doi:10.6041/j.issn.1000-1298.2026.09.030

基于深度迁移学习的木虱取食行为识别方法

翁海勇[1,2]　胡娜娜[2,3]　许金钗[2,3]　孔祥增[1,2]　李　猷[4]　叶大鹏[1,2]

(1. 福建农林大学机电工程学院, 福州 350002; 2. 福建省农业信息感知技术重点实验室, 福州 350002;
3. 福建农林大学计算机与信息学院, 福州 350002; 4. 福建农林大学植物保护学院, 福州 350002)

摘要: 刺吸电位图谱技术(Electrical penetration graph,EPG)是解析木虱取食行为的重要手段。然而,目前对 EPG 信号的分析仍严重依赖人工判读,效率低下。因此,本研究提出一种基于深度迁移学习的木虱 EPG 自动识别方法,融合 Transformer 与双向门控循环单元(BiGRU)以提升模型在有限样本下的识别性能。首先对原始 EPG 信号进行变分模态分解(VMD)以降低噪声干扰,随后构建基于 Transformer 编码器与 BiGRU 的混合模型,充分利用其全局感知与局部时序建模能力,实现波形特征的协同提取。为缓解木虱样本不足的问题,先在规模较大的蚜虫 EPG 数据集上构建预训练模型,然后通过领域自适应策略迁移至目标木虱数据集,并通过微调机制完成跨物种知识迁移。结果表明,当单类别样本量为 40 且采用全参数微调策略时,模型识别准确率可达到 98.50%;而在资源受限条件下(单类别样本量 20 且仅微调末 2 层),模型准确率仍能保持 97.54%。本研究提出的融合迁移学习技术与深度学习特征提取方法的思路,可用于木虱取食行为的自动分析,也可为其他刺吸式昆虫 EPG 信号的分析提供参考。

关键词: 木虱; 刺吸电位波形; 迁移学习; Transformer; 双向门控循环单元

中图分类号: TP391; TN911.72　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)09-0319-10　　**OSID**:

Deep Transfer Learning-based Approach for Recognition of Psyllid Feeding Behaviors

WENG Haiyong[1,2]　HU Na'na[2,3]　XU Jinchai[2,3]　KONG Xiangzeng[1,2]　LI You[4]　YE Dapeng[1,2]

(1. *College of Mechanical and Electrical Engineering, Fujian Agriculture and Forestry University, Fuzhou* 350002, *China*
2. *Fujian Key Laboratory of Agricultural Information Sensoring Technology, Fuzhou* 350002, *China*
3. *College of Computer and Information Sciences, Fujian Agriculture and Forestry University, Fuzhou* 350002, *China*
4. *College of Plant Protection, Fujian Agriculture and Forestry University, Fuzhou* 350002, *China*)

Abstract: The electrical penetration graph (EPG) technique serves as a critical tool for analyzing psyllid feeding behaviors, investigating psyllid-citrus host interactions, and exploring pathogen transmission mechanisms. Nevertheless, the interpretation of EPG signals still heavily relies on manual effort, which remains inefficient and labor-intensive. To address this issue, an automated EPG recognition method was proposed based on deep transfer learning, which integrated a Transformer and a bidirectional gated recurrent unit (BiGRU) to enhance recognition performance under limited sample availability. The proposed method began with variational mode decomposition (VMD) to suppress noise in raw EPG signals, followed by a hybrid model, combining a Transformer encoder and a BiGRU network. This architecture leveraged the Transformer's global perception and the BiGRU's local temporal modeling capability to collaboratively extract discriminative waveform features. To mitigate the scarcity of labeled psyllid data, the model was firstly pre-trained on a larger aphid EPG dataset and then transferred to the target psyllid dataset via a domain adaptation strategy. Cross-species knowledge transfer was accomplished through a fine-tuning mechanism. Experimental results demonstrated that the model achieved a recognition accuracy of 98.50% when using 40 samples per category with full-parameter fine-tuning. Under resource-constrained conditions (20 samples per category with only the last two layers fine-tuned), the model still maintained an accuracy of 97.54%. The research result demonstrated the viability of

收稿日期: 2025-10-21　修回日期: 2025-12-08

基金项目: 国家自然科学基金项目(62005046)、福建省工信厅人工智能应用场景项目(KLY24501XA)、福建农林大学科技创新基金项目(KFB24041A)和农业农村部东南丘陵山地农业装备重点实验室(部省共建)开放课题(KFKT2024008)

作者简介: 翁海勇(1989—),男,副教授,博士,主要从事农作物光学传感及装备研究,E-mail: hyweng@fafu.edu.cn

integrating transfer learning with deep learning-based feature extraction for automated analysis of psyllid feeding behavior, while also offering a valuable reference for analyzing EPG signals in other piercing-sucking insects.

Key words: psyllid; electrical penetration graph waveform; transfer learning; Transformer; bidirectional gated recurrent unit

0 引言

柑橘黄龙病(Citrus Huanglongbing, HLB)是一种对全球柑橘产业构成严重威胁的毁灭性病害[1]。这种病害由限于韧皮部寄生的候选韧皮部杆菌属(*Candidatus Liberibacter spp.*)引起,主要通过亚洲柑橘木虱(Diaphorina citri Kuwayama,半翅目:木虱科)传播。木虱通过取食行为,将病菌从患病柑橘植株传播到健康柑橘植株[2]。因此,深入解析木虱的取食与传病行为已成为实现 HLB 防控的关键技术。

刺吸电位图谱(Electrical penetration graph, EPG)技术通过实时记录昆虫口针在植物组织间穿行时的电信号变化,能够以毫秒级分辨率捕捉取食过程中的关键行为事件[3]。这些电生理信号揭示了昆虫与寄主植物之间的互作机制,为理解病原体传播窗口期提供了直接证据,构成了木虱防治策略的重要理论支撑[4-5]。因此,在利用 EPG 技术进行科学研究时,需要准确高效地解读波形。然而,目前木虱 EPG 数据分析主要依靠科研人员人工判读,耗时费力,且主观性强,不利于 EPG 技术的推广应用。

随着计算机技术的快速发展,针对波形自动解析的需求,PRÜFER 等[6]和 ADASME-CARREÑO 等[7]基于幅度和峰值等数学特征,采用基于规则的分类逻辑,开发了 Aphid Auto EPG 和 A2EPG 等自动标注工具。但 EPG 信号含有大量复杂信号模式,仅通过数学特征难以构建完善的分类规则,因此还需研究人员二次判别。随着机器学习技术的不断发展,其在 EPG 信号自动分析中的应用逐步深入。虽然已有研究[8-11]推进了 EPG 波形的自动识别进程,但是在特征构建阶段仍依赖于专家先验知识与人工设计,存在一定的局限性。因此,在提升分析流程的自动化水平、减少对人工干预的依赖等方面,仍有待进一步探索。随着深度学习技术的发展,吴莉莉等[12]提出了一种基于 CNN 的自动识别方法,在蚜虫 EPG 信号数据集上达到了 97.50% 的平均识别率。该方法实现了从原始信号到最终分类结果的端到端识别,为该领域的研究提供了新范式。然而,将其直接应用于木虱 EPG 识别时,仍存在一定问题:无翅成蚜活动性较弱、EPG 波形典型且稳定,且 EPG 技术起源于蚜虫研究,已有数十年积累,更容易构建高质量的大型数据集[12]。而木虱带翅、体型微小、活动频繁,导致 EPG 试验难以获取足量高质量标注数据。这一问题严重制约了依赖大数据驱动的深度学习模型的训练与泛化能力。因此,迫切需要一种能够在有限数据资源的条件下,实现木虱 EPG 波形的高精度自动化识别方法。

对于非线性、非平稳时序信号的识别问题,已有研究在多个技术方向上取得了明显进展。Transformer-BiGRU 混合模型在时序特征提取以及迁移学习在跨域小样本适应方面的成功应用[13-21],提供了技术基础。在刺吸式昆虫生物电信号方面,BONANI 等[22]研究表明,尽管木虱与蚜虫在系统发育上分属不同科,但二者在取食生理机制上具有高度保守性,其 EPG 波形在形态特征、电生理属性及行为功能方面均表现出显著的跨物种相似性。例如,C 波对应于表皮层探查行为,G 波反映木质部取食,E1 与 E2 波则分别表征韧皮部唾液分泌与持续汁液摄取。蚜虫与木虱在取食行为及 EPG 波形上的高度相似性,为迁移学习技术在 EPG 信号识别问题中的应用提供了关键的生物学依据。

基于此,本文针对木虱 EPG 自动识别问题的困境,提出一种基于迁移学习的蚜虫-木虱 EPG 联合分析方法(Transformer-BiGRU based domain adaptation, TBDA)。该方法的核心思想是通过领域自适应(Domain adaptation)策略对齐两物种间的波形特征分布,利用大规模蚜虫数据(源域)指导木虱模型(目标域)的训练。在模型架构方面,构建融合 Transformer 全局注意力机制与 BiGRU 局部时序建模能力的混合网络(Transformer-BiGRU,TB),以协同捕捉 EPG 信号中的长程依赖与精细动态特征。

1 材料与方法

1.1 试验材料

在实验室标准条件(温度(25±1)℃,相对湿度 70%±5%,光周期亮暗时间比为 14∶10)下,使用铝框纱网笼(35 cm×35 cm×53 cm),分别饲养桃蚜与柑橘木虱。试验选用健康烟草(供桃蚜)和有嫩梢

的健康柑橘植株(供木虱)作为供试植物。试验前，选取健康活跃的无翅成蚜和木虱成虫，禁食 1 h。试验采用荷兰产 Giga－8 DC－EPG 系统记录刺吸行为，该系统输入阻抗为 1 GΩ，配备 12 位分辨率 A/D 采集卡，采样频率设置为 100 Hz。所有 EPG 试验均在人工气候室(温度(25 ± 1)℃，相对湿度 60% ± 5%)中进行。为构建完整电生理回路，将直径 20 μm 的金丝电极以导电银胶固定于昆虫前胸背板，植物端电极则插入植株根际湿润土壤中(图 1)。随后开启 EPG 系统电源与记录软件，使用软质工具将昆虫轻柔引导至叶片表面，并关闭法拉第笼以屏蔽外界电磁干扰。每次记录持续 8 h，以确保充分捕捉不同取食阶段的波形特征。在如图 1 所示闭合回路中，昆虫口针在植物组织内的刺探与取食行为会引起电路电压的实时变化，这些变化经放大器采集后表现为具有特定形态的 EPG 波形，从而实现对取食行为的精确监测。

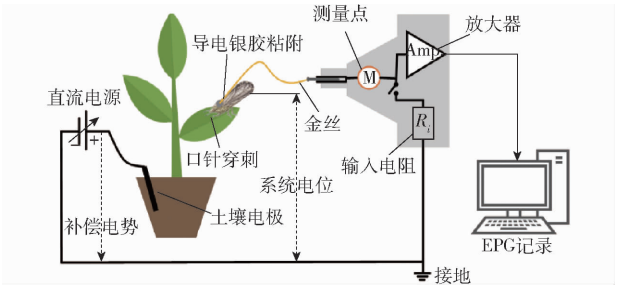

图 1　木虱 EPG 信号采集方法

Fig. 1　Method for psyllid EPG signal acquisition

1.2　EPG 波形判别标准

蚜虫与木虱的 EPG 信号通常可分为 6 类典型波形：NP(非刺探)、C(路径波)、pd(电势落差)、E1(韧皮部唾液分泌)、E2(韧皮部汁液摄取)与 G(木质部取食)。如图 2 所示，NP 波表示非刺探波，此时蚜虫或木虱尚未将口器刺入植物表皮，其波形通常表现为近似直线。A 波波形不稳定，幅度变化显著，代表口器刺入表皮并分泌水溶性唾液的过程[23]；B 波通常紧随 A 波出现，反映口器在表皮与薄壁组织间的细胞间移动及凝胶型唾液分泌行为；C 波则常见频繁的电势起伏，指示口针在表皮与维管束组织间的路径推进。由于 A、B、C 3 类波形在形态上缺乏明确界限，传统研究常将其合并统称为 C 波，该波形在木虱与蚜虫中均代表口针在细胞间穿行并分泌唾液的过程[9]。pd 波持续时间短暂，对应刺吸式昆虫口针刺破细胞膜的行为[11]。值得注意的是，蚜虫在 C 波期间常伴随出现 pd 波，体现其频繁的细胞穿刺行为，而木虱中该波形极为罕见。这一差异可能源于两者取食策略的不同：蚜虫借助细胞穿刺进行寄主评估与非持久性病毒传播，而木虱则主要依赖持续的韧皮部取食以完成病原传播[22]。出于对木虱生物学特性的考虑，本研究不对木虱的 pd 波进行单独处理。E 波表示口针刺探韧皮部筛管的过程，可进一步区分为分泌水溶性唾液的 E1 波与摄取韧皮部汁液的 E2 波，木虱的病原传播主要发生于该阶段[24]。木虱与蚜虫的 E 波在形态(如峰值方向)与频率范围上高度相似：木虱 E1 波为 5 ~ 7.5 Hz(向上峰值)，E2 波为 3 ~ 9 Hz(向下峰值)；蚜虫则分别为 2 ~ 4 Hz 与 4 ~ 9 Hz。此外，两者在 E1 与 E2 期间均维持稳定的负电压水平，表明其口针尖端位于细胞内，并且细胞膜电位得以维持，即其口针在此时都已成功刺入活细胞(筛管)。G 波反映昆虫吸食木质部汁液以维持水分平衡的行为。木虱 G 波频率为 5 ~ 7 Hz，蚜虫为 4 ~ 9 Hz，两者范围高度重叠。该波形在 2 种昆虫中均呈现细胞外电压特征，符合木质部取食的电生理机制，表明其背后具有高度相似的生物物理机制。

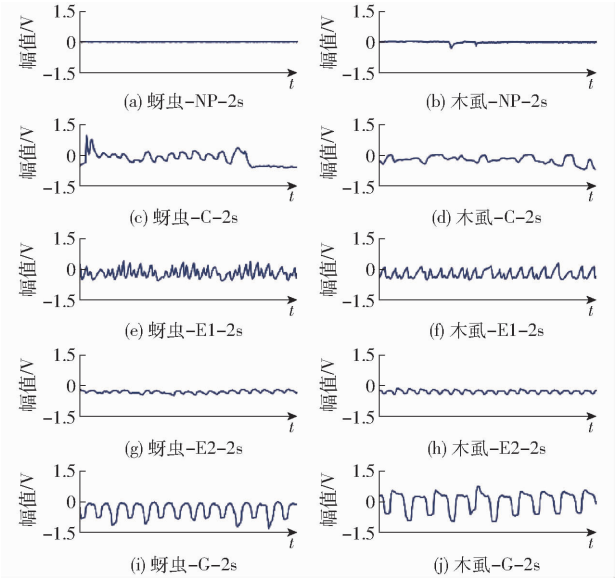

图 2　蚜虫和木虱的 EPG 波形对比图

Fig. 2　Comparison of typical EPG waveforms by aphids and psyllids

1.3　数据构建与预处理

本研究构建了源域(蚜虫 EPG 数据)与目标域(木虱 EPG 数据)2 个数据集。各数据集均由单通道电压信号(ASCII 格式)及其对应的波形标注文件构成。依据 1.2 节所描述的各类波形时频域特征，利用波形分析软件 stylet + a，对原始信号进行人工标注、波段分割(固定长度为 1 024 个采样点)与数据划分。蚜虫取食行为数据集共包含 101 140 个样本，涵盖 5 类典型波形，各类别样本数量均衡。该数据集按比例 8∶1∶1 随机划分为训练集、验证集与测试集，以确保模型训练与评估的独立性。木虱取食行为数据集共包含 1 000 个样本，每类波形各 200

个。为适应小样本迁移学习场景,从每类中随机选取 20 个样本组成微调训练集,其余样本则作为验证集和测试集用于模型选择与性能评估。

变分模态分解(Variational mode decomposition, VMD)是一种完全非递归的信号分解方法,能够有效克服经典方法(如经验模态分解)的模态混叠与端点效应问题[25]。ZHANG 等[26]和 LI 等[27]的研究表明,将 VMD 算法应用于非平稳、非线性时间序列处理,能够有效提升信号信噪比、降低边界失真率。因此,本研究采用该算法进行数据预处理,以抑制原始信号中固有的环境噪声与个体变异干扰,分离与不同取食行为相关的频带信息。具体数据处理过程是通过构造并求解一个约束性变分问题,将原始实值输入信号 f 自适应地分解为 A 个具有特定稀疏性的本征模态函数(Band-limited intrinsic mode functions, BLIMFs)。该变分问题旨在使所有模态的估计带宽之和最小,其数学式为

$$\begin{cases} \min\limits_{\{u_k\},\{\omega_k\}} \left\{ \sum\limits_{k=1}^{A} \left\| \partial_t \left[\left(\delta(t) + \dfrac{\mathrm{j}}{\pi t} \right) * u_k(t) \right] \mathrm{e}^{-\mathrm{j}\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum\limits_{k=1}^{A} u_k = f \end{cases} \tag{1}$$

其中
$$\{u_k\} = \{u_1, u_2, \cdots, u_A\}$$
$$\{\omega_k\} = \{\omega_1, \omega_2, \cdots, \omega_A\}$$

式中 A——模态分解总数

u_k——第 k 个本征模态函数

ω_k——第 k 个模态的中心频率

$\{u_k\}$、$\{\omega_k\}$——分解得到的 A 个 BLIMF 分量及其对应的中心频率

$\partial_t(\cdot)$——时间 t 的偏导数

$\delta(t)$——狄拉克 δ 函数

f——原始输入信号

为求解上述约束优化问题,引入 α 和 $\lambda(t)$,将其转换为增广拉格朗日函数

$$\mathscr{L}(\{u_k\},\{\omega_k\},\lambda) = \alpha \sum_{k=1}^{A} \left\| \partial_t \left[\left(\delta(t) + \frac{\mathrm{j}}{\pi t} \right) * u_k(t) \right] \mathrm{e}^{-\mathrm{j}\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^{A} u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^{A} u_k(t) \right\rangle \tag{2}$$

式中 λ——拉格朗日乘子

α——二次惩罚因子

通过交替方向乘子法(Alternate direction method of multipliers, ADMM)迭代更新 u_k、ω_k 和 λ,即可求得函数最优解,从而完成信号分解。

1.4 模型方法

1.4.1 构建预训练模型

为充分捕捉 EPG 信号中的长程依赖与局部时序特征,本研究构建了一种融合 Transformer 编码器与 BiGRU 的混合模型(Transformer - BiGRU, TB)。Transformer 凭借其自注意力机制,能够有效建模序列的全局上下文信息[28],但在处理长序列时,其捕捉精确双向时序依赖的能力存在局限[29]。为此,模型引入 BiGRU,利用其双向门控循环结构,进一步增强对前后向局部动态特征的提取能力,从而形成优势互补的协同特征提取架构[30]。该混合模型由输入预处理、Transformer 编码器、BiGRU 时序建模器和分类器 4 个核心组件构成。首先,波段经预处理操作后进入 4 层 Transformer 编码器,建立长程依赖关系。其次,编码器输出特征送入 3 层 BiGRU 网络,形成多尺度特征表示。最后,融合后的特征经分类器映射至 5 类波形标签(图 3a)。

进一步分析(图 3b),Transformer 编码器主要由多头注意力机制、前馈神经网络、残差连接和归一化 3 部分组成。输入序列 $\boldsymbol{X} \in \mathbf{R}^{L \times d_{\text{model}}}$(其中 L、d_{model}为隐藏层维度,分别取 1 024、64)首先经由多头自注意力机制进行全局上下文建模。该机制通过线性变换生成查询(Query)、键(Key)与值(Value)矩阵 $\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$。

每个矩阵进一步沿特征维度划分为 $h = 8$ 个头,形成形状为 $\left(h, T, N, \dfrac{d_{\text{model}}}{h}\right)$ 的子张量。每个注意力头独立执行自注意力计算

$$head_i = \text{softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_k}} \right) \boldsymbol{V} \tag{3}$$

式中 d_k——键向量维度

使序列中的任意时间步能够关注到整个序列中的其他位置,从而捕捉长程依赖关系。所有注意力头的输出经拼接与线性投影后,得到多头注意力输出

$$\text{MultiHead}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V}) = \text{Concat}(head_1, \cdots, head_h)\boldsymbol{W}^O \tag{4}$$

式中 $\boldsymbol{W}^O$——多头输出融合权重矩阵

Concat( )——拼接操作函数

随后,每个时间步的特征进一步通过一个前馈神经网络(Feed forward network, FFN)进行非线性变换

$$\boldsymbol{Z} = \text{LayerNorm}(\boldsymbol{X} + \text{Dropout}(\text{MultiHead}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V}))) \tag{5}$$

式中 Dropout——正则化函数

LayerNorm——层归一化函数

该网络由 2 个全连接层及其中间的激活函数组成,旨在从全局角度增强特征的表示能力。为提升

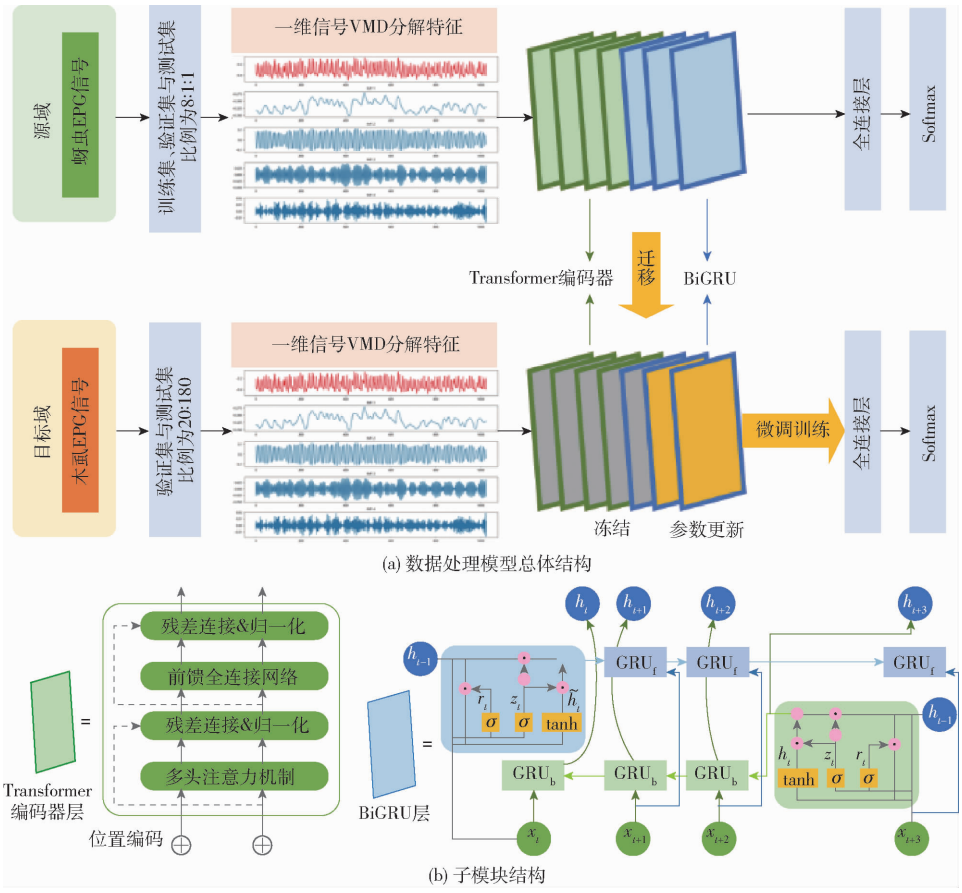

图 3　基于迁移学习的木虱取食行为识别流程

Fig. 3　Transfer learning-based approach for recognition of psyllid feeding behaviors

训练稳定性、缓解梯度消失或爆炸问题并加速收敛，在自注意力子层与前馈子层之后均引入残差连接和层归一化

$$\mathrm{FFN}(\boldsymbol{Z}) = \mathrm{ReLU}(\boldsymbol{Z}\boldsymbol{W}_1 + \boldsymbol{b}_1)\boldsymbol{W}_2 + \boldsymbol{b}_2 \tag{6}$$

式中　FFN( )——前馈神经网络

$\boldsymbol{W}_1$、$\boldsymbol{W}_2$——前馈网络权重矩阵

$\boldsymbol{b}_1$、$\boldsymbol{b}_2$——前馈网络偏置项

形成该层输出

$$Output = \mathrm{LayerNorm}(\boldsymbol{Z} + \mathrm{Dropout}(\mathrm{FFN}(\boldsymbol{Z}))) \tag{7}$$

本模型堆叠 4 层上述结构，逐步构建具有丰富全局语义信息的特征表示。

为增强模型对局部时序动态与双向依赖的捕捉能力，将 Transformer 编码器的输出送入一个 3 层 BiGRU 网络。每一时间步 t，前向与后向 GRU 对输入向量进行独立处理：前向 GRU($\overrightarrow{GRU}$)沿时间方向逐步更新隐藏状态，捕捉当前时间步与历史信息之间的依赖关系

$$\overrightarrow{h}_t = \overrightarrow{GRU}(\boldsymbol{x}_t, \overrightarrow{h}_{t-1}) \tag{8}$$

式中　$\boldsymbol{x}_t$——第 t 个时间步的输入向量

h_t——第 t 个时间步的隐藏状态

→——前向传播方向

后向 GRU($\overleftarrow{GRU}$)则沿逆向时序进行处理，以建模当前时间步与未来上下文间的关联

$$\overleftarrow{h}_t = \overleftarrow{GRU}(\boldsymbol{x}_t, \overleftarrow{h}_{t+1}) \tag{9}$$

式中　←——后向传播方向

每一时间步中，前向隐藏状态$\overrightarrow{h}_t$与后向隐藏状态$\overleftarrow{h}_t$通过拼接操作进行融合，形成该时间步的最终隐藏表示为

$$h_t = [\overrightarrow{h}_t; \overleftarrow{h}_t] \tag{10}$$

从而实现对每一时刻双向语义信息的有效集成。该 BiGRU 模块共堆叠 3 层，逐层提取并融合不同时间尺度下的局部时序特征。最终，所有时间步的双向隐藏状态构成融合多尺度时序特征的高维表示，经由全连接层映射至 5 维输出空间，对应 NP、C、E1、E2、G 5 类波形。

1.4.2　模型微调

为实现从数据充足的蚜虫域（源域）到数据稀缺的木虱域（目标域）的有效知识迁移，本研究在 TB 模型的基础上引入了深度迁移学习技术，构建了一种基于领域自适应策略的 EPG 联合分析方法（Transformer – BiGRU based domain adaptation，TBDA）。为了最小化数据标注成本与模型训练开销，从所需样本量和微调参数量 2 个关键维度出发，探究模型迁移策略，以寻求模型性能与训练成本之

间的平衡。

(1)微调样本量选择

为进一步探究目标域标注样本规模对迁移学习效果的影响,本研究在全参数微调框架下,系统评估了不同训练集大小(单类别数据样本量从 10 条至 100 条,步长为 10)对模型收敛动态与分类性能的作用规律(图 4)。当训练集仅含 10 条样本时,模型准确率增长缓慢,并在第 7 个训练周期后趋于饱和,最终性能在 77% 左右波动,反映出极小样本条件下即便借助预训练仍难以支撑深层网络的有效优化。将样本量增至 20 条后,模型性能出现显著跃升,准确率最高可达 97.88%,并在第 30 轮开始收敛,体现出迁移学习在缓解小样本困境方面的巨大潜力。进一步增加至 30 条样本时,收敛速度明显加快,模型于第 22 轮开始收敛,准确率最高可达 98.44%,表明更多数据有助于加速特征空间的领域对齐过程。当训练集扩展至 40 条样本时,模型收敛效率稳步提升——仅需 15 个周期即可开始收敛,准确率最高可达 98.50%,标志着模型进入高精度、高稳定性的工作区间。继续增加样本数量,虽然模型收敛速度和分类准确率持续提升,但二者的增益均逐渐趋于平缓:从 40 条到 100 条样本,每增加 10 个样本,准确率仅提升 0.1% 左右,训练效率仅提升 2 轮左右,呈现出一定程度的边际效益递减现象。

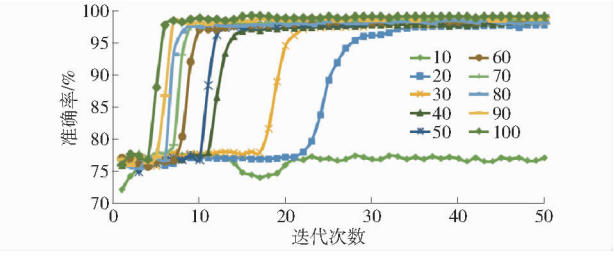

图 4 不同训练集规格下训练效果评估

Fig. 4 Evaluation of training performance under different training set sizes

(2)微调方案选择

为实现从源域(蚜虫 EPG 数据)到目标域(木虱 EPG 数据)的有效知识迁移,本研究基于图 2 所示的迁移学习流程,在固定超参数(批次大小为 32,学习率为 0.000 1)、单类别数据样本量 40 的前提下,系统比较了微调不同参数量(即网络层数)对模型适应性能的影响(图 5),旨在确定最优的参数更新机制。所有试验均以在蚜虫数据集上预训练完成的 TB 模型为初始权重,以仅优化顶层分类器(Classifier - Only)作为基准对照组,逐步解冻并微调 BiGRU 层和 Transformer 编码器层的网络参数,从而评估不同层级可训练性对模型迁移能力的影响。试验结果表明,仅微调分类头(Classifier - Only)的策略性能最为有限,其在验证集上的最终分类准确率约为 72.33%。该结果说明,尽管预训练模型已具备较强的时序特征提取能力,但是蚜虫与木虱在 EPG 信号形态、幅值分布及行为时序结构上存在固有的跨物种差异,仅调整输出层参数难以实现源域与目标域之间特征空间的充分对齐,所以模型在木虱数据上的泛化能力受到限制。当微调策略扩展至包含一层 BiGRU 时,模型准确率显著提升,表明深层网络中所蕴含的通用表征仍需结合目标域特性进行针对性优化,以有效捕捉木虱取食行为中更具判别性的细微模式。随着微调深度的进一步增加,即逐步开放更多低层特征提取模块参与训练,模型性能呈稳步上升趋势,但提升幅度逐步收窄。其中,全参数微调(Full Fine - Tuning)策略,即微调 7 层时,展现出最优的综合性能:该策略不仅训练效率最高,在第 15 个训练周期时即进入收敛状态,且最终性能稳定,表现出更强的分类精度与模型鲁棒性。值得注意的是,当微调层数从 2 层增加至全部 7 层时,模型准确率从 97.58% 提高到 98.50%,提升幅度不足 1%;收敛所需轮次从 18 轮到 15 轮,仅加速 3 个周期。反映出在微调 2 层时模型已具备良好的可迁移基础,能够在有限目标域样本的支持下实现较为高效的领域适配。

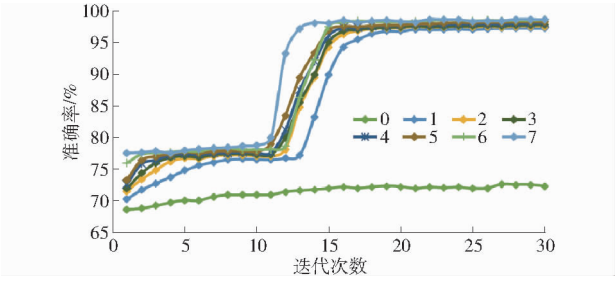

图 5 不同微调方案下训练效果评估

Fig. 5 Evaluation of training performance under different fine-tuning strategies

1.5 评价指标

为全面评估所提出分类模型的性能,本研究以精确度(Precision)、召回率(Recall)、F1 分数(F1-score)、准确率(Accuracy)、损失值(loss)和收敛所需轮次(Epoch)作为模型的评价指标。

在 EPG 波形分类任务中,精确度用于衡量模型正确识别特定取食行为波形的能力,高精确度表明模型在判定为正类的样本中误判较少;召回率则反映模型对某一类波形实际出现情形的检出完整性,高召回率表明模型能够有效捕捉该类波形实例;F1 分数作为精确度与召回率的调和平均数,综合评价模型在识别准确性与覆盖度之间的平衡能力,其值越高,表明 EPG 识别模型的性能越稳健。准确率从

整体上衡量模型对所有类别波形的综合判别能力，反映了模型在整体样本上的分类正确比例。损失值衡量模型预测结果与真实标签之间的差异程度，较低的损失值表示模型在训练数据上的拟合程度较好。收敛所需轮次指模型在验证集上达到预定性能阈值所需的最小迭代轮次，其值越小，说明模型的训练效率越高。最后，绘制混淆矩阵，将模型得到的波形识别结果与专家标注的真实标签作比较，验证模型对 EPG 波形识别的准确性。

2　结果与分析

2.1　TBDA 模型运行结果分析

为验证本研究提出的 EPG 波形自动识别方法在小样本场景下的有效性，设定训练集每类波形样本量为 20，验证集每类波形样本量为 180，并在固定超参数条件下，将全量微调策略下的 TBDA 模型与传统 CNN 网络、BiGRU、Transformer 编码器、TB 模型进行对比分析。

为系统评估模型特征提取能力，采用 t-分布随机领域嵌入（t-distributed stochastic neighbor embedding，t-SNE）对原始输入数据及 5 种模型输出的高维特征进行二维可视化[31]。结果显示，原始特征空间（图 6a）中各波形类别呈现显著重叠与离散分布，反映出 EPG 信号固有的高复杂性与低可分性问题。在模型对比层面，不同模型架构表现出显著差异。BiGRU 模型（图 6b）输出呈现连续“W”形轨迹且多类别完全重叠，表明其特征表征失效。该现象可能归因于其在长序列小样本条件下全局感知能力的缺失，导致模型仅学习到底层时序共性模式，无法建立有效的类间判别边界。CNN 模型（图 6c）虽展现初步聚类趋势，但存在 NP 波形误分为 C 类，并与 E2 类特征交叉等问题，反映其局部感受野对长程依赖建模不足。Transformer 编码器特征空间（图 6d）已呈现 5 类聚集形态，但 C、E1、E2 类内分布松散且类间边界模糊，这可能源于其缺乏局部特征提取机制与小样本条件下全局建模能力受限的双重局限。TB 模型（图 6e）在簇内紧凑性上有所提升，然而 C、E2 类间判别性仍不足，且 E1 类异常分裂，表明模型在数据稀缺时出现过度参数化问题。相比之下，本文所提 TBDA 模型生成的特征空间（图 6f）展现出最优的簇内紧凑性与簇间分离性，5 类波形形成几何边界明晰的独立簇群。这一从“混沌重叠”到“高度可分”的演化路径表明 Transformer－BiGRU 混合架构可通过全局-局部特征互补增强时序建模能力；跨物种迁移学习的协同优化机制可通过源域知识注入提升小样本条件下的特征解耦效率。

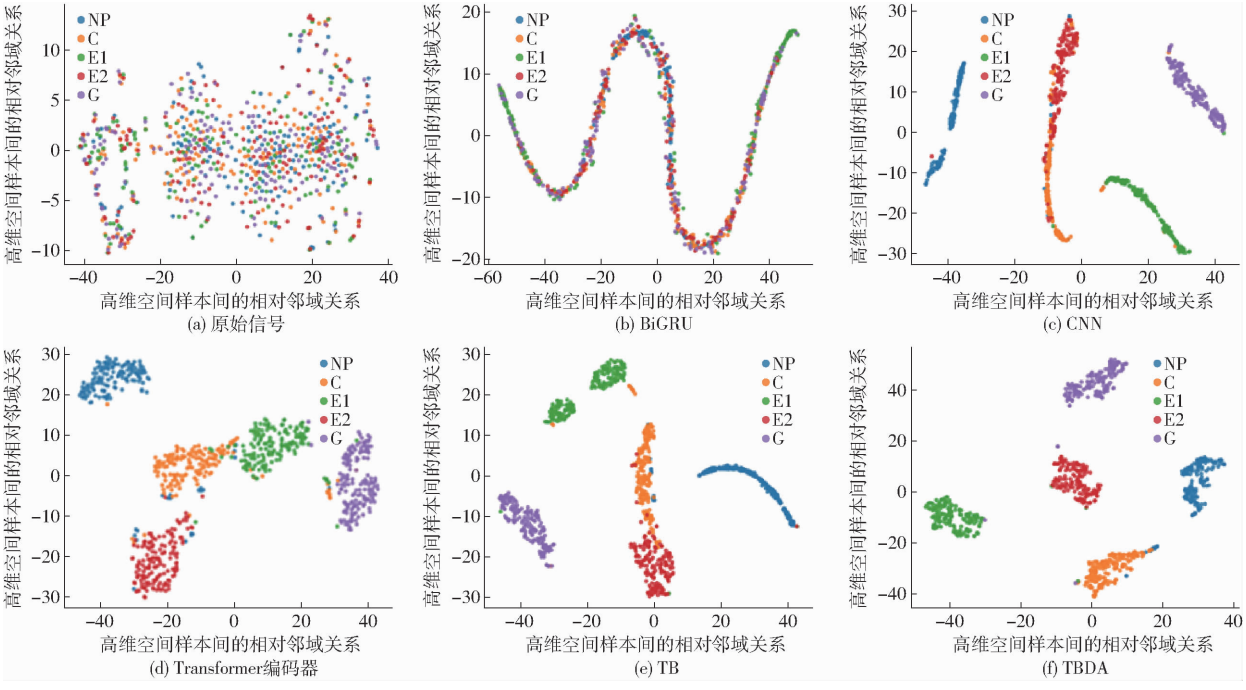

图 6　不同特征提取方法的 t-SNE 可视化结果

Fig. 6　t-SNE visualization of features extracted by different methods

为系统评估各模型在 EPG 波形分类任务中的综合性能，表 1 展示了量化对比结果。首先，BiGRU 模型全面失效，其准确率仅为 21.23% 且未能正常收敛，表明纯循环神经网络架构可能难以处理此类小样本的长序列信号。CNN 模型虽达到 75.88% 的准确率，但需 233 次迭代才收敛，且 F1 分数仅 69.58%，显示其局部感受野对时序特征建模存在局限。相比于 CNN，Transformer 编码器模

型展现出显著的性能提升:准确率和召回率均提高 7.12 个百分点,精确度提高 2.16 个百分点,F1 分数提高 12.71 个百分点、拟合所需轮次减小 148 次,验证了自注意力机制在全局特征提取中的优势。TB 模型在其基础上,准确率和召回率均提高 4 个百分点,精确度提高 0.83 个百分点,F1 分数提高 4.52 个百分点(相比于 CNN,分别提升 11.12、2.99、11.12、17.23 个百分点),但 150 轮的收敛轮次暴露了其在训练效率方面的不足。引入迁移学习后,TBDA 模型实现了更明显的进一步性能提升:准确率、精确度、召回率与 F1 分数均提升至少 10 个百分点,同时仅需 35 轮次即可收敛(相比于 TB 模型,迭代次数减少约 77%)。这一结果充分验证了跨物种迁移学习与混合架构的协同优势,不仅显著提升了小样本条件下的分类性能,同时大幅优化了训练效率。

表 1 不同模型的性能比较

Tab. 1 Performance comparison of different models

模型	准确率/%	精确度/%	召回率/%	F1 分数/%	拟合所需轮次
BiGRU	21.23	21.65	21.42	9.65	∞
CNN	75.88	84.08	75.88	69.58	233
Transformer	83.00	86.24	83.00	82.29	85
TB	87.00	87.07	87.00	86.81	150
TBDA	97.88	97.97	97.88	97.89	35

2.2 跨域迁移策略的性能分析

为系统评估迁移学习策略在不同资源条件下的适应性,设置了 4 种典型试验场景进行对比分析(图 7):图中,“160 - Scratch”为对照组,表示目标域训练集规格 160 条/类、从头训练的模型;“TL”表示迁移学习;“Pre_train”表示源域预训练模型;“20 - 2”表示目标域训练集规格 20 条/类、微调 2 层策略

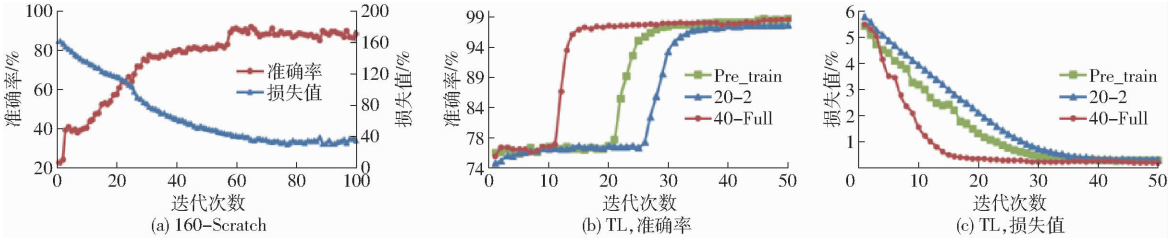

图 7 准确率与损失值对比图

Fig. 7 Comparison charts of loss and accuracy values

下的模型;“40 - Full”表示目标域训练集规格 40 条/类、全量微调策略下的模型,下同。

以目标域全样本按照比例 8∶1∶1 划分并从头训练(Train from scratch)的模型作为基准对照组(160 -Scratch,图 7a),同时对比分析源域预训练模型(Pre_train)和 2 种迁移学习策略——目标域中等样本全参数微调模型(40 - Full)与目标域小样本部分微调模型(20 - 2)(图 7b、7c)。试验结果表明,160 -Scratch 模型从初始状态(准确率 23.05%,损失值 161.58%)开始训练,需要 60 个训练周期才能达到收敛状态(准确率为 91.99%,损失值 30.78%)。相比之下,3 种迁移学习模型均从较高的初始状态(准确率约为 75%,损失值约为 5.5%)出发,最终都收敛到相近的性能水平(准确率大于 97.5%,损失值小于 0.35%),但收敛路径呈现一定差异。40 - Full 模型仅需 15 次迭代即达最优收敛态(准确率 98.50%,损失值 0.21%),彰显全量微调在目标域适应中的效率优势;预训练模型需 31 轮达到准确率 98.66%,反映出在充足数据支撑下,TB 模型能充分发挥出优势;而 20 - 2 模型虽然需要 40 个周期收敛至 97.54% 的准确率,但与对照组相比仍减少了约 20 个训练周期,且准确率提升超过 5 个百分点。证明了在极端资源受限条件下,基于迁移学习的部分微调策略仍能保持良好的适应性。

如图 8 所示,混淆矩阵的定量分析进一步揭示了不同迁移策略下的分类特性。160 - Scratch 模型以较高的训练成本仅获得有限的分类效果(C 波:74.44%,E1 波:88.10%);Pre_train 预训练模型以最高的代价在源域上取得最优类别识别性能(NP:

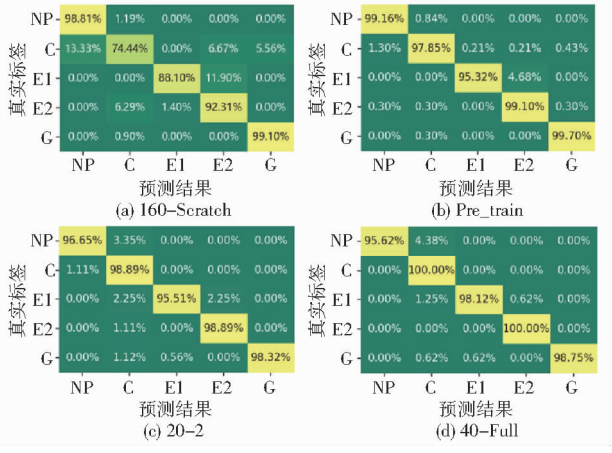

图 8 模型识别结果与实际标签值的比较

Fig. 8 Comparison between model identification results and actual ground truth labels

99.16%，C：97.85%，E1：95.32%，E2：99.10%，G：99.70%）；20－2 模型以较低的微调成本在目标域获得稳健表现（各类别准确率均高于 95.50%）；而 40－Full 模型则在目标域上实现了最佳的性能平衡（C 与 E2 达 100% 识别率，整体准确率 98.50%），展现出全参数微调对特征适应的充分性。值得关注的是，预训练模型与两类微调模型均呈现一致的误判规律：NP 与 C 波形间存在一定混淆（最高误判率 4.38%），E1 与 E2、E1 与 C 以及 G 与 C/E1 之间也存在少量误判。该现象可能与刺吸式昆虫的电生理学特征相关：取食行为中连续的刺探活动、唾液分泌以及韧皮部/木质部取食行为之间的过渡状态，会形成具有相似时频域特征的过渡波形，导致模型难以实现完全区分。需要指出的是，利用 TBDA 模型自动识别 EPG 波形的过程中，仍存在一些影响因素需要考虑。例如，工频干扰、运动伪迹与幅值失真等常见噪声源均会降低信号信噪比，在特征空间中引入类间混淆噪声，从而干扰模型判别。因此，建议在数据采集阶段严格执行标准化实验流程，并做好设备校准与环境控制，以构建高质量数据集。总体而言，研究结果可为木虱取食行为分析提供技术支持。

3　结束语

本研究针对亚洲柑橘木虱 EPG 信号分析中存在的样本稀缺、人工判读效率低等长期制约其高通量分析的挑战，提出了一种融合跨物种知识迁移与多尺度时序建模的智能解析框架。在小样本训练条件下（总样本量为 100，每类波形各 20 个），TB 模型的分类精确度、召回率与 F1 分数较 CNN 模型分别提升 2.99、11.12、17.23 个百分点；进一步引入迁移学习的 TBDA 模型在上述指标上较 TB 模型提升均超过 10 个百分点，迭代次数减少约 77%。在不同微调策略与样本规模下，TBDA 模型均保持与专家行为语义标注高度一致。在单类样本量为 40 且采用全量微调时，模型识别准确率最高可达 98.50%；而在资源受限场景（单类样本量 20，仅微调末 2 层），准确率仍可达到 97.54%。因此，本研究提出的智能解析方法能够有效实现 EPG 波形的自动化识别，可为木虱及跨物种取食行为研究提供理论依据与技术支持。

参　考　文　献

[1] YOUNAS M, ZHENG Z, ATIQ M, et al. Insights into the Huanglongbing pandemic focusing on transmission biology, virulence factors and multifaceted management strategies[J]. Pest Management Science, 2025, 81(10): 6076－6094.

[2] PÉREZ-HEDO M, HODDLE M S, ALFEREZ F, et al. Huanglongbing (HLB) and its vectors: recent research advances and future challenges[J]. Entomologia Generalis, 2025,48: 1－19.

[3] TJALLINGII W F. Electronic recording of penetration behaviour by aphids[J]. Entomologia Experimentalis et Applicata, 1978, 24(3): 721－730.

[4] 李静静，潘建斌，吴莉莉，等. 我国刺吸电位技术三十年应用及创新[J]. 应用昆虫学报，2019，56(6)：1224－1234.
LI Jingjing, PAN Jianbin, WU Lili, et al. Three-decades of electrical penetration graph technique innovation in China[J]. Chinese Journal of Applied Entomology, 2019, 56(6): 1224－1234. (in Chinese)

[5] ZHANG J, XIA F, LI Y, et al. Metabolites induced by citrus tristeza virus and '*Candidatus* Liberibacter asiaticus' influence the feeding behavior of *Diaphorina citri*: an electrical penetration graph and LC－MS/MS study[J]. Phytopathology Research, 2025, 7(1): 1－16.

[6] PRÜFER T, THIEME T, TJALLINGII W F. Aphid-AutoEPG software for analysing electrically monitored feeding behaviour of aphids[J]. European Journal of Environmental Sciences, 2014, 4(1): 53－59.

[7] ADASME-CARREÑO F, MUÑOZ-GUTIÉRREZ C, SALINAS-CORNEJO J, et al. A2EPG: a new software for the analysis of electrical penetration graphs to study plant probing behaviour of hemipteran insects[J]. Computers and Electronics in Agriculture, 2015, 113: 128－135.

[8] WILLETT D S, GEORGE J, WILLETT N S, et al. Machine learning for characterization of insect vector feeding[J]. PLoS Computational Biology, 2016, 12(11): e1005158.

[9] 吴莉莉，贾树恒，邢玉清，等. 基于分形维数和 HHT 的蚜虫刺吸电位波形机器识别[J]. 农业工程学报，2018，34(24)：175－183.
WU Lili, JIA Shuheng, XING Yuqing, et al. Machine identification of electrical penetration graphic waveforms of aphid based on fractal dimension and Hilbert-Huang transform[J]. Transactions of the CSAE, 2018, 34(24): 175－183. (in Chinese)

[10] XING Y, LI B, WU L, et al. Aphid EPG waveforms classification based on wavelet kernel extreme learning machine[J/OL]. Research Square Preprint, Research Square, 2022. https://doi.org/10.21203/rs.3.rs－1484523/v1.

[11] DINH Q D, KUNK D, SON H T, et al. Machine learning for automated electrical penetration graph analysis of aphid feeding behavior: accelerating research on insect-plant interactions[J]. PloS One, 2025, 20(4): e0319484.

[12] 吴莉莉，谷小青，邢玉清，等. 卷积神经网络在昆虫刺吸电位波形识别中的应用研究[J]. 现代电子技术，2022，45(16)：181－186.

WU Lili, GU Xiaoqing, XING Yuqing, et al. Application of convolutional neural network in recognition insect EPG waveforms [J]. Modern Electronics Technique, 2022, 45(16): 181 – 186. (in Chinese)

[13] SIAMI-NAMINI S, TAVAKOLI N, NAMIN A S. A comparative analysis of forecasting financial time series using ARIMA, LSTM, and BiLSTM[J]. arXiv Preprint, arXiv: 1911.09512, 2019.

[14] LIU S, LIN W, WANG Y, et al. Convolutional neural network-based bidirectional gated recurrent unit-additive attention mechanism hybrid deep neural networks for short-term traffic flow prediction[J]. Sustainability, 2024, 16(5): 1986.

[15] WANG W, GU M, HONG Y, et al. SMGformer: integrating STL and multi-head self-attention in deep learning model for multi-step runoff forecasting[J]. Scientific Reports, 2024, 14(1): 23550.

[16] LIU H, ZHANG F, TAN Y, et al. Multi-scale quaternion CNN and BiGRU with cross self-attention feature fusion for fault diagnosis of bearing[J]. Measurement Science and Technology, 2024, 35(8): 086138.

[17] ANJUM N, SATHI K A, HOSSAIN M A, et al. A temporal transformer-based fusion framework for morphological arrhythmia classification[J]. Computers, 2023, 12(3): 68.

[18] PANG Y, ZHANG H, ZHOU Y. Bearing fault diagnosis method based on BiGRU and Swin Transformer attention fusion time-frequency features[C]//2025 5th International Conference on Neural Networks, Information and Communication Engineering (NNICE). IEEE, 2025: 1418 – 1424.

[19] LU W, LIU H, MA H, et al. Hybrid transfer learning strategy for cross-subject EEG emotion recognition[J]. Frontiers in Human Neuroscience, 2023, 17: 1280241.

[20] CÔTÉ-ALLARD U, FALL C L, DROUIN A, et al. Deep learning for electromyographic hand gesture signal classification using transfer learning[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(4): 760 – 771.

[21] IMTIAZ M N, KHAN N. Cross-database and cross-channel electrocardiogram arrhythmia heartbeat classification based on unsupervised domain adaptation[J]. Expert Systems with Applications, 2024, 244: 122960.

[22] BONANI J P, FERERES A, GARZO E, et al. Characterization of electrical penetration graphs of the Asian citrus psyllid, *Diaphorina citri*, in sweet orange seedlings[J]. Entomologia Experimentalis et Applicata, 2010, 134(1): 35 – 49.

[23] 荆裴, 白素芬, 刘芳. 常见植食性刺吸式昆虫取食行为的 EPG 波形分析研究进展[J]. 中国植保导刊, 2013(4): 18 – 23.
JING Pei, BAI Sufen, LIU Fang, et al. Research progress on EPG waveform types analysis on the feeding behavior of common piercing-sucking insects[J]. China Plant Protection, 2013(4): 18 – 23. (in Chinese)

[24] WU T, LUO X, XU C, et al. Feeding behavior of *Diaphorina citri* and its transmission of '*Candidatus* Liberibacter asiaticus' to citrus[J]. Entomologia Experimentalis et Applicata, 2016, 161(2): 104 – 111.

[25] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531 – 544.

[26] ZHANG H, SHI P, HAN D, et al. Research on rolling bearing fault diagnosis method based on AMVMD and convolutional neural networks[J]. Measurement, 2023, 217: 113028.

[27] LI C, WU Y, LIN H, et al. ECG denoising method based on an improved VMD algorithm[J]. IEEE Sensors Journal, 2022, 22(23): 22725 – 22733.

[28] LIU H, ZHAN Y, SUN J, et al. A transformer-based model with feature compensation and local information enhancement for end-to-end pest detection[J]. Computers and Electronics in Agriculture, 2025, 231: 109920.

[29] WEN Q, ZHOU T, ZHANG C, et al. Transformers in time series: a survey[J]. arXiv Preprint, arXiv: 2202.07125, 2022.

[30] BANO S, KHALID S, TAIRAN N M, et al. Summarization of scholarly articles using BERT and BiGRU: deep learning-based extractive approach[J]. Journal of King Saud University—Computer and Information Sciences, 2023, 35(9): 101739.

[31] CAI T T, MA R. Theoretical foundations of t-SNE for visualizing high-dimensional clustered data[J]. Journal of Machine Learning Research, 2022, 23(301): 1 – 54.