 2021 年影像), 保留红、绿、蓝和近红外四个光谱通道, 通过算法对遥感影像进行拼接、去云、地块级裁剪和标注等操作, 生成地块序列如图 4 所示。最终标注数据集共 37 141 个地块序列, 标注结果如表 2 所示。




图 4 数据采集和处理

表 2 各研究区作物类别标注信息

类别	小麦	大豆	油菜	甜菜	水飞蓟	马铃薯	玉米
	0	1	2	3	4	5	6
LB	7 392	48	7 731	888	1 355	459	71
LN	193	11 605	0	0	0	0	3 885
NH	1 284	324	0	0	0	0	469
XA	598	0	0	0	0	0	839
ALL	9 467	11 977	7 731	888	1 355	459	5 264

气象数据采用 ECMWF (欧洲中期天气预报中心) 提供的 ERA5 数据集 AgERA5, 该数据集提供了自 1979 年至今的每日地面气象数据, 选取各研究区的每日平均气温计算活动积温与生长率。

#### 3.2 评价指标

本研究的对象为地块级遥感影像时间序列, 为了准确地评估模型的分类效果, 本实验采用总体分类精度(OA)、F1 分数(F1-score)来评估分类结果。

OA 表示分类正确的样本数占总样本数的比例:

$$OA = \frac{TP}{TP + FP + FN} \quad (23)$$

F1-score 可以有效反映模型对每个分类类别的分类性能:

$$F1 = 2 \times \sum_{i=1}^n \frac{Precision_i \times Recall_i}{Precision_i + Recall_i} \quad (24)$$

#### 3.3 消融实验

为了验证 ShiftAug、ShakeAug 增强方法以及 GRE 在测试集中每个研究区测试集上的有效性, 实验将以 PSE-TAE 为基线模型, 分别加入 ShiftAug、ShakeAug 以及 GRE 方法测试这些方法的有效性。实验在 LN、LB、NH 和 XA 四个数据集的融合数据集的训练集上分别训练模型, 并在其测试集上进行消融实验。消融实验结果如表 3 所示, 其中对不同场景下每个研究区数据集和整体融合数据集下的分类整体准确率和 F1 分数。

表 3 数据增强和 GRE 的消融实验结果

Method	LN		LB		NH		XA		Avg.	
	OA	F1	OA	F1	OA	F1	OA	F1	OA	F1
PSE-TAE	82.23	69.75	77.34	52.63	82.06	61.56	80.41	73.37	80.51	64.33
+ShiftAug	85.9	71.81	82.81	67.31	86.05	73.52	85.24	72.16	85.0	71.20
+ShakeAug	88.14	74.75	84.75	69.54	84.35	67.92	84.67	73.76	85.48	71.49
+Shake_Shift	90.64	82.04	87.91	74.94	87.29	76.33	86.81	74.72	88.16	77.01
PSE-GRE	89.9	75.71	87.0	72.89	86.85	72.66	86.72	74.82	87.62	74.02
+Shake_Shift	92.54	91.33	88.86	82.47	92.45	81.16	90.98	78.92	91.22	83.47

消融实验结果显示, ShiftAug 方法将这些研究区的 SITS 数据进行了平移规整, ShakeAug 方法增加了时序数据中不同生育期的特征多样性, 使模型学习到了动态的生育期特征, 两种方法均有效提升了多数地区作物的分类效果。具体而言, PSE-TAE 模型在加入数据增强方法后,  $F1$  分数较默认方法分别提升了 6.87% 和 7.16%, 且在联用两种增强方法时  $F1$  分数平均增加了 12.68%。

在使用生长率位置编码的场景下, 生长率编码器将不同研究区的积温与时序像素特征进行了嵌入, 有效捕获了不同地区作物的生长规律特征, 分类结果相比于 PSE-TAE 的  $F1$  分数平均增加了 9.69%, 然而与同时使用两种数据增强方法, 即 Shake\_Shift 的场景相比却减少了 2.99%。单独使用生长率位置编码的效果并没有达到预期, 因此又增设了同时应用两种方案的实验场景, 最终  $F1$  分数较提升了 6.46%。

为进一步验证可学习位置编码的有效性, 消融实验还对比了未使用生长率编码器的 TAE、以生长率直接替代日历时间的 GRE-Sin、通过 GRU 学习位置编码的 GRE-GRU 和通过  $\gamma$ LSTM 学习位置编码的 GRE- $\gamma$ LSTM 这四个模型在融合数据集上的分类效果。实验结果如表 4 所示。

表 4 可学习位置编码有效性的评估结果

Model	OA	F1	Training(s/epoch)
TAE	80.51	64.33	34.7
GRE-Sin	81.21	64.72	34.2
GRE-GRU	84.94	62.94	49.6
GRE- $\gamma$ LSTM	87.62	74.02	54.5

表 4 结果显示, 采用生长率直接代替日历时间的 GRE 模型效果与 TAE 模型相比, OA 和  $F1$  分数有小幅提升。相比之下, 采用可学习位置编码的模型, 虽然训练速度有所延缓, 但分类效果提升明显。GRE- $\gamma$ LSTM 模型分类效果最佳, GRE-GRU 模型的 OA 较 GRE-Sin 模型提升了 3.73%, 但  $F1$  分数下降了 1.78%, 完整的可学习位置编码与 GRE 提取缺失时序数据的依赖关系存在偏差, 而通过衰减机制学习的位置

编码有效避免了这一问题影响。

以上消融实验的结果表明, ShiftAug 方法和 ShakeAug 方法均可以提升模型分类效果。同时, 引入可学习位置编码的 GRE 模型通过学习生长率编码的时序特征能够提高模型的泛化能力。在同时引入数据增强方法和 GRE 模型后, 模型可以取得最佳分类效果。

### 3.4 对比实验

为了验证本文方法较其他模型的推广泛化能力更加优秀, 实验选取了基线模型 PSE-TAE 以及 GL-TAE、TSViT、TempCNN 四种时序分类模型进行对比。实验在 LN、LB、NH 和 XA 这 4 个数据集的融合数据集的训练集上分别训练模型, 并在其测试集进行对比试验。对比试验结果如表 5 所示, 其中列举了各模型在融合数据集上的 OA、 $F1$  分数、每 epoch 的训练时间 Training 和在测试集上推理时的内存占用 Memory。

表 5 各模型在数据集上的评估结果

Model	OA	F1	Training	Memory
PSE-GRE	91.22	83.47	54.5	8.6
GL-TAE	84.73	62.15	46.4	13.4
PSE-TAE	80.51	64.33	34.7	6.7
TSViT	78.67	69.8	376.7	24.5
TempCNN	76.2	53.7	329.5	18.5

对比实验结果显示, PSE-GRE 模型分类结果较其他模型更优秀, 但是训练时间有所增加。具体来说, PSE-GRE 与其他模型中表现最优秀的 GL-TAE 模型进行对比, 在 OA 和  $F1$  分数上分别提升了 2.89% 和 11.87%。

GL-TAE 可以同时提取到 SITS 的全局时序特征和局部时序特征, 并且平均了两种方法提取特征的像素通道数量, 保持了较高的运行速度。局部时序特征提取模块的轻量化时序卷积可以提取到生育期存在偏移的作物种类的序列特征, 但是其对于云层覆盖和填充数据的抗性较差, 导致模型存在对插值数据过于敏感的现象。

从对比试验中选择 PSE-GRE、PSE-TAE 和 GL-TAE 3 个模型进行更加详细的评估, 各模型在所有种类的分类评估结果如表 6 所示。对比结果显示, PSE-




图 5 混淆矩阵

GRE 方法在大多数作物的分类  $F1$  分数上表现更加优秀。而在样本数量较小的种类上, 3 个模型的分类效果均不佳。

表 6 测试集所有作物种类  $F1$  分数评估

作物	PSE-GRE	PSE-TAE	GL-TAE	Support
小麦	97.32	87.65	82.43	3 190
大豆	88.36	71.42	65.23	2 313
油菜	95.42	84.65	79.56	3 183
甜菜	68.81	58.37	60.12	386
水飞蓟	77.70	75.75	73.21	478
马铃薯	53.38	57.33	59.84	165
玉米	81.14	80.73	74.29	1 276

举例来说, 由于测试集中的小麦种类包括春小麦与冬小麦, 因此数据集中小麦的生育期存在差异。结果显示, PSE-TAE 可以很优秀地提取小麦不同品种之间生育期的共同点, 但 PSE-GRE 的  $F1$  分数依然高出了 9.67%, 说明生长率编码器可以更好地提取到不同季节种植的作物的时序特征。

图 5 为 3 个模型分类结果的混淆矩阵, 图 6 为 3 个模型在岭北地区的拉布大林、谢尔塔拉和岭南地区的欧肯河 3 个农场的分类效果对比图, 从左到右依次为地块原图、真实值标注、PSE-TAE、GL-TAE 和 PSE-GRE 模型的分类标注。

结合图 5 和图 6 的结果可以观察到, PSE-TAE 和 GL-TAE 模型的分类结果中均出现了大豆与其他跨地域种类混淆的情况。根据数据集标注情况和表 6 中的  $F1$  分数评估结果可知, 大豆种类的样本在数据集中占据较大比例, 由于大豆种类的生育期与其他地域种类作物重合度较高, 这可能会导致时序模型对小样本种类的特征提取不够充分, 从而影响整体的分类精度。而在 PSE-GRE 的分类效果图中, 这种现象明显减少, 说明由于结合了作物生长率的时序特征, 生长率编码器可以在一定程度上避免在分类时由于样本数量不平衡而导致的跨地域分类错误。

然而本实验并未针对数据不平衡的情况本身进行调整, 模型可能存在对小样本种类的过拟合问题。后续将针对小样本作物 SITS 分类场景, 结合迁移学习、无监督学习等技术展开研究。

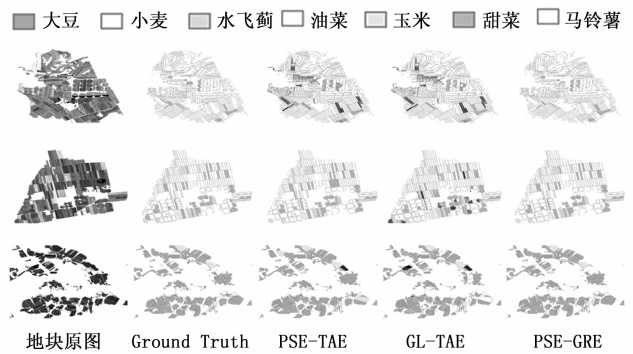


图 6 3 种模型分类效果对比图

### 4 结束语

本研究基于地块级卫星遥感影像时间序列, 结合地理信息和气候信息对农作物的生育期进行建模, 提出了 ShiftAug、ShakeAug 数据增强方法和 GRE 生长率位置编码方法, 将作物的生长率趋势嵌入像素特征得到与生长进度相关的时序特征, 实现了时序模型对跨年份、跨地域数据分类任务的推广, 并提高了分类结果的精确度。在多地域农作物数据集上的对比实验表明, 本文的方法总体分类精度达到了 91.22%,  $F1$  分数达到了 83.47%, 较其他对比模型都有一定的提升, 也验证了本文的方法拥有更优秀的推广能力。

尽管本文的方法在很大程度上提高了时序模型的泛化能力, 但在小样本的作物种类分类效果并不理想, 对于类别分布不平衡的数据集可能存在过拟合等问题。此外, 影响作物生长的不只有气温因素, 并且不同作物在不同积温条件下的生长模型也存在差异, 本文仅验证了利用积温推算通用生长率的方法, 并未完整地将作物的生长规律在卫星遥感中的特征进行更加准确地建模。同时, 由于衰减 LSTM 的引入, 导致模型的训练速度有

所下降。探索结合更多气象因素和作物生长模型来更加准确地对作物生长规律进行建模, 继续推进基于注意力机制的时间序列分类模型的推广是接下来主要研究的方向。

#### 参考文献:

- [1] 闻 天, 马振芳, 李光燕. 基于 GIS 可视化技术的物联网边缘计算在农业智能化管理中的应用 [J]. 集成电路应用, 2024, 41 (7): 134 - 135.
- [2] 郝永征. 基于 GIS 的农业耕地质量等级评价系统的设计 [J]. 农业工程技术, 2024, 44 (19): 63 - 64.
- [3] HU WEI, et al. Deep convolutional neural networks for hyperspectral image classification [J]. Journal of Sensors 2015, 1 (2015): 258619.
- [4] 刘雅举, 张 莉, 李东明, 等. 计算机视觉在农作物管理方面的应用研究 [J]. 科技情报开发与经济, 2007 (21): 158 - 159.
- [5] SHEN HUAFENG, et al. Missing information reconstruction of remote sensing data: a technical review [J]. IEEE Geoscience and Remote Sensing Magazine 3.3 (2015): 61 - 85.
- [6] MILLER L, PELLETIER C, WEBB G I. Deep learning for satellite image time-series analysis: a review [J]. IEEE Geoscience and Remote Sensing Magazine, 2024.
- [7] JI S, ZHANG C, XU A, et al. 3D convolutional neural networks for crop classification with multi-temporal remote sensing images [J]. Remote Sensing, 2018, 10 (1): 75.
- [8] ZHONG L H, HU L N, ZHOU H. Deep learning based multi-temporal crop classification [J]. Remote Sensing of Environment, 2019, 221: 430 - 443.
- [9] SUN, ZIHENG, LIPING DI, HUI FANG. Using long short-term memory recurrent neural network in land cover classification on landsat and cropland data layer time series [J]. International Journal of Remote sensing 40.2 (2019): 593 - 614.
- [10] EMILE NDIKUMANA, DINH HO TONG MINH, NICOLAS BAGHDADI, et al. Deep recurrent neural network for agricultural classification using multitemporal SAR Sentinel-1 for Camargue, France [J]. Remote Sensing, 10 (8): 1217, 2018. 1, 2.
- [11] MARC RUWURM and MARCO KORNER. Temporal vegetation modelling using long short-term memory networks for crop identification from medium-resolution multi-spectral satellite images [C] //In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2017: 11 - 19.
- [12] VASWANI A. Attention is all you need [Z]. Advances in Neural Information Processing Systems, 2017.
- [13] GARNOT V S F, LANDRIEU L, Giordano S, et al. Satellite image time series classification with pixel-set encoders and temporal self-attention [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 12325 - 12334.
- [14] GARNOT V S F, LANDRIEU L. Lightweight temporal self-attention for classifying satellite images time series [C] //Advanced Analytics and Learning on Temporal Data: 5th ECML PKDD Workshop, AALTD 2020, Ghent, Belgium, September 18, 2020, Revised Selected Papers 6. Springer International Publishing, 2020: 171 - 181.
- [15] TARASIOU M, CHAVEZ E, ZAFEIRIOU S. Vits for sits: Vision transformers for satellite image time series [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023: 10418 - 10428.
- [16] ZHANG W, ZHANG H, Zhao Z, et al. Attention to both global and local features: A novel temporal encoder for satellite image time series classification [J]. Remote Sensing, 2023, 15 (3): 618.
- [17] LU W, WANG J, Sun X, et al. Out-of-distribution representation learning for time series classification [J]. ArXiv Preprint ArXiv: 2209.07027, 2022.
- [18] VALERO, SILVIA, CHARLOTTE PELLETIER, MARINA BERTOLINO. Patch-based reconstruction of high resolution satellite image time series with missing values using spatial, spectral and temporal similarities [J]. 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), IEEE, 2016.
- [19] PELLETIER, CHARLOTTLE GEOFFREY I. WEBB, FRANCOIS Petitjean. Temporal convolutional neural network for the classification of satellite image time series [J]. Remote Sensing 11. 5 (2019): 523.
- [20] NYBORG J, PELLETIER C, LEFÈVRE S, et al. TimeMatch: Unsupervised cross-region adaptation by temporal shift estimation [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 188: 301 - 313.
- [21] 马欣甜, 何英彬, 林泽儒, 等. 作物生长模型物候建模的函数解析及应用研究 [J]. 天津农业科学, 2023, 29 (7): 6 - 14.
- [22] LIU XUANQING, et al. Learning to encode position for transformer with continuous dynamical model [J]. International Conference on Machine Learning, PMLR, 2020.
- [23] 孙晓丽, 郭 艳, 李 宁, 等. 基于改进 RNN 的多变量时间序列缺失数据填充算法 [J]. 信息技术与网络安全, 2019, 38 (11): 47 - 53.