

基于时序-空间特征自适应融合的非正交PSWFs信号检测方法

陈文华^{①②③} 毛忠阳^{①②} 陆发平^{*①②} 孙 烨^③ 高翊轩^④

^①(中国人民解放军海军航空大学 烟台 264001)

^②(山东省海空信息感知与处理技术重点实验室 烟台 264001)

^③(中国人民解放军91428部队 宁波 315456)

^④(哈尔滨工程大学 哈尔滨 150001)

摘 要: 针对非正交椭圆球面波函数(Prolate Spheroidal Wave Functions, PSWFs)信号间相互干扰严重, 传统检测方法难以有效分离干扰导致性能下降的难题, 提出了一种基于时序-空间特征自适应融合(Adaptive Temporal-Spatial Feature Fusion, ATSFF)的非正交PSWFs信号检测方法。该方法构建时序-空间双路径并行特征提取架构, 分别提取信号的一维时序相关特征与二维空间结构特征, 设计基于预测置信度的自适应概率加权融合机制实现特征互补增强。仿真结果表明, 在误比特率为 4×10^{-6} 时, 所提方法系统误码性能比交叉项检测方法提升约0.2 dB。

关键词: 椭圆球面波函数; 非正交信号检测; 时序-空间特征融合; 自适应加权融合

中图分类号: TN911.3

文献标识码: A

文章编号: 1009-5896(2026)00-0001-10

DOI: 10.11999/JEIT260024

CSTR: 32379.14.JEIT260024

1 引言

随着第五代移动通信技术的规模化部署和第六代移动通信技术的快速发展, 无线数据业务呈现爆炸式增长态势, 对通信系统的频谱效率和传输容量提出了更为严苛的要求^[1-3]。在这一背景下, 非正交多址接入技术作为一种突破传统正交资源分配限制的关键技术, 已成为超五代(Beyond Fifth-Generation, B5G)/ 第六代(6G)通信系统研究的重要方向^[4,5]。其中, 基于椭圆球面波函数(Prolate Spheroidal Wave Functions, PSWFs)的非正交调制技术因其优异的时频能量聚集特性和更高的频谱利用率而备受关注^[6]。PSWFs作为一类在时间和频率域同时具有紧支撑特性的特殊函数, 其基函数在给定时间带宽积条件下能够实现最优的能量集中, 相比传统正交调制方式可显著提升单位频带内的信息传输密度^[7]。然而, 当多个PSWFs信号在功率域进行非正交复用, 信号间的相互干扰成为制约系统性能提升的关键瓶颈^[8], 特别是在高动态、多径衰落的复杂无线信道环境中, 如何实现高精度、低复杂度的非正交PSWFs信号检测已成为当前研究面临的重大技术挑战。

针对非正交PSWFs信号检测中存在的信号间相互干扰问题, 国内外学者已开展了大量研究工作

并提出了多种解决方案。传统检测方法主要包括基于白化变换的相干检测技术和基于交叉项抑制的干扰消除算法, 通过预处理接收信号来降低非正交信号间的相关性, 从而改善检测性能^[9,10]。然而, 此类方法通常依赖于理想的信道状态信息和精确的系统参数建模, 在实际复杂多变的无线信道环境中往往难以获得较高的检测精度^[11]。近年来, 随着深度学习技术在无线通信领域的广泛应用, 一些研究者尝试将神经网络模型引入信号检测中, 通过数据驱动的方式学习信号特征并实现智能化检测。黄永明等人^[12]提出了基于广义投影梯度下降算法的深度学习大规模多输入多输出(Multiple-Input Multiple-Output, MIMO)信号检测方法, 在多次梯度下降后执行一次投影, 构建了自纠错自动检测器框架。蒲旭敏等人^[13]针对高多普勒场景下正交时频空系统信道估计精度受限的问题, 提出了基于模型驱动深度学习的信道估计方案, 将传统估计算法的结构先验融入神经网络设计, 有效平衡了估计性能与计算复杂度。王骥等人^[14]提出了基于低复杂度加法网络的非正交多址短报文多用户检测算法, 通过轻量化网络压缩模型参数量, 实现低复杂度多用户盲检测。Kumar等人^[15]针对非正交多址接入(Non-Orthogonal Multiple Access, NOMA)系统中串行干扰消除(Successive Interference Cancellation, SIC)检测方法存在的处理速度慢、误差传播严重等问题, 通过深度神经网络实现用户检测、信道估计和功率分配的一体化处理。随后, 该团队在2024年进一步将该思路拓展至大规模MIMO-NOMA场景, 提出了基于深度学习(Deep Learning-based

收稿日期: 2026-xx-xx; 改回日期: 2026-07-21; 网络出版: 2026-07-30

*通信作者: 陆发平 lufaping@163.com

基金项目: 博士后创新人才支持计划(BX20200039), 山东省自然科学基金(ZR2023MD045)

Foundation Item: China National Postdoctoral program for Innovative Talents(BX20200039), The National Natural Science Foundation of Shandong Province(ZR2023MD045)

Method, DLM)的信号检测方法^[16], 利用功率分配系数等信息, 在误比特率(Bit Error Rate, BER)、功率谱密度(Power Spectral Density, PSD)和复杂度方面均优于传统检测方法。Wang等人^[17]提出了基于学习型预处理共轭梯度下降网络的信号检测方法, 用于下行链路MIMO-NOMA系统, 显著提升了网络复用性和检测性能。尽管上述深度学习方案在特定场景下展现了强大的特征学习能力, 但将其直接迁移至非正交 PSWFs 信号检测时仍存在明显不足。现有工作多侧重于挖掘信号的一维时序特征或直接处理复数域信号, 忽视了 PSWFs 信号在时频转换后蕴含的丰富二维空间纹理特征, 导致关键判别信息丢失, 并且大多数研究采用单一路径网络, 未能建立时序动态性与空间结构性之间的互补关联, 难以应对非正交信号间复杂的非线性干扰。因此, 如何构建一种能够自适应融合时空多维特征的检测框架, 仍是当前需要解决的关键难题。

针对上述问题, 本文提出一种基于时序-空间特征自适应融合(Adaptive Temporal-Spatial Feature Fusion, ATSFF)的非正交 PSWFs 信号检测方法。该方法从多维特征挖掘和自适应决策融合两个维度突破现有方法的局限, 通过时序与空间双路信息的互补增强, 有效抑制非正交信号间的干扰。理论分析与仿真实验表明, 所提方法在检测精度和鲁棒性上均优于传统算法。本文的主要贡献如下:

(1)构建了时序-空间双路径互补特征提取架构。利用门控循环单元(Gated Recurrent Unit, GRU)挖掘信号长时依赖, 结合格拉姆角差场(Gramian Angular Difference Field, GADF)变换与50层残差网络(Residual Network 50-layer, ResNet50)提取二维空间纹理, 突破单一维度特征局限, 实现了对非正交PSWFs信号内在时频特性的全方位深度表征。

(2)提出了基于预测不确定性的自适应概率加权融合机制。通过量化双网络输出熵值动态调节融合权重, 智能调节时序动态与空间结构特征的贡献度, 有效抑制复杂信道下的非线性干扰, 显著增强检测的鲁棒性。

(3)实现了检测精度与计算复杂度的良好平衡。仿真表明, 该方法在高信噪比下误码性能较传统算法提升约0.2 dB, 计算量不随用户数增加而上升, 区别于传统方法的矩阵求逆类算法, 但受网络结构影响, 实际运算耗时偏高。该算法侧重高精度检测, 适用于对误码性能指标要求高的非正交系统。

2 非正交PSWFs信号传输模型与现有方法分析

本章重点构建非正交PSWFs信号传输模型,

基于模型定量分析非正交干扰的本质特性, 进而系统剖析现有检测方法的原理性缺陷, 为本文时序-空间特征自适应融合检测方法的设计提供依据。

2.1 非正交PSWFs信号模型与非正交干扰本质特性

在非正交传输系统中, 发送端同时传输 K 个 PSWFs 信号, 经过加性高斯白噪声(Additive White Gaussian Noise, AWGN)信道传输后, 接收端离散时间信号可表示为:

$$y(n) = \sum_{k=1}^K s_k(n) + w(n), n = 1, 2, \dots, N \quad (1)$$

其中, n 为离散时间索引, N 为信号长度, $s_k(n)$ 为第 k 个PSWFs信号, $w(n)$ 为均值为0、方差为 σ^2 的AWGN。PSWFs信号 $s_k(n)$ 由第 k 阶PSWFs基函数 $\Phi_k(t)$ 生成, 该基函数满足积分方程:

$$\int_{-T/2}^{T/2} \Phi_k(t) \cdot \frac{\sin[\pi R(t-t')]}{\pi(t-t')} dt' = \lambda_k \Phi_k(t') \quad (2)$$

其中, T 为信号持续时间, R 为带宽, λ_k 为特征值。PSWFs基函数具有最优时频聚集性, 在给定的时间带宽积($T \times R$)条件下, 能量聚集度最高, 这使得PSWFs信号在非正交传输场景下具有独特优势。

非正交PSWFs信号模型可定量分析非正交干扰的本质特性: 非正交PSWFs传输中的干扰并非传统意义上的加性随机噪声, 其本质是不同阶数PSWFs基函数之间的不完全正交性所产生的结构性干扰。这种干扰由基函数的固有数学特性决定, 具有明确的确定性和可预测性, 而非完全随机的不可控扰动; 其干扰强度与基函数的阶数差直接相关, 阶数越接近的基函数之间, 相互产生的非正交干扰越显著。

2.2 现有检测方法局限性分析

基于上述传输模型与干扰特性, 现有非正交PSWFs信号检测方法可分为传统信号处理与深度学习两大技术方法, 两类方法均难以有效抑制强非线性干扰, 存在明显的局限性。

2.2.1 传统信号处理方法的局限性

相干检测^[11]: 基于信号正交性假设设计最优判决边界, 非正交场景下干扰项破坏正交性, 导致判决边界严重偏移, 误码率随用户数呈指数级上升, 不适用于多用户非正交传输。

交叉项检测^[11]: 通过时频分析与高阶累积量提取特征抑制干扰, 但低信噪比下其统计特性会发生严重畸变, 鲁棒性不足, 难以大规模工程应用。

时序多重稀疏贝叶斯学习-最小二乘(Temporal Multiple Sparse Bayesian Learning-Least Squares,

TMSBL-LS)^[18]：基于信号稀疏重构思想，依赖PSWFs叠加信号的稀疏性假设，但非正交信号叠加后不再满足严格稀疏性，重构误差增大，检测精度下降明显。

近似消息传递-交织多址接入(Approximate Message Passing - Interleave Division Multiple Access, AMP-IDMA)^[19]：采用近似消息传递与交织多址迭代检测，虽能抑制部分非正交干扰，但迭代过程依赖精确的信道估计，且非正交PSWFs强干扰下易出现迭代发散，同时复杂度随用户数呈非线性增长，实时性不足。

2.2.2 现有深度学习方法的局限性

现有深度学习检测方法^[12-17]虽具备强非线性拟合能力，但针对非正交PSWFs信号检测仍存在明显短板：

(1)特征维度单一：多采用单一时序网络，仅挖掘一维时序特征，忽略了非正交干扰在二维时频图像中呈现的可分纹理特征，导致关键判别信息丢失，强干扰下泛化能力不足。

(2)融合机制缺乏灵活性：少量多分支网络采用固定权重或简单拼接融合，无法根据实时干扰强度动态调整时序与空间特征的贡献度，低信噪比下特征权重分配失衡，检测鲁棒性差。

由于现有方法难以兼顾检测精度与鲁棒性，无法很好适配非正交PSWFs信号的强干扰传输场景。所以本文提出了时序-空间特征自适应融合(ATSFF)

的检测方法，通过双路径特征提取与自适应加权融合，从根源上抑制非正交干扰，提升检测性能。

3 基于ATSFF的非正交PSWFs信号检测架构及原理

3.1 ATSFF架构

ATSFF架构如图1所示，非正交PSWFs信号检测的核心原理在于构建时序-空间双路径特征提取与自适应融合机制，以克服信号间相互干扰对检测性能的制约。该架构将一维时序输入信号 $S_t = [s_1, s_2, \dots, s_T]$ 并行馈入双通道处理流。一方面，原始信号经GRU网络直接挖掘时序动态相关性，输出时间特征概率向量 $P_t(x) = [p_{11}, p_{12}, \dots, p_{1n}]$ 及其对应的预测置信度 C_1 ，其中 p_{1i} 表示第 i 类信号的时序特征概率；另一方面，信号通过GADF转换映射为二维图像表示 $G \in \mathbb{R}^{H \times W}$ ，继而由ResNet50网络提取空间结构特征，生成空间特征概率向量 $P_s(x) = [p_{21}, p_{22}, \dots, p_{2n}]$ 及其对应的预测置信度 C_2 ，其中 p_{2i} 表示第 i 类信号的空间特征概率。引入自适应概率加权融合机制，依据置信度 C_1 和 C_2 ，动态计算权重系数 w_1 和 w_2 ，实现时序与空间特征的互补增强，从而在复杂信道环境下自适应协调特征贡献度，有效抑制非正交信号间的干扰。最终输出高鲁棒性的检测结果。

3.2 基于GADF的非正交PSWFs信号空间特征转化

GADF作为一种时序信号到图像空间的非线性




图1 ATSFF架构

映射技术^[20], 在ATSFF架构中承担着将一维PSWFs时序特征转换为空间可处理形式的核心功能^[21]。假设PSWFs时序信号为 $\mathbf{S}_t = [s_1, s_2, \dots, s_T]$, 通过反余弦函数进行极坐标映射得到角度序列 $\Phi = [\phi_1, \phi_2, \dots, \phi_T]$, 其中 $\phi_t = \arccos(s_t)$ 表示第 t 个时序点对应的极角。随后, GADF通过计算角度差分的正弦函数构建二维特征矩阵 $\mathbf{G} \in \mathbb{R}^{T \times T}$, 矩阵内各元素 G_{ij} 为

$$G_{ij} = \sin(\phi_i - \phi_j) = \sin \phi_i \cos \phi_j - \cos \phi_i \sin \phi_j, \quad \forall i, j \in \{1, 2, \dots, T\} \quad (3)$$

转化为矩阵计算形式为

$$\mathbf{G} = \Phi_{\sin} \Phi_{\cos}^T - \Phi_{\cos} \Phi_{\sin}^T \quad (4)$$

其中 $\Phi_{\sin} = [\sin \phi_1, \sin \phi_2, \dots, \sin \phi_T]^T$ 和 $\Phi_{\cos} = [\cos \phi_1, \cos \phi_2, \dots, \cos \phi_T]^T$ 分别为角度序列的正弦和余弦向量。

图2展示了非正交PSWFs信号的时域波形图及其对应的GADF二维纹理图谱, 直观揭示了不同符号组合模式下, 时域叠加畸变与空间纹理特征之间的对应规律。我们发现符号极性一致时, GADF图呈现稀疏规则的网格, 中心点清晰; 符号极性交替变化时, 干扰增强, GADF图呈现密集且非结构化的纹理, 中心点有所弥散。这个规律表明GADF变换已将不同信号类别的干扰模式解耦为图像空间中可被卷积核善于捕捉的网格密度、纹理方向和中心点分布等判别性特征, 这为ResNet50深层卷积提取空间结构信息提供了物理前提。同时, 我们还发现干扰越强则空间纹理越显著, 这一规律为后续自适应权重分配提供了物理依据, 使得时序与空间特征能够根据环境变化进行智能互补。

3.3 基于GRU的非正交PSWFs信号时序特征提取

时域分支采用GRU网络可有效捕获非正交PSWFs信号的幅值、相位时序演化特性^[22]。与传统循环神经网络相比, GRU通过整合遗忘门和输

入门为单一更新门, 并引入重置门机制, 在保持记忆能力的同时显著降低了网络复杂度^[23], 其单元结构如图3所示。

在时序特征提取流程中, 输入的非正交PSWFs时序信号经GRU网络逐层提取深层时序特征, 输出隐状态特征向量 $\mathbf{h}_{\text{temporal}}$ 。该向量通过全连接层映射至分类概率空间, 再经Softmax函数归一化, 得到各类信号对应的时序特征概率分布 $\mathbf{P}_1$, 计算过程如下:

$$\mathbf{P}_1 = \text{Softmax}(\mathbf{W}_c \mathbf{h}_{\text{temporal}} + \mathbf{b}_c) \quad (5)$$

其中, $\mathbf{W}_c$ 为全连接层权重矩阵, $\mathbf{b}_c$ 为偏置向量。 $\mathbf{P}_1$ 为后续自适应特征融合提供时序维度的概率信息, 其预测结果对应的置信度记为 C_1 。

3.4 基于Resnet50的非正交PSWFs信号空间特征提取

空间分支采用ResNet50网络, 从GADF生成的二维纹理图像中提取非正交干扰的空间特征^[24-26]。该网络通过残差连接结构, 有效缓解了深层网络训练时的梯度消失问题, 能够从GADF图像中捕捉到网格密度、纹理方向等关键判别信息, 为非正交PSWFs信号检测提供了可靠的空间维度特征。

本文在空间特征提取过程中, 先将GADF图像输入ResNet50, 再经过多轮卷积与残差模块处理, 输出高维空间特征向量 $\mathbf{h}_{\text{spatial}}$ 。该向量经全局平均池化压缩后, 通过全连接层映射至分类概率空间, 再经Softmax函数归一化, 得到各类信号对应的空间特征概率分布 $\mathbf{P}_2$, 计算过程如下:

$$\mathbf{P}_2 = \text{Softmax}(\mathbf{W}_f \mathbf{h}_{\text{spatial}} + \mathbf{b}_f) \quad (6)$$

其中, $\mathbf{W}_f$ 为全连接层权重矩阵, $\mathbf{b}_f$ 为偏置向量。 $\mathbf{P}_2$ 为后续自适应特征融合提供空间维度的概率信息, 其预测结果对应的置信度记为 C_2 。

3.5 自适应概率加权融合机制

由于时域与空间特征的可靠性随干扰强度动态




图2 GADF转换前后图像




图 3 GRU 单元结构

变化，我们引入自适应概率加权融合机制，根据 GRU 和 ResNet50 两个并行网络的预测置信度动态调节融合权重，从而在复杂多变的信道环境下实现鲁棒的特征集成^[27]。

首先，基于预测熵的概念构建不确定性度量函数 $U(\cdot)$ ：

$$U_k = - \sum_{i=1}^n p_{ki} \log(p_{ki}), k = 1, 2 \quad (7)$$

其中， U_1 和 U_2 为时序特征和空间特征的预测不确定性。熵值越小，表明模型预测越确定，相应特征的可靠性越高。

为了将不确定性转换为可解释的权重系数，引入 softmax 归一化策略计算融合权重：

$$w_k = \frac{\exp(-\alpha \cdot U_k)}{\sum_{j=1}^2 \exp(-\alpha \cdot U_j)}, k = 1, 2 \quad (8)$$

其中 $\alpha > 0$ 为温度系数，用于调节权重分配的敏感度。当 α 较大时，权重分配更加偏向于置信度高的特征。

基于计算得到的自适应权重，最终的融合概率分布为：

$$\mathbf{P}_{\text{final}} = w_1 \cdot \mathbf{P}_1 + w_2 \cdot \mathbf{P}_2 \quad (9)$$

最终的检测决策通过最大化融合概率获得：

$$\hat{y} = \arg \max_{i \in \{1, 2, \dots, n\}} [\mathbf{P}_{\text{final}}]_i \quad (10)$$

为确保融合机制的稳定性和鲁棒性，引入权重平滑因子 $\epsilon \in (0, 0.5)$ 对极端权重进行约束：

$$\tilde{w}_k = \min(\max(w_k, \epsilon), 1 - \epsilon), k = 1, 2 \quad (11)$$

$$\bar{w}_k = \frac{\tilde{w}_k}{\sum_{j=1}^2 \tilde{w}_j}, k = 1, 2 \quad (12)$$

经过平滑处理后的最终权重为 $\bar{w}_1$ 和 $\bar{w}_2$ ，相应的融合概率分布修正为：

$$\bar{\mathbf{P}}_{\text{final}} = \bar{w}_1 \cdot \mathbf{P}_1 + \bar{w}_2 \cdot \mathbf{P}_2 \quad (13)$$

3.6 算法复杂度分析

设 L 为卷积层总数， M 为全连接层总数， A 为池化层总数， B 为池化窗口大小， $O\left(\sum_{l=1}^{49} F_l \cdot C_l \cdot K_l^2 \cdot H_l \cdot W_l\right)$ 为第 l 层卷积操作步长，对于第 l 层卷积层 ($l = 1, 2, \dots, L$)， F_l 为滤波器数量， C_l 为输入通道数， K_l 为方形卷积核尺寸， H_l 、 W_l 分别为输入特征图的高度和宽度，则网络所有卷积操作的时间复杂度为 $O\left(\sum_{l=1}^L F_l \cdot C_l \cdot K_l^2 \cdot H_l \cdot W_l / D_l^2\right)$ ，所有全连接层的时间复杂度为 $O\left(\sum_{m=1}^M I_m \cdot O_m\right)$ (其中 I_m 、 O_m 分别为第 m 层全连接层的输入神经元数、输出神经元数)，所有池化层的时间复杂度为 $O\left(\sum_{a=1}^A C_a \cdot H_a \cdot W_a\right)$ ，其中 C_a 、 H_a 、 W_a 分别为第 a 层池化层的输入通道数、输入特征图高度和宽度，而 ResNet50 网络共包含 49 个卷积层、 l 个全连接层以及 2 个池化层，由于时间复杂度计算中常忽略低阶项，且卷积步长 D_l 通常为常量，同时全连接层与池化层的计算量远低于卷积层可以忽略，因此 ResNet50 网络最终的时间复杂度可简化表示为 $O\left(\sum_{l=1}^{49} F_l \cdot C_l \cdot K_l^2 \cdot H_l \cdot W_l\right)$ 。

设输入维度为 $O(N \times (n_{\text{input}} \times n_{\text{hidden}} + n_{\text{hidden}}^2))$ ，隐状态维度为 n_{hidden} ，随着 n_{input} 与 n_{hidden} 的增加，GRU 参数数量线性增长，对于一个长度为 N 的序列：GRU 网络的时间复杂度为 $O(K^3)$ ， $K \gg N$ ，由于 GRU 的时间复杂度相对于 ResNet50 仍为可忽略的低阶量，因此 ATSFF 的时间复杂度为 $O\left(\sum_{l=1}^{49} F_l \cdot C_l \cdot K_l^2 \cdot H_l \cdot W_l\right)$ 。

各模型的计算复杂度如表 1 所示。从理论复杂度来看，传统方法均与用户数 N 有关：相干检测^[11]为 $O(N^2)$ ，随 N 增加呈平方增长；TMSBL-LS^[18]为 $O(K^3)$ ，随 K 增加呈立方增长；交叉项检测^[11]为 $O(N^3)$ ，随 N 增加呈立方增长；AMP-IDMA^[19]检测基于迭代消息传递，复杂度为 $O(KN_tN_r + KN_tM)$ ，呈立方增长。本文 ATSFF 方法的检测阶段复杂度由固定网络结构决定，与 N 无关，主要计算开销来

表 1 模型复杂度

模型	时间复杂度
相干检测	$O(N^2)$
AMP-IDMA	$O(KN_tN_r + KN_tM)$
TMSBL-LS	$O(K^3), K \gg N$
交叉项检测	$O(N^3)$
ATSFF	$O\left(\sum_{l=1}^{49} F_l \cdot C_l \cdot K_l^2 \cdot H_l \cdot W_l\right)$

自ResNet50的卷积运算,网络结构一旦确定,推理开销即为常量,但复杂度比传统算法整体偏高。

从实际运算时间来看,传统算法运算量会随接入用户数 N 上升逐步增加,大规模接入时总开销有所抬升;ATSFF推理运算量由固定网络结构决定,与用户数量 N 无关,网络定型后单次推理计算量固定。该算法支持多用户信号批量并行输入,可摊薄单样本运算时间,但受网络本身庞大计算量制约,批量并行也无法实现处理效率反超传统算法。因此,本文ATSFF算法核心价值体现在非正交PSWFs复杂干扰环境下更优的信号检测性能,依靠更优异的抗干扰与检测精度弥补运算开销偏大的短板,在对检测精度要求高的场景中具备应用价值。

4 实验结果及分析

4.1 数据集

鉴于国内外尚无公开的非正交PSWFs实测信号数据集,本文采用通信系统误码率性能评估通用的蒙特卡洛仿真方法来开展算法检测性能验证,通过大量独立重复试验来构建专用仿真数据集。具体而言,使用MATLAB生成非正交PSWFs信号数据集:选取5个标准PSWFs基函数作为模板信号,通过正交化预处理控制基函数间的最小相关性;考虑到实际通信系统的双极性传输特性,每个模板信号可取+1和-1两种幅值,从而可形成32种不同信号组合模式,每种模式对应一类独特的非正交PSWFs信号;每类信号生成2 000个独立样本,总计64 000个样本数据,每个样本的时间序列长度为512个采样点。该数据集覆盖了AWGN信道下0~10 dB的信噪比区间样本,力求在缺乏实测数据的条件下,最大限度构造验证场景来检验算法的有效性。数据集按照7:2:1的比例随机划分为训练集、验证集和测试集,其中训练集包含44 800个样本,验证集12 800个样本,测试集6 400个样本。所有样本均经过最大最小值归一化预处理,以消除信号幅度差异对网络训练的影响。

4.2 实验平台及参数设置

实验的硬件条件如下:CPU为Intel(R) Core(TM) i9-14900K (3.20 GHz),GPU为NVIDIA GeForce RTX 4090 D, RAM为内存128 GB DDR5。所有模型均基于Python语言实现,使用PyTorch 1.13框架进行深度学习模型的设计与训练。操作系统为Ubuntu 22.04 LTS, CUDA版本为12.1, cuDNN版本为8.9.7。各项模型超参数设置如表2所示。

4.3 评价指标

总误码率(Total BER)作为衡量检测系统整体性能的关键指标,其计算公式如下:

$$\text{TotalBER} = \frac{N_{\text{totalerror}}}{N_{\text{totalbit}}} = \frac{\sum_{k=0}^{B-1} N_{\text{bit},k}}{N_{\text{total}} \times B} \quad (14)$$

其中, $N_{\text{totalerror}}$ 为所有比特位的累积错误次数, N_{totalbit} 为测试集中的总比特数, B 为每个样本对应的比特位数,对于32类信号分类问题,需要 $\log_2(32) = 5$ 位二进制编码表示,故 $B=5$, N_{total} 为测试集的总样本数量, $N_{\text{bit},k}$ 为第 k 个比特位的错误样本数。

4.4 信号检测结果及分析

图4展示了通过t-SNE降维技术对PSWFs信号特征在训练前后的可视化对比结果。左侧图为原始输入信号经初步预处理后的特征分布,可以看出不同类别的信号在特征空间中存在严重重叠,类间边界模糊,表明原始信号特征缺乏足够的判别能力。右侧图为经过ATSFF网络充分训练后提取的高维特征分布,可以明显观察到各类信号在特征空间中形成了清晰可分的聚类结构,同类信号样本高度集中,异类信号之间界限分明。ATSFF中GRU网络成功捕获了信号的时序动态相关性,而ResNet50网络则充分提取了GADF图像的空间结构信息,两者协同作用显著提升了信号特征的可分性,有效挖掘了非正交PSWFs信号的内在特性,并通过深层神经网络学习到具有强判别性的特征表示。

图5展示了在不同比特信噪比条件下,GRU、ResNet50以及自适应融合方法的误码率性能对比。从图中可以看出,随着 E_b/N_0 的增加,三种方法的BER均呈现下降趋势,但所提自适应融合方法在全信噪比范围内均显著优于单一特征提取网络。优异性能得益于所设计的自适应概率加权融合机制,能

表 2 模型超参数

参数类别	参数名称	参数值
训练配置	优化器	Adam
	学习率	0.001
	批次大小	100
	最大训练轮数	200
	早停机制耐心值	15
	权重衰减系数	1e-4
	损失函数	CrossEntropyLoss
网络特定参数	ResNet50权重初始化	ImageNet
	GRU权重初始化	预训练权重 随机初始化




图 4 t-SNE散点变化

够根据两个并行网络的实时预测置信度动态调整融合权重，有效实现了时序特征与空间特征的优势互补，从而在复杂干扰环境下实现了更鲁棒的信号检测性能。

4.5 对比实验结果及分析

图6展示了本文所提ATSFF方法与多种经典非正交PSWFs信号检测方法在相同测试条件下的误码率对比性能曲线，包括相干检测^[11]、交叉项抑制检测^[11]、TMSBL-LS^[18]以及AMP-IDMA^[19]等方法。




图 5 不同比特信噪比误码性能分析




图 6 不同信号检测方法系统误码性能

结果显示，在整个 E_b/N_0 变化范围内，ATSFF方法始终优于其他对比方法，尤其是在中高信噪比区域优势尤为明显。相比于AMP-IDMA和TMSBL-LS两种方法，ATSFF因其能够更好地捕捉信号内部的时序动态与空间结构信息，从而展现出更强的非线性拟合能力与泛化性能，有效提升了检测精度与系统鲁棒性。

5 结论

针对非正交PSWFs信号间相互干扰严重，传统检测方法难以有效分离干扰导致性能下降的难题，提出了一种基于时序-空间特征的自适应融合检测方法。该方法通过构建双路径特征提取网络和自适应加权融合机制，有效提升了非正交PSWFs信号的检测精度与鲁棒性。得出的主要结论如下：

(1)所提出的ATSFF方法取得了现有方法的最佳性能，在误比特率为 4×10^{-5} 时，系统误码性能提升约0.2 dB，验证了时序-空间特征融合策略在非正交信号检测中的有效性，充分体现了所提方法在实际通信环境中的应用价值。

(2)自适应概率加权融合机制能够根据GRU和ResNet50两个并行网络的实时预测置信度动态调整融合权重，实现了时序特征与空间特征的最优互补。通过t-SNE可视化分析可见，融合后的特征在高维空间中呈现出更加清晰的类间分离结构，有效提升了信号的可分性和检测决策的可靠性。

(3)ATSFF方法有效提升非正交PSWFs信号检测精度，单样本推理计算量固定，可依托GPU进行多用户批量处理，但网络固有开销偏大，实时效率不及传统算法，适用于对检测精度要求较高的非正交通信场景。

参考文献

[1] SADIA H, HASSAN A K, ABBAS Z H, *et al.* IRS-enabled

- NOMA communication systems: A network architecture primer with future trends and challenges[J]. *Digital Communications and Networks*, 2024, 10(5): 1503–1528. doi: [10.1016/j.dcan.2023.09.002](https://doi.org/10.1016/j.dcan.2023.09.002).
- [2] CHOWDHURY R and CHOYON A K M S J. Design and performance analysis of spectral-efficient hybrid CPDM-CO-OFDM FSO communication system under diverse weather conditions[J]. *Journal of Optical Communications*, 2023, 44(s1): s1747–s1766. doi: [10.1515/joc-2021-0113](https://doi.org/10.1515/joc-2021-0113).
- [3] 徐常志, 靳一, 李立, 等. 面向6G的星地融合无线传输技术[J]. 电子与信息学报, 2021, 43(1): 28–36. doi: [10.11999/JEIT200363](https://doi.org/10.11999/JEIT200363).
XU Changzhi, JIN Yi, LI Li, *et al.* Wireless transmission technology of satellite-terrestrial integration for 6G mobile communication[J]. *Journal of Electronics & Information Technology*, 2021, 43(1): 28–36. doi: [10.11999/JEIT200363](https://doi.org/10.11999/JEIT200363).
- [4] LIU Rui, GUO Kefeng, LI Xingwang, *et al.* RIS-empowered satellite-aerial-terrestrial networks with PD-NOMA[J]. *IEEE Communications Surveys & Tutorials*, 2024, 26(4): 2258–2289. doi: [10.1109/COMST.2024.3393612](https://doi.org/10.1109/COMST.2024.3393612).
- [5] SARKAR D, YOGITA, YADAV S S, *et al.* A comprehensive survey on IRS-assisted NOMA-based 6G wireless network: Design perspectives, challenges and future directions[J]. *IEEE Transactions on Network and Service Management*, 2024, 21(2): 2539–2562. doi: [10.1109/TNSM.2023.3348138](https://doi.org/10.1109/TNSM.2023.3348138).
- [6] ZHOU Wenjing, SHEN Mingwei, WU Di, *et al.* Efficient gridless wideband sparse array synthesis with tapped delay-lines[J]. *Digital Signal Processing*, 2025, 157: 104893. doi: [10.1016/j.dsp.2024.104893](https://doi.org/10.1016/j.dsp.2024.104893).
- [7] BONAMI A, KERKYACHARIAN G, and PETRUSHEV P. Gaussian bounds for the heat kernel associated to prolate spheroidal wave functions with applications[J]. *Constructive Approximation*, 2023, 57(2): 351–403. doi: [10.1007/s00365-022-09595-0](https://doi.org/10.1007/s00365-022-09595-0).
- [8] DENG Kefeng and XUE Rui. Preamble design for frame synchronization in VLF communication based on prolate spheroidal wave function sequences[J]. *IEEE Communications Letters*, 2025, 29(8): 1948–1952. doi: [10.1109/LCOMM.2025.3581198](https://doi.org/10.1109/LCOMM.2025.3581198).
- [9] ALPARONE L, ARIENZO A, and LOMBARDINI F. Improved coherent processing of synthetic aperture radar data through speckle whitening of single-look complex images[J]. *Remote Sensing*, 2024, 16(16): 2955. doi: [10.3390/rs16162955](https://doi.org/10.3390/rs16162955).
- [10] WANG Guoyang, WU Ruoxi, ZHANG Liangliang, *et al.* Coherent detection of pulsed terahertz waves in solid, gaseous, and liquid media[J]. *Fundamental Research*, 2025, 5(2): 516–525. doi: [10.1016/j.fmre.2024.08.003](https://doi.org/10.1016/j.fmre.2024.08.003).
- [11] 陆发平, 毛忠阳, 许志超, 等. 基于信号间交叉项的非正交椭圆球面波信号检测方法[J]. 电子与信息学报, 2025, 47(8): 2714–2723. doi: [10.11999/JEIT250052](https://doi.org/10.11999/JEIT250052).
LU Faping, MAO Zhongyang, XU Zhichao, *et al.* Non-orthogonal prolate spheroidal wave functions signal detection method with cross-terms[J]. *Journal of Electronics & Information Technology*, 2025, 47(8): 2714–2723. doi: [10.11999/JEIT250052](https://doi.org/10.11999/JEIT250052).
- [12] 黄永明, 王正. 基于广义投影梯度下降算法的深度学习大规模MIMO信号检测[J]. 东南大学学报: 自然科学版, 2024, 54(4): 961–971. doi: [10.3969/j.issn.1001-0505.2024.04.020](https://doi.org/10.3969/j.issn.1001-0505.2024.04.020).
HUANG Yongming and WANG Zheng. Generalizing projected gradient descent algorithm for massive MIMO detection based on deep-learning[J]. *Journal of Southeast University: Natural Science Edition*, 2024, 54(4): 961–971. doi: [10.3969/j.issn.1001-0505.2024.04.020](https://doi.org/10.3969/j.issn.1001-0505.2024.04.020).
- [13] 蒲旭敏, 刘雁翔, 宋米雪, 等. 基于模型驱动深度学习的OTFS信道估计[J]. 电子与信息学报, 2024, 46(2): 680–687. doi: [10.11999/JEIT230072](https://doi.org/10.11999/JEIT230072).
PU Xumin, LIU Yanxiang, SONG Mixue, *et al.* Orthogonal time frequency space channel estimation based on model-driven deep learning[J]. *Journal of Electronics & Information Technology*, 2024, 46(2): 680–687. doi: [10.11999/JEIT230072](https://doi.org/10.11999/JEIT230072).
- [14] 王骥, 李子龙, 肖健, 等. 基于低复杂度加法网络的非正交多址接入短报文多用户检测算法研究[J]. 电子与信息学报, 2024, 46(6): 2409–2417. doi: [10.11999/JEIT231186](https://doi.org/10.11999/JEIT231186).
WANG Ji, LI Zilong, XIAO Jian, *et al.* Research on multi-user detection algorithm for non-orthogonal multiple access short message based on low complexity adder network[J]. *Journal of Electronics & Information Technology*, 2024, 46(6): 2409–2417. doi: [10.11999/JEIT231186](https://doi.org/10.11999/JEIT231186).
- [15] KUMAR A and KUMAR K. Deep learning-based joint NOMA signal detection and power allocation in cognitive radio networks[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2022, 8(4): 1743–1752. doi: [10.1109/TCCN.2022.3193389](https://doi.org/10.1109/TCCN.2022.3193389).
- [16] KUMAR A, NANTHAAMORNPHONG A, ALSHARIF M H, *et al.* SIC based RL for massive MIMO NOMA signal detection for different modulation schemes under diverse channel conditions[J]. *Scientific Reports*, 2025, 15(1): 24641. doi: [10.1038/s41598-025-06492-x](https://doi.org/10.1038/s41598-025-06492-x).
- [17] WANG Xiaoming, ZHANG Dongcai, CHEN Bingcen, *et al.* Deep transfer learning for model-driven signal detection in MIMO-NOMA systems[J]. *IEEE Transactions on Vehicular Technology*, 2023, 72(10): 13039–13054. doi: [10.1109/TVT.2023.3274561](https://doi.org/10.1109/TVT.2023.3274561).
- [18] 李有明, 陈江涛, 吴永宏, 等. 脉冲噪声干扰下免调度非正交多址接入系统的联合多用户检测和信道估计方法[J]. 通信学报, 2025, 46(2): 240–250. doi: [10.11999/JEIT250052](https://doi.org/10.11999/JEIT250052).

- 2025, 46(3): 122–130. doi: [10.11959/j.issn.1000-436x.2025055](https://doi.org/10.11959/j.issn.1000-436x.2025055).
- LI Youming, CHEN Jiangtao, WU Yonghong, *et al.* Joint multi-user detection and channel estimation method for grant-free NOMA systems under impulsive noise interference[J]. *Journal on Communications*, 2025, 46(3): 122–130. doi: [10.11959/j.issn.1000-436x.2025055](https://doi.org/10.11959/j.issn.1000-436x.2025055).
- [19] 康洁思, 朱静. 基于交织多址技术的非正交多用户新型检测方法[J]. *电子技术与软件工程*, 2021(2): 32–33. doi: [10.20109/j.cnki.etsc.2021.02.014](https://doi.org/10.20109/j.cnki.etsc.2021.02.014).
- KANG Jiesi and ZHU Jing. A novel non-orthogonal multi-user detection method based on interleave division multiple access[J]. *Electronic Technology & Software Engineering*, 2021(2): 32–33. doi: [10.20109/j.cnki.etsc.2021.02.014](https://doi.org/10.20109/j.cnki.etsc.2021.02.014).
- [20] XIONG Weihua, JIANG Yufei, and CAO Lixian. Multi-feature fusion recognition method of heart sound signal based on GADF and CNN-ViT[J]. *Academic Journal of Computing & Information Science*, 2025, 8(4): 1–10. doi: [10.25236/AJCIS.2025.080401](https://doi.org/10.25236/AJCIS.2025.080401).
- [21] FENG Min and XU Juncai. Enhancing non-destructive testing in concrete structures: A GADF-CNN approach for defect detection[J]. *Journal of Measurements in Engineering*, 2024, 12(2): 333–352. doi: [10.21595/jme.2024.23829](https://doi.org/10.21595/jme.2024.23829).
- [22] PANDA B and SINGH P. A deep convolutional-GRU-SVM-based hybrid approach for signal detection of uplink NOMA system[J]. *Wireless Personal Communications*, 2024, 138(2): 861–878. doi: [10.1007/s11277-024-11529-x](https://doi.org/10.1007/s11277-024-11529-x).
- [23] XU Shaohua, LI Jingjing, LIU Kun, *et al.* A parallel GRU recurrent network model and its application to multi-channel time-varying signal classification[J]. *IEEE Access*, 2019, 7: 118739–118748. doi: [10.1109/ACCESS.2019.2936516](https://doi.org/10.1109/ACCESS.2019.2936516).
- [24] LIU Fugang, ZHANG Ziwei, and ZHOU Ruolin. Automatic modulation recognition based on CNN and GRU[J]. *Tsinghua Science and Technology*, 2022, 27(2): 422–431. doi: [10.26599/TST.2020.9010057](https://doi.org/10.26599/TST.2020.9010057).
- [25] 邢六一, 张育芝, 汪洋, 等. 基于深度学习的水声索引调制正交啁啾复用信号检测[J]. *应用声学*, 2026, 45(2): 485–493. doi: [10.11684/j.issn.1000-310X.2026.02.022](https://doi.org/10.11684/j.issn.1000-310X.2026.02.022).
- XING Liuyi, ZHANG Yuzhi, WANG Yang, *et al.* Deep learning based detector for underwater acoustic orthogonal chirp division multiplexing with index modulation[J]. *Journal of Applied Acoustics*, 2026, 45(2): 485–493. doi: [10.11684/j.issn.1000-310X.2026.02.022](https://doi.org/10.11684/j.issn.1000-310X.2026.02.022).
- [26] 覃日升, 徐志, 况华, 等. 基于双分辨率S变换和改进的多尺度ResNet模型的电能质量扰动检测方法[J]. *广东电力*, 2024, 37(7): 68–77. doi: [10.3969/j.issn.1007-290X.2024.07.008](https://doi.org/10.3969/j.issn.1007-290X.2024.07.008).
- QIN Risheng, XU Zhi, KUANG Hua, *et al.* Detection method of power quality disturbances based on double resolution S transform and improved multi-scale ResNet[J]. *Guangdong Electric Power*, 2024, 37(7): 68–77. doi: [10.3969/j.issn.1007-290X.2024.07.008](https://doi.org/10.3969/j.issn.1007-290X.2024.07.008).
- [27] WANG Bo, SHEN Lei, WANG Huaxia, *et al.* Direct sequence spread spectrum (DSSS) signal detection based on eigenvalues local binary pattern residual network (EL-ResNet)[J]. *Signal, Image and Video Processing*, 2024, 18(5): 4741–4751. doi: [10.1007/s11760-024-03110-7](https://doi.org/10.1007/s11760-024-03110-7).
- 陈文华：男，博士研究生，工程师，研究方向为现代通信理论与应用、通信信号波形设计、非正弦通信。
- 毛忠阳：男，教授，研究方向为现代通信理论与应用、激光通信、无线通信组网技术。
- 陆发平：男，讲师，研究方向为现代通信理论与应用、测控与通信信号波形设计、非正弦通信。
- 孙 烨：男，工程师，研究方向为现代通信理论与应用、通信对抗技术。
- 高翊轩：男，硕士研究生，研究方向为现代通信理论与应用、深度学习。

Non-Orthogonal PSWFs Signal Detection Method Based on Adaptive Time-Space Feature Fusion

CHEN Wenhua^{①②③} MAO Zhongyang^{①②} LU Faping^{①②}
SUN Ye^③ GAO Yixuan^④

^①(Naval Aviation University, People's Liberation Army of China, Yantai 264001, China)

^②(Shandong Provincial Key Laboratory of Sea-Air Information Perception and Processing Technology, Yantai 264001, China)

^③(No. 91428 Force, People's Liberation Army of China, Ningbo 315456, China)

^④(Harbin Engineering University, Harbin 150001, China)

Abstract:

Objective To address B5G/6G demands for high spectral efficiency and transmission reliability, non-

orthogonal Prolate Spheroidal Wave Function (PSWF) modulation has drawn extensive research interest for its strong time-frequency energy concentration. However, severe mutual interference in PSWF signal multiplexing degrades conventional detection performance in complex channels. Limited by ideal channel assumptions or single-modal feature extraction, existing methods cannot fully exploit signal temporal-spatial information and lack adaptability to dynamic interference. This work proposes an intelligent detection architecture with adaptive temporal-spatial feature fusion (ATSFF) for accurate, robust non-orthogonal PSWF signal detection.

Method A dual-path parallel framework extracts complementary features from time and transform domains. A Gated Recurrent Unit (GRU) extracts deep temporal features and captures long-range dependencies from 1D received signals. The other path converts 1D signals into 2D representations via the Gramian Angular Difference Field (GADF), and extracts hierarchical spatial features using ResNet50. An adaptive probability-weighted fusion mechanism dynamically adjusts feature contributions based on sub-network prediction uncertainty to generate robust detection outputs.

Results and Discussion Simulations on a 32-class non-orthogonal PSWF dataset (Fig. 2) show the proposed ATSFF outperforms conventional coherent detection, cross-term suppression detection, Approximate Message Passing Interleave Division Multiple Access (AMP-IDMA) and Temporal Sparse Bayesian Learning Least Squares (TMSBL-LS) across the full Signal-to-Noise Ratio (SNR) range. t-SNE visualization (Fig. 4) confirms better inter-class separability and intra-class compactness of fused features. At a bit error rate of 4×10^{-5} , it achieves 0.2 dB gain (Fig. 6) over coherent detection. ATSFF has higher network overhead and weaker real-time performance than linear detection, yet it supports GPU batch inference with fixed single-sample computation cost, suiting accuracy-sensitive communication scenarios.

Conclusions Targeting interference issues in non-orthogonal PSWF signal detection, this paper presents an adaptive temporal-spatial feature fusion detection method. It realizes dual-modal feature extraction via GRU and ResNet50, and adopts a prediction-uncertainty-based adaptive weighted fusion mechanism to integrate dual-path strengths, significantly improving detection accuracy and robustness. Simulations validate its superior performance and stable channel adaptability, providing an efficient solution and design reference for intelligent detection of non-orthogonal PSWF signals.

Key words: prolate spheroidal wave functions; non-orthogonal signal detection; time-space feature fusion; adaptive weighted fusion