

引用:孙海洋,李天成,刘广虎,等. 基于 DB-GS-Yolo11 的跨域智能无线感知算法[J]. 聊城大学学报(自然科学版), 2026, 39(2): 224-237

Citation: SUN Haiyang, LI Tiancheng, LIU Guanghu, XU Lingwei. Intelligent wireless cross-domain sensing algorithm based on DB-GS-Yolo11[J]. Journal of Liaocheng University (Natural Science Edition), 2026, 39(2): 224-237.

文章编号 1672-6634(2026)02-0224-14

DOI 10.19728/j.issn1672-6634.2025040006

基于 DB-GS-Yolo11 的跨域智能无线感知算法

孙海洋^{1,2,3}, 李天成^{1,2,3}, 刘广虎¹, 徐凌伟^{1,2,3}

(1. 青岛科技大学 信息科学技术学院, 山东 青岛 266000; 2. 数字化学习技术集成与应用教育部工程研究中心, 北京 100039; 3. 广西高校非线性电路与光通信重点实验室, 广西师范大学, 广西 桂林 541004)

摘要 无线感知技术利用环境中的 WiFi 信号提取特征信息, 识别目标运动状态。无线感知技术随智能设备普及, 已广泛应用于智能家居、医疗健康、人机交互和自动驾驶等领域。然而, 移动通信环境复杂多变, 无线感知存在着模型感知精度低、场景泛化能力差、环境依赖性高等问题。因此, 针对不同的跨域场景, 提出基于双支路门控时序 Yolo11 跨域智能无线感知算法 DB-GS-Yolo11。该算法采用双支路结构设计, 融合了 Yolo11 神经网络、门控注意力模块(Gated Attention Coding, GAC)和状态空间模块(State Space Model, SSM), 能够高效感知输入信号, 并有效提取关键跨域特征, 从而大幅提升模型的泛化能力。这一改进显著降低了感知任务对特定环境的依赖, 使其具备更强的鲁棒性、可移植性以及跨领域识别精度。在对比实验中, 所提出的 DB-GS-Yolo11 算法与多种主流神经网络模型, 包括深度神经网络(Deep Neural Network, DNN)、门控循环网络(Gated Recurrent Unit, GRU)以及 Google Inception Net 神经网络(GoogLeNet)进行了性能对比。实验结果表明, DB-GS-Yolo11 在感知复杂度优化、识别精度提升以及跨域适应能力方面均展现出更优越的表现。在域内数据集中识别精度整体提高 5.33%~9.67%, 耗时减少 1.35%~17.81%。同时在跨位置、跨方向等跨域数据集上提出的算法的识别精度提升 2.33%~7.33%和 2.67%~4.33%, 耗时减少 1.63%~4.69%和 0.23%~3.11%。

关键词 智能无线感知; 跨域识别; 注意力机制; 双支路 Yolo11 神经网络

中图分类号 TN929.5; TP393

文献标志码 A

开放科学(资源服务)标识码(OSID)



Intelligent wireless cross-domain sensing algorithm based on DB-GS-Yolo11

SUN Haiyang^{1,2,3}, LI Tiancheng^{1,2,3}, LIU Guanghu¹, XU Lingwei^{1,2,3}

(1. College of Information Science and Technology, Qingdao University of Science and Technology, Qingdao 266000, China;

2. Engineering Research Center of Integration and Application of Digital Learning Technology, Ministry of Education,

Beijing 100039, China; 3. Guangxi Universities Key Laboratory for Nonlinear Circuit and Optical

Communication, Guangxi Normal University, Guilin 541004, China)

Abstract Wireless sensing technology utilizes WiFi signals in the environment to extract feature informa-

收稿日期: 2025-04-09

基金项目: 国家自然科学基金项目(62201313); 数字化学习技术集成与应用教育部工程研究中心创新基金项目(1321012); 广西高校非线性电路与光通信重点实验室开放基金课题(NCOC-25-03); 国家级大学生创新创业训练计划项目(202410426019)资助

通信作者: 徐凌伟, 男, 汉族, 博士, 副教授, 研究方向: 智能信息与通信系统, E-mail: gaomilaojia2009@163.com。

tion and identify target motion states. With the widespread adoption of smart devices, this technology has been extensively applied in fields such as smart homes, healthcare, human-computer interaction, and autonomous driving. However, due to the complex and dynamic nature of mobile communication environments, wireless sensing faces challenges such as low model accuracy, poor scenario generalization, and high environmental dependency. To address these issues across diverse cross-domain scenarios, we propose DB-GS-Yolo11, a dual-branch gated sequential Yolo11-based cross-domain intelligent wireless sensing algorithm. The algorithm employs a dual-branch architecture, integrating Yolo11 neural networks, a Gated Attention Coding (GAC) module, and a State Space Model (SSM). This design enables efficient signal perception and robust extraction of key cross-domain features, significantly improving the model's generalization capability. The proposed enhancement substantially reduces environmental dependency, endowing the system with greater robustness, portability, and cross-domain recognition accuracy. In comparative experiments, the proposed DB-GS-Yolo11 algorithm is compared in performance with various mainstream neural network models, including Deep Neural Network (DNN), Gated Recurrent Unit (GRU), and Google Inception Net neural network (GoogLeNet). The experimental results show that DB-GS-Yolo11 exhibits superior performance in optimizing perceptual complexity, improving recognition speed, and cross domain adaptability. The overall perception accuracy in the domain dataset has improved by 5.33% to 9.67%, and the recognition efficiency has increased by 1.35% to 17.81%. The recognition accuracy of the algorithm proposed on cross domain datasets such as cross position and cross direction has been improved by 2.33% to 7.33% and 2.67% to 4.33% while the recognition efficiency has been improved by 1.63% to 4.69% and 0.23% to 3.11% respectively.

Keywords intelligent wireless sensing; cross-domain recognition; attention mechanism; dual-branch Yolo11 neural network

0 引言

随着 5G、云计算、区块链和边缘计算等新一代信息技术的飞速发展,物联网已成为全球新一轮科技革命与产业变革的重要驱动力^[1]。为了高效实现物联网信息交换过程,需要性能优异的感知技术做支撑。Xu 等提出基于多模态变换的网络安全态势评估与预测方法^[2]。唐卫贞等提出了一种增强内在语义属性,提高了特征的可区分性的域自适应流量检测方法^[3]。郭佳琦等提出一种可验证云辅助物联网环境的安全图像检索框架^[4]。Cao 等提出一种用于音频传感应用的分布式边缘计算框架,具有精确的无线链路预测功能^[5]。

无线感知作为一项新兴的物联网感知技术,能够捕捉环境中的无线信号,灵活实现对物联网环境的监测和控制^[6]。Wazid 等提出了一种基于空间物联网的安全智能运输管理框架^[7]。Wei 等引入区块链技术提出基于状态通道的资源交易方案^[8]。Yao 等提出了基于物联网定位技术的智能配送系统^[9]。Zhang 等提出了基于磁无线传感器网络的停车检测算法^[10]。Shao 等针对雷达传感信号提出智能反射表面辅助传感系统^[11]。李新羽等提出了非视距场景下无接触式人体生命体征感知方法^[12]。吴磊等研究通信感知一体化,提出了抗码间串扰的参考信号模式和模糊消除方法^[13]。曹书博等通过结合深度可分离卷积、空洞卷积和 Transformer 结构,提出了一种智能安全中断概率预测算法^[14]。

然而,无线感知面临跨域问题的挑战。环境变化常常导致信号扰动,破坏感知模型的映射关系,影响识别精度和泛化能力^[15]。跨域模型训练成本高,需适应不同域数据,且因模型复杂度高,难以实现实时感知^[16-18]。当前研究基于域自适应思想方法和域泛化思想方法提出过诸多解决方案:

域自适应的思想研究核心是使在源域上训练好的模型能够在目标域上也表现出良好的性能。Yin 通过小样本学习,提前使用部分样本对特征提取器进行微调来实现域自适应^[19]。Zhang 等提出了一种不依赖训练集数据量的 WiFi 手势 ID 模型,通过针对性识别动态手势实现跨域感知^[20]。这种数据采集和模型训练方式耗费的计算和时间成本过高,且从目标域收集的数据存在时效性。

域泛化思想的重点在于使训练好的参数在新目标域中也成立,使模型可以在从未接触过的目标域上也

表现出良好的性能。Liu 等通过提取域不变特征和利用子域扰动对信号的增强效果实现跨域识别^[16]。Liu 提出无线域泛化模型,使用对抗性训练框架使域分类器减少域信号对特征提取器的影响^[21]。Wang 设计并行对抗网络,融合子网络和评估网络,对粗识别结果进行高精度再识别^[22]。此种方法难以解决无线信号受多种环境因素共同影响的跨多子域问题,使该方法常表现出低鲁棒性。

针对上述研究瓶颈,本文创新性地设计了基于深度学习思想的新型跨域智能无线感知模型 DB-GS-Yolo11。主要工作有:(1) 设计了双支路门控时序 Yolo11 网络结构 DB-GS-Yolo11,模型由 Yolo11 框架、门控注意力模块和时序状态空间模块组成。将门控注意力(Gated Attention Coding, GAC)嵌入上支路中的 Neck 瓶颈网络,通过多维度门控单元高效编码时空特征,达到减轻模型体量、增强模型对提取时空特征的融合能力的效果。(2) 将状态空间模块(State Space Model, SSM)嵌入下支路中 Head 部分,增强了对无线信号动态时空特征的融合能力,有效处理跨域数据集中的不确定性。通过融合 GAC 和 SSM 模块,显著提升了模型对跨域特征的自主学习与整合能力。这种模型架构确保了感知系统维持高精度,同时实现了跨域场景下的高性能稳定识别,降低环境依赖性并增强了鲁棒性、可移植性。(3) 将所提出算法与深度神经网络(Deep Neural Network, DNN)、门控循环网络(Gated Recurrent Unit, GRU)以及 Google Inception Net 神经网络(GoogLeNet)进行了性能对比。以上三种算法在跨域仿真实验中存在一定局限,DNN 难以处理动态时序特征,GRU 对空间特征建模不足,GoogLeNet 则缺乏针对跨域无线信号的优化,对跨域感知问题的建模不够充分。而所提出的 DB-GS-Yolo11 融合 GAC 和 SSM 模块之后增强了对跨域数据集的特征提取和融合能力,能够在受诸多跨域因素影响的无线环境中实现准确感知。(4) 为验证算法效果,使用 Wicar3.0 数据集的 CSI 数据开展实验。DB-GS-Yolo11 算法在域内数据集中识别精度提升 5.33%~9.67%;在跨位置、跨方向等跨域数据集上,精度分别提升 2.33%~7.33%和 2.67%~4.33%,同时消耗时间整体降低 0.23%~17.81%。

1 跨域智能无线感知模型

在 WiFi 无线感知环境中,感知目标活动会通过改变电磁波传播路径来影响信号特性。当无线信号遇到移动目标时,会产生多径传播、信号散射和反射等现象^[23-24]。这些物理效应会调制信号的频率、幅度和相位等关键参数。接收端捕获的信道状态信息(Channel State Information, CSI)实际上记录了这些细微变化,形成独特的时空特征模式^[25]。通过分析 CSI 信号的波动规律,建立无线信号与人体动作的映射,可实现基于 WiFi 的无接触动作识别^[26]。

图 1 展示了无线感知的场景,在该场景中实现无线感知的过程:(1) CSI 数据采集:通过 WiFi 终端设备测量无线信号,获取 CSI 数据。(2) 降噪与预处理:对含噪声的 CSI 数据进行滤波、小波分解等处理,以消除干扰。(3) 特征提取:利用算法从 CSI 数据中自动提取位置、动作状态等有效特征。(4) 数据分类:通过分类器对特征进行回归统计,区分动作类型,并更新模型参数。(5) 输出结果:分类器将特征数据输入激活函数,决策后得到最终感知结果。




图 1 无线感知场景

Fig. 1 WiFi sensing scenarios

在实际应用中,由于无线信号在跨域场景中不仅存在时空多维特征偏移,还要应对多径效应、环境噪声和硬件差异带来的动态干扰。模型需要同时处理局部细粒度特征和全局时序依赖关系,而现有架构往往难以兼顾。复杂的跨域模型通常计算量庞大,难以满足边缘设备资源受限的实际部署需求。基于这些关键问题,本文提出了 DB-GS-Yolo11。

2 基于 DB-GS-Yolo11 的跨域智能无线感知算法

本文设计了 DB-GS-Yolo11 神经网络,其在双支路的 Yolo11 网络上下支路中分别融合了 GAC 模块和

SSM 模块,可以更好的捕捉跨域数据中的时空依赖关系。

2.1 数据预处理

算法采用 CSI-ratio 方法处理原始信号,通过降噪和子载波相位特征提取,将信号转换为时序图像作为模型输入^[27]。为消除无关因素和奇异样本的干扰,对时间序列 T 进行标准化与归一化处理,统一样本形式,去除无关差异性。标准化与归一化过程如

$$T = \text{resize}(T), \quad (1)$$

$$T_{\text{Norm}} = \gamma \cdot \frac{T_i - \mu(T_i)}{\text{std}(T_i)} + \delta, \quad (2)$$

其中,输出的 T_{Norm} 为归一化后的时间序列张量,通过对第 i 个通道的张量 T 的二维数据 T_i 进行求均值 $\mu()$ 和求标准差 $\text{std}()$ 操作之后,再经由权值 γ 和偏置 δ 的仿射变换得到。

2.2 DB-GS-Yolo11 网络

DB-GS-Yolo11 网络通过双支路架构融合 GAC 和 SSM 模块,在保持特征学习能力的同时优化模型效率^[28-29]。上下双支路均采用轻量化设计,优化卷积运算模块以及增强特征映射能力,一定程度上降低了参数量,提升了识别速度。如图 2 所示为 DB-GS-Yolo11 网络架构。




图2 基于 DB-GS-Yolo11 智能无线感知算法的总体结构图

Fig. 2 Architecture of the DB-GS-Yolo11 algorithm for intelligent WiFi sensing

DB-GS-Yolo11 采用双支路架构,上支路在 C3k2 层嵌入 GAC 模块,替代冗余卷积,减少 Neck 计算量并增强特征提取。下支路在 Head 分类头嵌入 SSM 模块优化特征融合。双支路特征拼接后经 Softmax 分类器输出结果,降低模型参数量和计算复杂度,提高识别效率。双支路设计使其能够分别提取特征,保证运算时互不干扰,最终整合特征进行分类识别^[30]。

2.2.1 Backbone 主干网络。针对传统感知模型运行效率问题以及实现高效数据集多维特征提取,本文使用 YOLO11 提出的 C3k2 块以及 C2PSA 块进行结构优化,图 3 展示了 Yolo11 的 Backbone 架构。

C3k2 块采用两个小卷积核替代原本的单个大卷积核,通过多个卷积层提取图像特征减少计算量同时保持特征表达能力。在 C3k2 模块中,每个卷积层可以表示为

$$h_l = \sigma(W_l \times h_{l-1} + b_l), \quad (3)$$

其中 h_l 、 W_l 、 b_l 分别表示第 l 层的特征图、卷积核和偏置项, σ 表示激活函数。为改善梯度传播, C3k2 块通常包含残差连接以改善梯度消失问题

$$h_{out} = h_l + h_{in}, \quad (4)$$

其中 h_{out} 和 h_{in} 分别表示模块的输出和输入。




图3 Backbone 网络结构

Fig. 3 Backbone architecture

经过 C3k2 模块处理后,最终输出特征图表示为

$$h_{out} = \sigma(W_3 \times (\sigma(W_2 \times (\sigma(W_1 \times h_{in} + b_1) + b_2)) + b_3)). \quad (5)$$

C2PSA 模块结合了卷积、池化和空间注意力机制,提升特征提取效果和模型性能,并对 Backbone 提取的多维度特征进行融合。DB-GS-Yolo11 的 Backbone 采用双支路架构处理时序图像 T 。每条支路包含 4 个卷积-C3k2 模块的组合结构,经 SPPF 层整合后,由 C2PSA 层输出特征图。

2.2.2 Neck 颈部网络。如图 4 所示,DB-GS-Yolo11 在 Yolo11 颈部网络中采用改进型 PAN 拓扑结构,通过优化宽度和深度参数构建自适应特征金字塔^[31]。针对传统模型对跨域数据集的动态时空特征捕捉能力弱的问题,本文进一步引入 GAC 模块,在保持原有计算资源消耗的同时显著提升模型性能。引入的注意力模块有效强化了跨域动态特征提取能力,提升跨域识别的准确率,通过自下而上的特征传播方式聚合多层次特征,充分利用语义和定位信息。

Neck 网络采用双向特征金字塔进行处理 Backbone 主干网络所输出的特征图张量 P_3 、 P_4 和 P_5 ,特征图自下而上的路径通过点卷积、上采样和注意力提取特征,并与上层特征拼接;自上而下路径则通过 C3k2 模块和 3×3 卷积下采样,融合下层特征。最终三个注意力模块分别输出优化后的多尺度特征图。

门控注意力(GAC)最初用于改进脉冲神经网络的编码方式,通过多维度门控注意力机制提升时空动态性和编码效率,同时保留脉冲驱动特性。本文中,GAC 模块被插入在 Neck 网络的第一个 C3k2 模块中替换其原有卷积层,将来自 Backbone 的 32 通道的特征图和中间特征在通道维度拼接为 64 通道的拼接特征后输

入到 GAC 模块内部。




图 4 Neck 网络结构

Fig. 4 Neck architecture




图 5 门控注意力结构

Fig. 5 Gated attention coding

如图 5 所示, GAC 由时间注意力、空间通道注意力和门控三个子模块组成。GAC 通过这三个模块将静态输入图像转换为动态时空特征, 同时保持硬件友好的脉冲驱动特性。时间注意力以及空间通道注意力组合成 GAC 的动态注意力门控机制, 通过先计算时间维度权重来学习跨域动态场景中的关键帧等不同时间步的特征, 再利用卷积操作提取空间的通道维度特征, 强化跨域数据中的判别性纹理, 最终融合为时变特征。这种处理方式打破周期性限制, 每个时间步的编码结果受输入内容和注意力权重共同调制, 模拟生物视觉的动态信息处理。同时延长了动态持续时间, 使模型能够充分利用时间维度提取跨域时空特征。

时间注意力通过平均池化和最大池化提取时间维度的权重, 对于输入特征 $X \in R^{T \times C \times H \times W}$, 沿时间轴进行平均池化以及最大池化压缩为 1×1 大小, 并通过共享多层感知机生成时间权重, 其中 T 是时间步数, C 是通道数, H 和 W 是空间维度

$$F_T(X) = W_m(\text{ReLU}(W_n(\text{AvgPool}(X)))) + W_m(\text{ReLU}(W_n(\text{MaxPool}(X)))) \quad (6)$$

其中 W_m 和 W_n 分别为第一层和第二层的权重矩阵。之后利用空间通道注意力通过 7×7 卷积操作提取空间和通道信息, 使用共享的二维卷积核提取空间和通道特征

$$F_{sc}(X) = \sum_{i,j} W_{i,j} \cdot X_{i,j}^t. \quad (7)$$

最后,将时间权重 M 广播后与通道 N 特征进行门控融合,通过 3×3 分组卷积和 1×1 卷积,先进行 Hadamard 乘积,并通过 Sigmoid 函数激活,得到最终编码特征

$$F_G(X) = \sigma(M \odot N). \quad (8)$$

GAC 通过模拟生物视觉的动态注意力机制,将静态输入转化为富含时空动态性的特征序列,使模型能更健壮地捕捉跨域数据中的时空依赖关系,同时维持低复杂度。动态注意力门控能够过滤跨域数据中的无关噪声,使感知模型聚焦于判别性区域。时变编码能够根据不同域数据的时空特征差异,动态地调整特征表达,实现跨域特征的自适应对齐。为跨域图像分类任务提供了更为高效的方法。

2.2.3 Head 预测网络。DB-GS-Yolo11 采用分类头设计构建 Head 网络,其结构宽度由 Backbone 和 Neck 输出的特征张量决定,如图 6 所示。引入的 SSM 模块有效强化了特征图中的动态时空信息,解决了深层网络中的特征退化问题,提升时空特征保留率。

DB-GS-Yolo11 的 Neck 网络输出三个特征张量,各通过 1 280 通道卷积层后,经自适应平均池化压缩至 1×1 尺寸,并在池化层后添加 Dropout 层,失活率设置为 0.5。Head 网络对这三个特征张量采用“池化-拉直”整合策略:先进行平均池化提取关键特征并降维,再将结果展平为一维向量按类别顺序拼接,最终形成整合特征向量输入分类器。该设计在保留核心特征的同时,有效降低了模型参数量,小幅提升推理速度。




图 6 Head 网络结构

Fig. 6 Head architecture

SSM 模型(State Space Model, SSM)是一种广泛用于动态系统建模的数学框架,通过状态变量描述系统的动态行为,可以有效处理多变量系统和不确定性,在 DB-GS-Yolo11 中其被融合在 Head 网络的分类头模块中增强对无线信号数据融合之后特征的分类能力并降低模型复杂度。

将 SSM 假设为动态系统,通常可用以下两个方程进行状态预测

$$\mathbf{h}(t) = \mathbf{A}\mathbf{h}(t-1) + \mathbf{B}\mathbf{u}(t) + \mathbf{w}(t), \quad (9)$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{h}(t) + \mathbf{D}\mathbf{u}(t) + \mathbf{v}(t), \quad (10)$$

其中(9)为状态方程, $\mathbf{x}(t)$ 表示系统状态向量, $\mathbf{A}, \mathbf{B}$ 分别为状态转移矩阵和输入矩阵, $\mathbf{u}(t)$ 表示输入向量, $\mathbf{w}(t)$ 为过程噪声。(10)为观测方程, $\mathbf{y}(t)$ 表示系统状态向量, $\mathbf{C}, \mathbf{D}$ 分别为输出矩阵和直接传递矩阵, $\mathbf{v}(t)$ 为观测噪声。通过上述方程,根据观察到的数据去预测当前状态 $\mathbf{h}(t)$, 最终目标是找到这种状态表示,得到向量从输入序列 $\mathbf{h}(t-1)$ 到输出序列 $\mathbf{y}(t)$ 的状态。将上述两式可视化可得 SSM 整体结构如图 7 所示。

在下支路,SSM 首先初始化一个状态向量 $\mathbf{h}$, 随后按照空间位置对输入的 32 通道特征图的每个位置使用状态方程(9)进行更新,得到重组特征图。随后利用 3×3 卷积进行线性映射,将原始特征空间分解为状态维度和观测维度两个互补的子空间。状态维度聚焦于特征的潜在动态演化规律,其决定了 SSM 内部状态向量的容量,即模型能够存储多少历史时空信息。在状态方程(9)中,状态维度越大越能保留低频长程信号。在跨域问题中,不同域的时空依赖模式存在差异,调整合适的状态维度能够有效捕获跨域数据集的特征关联信息和跨时间特征变化,提升跨域长程建模能力。而观测维度则对应特征在任务目标下的显式可测量属性,控制着模型将当前状态到输出特征的映射自由度。如果需要将跨域数据统一投射到共享特征空间,则需

要合适的观测维度来容纳足够多的判别信息,进而分离出域不变特征和跨域环境噪声。




图 7 状态空间模型

Fig. 7 State space model

投影后的张量通过通道拆分操作,被划分为状态分支与观测分支,并分别经过非线性激活函数处理。随后通过递归更新机制对特征向量的时序依赖性进行建模。状态分支的隐藏状态在每个时间步内根据上一状态与当前输入动态调整。通过观测矩阵与观测分支的特征进行耦合实现跨域时空特征的互补增强,最终输出融合时空动态特性的状态表征到分类头。

2.2.4 线性分类器与结果输出模块。DB-GS-Yolo11 基于双支路并行架构,通过改进的 Yolo11 支路分别提取手势特征并输出向量,经特征拼接融合整合互补信息(如频域与时空特征),形成统一表征。




图 8 线性分类器与结果输出模块

Fig. 8 Linear classifier and result output module

如图 8 所示,融合后的特征向量经过线性投影层进行降维处理后输入分类器,上支路与下支路各输出三个通道数为 32 的特征图,特征图来自不同深度,捕获涵盖高层到低层的语义信息。将特征图拼接为 192 通道的特征图,并经过一层 Dropout 消除过拟合影响,最终通过 Softmax 函数输出各类别的概率分布。最后,通过 Softmax 激活函数将分类特征向量映射为大小为 1×6 的分类概率向量,表示为

$$Y = \text{ReLU}(\text{BN}(w_1 * X + b_1)), \quad (11)$$

$$R = \text{Softmax}(w_2 * Y_1 + b_2), \quad (12)$$

其中 w_1 与 w_2 分别表示两个全连接层的权重矩阵; b_1 与 b_2 分别为两个全连接层的偏置向量; BN 为批量归一化操作, * 为矩阵向量的线性变换运算。

在训练过程中,模型损失函数使用多分类交叉熵

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(p_{i,c}), \quad (13)$$

其中 N 表示样本总数, C 表示类别数量, y 表示真实标签的 one-hot 编码即样本 i 属于类别 c 时值为 1, p 表示模型预测样本 i 属于类别 c 时的概率。

本文设计算法所融合的 GAC 以及 SSM 模块能够捕获和处理环境中的时空特征,使得 DB-GS-Yolo11 网络能够有效地从跨域数据集中提取动态的特征信息,提高了模型在面对时刻变化的感知环境时对 CSI 数据的建模能力,在实现跨域智能无线感知时能够体现出优势。算法流程和仿真实验将在第三章节展示。

3 算法流程与仿真实验结果

3.1 算法流程

所提出的基于 DB-GS-Yolo11 的智能无线感知算法的伪代码描述如下算法所示。

Algorithm 1 DB-GS-Yolo11-Based Intelligent Wireless Sensing Algorithm

Input: CSI Feature Dataset for Wireless Sensing-Based Gesture Recognition

Feature Data: $D = \{d_i \mid i = 1, 2, \dots, N\}$;

Label Data: $Y = \{y_i \mid i = 1, 2, \dots, N\}$;

Output: Gesture Type Recognition Results

$\hat{Y} = \{\hat{y}_i \mid i = 1, 2, \dots, N\}$;

1. // Data Partitioning and Preprocessing
 2. $T_1, T_2 \leftarrow \text{SplitDataset}(\text{CSI_dataset}, \text{ratio}=0.8)$ // Partition the dataset into training set T_1 and testing set T_2
 3. // Denoising and Visualization
 4. FOR each sample (x, y) IN T_1 DO
 5. $x_{\text{denoised}} \leftarrow \text{CSI_Ratio_Denoising}(x)$ // Denoising by using CSI-Ratio method
 6. $x_{\text{visual}} \leftarrow \text{TimeSeriesToImage}(x_{\text{denoised}})$ // Convert to Time-Series Images
 7. $x_{\text{normalized}} \leftarrow \text{StandardScaler}(x_{\text{visual}})$ // Standard Normalization
 8. ADD $(x_{\text{normalized}}, y)$ TO processed T_1
 9. END FOR
 10. // Model Initialization
 11. model $\leftarrow$ DB_GS_Yolo11(
 12. cfg=parameter_config_dict,
 13. in_channels=3,
 14. num_classes=6,
 15. activation="ReLU")
 16. optimizer $\leftarrow$ RMSProp(lr= α)
 17. // Train
 18. FOR epoch FROM 1 TO max_epochs DO
 19. // Forward Propagation
 20. OUT_U $\leftarrow$ model.GAC_Module(processed T_1) // Feature of GAC in upper branch
 21. OUT_L $\leftarrow$ model.SSM_Module(processed T_1) // Feature of SSM in lower branch
 22. OUT_Fusion $\leftarrow$ CONCAT(OUT_U, OUT_L) // Feature Concatenation
 23. $\hat{Y} \leftarrow$ model.Classifier(OUT_Fusion) // Classifier Output Prediction
 24. // Backward Propagation
 25. loss $\leftarrow$ CrossEntropyLoss($\hat{Y}, Y$) // Loss Computation
 26. $\Delta w \leftarrow$ optimizer.compute_gradient(loss) // RMSProp update parameter w to minimize the loss function.
 27. model.update_parameters(Δw)
 28. END FOR
 29. // Model Evaluation
 30. accuracy $\leftarrow$ Evaluate(model, T_2)
-

```

31. IF accuracy < threshold THEN
32.     ADJUST hyperparameters OR model_structure // Adjust Hyperparameters or Architecture
33.     GOTO 12 // Retrain
34. ELSE
35.     RETURN model // Return the trained model
36. END IF

```

37. Based on the evaluation results of the post-training model using T_2 , if the accuracy meets the requirements, the trained model parameters can be applied to practical intelligent wireless sensing tasks. Otherwise, adjust the network architecture and hyperparameters and return to Step 5 to retrain the model.

3.2 仿真实验数据集

DB-GS-Yolo11 算法使用清华大学公开的 Widar3.0 数据集中所监测采集的无线信号 CSI 数据^[27]。

表 1 评估数据集的细节描述

Tab. 1 Detailed description of the evaluation dataset

Environments	No. of Users	Gestures Label	No. of Locations	No. of Orientations	No. of Samples
Classroom	2	1: Slide;	1~5	1~5	3 000
		2: Draw-O(Horizontal);			
		3: Draw-Zigzag(Horizontal);			
		4: Draw-N(Horizontal);			
		5: Draw-Triangle(Horizontal);			
		6: Draw-Rectangle(Horizontal)			

表 1 展示了在教室环境中针对用户 2 进行的域内、跨位置和跨方向实验所使用的数据集,其规模为 $N=3\,000$ 。该数据集包含来自五个不同位置和方向的六类动作数据。感知区域为 $2\text{ m}\times 2\text{ m}$ 的正方形场地,所有收发设备均为物理尺寸 $170\text{ mm}\times 170\text{ mm}$ 的迷你台式计算机,并配备 Intel 5300 无线网卡。通过 Anaconda 23.7.4 配置 PyTorch 虚拟环境进行模型的训练和测试,PyTorch 使用 2.1.0 版本。如图 9 所示,跨位置感知由用户在 A 至 E 五个位置进行,而跨方向感知在 1 至 5 五个方向上进行。域内实验使用 90% 训练集和 10% 测试集,跨域实验则根据域因素采用 80% 训练集和 20% 测试集的划分方式,所有实验均通过 20 折交叉验证确保结果可靠性。

3.3 仿真实验结果分析

本节从对比算法以及消融实验的角度研究了所提出算法在跨域无线感知手势识别精度和效率上面的实验表现,评估指标使用识别准确率和测试运行时间。

3.3.1 不同算法对比分析。为了验证所提算法在感知精度、识别效率以及跨域识别上的性能表现,将该算法模型与其它智能感知算法在同一训练集、测试集的条件下进行实验结果的比较,并选取了 DNN^[32],GRU^[33] 以及 GoogLeNet^[34] 三种智能无线感知算法作为对比算法。表 2 显示了训练超参数。

表 3 显示了不同算法在精度和时间指标性能上的对比结果。图 10 为对比算法的域内识别混淆矩阵以及所提算法的跨域识别混淆矩阵图,图 11 展示了不同算法在不同场景下的识别准确率、测试运行时间的对比。其中, A 表示准确率; T 表示测试运行时间; CL 表示跨位置; CO 表示跨朝向。

由图 10,图 11 可得出,DB-GS-Yolo11 算法识别准确率相较于所有对比算法,在域内以及各跨域场景下均展现出优势。在域内识别场景中,识别准确率提高了 $5.33\%\sim 9.67\%$;在跨域场景中,跨位置、跨方向的识别准确率分别提升了 $2.33\%\sim 7.33\%$ 、 $2.67\%\sim 4.33\%$ 。从横向角度上来看,在域内、跨位置、跨方向上




图 9 实验环境以及设备方位配置

Fig. 9 Experimental environment and device placement configuration

的测试运行效率分别提升了 1.35%~17.81%、1.63%~4.69%、0.23%~3.11%。

表 2 超参数设置值


Tab. 2 Hyperparameter Settings

Hyperparameter	Setting
BatchSize	40
LearnRate	0.004
K in k-Fold Cross-Validation	20
Batch Size	60
Dropout Rate	0.5
Proportion of Cross-Validation Set in Training Set	0.05
Initial Bias for the SSM Activation Function	0
Initial Bias for the Classifier's Activation Function	0.1

表 3 不同算法跨域性能和测试运行时间对比

Tab. 3 Comparison of cross-domain sensing accuracy and testing time across different algorithms

Algorithm	InDomain		CL		CO	
	A/%	T/ms	A/%	T/ms	A/%	T/ms
DNN	59.67	3 181	49.00	4 291	42.33	4 402
GRU	52.67	3 194	44.00	4 323	41.00	4 313
GoogLeNet	55.33	3 818	47.17	4 429	40.67	4 441
DB-GS-Yolo11	65.00	3 138	51.33	4 221	45.00	4 303




注: (a) DNN InDomain; (b) GRU InDomain; (c) GoogLeNet InDomain; (d) DB-GS-Yolo11 InDomain; (e) DB-GS-Yolo11 CL; (f) DB-GS-Yolo11 CO.

图 10 不同算法感知的混淆矩阵图

Fig. 10 Confusion matrices of different algorithms for sensing

在域内识别场景中,所有算法都表现出比跨域场景更高的准确率,这是因为相比较域内场景,在跨域环境下模型受更复杂环境因素影响,更难以对跨域特征实现彻底学习。在跨域无线感知任务中,DNN、GRU

和 GoogLeNet 均存在特定局限性。DNN 的全连接结构难以有效建模无线信号中动态变化的时序特征,往往无法区分短期波动与长期模式。GRU 对空间特征的提取能力较弱,难以有效捕捉多维空间关联性。GoogLeNet 的固定卷积核与静态权重分配难以动态适应不同域间的信号分布偏移,导致跨域迁移时性能显著下降。而 DB-GS-Yolo11 通过 GAC 模块选择性聚焦关键特征,同时 SSM 模块有效捕获跨域不变特征,双支路架构专门优化了无线信号的时空特征融合,在保持模型轻量化的基础上实现了跨域场景下的性能突破。不过,该算法仍存在一定识别精度分布不均衡的问题,后续还需对模型的特征提取和处理进一步优化。




注:(a) 跨域感知准确率对比柱状图;(b) 跨域感知测试时间对比柱状图。

图 11 不同算法各指标对比柱状图

Fig. 11 Comparative bar chart of various metrics across different algorithms

3.3.2 消融对照实验分析。为评估模型融合的 GAC 和 SSM 两个模块对跨域性能的提升程度,进行了消融实验,分别去除上下支路所添加两个模块中的其中一个,还原相应支路 Yolo11 网络中的原始模块;以及将模块全部去掉,直接跟 Yolo11 网络进行比较。消融实验在不同场景下的识别准确率、测试运行时间的对比柱状图分别如图 12 所示,消融实验跨域训练准确率趋势对比折线图如图 13 所示。消融实验识别准确率和测试时间的对比如表 4 所示。



注:(a) 消融实验准确率对比柱状图;(b) 消融实验测试时间对比柱状图。

图 12 消融实验各指标对比柱状图

Fig. 12 Comparative bar chart of various metrics in ablation experiment

表 4 消融实验跨域性能和测试运行时间对比

Tab. 4 Comparative analysis of cross-domain sensing accuracy and testing time in ablation experiment

Algorithm	InDomain		CL		CO	
	A/%	T/ms	A/%	T/ms	A/%	T/ms
Model without GCA	62.33	3 143	46.00	4 326	42.33	4 364
Model without SSM	63.67	3 357	49.00	4 568	43.67	4 792
Yolo11	59.67	3 361	45.33	4 782	40.67	4 936
DB-GS-Yolo11	65.00	3 138	51.33	4 221	45.00	4 303

在训练中,准确率呈现小幅波动,无过拟合或欠拟合现象,但 DB-GS-Yolo11 在两种跨域场景中的整体准确率均高于其他算法。分析表明,去除 GAC 模块或 SSM 模块会导致模型精度下降,域内、跨位置、跨方

向场景精度分别降低 1.33%~5.33%、2.33%~6.00%、1.33%~4.33%。这是由于上支路融合的 GCA 模块通过动态调节注意力权重,能够着重关注对跨域无线感知任务更重要的时空特征;在下支路融合的 SSM 模块在面对动态的跨域数据时能够捕捉其中的依赖关系,通过对状态的动态调整实现了高效的特征融合。同时双支路结构设计所采用的分而治之策略保证了上下支路模块的互补和特征表达的丰富性,当其中一个支路受到外界因素干扰导致失效时,可通过另一支路对其进行特征信息的补全,使整体模型结构在不断变化的跨域环境中更加稳定。

DB-GS-Yolo11 测试运行所消耗时间有一定程度降低(约 0.15%~12.7%),得益于 GAC 模块在保证精度的同时能够减少参数量,同时 SSM 模块有效增强了模型的域无关特征融合能力。排除模型在各类手势识别存在一定精度的精度分布不均衡问题,GAC 和 SSM 模块对模型跨域性能的提升达到了预期效果。

4 结论

本文提出了一种基于 DB-GS-Yolo11 的跨域智能无线感知模型。在网络结构中加入了门控注意力和状态空间模块,可以更有效地捕捉无线信号和感知目标的映射关系,利用门控注意力编码以及状态空间技术,能够增强对跨域特征的学习能力。实验结果表明,模型在预测准确率方面优于 DNN,GRU 和 GoogLeNet 网络模型。后续研究考虑进一步优化 Yolo 系列神经网络的模型结构,并在其中融合图卷积技术以进一步发掘数据集中的跨域特征,强化模型对特征图和无线数据集映射关系的架构能力,改善模型对感知对象的识别精度分布不均匀的问题。




图 13 消融实验跨领域训练精度趋势对比折线图

Fig. 13 Comparative line chart of cross-domain training accuracy trends in ablation experiment

参 考 文 献

- [1] MAITI M, GHOSH U. Next-generation Internet of Things in fintech ecosystem[J]. IEEE Internet of Things Journal, 2023, 10(3): 2104-2111.
- [2] XU M, LIU S H, LI X W, et al. Network security situation assessment and prediction method based on multimodal transformation in edge computing[J]. Computer Communications, 2024, 215(2): 103-111.
- [3] 唐卫贞, 刘波, 黄洲升, 等. 基于小波变换增强位置编码 Transformer 的空域流量预测[J]. 现代电子技术, 2025, 48(8): 127-132.
- [4] 郭佳琦, 马智, 王文胜, 等. 云辅助物联网环境下可验证的安全图像检索[J]. 通信学报, 2025, 46(3): 28-44.
- [5] CAO C H, DONG W, ZHANG W Z, et al. WiEdge: edge computing for audio sensing applications with accurate wireless link prediction[J]. IEEE Internet of Things Journal, 2023, 10(5): 3982-3994.
- [6] 钟怡, 毕添琪, 王菊, 等. 面向通信感知一体化的无线跨域感知研究综述[J]. 信号处理, 2023, 39(6): 951-962.
- [7] WAZID M, DAS A K, SHETTY S. An authentication and key management framework for secure and intelligent transportation of Internet of Space Things[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(6): 5242-5257.
- [8] CHEN W, HUO R, SUN C, et al. SCRT: a secure and efficient state-channel-based resource trading scheme for Internet of Things[J]. IEEE Internet of Things Journal, 2023, 10(11): 10038-10051.
- [9] YAO Y H, ZHANG H R, LIN L F, et al. Internet of Things positioning technology based intelligent delivery system[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(11): 12862-12876.
- [10] ZHANG Y, WU C, LIU S Y, et al. A parking detection algorithm based on multitransitory finite-state machine using magnetic wireless sensor network[J]. IEEE Internet of Things Journal, 2024, 11(5): 8360-8372.
- [11] SHAO X D, YOU C S, ZHANG R. Intelligent reflecting surface aided wireless sensing: applications and design issues[J]. IEEE Wireless Communications, 2024, 31(3): 383-389.
- [12] 李新羽, 张静远, 蔡子轩, 等. 可重构智能超表面辅助的非视距人体生命体征感知[J]. 电子学报, 2025, 53(1): 1-13.

- [13] 吴磊,胡浪涛,谭镇坤,等. 基于柔性天线阵列的通信感知一体化系统性能优化[J]. 无线电工程,2025,55(4):800-807.
- [14] 曹书博,高志贺,李玉芳,等. 基于 MDT-Net 的物联网安全性能智能预测[J]. 聊城大学学报(自然科学版),2023,36(6):18-26.
- [15] LU S H, LIU F, LI Y X, et al. Integrated sensing and communications: recent advances and ten open challenges [J]. IEEE Internet of Things Journal, 2024, 11(11):19094-19120.
- [16] LIU S J, CHEN Z H, WU M, et al. Generalizing wireless cross-multiple-factor gesture recognition to unseen domains[J]. IEEE Transactions on Mobile Computing, 2024, 23(5):5083-5096.
- [17] YIN G L, ZHANG J Q, Yi X P, et al. Evasion attacks and countermeasures in deep learning-based Wi-Fi gesture recognition [J]. IEEE Transactions on Mobile Computing, 2025, 24(9):8180-8195.
- [18] GU Y, ZHANG X, WANG Y T, et al. WiGRUNT: WiFi-enabled gesture recognition using dual-attention network[J]. IEEE Transactions on Human-Machine Systems, 2022, 52(4):736-746.
- [19] YIN G L, ZHANG J Q, SHEN G X, et al. FewSense: towards a scalable and cross-domain Wi-Fi sensing system using few-shot learning [J]. IEEE Transactions on Mobile Computing, 2024,23(1):453-468.
- [20] ZHANG R H, JIANG C X, WU S, et al. Wi-Fi sensing for joint gesture recognition and human identification from few samples in human-computer interaction[J]. IEEE Journal on Selected Areas in Communications,2022, 40 (7):2193-2205.
- [21] LIU S J, CHEN Z H, WU M, et al. WiSR: wireless domain generalization based on style randomization[J].IEEE Transactions on Mobile Computing,2024,23(5):4520-4532.
- [22] WANG J, ZHAO S Z, LV Y Y, et al. Cross-scenario device-free gesture recognition based on parallel adversarial network[J]. IEEE Transactions on Cognitive Communications and Networking,2024,10(3):893-904.
- [23] 张建华,田艺璇,孙语瞳,等. 面向 6G 无线环境可预测的感知重构、语义表征及应用[J]. 中兴通讯技术,2023,29(5):38-44.
- [24] LOU L L, SONG M X, CHEN X Q, et al. Optimized wireless sensing and deep learning for enhanced human-vehicle recognition[J]. IEEE Transactions on Intelligent Transportation Systems,2024, 25(7):7508-7521.
- [25] 何继爱,李先祺,赵雪,等. 一种室内 WiFi 环境下的人体活动识别方法[J]. 计算机技术与发展,2025,35(3):179-186.
- [26] 杨志勇,卢超,王俊杰,等. Wi-HFM:基于 WiFi 信道特征的人流量监测方法[J]. 计算机研究与发展,2025,62(3):720-732.
- [27] ZHANG Y, ZHENG Y, QIAN K, et al. Widar3.0: zero-effort cross-domain gesture recognition with Wi-Fi[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(11):8671-8688.
- [28] ZHU R J, ZHANG M L, Zhao Q H, et al. TCJA-SNN: temporal-channel joint attention for spiking neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(3):5112-5125.
- [29] LIU W Q, HUO H T, JI L Y, et al. CSPPNet: a convolution and state space based photovoltaic panel extraction network using Gaofen-2 high resolution imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2025, 18:7644-7661.
- [30] ZHAO Y, JIANG Z D. YOLO-WWBi: an optimized YOLO11 algorithm for PCB defect detection[J]. IEEE Access, 2025,13:74288-74297.
- [31] WU Y H, LIU Y, ZHAN X, et al. P2T: pyramid pooling transformer for scene understanding[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023,45(11):12760-12771.
- [32] LIU G Z, DAI F, XU X L, et al. An adaptive DNN inference acceleration framework with end-edge-cloud collaborative computing[J]. Future Generation Computer Systems, 2023,140:422-435.
- [33] ZHAO S C, XU Z J, ZHU Z F, et al. Short and long-term renewable electricity demand forecasting based on CNN-Bi-GRU model[J]. IEEE Transactions on Emerging Topics in Artificial Intelligence, 2025, 2(1):1-15.
- [34] NESHOV N, TONCHEV K, MANOLOVA A, et al. Feature-level fusion vs. score-level fusion for image retrieval based on pre-trained deep neural networks[J]. Journal of Mobile Multimedia, 2024, 20(4):769-783.

(责任编辑:赵海军)