

李论, 徐杨, 王义, 等. 基于多级小波分解时间序列的花椒图像分类识别模型[J]. 智能计算机与应用, 2024, 14(5): 235-240.  
DOI: 10.20169/j.issn.2095-2163.240533

# 基于多级小波分解时间序列的花椒图像分类识别模型

李论<sup>1</sup>, 徐杨<sup>1</sup>, 王义<sup>2</sup>, 王天一<sup>1</sup>, 蒋宁<sup>3</sup>

(1 贵州大学 大数据与信息工程学院, 贵阳 550025; 2 中国电信股份有限公司贵州分公司, 贵阳 550001;

3 贵州玄德花椒产业发展有限公司, 贵阳 550018)

**摘要:** 为提升花椒图像分类识别准确率, 借助自适应多级小波分解的时间序列分类(Adaptive Multi-level Wavelet Decomposition based neural network, AMWDNet)模型, 着重关注此分类模型中的频域信息, 克服从时域出发对目标序列进行建模造成频域信息缺失的瓶颈。本研究借鉴小波分解技术, 结合长、短期时间模式提取方法, 构建出更加精确、更加实时的时间序列花椒识别模型。经过对比试验研究发现, 在 UCR 数据库中的 4 个数据集测试上, AMWDNet 模型表现出优异的分类性能和强大的泛化能力, 超过其他 3 个基准模型, 由此提升花椒图像分类识别准确率。

**关键词:** 花椒图像分类; 时间序列分类; 小波分解; 时频信息; 准确率

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2024)05-0235-06

## Time series classification and recognition method for zanthoxylum bungeanum maxim based on multilevel wavelet decomposition

LI Lun<sup>1</sup>, XU Yang<sup>1</sup>, WANG Yi<sup>2</sup>, WANG Tianyi<sup>1</sup>, JIANG Ning<sup>3</sup>

(1 College of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China; 2 China Telecom Guizhou Branch, Guiyang 550001, China; 3 Guizhou Xuande Zanthoxylum Bungeanum Maxim Industry Development Co., Ltd., Guiyang 550018, China)

**Abstract:** To improve the accuracy of zanthoxylum bungeanum maxim image classification and recognition, the Adaptive Multi-level Wavelet Decomposition based neural network (AMWDNet) model is utilized to focus on the frequency domain information in this classification model, overcoming the bottleneck of missing frequency domain information caused by modeling the target sequence from the time domain. This study draws on wavelet decomposition technology and combines long and short-term time pattern extraction methods to construct the more accurate and real-time time series zanthoxylum bungeanum maxim recognition model. After comparative experimental research, it is found that the AMWDNet model demonstrates excellent classification performance and strong generalization ability on four datasets tested in the UCR database, surpassing the other three benchmark models. This research improves the accuracy of zanthoxylum bungeanum maxim image classification and recognition.

**Key words:** zanthoxylum bungeanum maxim image classification; time series classification; wavelet decomposition; time-frequency information; accuracy rate

## 0 引言

随着人工智能、大数据和物联网技术在智慧农业领域广泛运用, 智慧农业种植生产正逐渐向着智能、高效的方式加速迈进。在中国, 花椒 (Zanthoxylum Bungeanum Maxim, ZBM) 作为一种常见的经济农作物, 有着种类繁多、难以归类, 且分类

工作主要依靠纯手工操作, 再加上花椒树枝上密布尖刺, 且枝叶杂乱, 极易造成分类不准确, 为此投入了更大的人工成本, 但实际产出较低等情形<sup>[1-4]</sup>; 尤其在贵州山地、丘陵地带种植和加工成本投入巨大, 且收益缓慢, 如图 1 所示。基于此, 随着新兴技术的飞速发展, 大量专家和学者对时间序列分类问题利用在花椒图像分类识别上有了更多关注, 以此得到高度

基金项目: 贵州省科技计划项目(黔科合支撑[2021]一般 176)。

作者简介: 李论(1984-), 男, 博士, 副教授, 主要研究方向: 机器学习, 智能图像处理。

通讯作者: 王义(1997-), 男, 助理工程师, 主要研究方向: 智能计算, 机器学习。Email: ywang\_gzu@163.com

收稿日期: 2024-03-06

重视。然而,时间序列是一种极其特殊的数据类型,是按照时间顺序对观测到的数据点进行排列,是连续观测事物随时间变化所得到的有序样本集合。



图1 贵州山地花椒种植样例

Fig. 1 Samples of *zanthoxylum bungeanum maxim* planting of mountains in Guizhou Province

时间序列大量存在于日常生活中的许多地方,例如在金融领域、交通领域、生物医学领域等<sup>[5-7]</sup>,随着物联网以及传感器等技术的飞速发展,时间序列数据在各行业中表现出重要应用价值。时间序列数据中蕴藏着丰富的信息内容,这为研究人员提供了深入洞察问题本质和规律的宝贵资源。通过构建适当的模型和分析技术,能够更容易地揭示这些隐藏的信息,并为后期决策提供有力支持。常见的的时间序列分类模型主要依靠于形状比较、时域分析,以及变化趋势的相似性度量。进而,此类常规的分类模型对时间序列的处理存在明显的局限性<sup>[8]</sup>,且不利于场景运用极易导致分类效果不佳。相比之下,机器学习与神经网络提供了一种更为灵活有、且强大的分类工具,能够根据不同的业务场景定制特征提取自然规则输出理想模型。然而,特征工程在机器学习中具有至关重要的作用;一个优秀的特征提取策略能够显著提升模型的性能和速度,进而影响到花椒图像识别的准确率。因此,在设计特征提取规则时,需要细致考虑并结合具体问题需求背景,以确保最终模型能够达到预期的性能水平及检测速度。

此外,随着深度学习与神经网络的迅速发展,已陆续推出许多具有影响力的深度学习方法来研究时间序列分类问题。当前方法中,有一些无需对时序数据进行复杂的特征提取和繁琐的预处理,而是采用了纯端到端的学习方式,这种简洁而高效的学习方法使得应用范围更加广泛。如文献[9]中使用全卷积网络(FCN)和残差网络(ResNet)进行时间序列分类,直接将原始的时间序列作为输入,获得的分类效果相对于其他模型方法已经达到了非常好的水平。又如在文献[10]中,提出了一种长短期记忆完全卷积网络(LSTM-FCN),该模型大大提高了FCN

的性能,并且对数据集的预处理要求也不高,后续又通过引入探索注意力机制,使其注意力机制的ALSTM-FCN能更好地改善和提升时序分类效果。虽然此类方法确实从时域的方向对序列进行了建模,同时努力捕捉序列的基本时间特征,但却仍然无法充分发掘和利用其中蕴含的丰富潜在信息。这些潜在信息对于全面理解时间序列的特性和规律至关重要。特别是,该类方法并未深入探索时间序列中隐含的周期性、长期趋势和季节性变化等重要特征。这些方法在全面挖掘时间序列信息方面尚显不足。

为了解决花椒的图像分类问题,本文利用时间分类序列的多级小波变换,将自适应多级小波分解的时间序列分类识别算法<sup>[11-14]</sup>(AMWDNet)应用在花椒的图像分类识别中,建立一种花椒图像分类模型,进一步自适应地提出多级的时频特征,从而能从图像层面对花椒树、果实、形状、大小和颜色等特征进行精准分类,达到更优异的分类结果,同时也节省了人工分类的劳动力和成本。

## 1 相关研究

在探讨时间序列分类领域,目前采用的主流方法主要涉及特征提取、距离量度、集成学习以及深度学习技术<sup>[15-17]</sup>。在这些方法中,特征基方法通过抽取时间序列的关键特征,并以此作为分类器的输入,进而得出分类决策。然而,基于特征的方法存在仍需突破的局限性,其泛化性能通常较低;这就意味着对于不同的问题,需要精心设计和选择适合的时间序列特征表示后才能进行分类;因此,整个过程相对复杂、且依赖于特定的领域知识。

另一方面,评估2个序列的相似性可以采取基于距离的方法,这种相似性度量经过处理后可以经过分类器处理,由此得到最终的分类结果。在分类器选取上,频繁被选取的分类器包括支持向量机和K近邻等。在选择距离度量时,最重要的一点就是找到一种既合理又有效的方式,而欧式距离和动态时间规整等<sup>[18]</sup>则是2种被广泛使用的距离度量方法。但是,即使这2种方法计算相对简单且易于理解,但在处理大规模数据集时,其时间复杂度和空间复杂度较高,这在一定程度上限制了其在大数据环境下的应用。此外,基于集成学习方法则是综合多个分类器的预测,通过整合这些预测来提升分类的准确性。例如,COTE算法就集中了35种不同的分类器<sup>[19]</sup>,并通过加权方式整合各分类器的预测结果,进而得出最终的分类决策。

针对上述问题, 本文采用 AMWDNet 方法对时间序列中的花椒图像进行分类研究。该模型的创新之处在于首先采纳多级自适应小波分解技术, 此方法能够精确地从时间序列中解析出低频和高频特征; 使得模型在后续的步骤中, 可以更精确地把握数据的全局和局部特性。进而, 通过专门的长期和短期时间模式提取模块, 使得该模型能够敏锐地捕捉到时间序列的长期趋势和短期波动, 从而更全面地揭示数据的内在规律。最后, 模型将这些不同层级的预测结果进行有效融合处理, 得出最后的预测结果。此模型的应用有效提高了花椒图像分类的准确性和效率。

## 2 模型介绍

### 2.1 离散小波分解

离散小波变换 (DWT) 是一种普遍应用于多个领域的技术, 涵盖数字信号处理、语音信号分析和模式识别等<sup>[20-21]</sup>。该技术具有独特的分解能力, 能够将输入的时间序列细分为低频和高频部分。其中, 低频部分主要反映了时间序列的整体趋势和轮廓, 为研究提供了宏观的视角; 而高频部分则详细捕捉了数据中的局部变化和细节信息, 为深入分析提供了依据。Mallat 算法<sup>[22]</sup> 作为一种典型的离散小波变换方法, 在对需要分析的序列进行处理时, 采取了  $H$  和  $G$  这 2 组小波滤波器进行分解; 而在重构过程中, 则依赖  $h$  和  $g$  滤波器来完成; 这种方法在信号处理和数据分析中得到了广泛的应用。其计算模型机制如下:

$$A_0[S(t)] = S(t) \quad (1)$$

$$A_i[S(t)] = \sum_k H(2t - k) A_{i-1}[s(t)] \quad (2)$$

$$D_i[S(t)] = \sum_k G(2t - k) A_{i-1}[s(t)] \quad (3)$$

其中,  $t$  表示时间序列中的时刻;  $s(t)$  表示需要处理的时间序列;  $i$  表示小波分解的层数;  $H$  和  $G$  分别表示为低通滤波器和高通滤波器;  $A_i$  和  $D_i$  则是在第  $i$  层小波分解中得到的低频和高频小波系数。

假定  $A_0$  是一个时间序列, 则可将其展示为经由 2 层 Mallat 分解的时序过程, 如图 2 所示。

### 2.2 AMWDNet 模型

时间序列是一种隐藏信息特别多的序列, 涵盖了丰富的特征模式, 包括季节性变化、局部波动以及整体趋势等。在时域里, 各式各样的模式融合在一起, 使得直接从时域角度进行分析就有了一定难度。为了解决这个问题, 本研究引入了一种创新的模

型—AMWDNet。该模型的核心思想是利用多级小波分解技术, 对最初的时间序列进行逐层剖析, 经过这种处理方法, 高频分量和低频分量就以不同的分辨率尺度分离出来, 且时间序列中隐藏的丰富特征也随即能够被清晰地提取出来, 为后续的分析 and 决策提供技术支持。在分析高低频分量时, 模型中的长期和短期时间模式提取模块, 能够分别对这些分量中的长期趋势和短期波动进行精确建模, 从而实现对时间序列的全方位分析。与此同时, 模型还着重设计了多级时频信息融合模块, 此模型可以对提取的短期时间特征结果进行交融分析, 最终形成了精确的分类决策器。在此基础上, 为了验证 AMWDNet 模型在花椒图像分类任务上的有效性, 研究提供了其结构示意图如图 3 所示。




图 2 Mallat 分解过程

Fig. 2 Mallat decomposition process

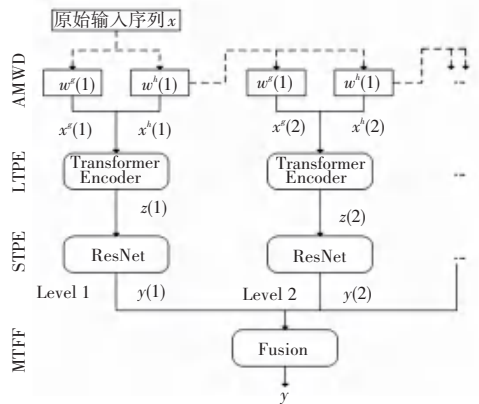


图 3 AMWDNet 模型架构

Fig. 3 AMWDNet model architecture

AMWDNet 模型由以下重要模块组成:

(1) 自适应多级小波分解模块 (AMWD)。具备对原始时间序列进行深度细化的能力, 可主要用于精确提取多层次的高低频特征。通过这一模块的处理, 时间序列数据可以被有效地分解为多个层级, 以利于更细致地分析和利用其中的信息;

(2) 长期时间模式提取模块 (LTPE)。采用先进的 Transformer 编码器结构, 其核心功能在于深入挖掘时频信息中隐含的长期依赖关系和全局变化趋势。通过 LTPE 的精准捕捉, 就能够更准确地把握

时间序列数据的整体动态,从而更好地预测和分析未来趋势;

(3)短期时间模式提取模块<sup>[22]</sup>(STPE)。充分运用了残差网络(ResNet)优秀的特征提取能力,其专注于精细捕捉时间序列中的局部细微变化。通过STPE的精准建模,能够实现对局部模式的深入理解和准确描述,从而更加全面地揭示时间序列数据的复杂性和动态性;

(4)多级时频信息融合模块(MTFF)。是整个模型的核心组成部分,承担着整合各级时频信息建模结果的重要任务。MTFF确保各类特征得到充分利用,通过精细化的信息融合,最终输出精确可靠的预测结果,为决策提供有力支持。

综上所述,经过应用自适应多级小波分解

表1 数据集详细信息

Table 1 Detailed information of the dataset

序号	数据集	训练集样本数	测试集样本数	序列长度	类别个数
1	FordA	3 601	1 320	500	2
2	PhalOutCorr	1 800	858	80	2
3	NonInvThor1	1 800	1 965	750	42
4	MelPedes	1 194	2 439	24	10

### 3.2 基准与评价指标

本算法选用4个基准方法作为对比探讨,其中包括融合频域信息的方法(MCNN)以及融合时频信息的方法(mWDN)。这里将展开研究分述如下。

(1)FCN架构。通过精心设计的卷积层块、全局平均池化层和 $softmax$ 层,实现了对输入数据的特征提取、整合和分类,展现出了强大的性能和应用潜力;

(2)长短期记忆网络(LSTM)。作为时间循环神经网络的典型代表,专门设计用于捕捉时间序列中长期依赖关系的循环神经网络。运行时是通过输入门、遗忘门和输出门协同工作,实现对细胞状态的有效控制和更新;

(3)多尺度卷积神经网络(MCNN)<sup>[24]</sup>。凭借其精致的设计,巧妙融合了恒等映射、下采样以及平滑滤波三种变换技术,实现了对时频信息的全面、精细的捕捉。在这一独特的网络结构中,3个卷积层发挥着关键作用,每个卷积层均致力于从对应的变换手段提取的特征中提炼出最具价值的信息。经过这3个卷积层的精细处理,所得特征最终被送入 $softmax$ 层进行转换,生成各个类别的预测概率;

(4)多级小波分解网络(mWDN)<sup>[25]</sup>。巧妙地结合了小波分解技术与多个分类器,实现了对多级

(AMWD),本研究成功地在时域内对时序特征进行了精细化分离。这一策略不仅简化了建模过程,还显著地提高了模型的分类精度和预测准确性。

## 3 实验与结果

### 3.1 数据集

实验部分采用了UCR<sup>[23]</sup>时间序列分类常用的数据集仓库,该仓库包括128个不同领域的时间序列数据集。在本研究中,为了全面评估所提出模型的性能,精心挑选了4个训练样本数量超过1 000的大规模数据集进行验证实验。被选用的数据集均来自UCR时间序列分类库,确保了实验数据的质量和多样性,随机抽取20%的样本进行模型参数选择,见表1,其余用于模型训练。

时频特征的精细提取与高效分类。

在每个数据集中,本文采用分类准确率( $Accuracy$ )这一技术指标来评估AMWDNet模型的表现。分类准确率是一种直观且常用的性能评价度量,具体量化了模型正确预测样本类别的能力。该指标的计算评价公式为:

$$Accuracy = \frac{N_{true}}{N_{total}} \quad (4)$$

其中, $N_{true}$ 表示模型正确分类的样本数, $N_{total}$ 表示样本总数。

### 3.3 实验环境与参数设置

本实验采用Pytorch深度学习框架进行模型的构建与训练。在该模型中,具有2种主要类型的超参数。首先是与低通和高通滤波器调整程度相关的正则化系数 $\alpha$ 和 $\beta$ ,分别与低通和高通滤波器的调整程度密切相关,用于调节滤波器在调整过程中的敏感度和平滑性。此外,小波分解层数 $l$ 与小波基 $coef$ 也是模型的重要超参数。另一方面,模型还涉及特征维度 $d_{model}$ 、多头注意力机制中头的数量 $h$ 以及子网络的层数 $N$ 等超参数,这些参数共同影响着模型的性能。

AMWDNet模型在各个数据集上的超参数设置见表2。

表2 各个数据集的超参数设置

Table 2 Hyperparameter settings for individual datasets

序号	数据集	$\alpha$	$\beta$	$l$	$coef$	$d_{model}$	$h$	$N$
1	FordA	0.2	0	1	db4	32	4	1
2	PhaCorr	0.2	0.2	4	db1	32	4	1
3	NonTh1	0.1	0	3	db8	8	4	1
4	MelPed	0	0.2	3	db3	16	4	2

在构建和训练模型的过程中,考虑到不同规模数据集的特点,研究设定了合适的批处理大小。具体数值已在表3中详细列出,以确保模型在不同数据集上都能获得良好的训练效果。通过合理设置批处理大小,能够有效平衡模型的训练速度和内存占用率,以提高训练过程的稳定性和效率。

表3 不同数据集批处理大小设置

Table 3 Different dataset batch size settings

序号	数据集	批处理大小
1	FordA	16
2	PhalOutCorr	16
3	NonInvThor1	16
4	MelPedes	16

表4 不同模型的准确率

Table 4 Accuracy of different models

序号	对比方法	FordA	PhCor	NoTh1	MelPed
1	FCN	90.4	82.0	95.6	91.2
2	LSTM	78.1	70.4	52.5	89.1
3	MCNN	51.3	61.3	65.1	48.9
4	mWDN	92.6	83.9	95.7	89.2
5	<b>AMWNet</b>	<b>94.8</b>	<b>84.0</b>	<b>96.2</b>	<b>90.9</b>

总地看来,AMWNet模型在3个数据集上均取得了最优异的性能表现,这充分彰显了其在不同应用场景下均能展现出卓越的分类能力。无论面对何种复杂情况,AMWNet模型都能保持出色的稳定性和准确性,为分类任务提供了强有力的支持。这一优异表现不仅验证了AMWNet模型设计的先进性,也为其在未来的广泛应用奠定了坚实基础。在MelPed数据集的实验中,尽管AMWNet模型的表现略逊于FCN,但差距并不显著。该数据集的样本长度仅为24,覆盖的时间跨度短,仅为一天,因而难以捕捉到如周,或月周期性的季节性特征,限制了模型在频域信息捕捉上的表现,导致在MelPed数据集上的准确率未达预期。

在FordA数据集(样本长度为500)的实验中,AMWNet模型相比最佳基准模型的性能提升了2.2%。这表明,当时间序列足够长时,AMWNet能有效捕捉时频信息,从而显著提高分类性能。目前,

### 3.4 实验结果

针对UCR数据集仓库中的4个数据集,独立开展了10次实验。在这些实验中,将AMWNet模型与4种基准模型进行了对比,重点观察了分类结果和性能的差异。通过计算每个数据集的平均分类准确率,得出的详细测试结果见表4。这些实验的目的在于全面评估AMWNet模型在不同数据集上的泛化能力和稳定性,并将其与基准模型进行对比,以突显其优越性和有效性。另外,由于尚未找到可训练的花椒图像数据集,目前未能进行实际的花椒图像分类训练,下一步将收集整理大量花椒图像素材自建数据集另行测试。

多级小波分解算法主要用于单变量时间序列分类。因此,AMWNet模型应用于花椒图像分类处理上是切实可行的,基本能满足初级图像处理要求,为减轻花椒产业用工成本和提高实际生产效率提供参考。

## 4 结束语

在花椒的图像分类识别中,本文的多级小波分解的算法模型将时域和频域的信息进行提取融入神经网络中,利用离散小波函数分解算法和深度学习方法进行训练,使其能根据数据特征进行自我调整,并通过长短期时间模式提取模块来提取时间特征,进而提高了模型的性能,以此来提升花椒图像分类的准确率。在该模型中,利用多级小波分解方法也克服实际生活中获得的时间序列大多具有季节性、长期趋势、周期性和随机变动因素造成时域上的影响,将频域信息利用起来,改善单一的时域模型的

分类算法缺陷。但目前多级小波分解算法只适用于单变量时间序列的分类,未来的工作将致力于开发适用于多变量时间序列分类的方法,从而更全面地提取花椒图像的多维特征,进一步提高分类的准确率,并为花椒分类识别提供更精确的判断。

## 参考文献

- [1] 杨培军,张宏熹,景芳玲. 经济高效树种-花椒及栽培技术[J]. 中国农村小康科技, 2003(12):11-12.
- [2] 王帅,赵敬坤,王洋,等. 重庆花椒种植区主要类型土壤剖面的肥力特征[J]. 西南大学学报(自然科学版),2021,43(11):40-47.
- [3] 熊熙,张仕超,梁靖茹,等. 丘陵山区家庭农场时空拓展特征及驱动力分析—以重庆市江津区为例[J]. 山地学报, 2021, 39(1):71-87.
- [4] 廖洪凯,龙健,李娟,等. 花椒(*Zanthoxylum bungeamun*)种植对喀斯特山区土壤水稳性团聚体分布及有机碳周转的影响[J]. 生态学杂志, 2015, 34(1):106-113.
- [5] 任守纲,张景旭,顾兴健,等. 时间序列特征提取方法研究综述[J]. 小型微型计算机系统,2021,42(2):271-278.
- [6] 谭海,陈利军,张军,等. 基于规则迭代的时间序列特征提取模型[J]. 计算机工程与设计, 2019, 40(1): 236-240.
- [7] 娄路,吕惠,宋然. 基于多视角时间序列图像的植物叶片分割与特征提取[J]. 农业机械学报, 2022, 53(1): 253-260.
- [8] 吕品,潘思羽,许嘉,等. 基于机器学习的网络流量分类算法[J]. 广西大学学报(自然科学版),2019,44(6):1650-1657.
- [9] WANG Zhiguang, YAN Weizhong, OATES T. Time series classification from scratch with deep neural networks: A strong baseline[J]. arXiv preprint arXiv:1611.06455, 2016.
- [10] KARIM F, MAJUMDAR S, DARABI H, et al. LSTM fully convolutional networks for time series classification[J]. arXiv preprint arXiv:1709.05206, 2017.
- [11] 梁小慧,郭晟楠,万怀宇. 基于自适应小波分解的时间序列分类方法[J]. 计算机工程, 2022,48(4): 81-88,98.
- [12] 尹建光,彭飞,谢连科,等. 基于小波分解与自适应多级残差修正的最小二乘支持向量回归预测模型的PM<sub>2.5</sub>浓度预测[J]. 环境科学学报, 2018, 38(5): 2090-2098.
- [13] 陶唐飞,周文洁,况佳臣,等. 融合多小波分解的深度卷积神经网络轴承故障诊断方法[J]. 西安交通大学学报,2024,58(5): 31-41.
- [14] 易利群,盛玉霞,柴利. 融合MRI信息的PET图像去噪:基于图小波的方法[J]. 自动化学报,2023,49(12):2605-2614.
- [15] 唐胜唐,吴共庆,台昌杨,等. 基于样本间潜在关系的多变量时间序列分类[J]. 合肥工业大学学报(自然科学版), 2023, 46(12):1642-1650.
- [16] 管业鹏,苏光耀,盛怡. 双向长短期记忆网络的时间序列预测方法[J/OL]. 西安电子科技大学学报; 1-11 [2023-12-27]. <https://doi.org/10.19665/j.issn1001-2400.20231205>.
- [17] 刘新,刘冬兰,付婷,等. 基于联邦学习的时间序列预测算法[J]. 山东大学学报(工学版),2024,54(2):1-9.
- [18] 薛悦平,胡彦蓉,刘洪久,等. 基于多模态预训练模型的水稻病虫害图像描述生成研究[J/OL]. 南京农业大学学报; 1-11 [2024-01-02]. <https://link.cnki.net/urlid/32.1148.S.20231229.1612.004>.
- [19] BAGNALL A, LINES J, HILLS J, et al. Time - series classification with COTE: The collective of transformation-based ensembles [J]. IEEE Transactions on Knowledge & Data Engineering, 2015, 27(9):2522-2535.
- [20] 姜志伟,李云飞,姜涛,等. 基于离散小波分解与重构的多源土壤含水量数据融合方法与评估[J]. 农业工程学报,2023,39(7):145-156.
- [21] 张春艳,李京兵,王双双. 基于离散小波变换和感知哈希的加密医学图像检索算法[J]. 计算机应用,2018,38(2): 539-544, 572.
- [22] MALLAT S G. A theory for multiresolution signal decomposition: the wavelet representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1989, 11(7): 674-693.
- [23] DAU H A, BAGNALL A, KAMGAR K, et al. The UCR time series archive [J]. IEEE/CAA Journal of Automatica Sinica, 2019, 6(6): 1293-1305.
- [24] CUI Zhicheng, CHEN Wenlin, CHEN Yixin. Multi - scale convolutional neural networks for time series classification [J]. arXiv preprint arXiv:1603.06995, 2016.
- [25] LI Shiyang, JIN Xiaoyong, XUAN Yao, et al. Enhancing the locality and breaking the memory bottleneck of transformer on time series forecasting[J]. arXiv preprint arXiv:1907.00235, 2019.