

引用格式: 陈炽根, 彭启航, 徐俊如, 等. 基于多任务学习的干扰认知方法 [J]. 电子科技大学学报, 2025, 54(6): 896-905.

CHEN C G, PENG Q H, XU J R, et al. A jamming cognition approach based on multi-task learning[J]. Journal of University of Electronic Science and Technology of China, 2025, 54(6): 896-905.



基于多任务学习的干扰认知方法

陈炽根, 彭启航*, 徐俊如, 王 军

(电子科技大学 信息与通信工程学院, 成都 611731)

摘要: 干扰信号认知在复杂电磁环境的通信、测控、预警中具有重要作用, 可为后续干扰抑制提供关键决策依据, 因此, 高效可靠的干扰认知尤为关键。然而, 现有干扰认知方法主要遵循先识别信号类型后估计参数的串行认知架构, 导致干扰认知整体时效性不够高。针对该问题, 提出了一种多任务学习的并行干扰认知方法, 可同时识别干扰信号类型并估计干扰参数。该算法基于参数硬共享的多任务框架, 通过设计共享层网络挖掘干扰信号及其参数间相关信息, 利用不同独立任务层网络提取不同干扰信号间的差异特征, 从而对干扰信号同时进行类型识别和参数估计。此外, 为避免网络被单任务主导, 进而导致困难任务无法有效优化的问题, 采用改进的多梯度下降算法对干扰识别和参数估计任务进行联合优化。仿真结果表明: 该方法干扰识别准确率在低干噪比下明显优于 LSTM 和 SKNet 基线算法; 对于参数估计任务, 在干噪比大于 10 dB 时算法对中心频率参数估计归一化均方根误差能够达到 10^{-2} , 优于传统算法和单任务算法; 最后, 相比于遵循串行架构的干扰认知过程, 该方法的干扰认知时间降低了 40%, 有效提升了干扰认知过程的时效性。

关键词: 干扰认知; 多任务学习; 干扰分类; 参数估计

中图分类号: TN975

文献标志码: A

DOI: 10.12178/1001-0548.2024302

A jamming cognition approach based on multi-task learning

CHEN Chigen, PENG Qihang*, XU Junru, and WANG Jun

(School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: Jamming signal cognition plays a crucial role in communication, control, and early warning within complex electromagnetic environments, providing key decision-making support for subsequent jamming suppression. Therefore, efficient and reliable jamming cognition is particularly critical. However, existing jamming cognition methods primarily follow a serial cognitive architecture where signal type is identified first, followed by parameter estimation, leading to suboptimal overall timeliness. To address this issue, a parallel jamming cognition method based on multi-task learning is proposed, which can simultaneously identify the jamming signal types and estimate the interference parameters. This algorithm is developed within a multitask framework characterized by hard parameter sharing. It incorporates a shared-layer network to extract the correlation information between jamming signals and their corresponding parameters. Furthermore, distinct independent task-layer networks are employed to capture the distinguishing features among various jamming signals. This approach facilitates the simultaneous identification of signal types and the estimation of their parameters. Moreover, to prevent the network from being dominated by a single task, which could hinder the effective optimization of difficult tasks, an improved multi-gradient descent algorithm is used for joint optimization of jamming recognition and parameter estimation tasks. Simulation results show that the proposed method significantly outperforms the LSTM and SKNet baseline algorithms in jamming recognition accuracy at low jamming-to-noise ratio. For the parameter estimation task, the algorithm is able to achieve a normalized root-mean-square error of 10^{-2} for centre-frequency parameter estimation when the jamming-to-noise ratio is greater than 10 dB, which is better than that of traditional algorithms and single-task algorithms. Lastly, compared to the jamming cognition process that follows a serial architecture, the proposed method reduces the jamming cognition time by 40%, which effectively improves the timeliness of the jamming cognition process.

收稿日期: 2024-11-02

基金项目: 国家自然科学基金 (62131005)

作者简介: 陈炽根, 主要从事智能无线抗干扰通信方面的研究。

*通信作者 E-mail: anniepqh@uestc.edu.cn

Key words: jamming with cognition; multi-task learning; classification of jamming; parameter estimation

随着通信技术的发展, 无线电通信系统传输速率和可靠性极大地提高, 在军事和民用领域都起到至关重要的作用。但伴随着日益复杂的电磁环境, 频谱空间拥挤严重, 有意或无意干扰的问题日益突出^[1]。为保障无线通信系统性能, 提升系统的抗干扰能力, 需要对系统出现的恶意干扰进行快速检测、识别和表征^[2]。

传统干扰认知过程由干扰识别和干扰参数估计两部分构成。干扰识别是对信道中干扰信号进行检测并分类, 参数估计则是对信号模型进行定量分析^[3]。现有干扰识别算法可分为基于人工特征提取的方法^[4-6]和基于自动特征提取的深度学习算法^[7-10]。基于人工特征提取的方法首先对干扰信号的基本特征信息, 如幅值、相位、频率、星座图、高阶统计量等进行人工特征提取, 然后通过支持向量机 (support vector machine, SVM)^[4]、决策树 (decision tree, DT)^[5]、反向传播 (back propagation, BP) 神经网络^[6]等算法进行分类。由于这类方法需人工提取信号特征, 识别性能过度依赖专家知识。其次, 特征的提取都是针对特定干扰场景, 算法整体鲁棒性较差, 无法适应复杂的电磁干扰环境。随着深度学习在计算机视觉和自然语言处理领域大放异彩, 深度学习方法也逐渐被应用到信号识别领域。深度学习方法通过神经网络自动提取干扰信号特征, 能够比传统算法更有效地实现干扰识别任务。文献 [7] 首先利用短时傅里叶变换 (short time Fourier transform, STFT) 对干扰信号进行时频分析, 得到干扰信号时频图, 并以此作为输入数据, 然后设计 2 层卷积层对干扰信号时频图进行特征提取, 最后通过 3 层全连接层实现干扰信号分类。仿真结果表明: 在干噪比 (jamming noise ratio, JNR) 为 $-10 \sim 10$ dB 时, 4 类压制式干扰信号的总体识别准确率能够达到 97.8%。文献 [8] 提出一种基于去噪扩散概率模型的离线干扰信号分类算法, 通过将采集的时域信号经频域变换后输入扩散模型进行特征增强, 生成抗噪特征图作为分类器输入。仿真结果表明: 在训练样本量仅为 5 时, 该方法对 8 类真实场景干扰信号的平均识别准确率可达 91%, 在动态信道环境下表现出更强的鲁棒性。文献 [9] 提出一种基于注意力机制的卷积神经网络用于欺骗干扰识别, 通过设计多模态信息预处理模块提取干扰信号的时频图像作为输入, 并利用

卷积层与自注意力机制结合的方式增强全局特征提取能力。仿真结果表明: 在干噪比为 -10 dB 时, 该方法对多类干扰信号的识别准确率较传统方法提升 15%, 收敛速度提高 30%。为充分利用不同变换域信息, 文献 [10] 利用信号频域序列和时频图像进行联合多域特征提取, 在 14 类单干扰以及单干扰两两线性组合成的 10 类复合干扰上取得良好的分类效果。虽然基于深度学习的干扰识别方法能够利用神经网络强大的特征提取能力, 更准确、鲁棒地识别干扰信号, 但是神经网络也存在着复杂度较高、时效性低的问题, 现有深度学习算法主要考虑的是如何设计合理的网络架构来提升干扰识别性能, 忽视了模型的时效性和可部署性问题, 因此如何高时效地实现干扰识别是亟待解决的关键问题。

传统估计算法需针对干扰信号类型和关键参数类型设计不同的算法。针对音调类干扰, 多采用基于离散傅里叶变换 (discrete Fourier transform, DFT) 或平均最小二乘法 (mean least square, MLS) 的频率估计算法; 针对时域或频域上的部分连续性干扰, 如部分频带干扰, 多采用能量检测算法, 包括基于一阶矩/二阶矩的门限法、前向连续均值去除 (forward consecutive mean excision, FCME)、双门限检测算法^[11]和三门限 FCME^[12]等。由于传统干扰参数估计算法基于频域信息, 其估计性能依赖于频域数据的精度, 并且部分估计算法利用门限判决, 易受门限因子和滑动窗长等因素影响, 算法整体的鲁棒性较差。

从整个干扰认知过程来看, 传统参数估计算法须建立在信号识别结果之上, 这种串行的任务处理方式会导致整个认知过程的时效性较低。其次, 不同信号类型与其参数具有一定的相关关系, 估计出的信号关键参数也可以作为基本特征信息为信号分类提供重要依据, 但传统认知过程串行的任务处理方式使得分类过程无法有效利用这部分信息。

为充分利用干扰识别任务和参数估计任务间的相关信息, 同时兼顾整个干扰认知过程的时效性, 本文提出并行干扰认知方法, 通过多任务学习网络同时实现干扰信号识别和干扰参数估计。

1 系统模型

1.1 接收信号模型

设通信系统接收到的复基带信号为 $r(t)$, $r(t)$ 通

常包含 3 部分, 可表示为:

$$r(t) = s(t) + j(t) + n(t) \quad (1)$$

式中, $s(t)$ 表示传输的通信信号; $j(t)$ 表示干扰信号; $n(t)$ 表示高斯白噪声。通过对系统接收到的时域复基带信号 r 进行 N 点采样, 形成一个复值向量 $\mathbf{r} = [r(1), r(2), \dots, r(N)]$, $\mathbf{r} \in \mathbb{C}^N$ 。由于神经网络只能对实数数据运算, 故将该向量进一步分解为一个 $2 \times N$ 的实数值矩阵 $\mathbf{r}' \in \mathbb{R}^{2 \times N}$, 可以表示为:

$$\mathbf{r}' = \begin{bmatrix} \text{Re}(r(1)), \text{Re}(r(2)), \dots, \text{Re}(r(N)) \\ \text{Im}(r(1)), \text{Im}(r(2)), \dots, \text{Im}(r(N)) \end{bmatrix} \quad (2)$$

式中, $\text{Re}(\cdot)$ 表示取实部运算; $\text{Im}(\cdot)$ 表示取虚部运算。

1.2 干扰识别数学模型

干扰信号识别的主要目的是判断接收到的干扰信号类型。因干扰识别任务是一类分类任务, 故可依据最大后验 (maximum-a-posterior, MAP) 准则对干扰信号的预测类别进行建模。假设 $r(t)$ 表示接收到的复基带信号, J_i 为干扰信号类型, $I = \{J_i\}_1^N$ 表示干扰信号类型集合, 则预测类别 i^* 可表示为:

$$i^* = \arg \max_{J_i \in I} [P(J(t) = J_i | r(t))] \quad (3)$$

由式 (3) 可知, 干扰识别任务就是寻找一个信号类别 J_i , 使得后验概率 $P(J(t) = J_i | r(t))$ 最大。在深度学习中, 最大后验概率 $P(J(t) = J_i | r(t))$ 可由下式表示:

$$\mathbf{P} = f(\mathbf{r}(t); \theta) \quad (4)$$

式中, $\mathbf{P} = [P_{J_1}, P_{J_2}, \dots, P_{J_N}]$, $P_{J_i} = P(J(t) = J_i | r(t))$; θ 表示神经网络模型 $f(\cdot)$ 的参数。本文主要研究单干扰场景下的典型压制式干扰信号的识别, 包括单音干扰 (single tone jamming, STJ)、多音干扰 (multi-tone jamming, MTJ)、线性扫频调制 (linear frequency modulation, LFM) 干扰、噪声调频干扰 (noise frequency modulation, NFM)。

1.3 参数估计数学模型

传统的参数估计方法主要是利用信号频域信息对干扰信号中心频率、带宽、JNR 等参数进行估计。传统参数估计算法的核心思想是利用门限值来查找满足要求的频点集合。假设时域干扰信号经过 FFT 变换后得到的功率谱为 $\mathbf{S} = \{S(1), S(2), \dots, S(N)\}$, N 为采样点数。则干扰信号带宽估计可表示为:

$$i_{\max} = \arg \max_i S(i) > \tau$$

$$i_{\min} = \arg \min_i S(i) > \tau$$

$$\hat{B} = f_s (i_{\max} - i_{\min}) / N \quad (5)$$

式中, τ 表示门限因子; i_{\max} 和 i_{\min} 分别表示大于门限值的频点对应的最大和最小频点下标; f_s 为采样频率。干扰信号中心频率估计可表示为:

$$\hat{f}_c = f_s \frac{(i_{\max} + i_{\min})}{2N} \quad (6)$$

对于干扰信号的 JNR 参数估计, 同样可以利用 i_{\min} 和 i_{\max} 进行估计。假设 \mathbf{I}_1 表示被占用带宽的离散频点集合 ($\mathbf{I}_1 = [i_{\min}, i_{\max}]$), \mathbf{I}_2 表示未被占用的频点集合 ($\mathbf{I}_2 = \mathbf{S} - \mathbf{I}_1$), 则 JNR 参数估计可表示为:

$$\widehat{\text{JNR}} = 10 \lg \left(\frac{\sum \left\{ S(i) - \frac{1}{N_2} \sum \{S(j) | j \in \mathbf{I}_2\} | i \in \mathbf{I}_1 \right\}}{\frac{N_1 + N_2}{N_1} \sum \{S(j) | j \in \mathbf{I}_2\}} \right) \quad (7)$$

式中, N_1 和 N_2 分别表示集合 \mathbf{I}_1 和 \mathbf{I}_2 的元素个数。

在深度学习中, 干扰信号的带宽和中心频率可以建模成一个回归问题。假设待估计干扰信号的中心频率、带宽以及 JNR 用 $\mathbf{y} = [f_c, B, \text{JNR}]$ 表示, 则通过神经网络 $f(\cdot; \theta)$ 后得到的估计值 $\hat{\mathbf{y}}$ 可表示为:

$$\hat{\mathbf{y}} = f(\mathbf{x}; \theta) \quad (8)$$

参数估计的优化目标是最小化估计的干扰信号参数与真实干扰信号参数之间的差距, 仿真中通过 MSE 损失衡量, 优化目标可表示为:

$$\min(\hat{\mathbf{y}} - \mathbf{y})^2 \quad (9)$$

1.4 基于多任务学习的干扰认知模型

近些年来, 神经网络在许多任务中表现出优异的性能, 如语义分割、图像分类和单目深度估计。传统上, 这些任务是孤立处理的, 即为每个任务训练一个单独的神经网络。然而, 现实生活中的许多问题都是多模式的, 研究人员希望给定输入即可推断出所有期望的任务输出。针对上述问题, 研究人员提出了多任务学习模型。与单任务相比, 多任务学习通过固有的层共享减少内存消耗, 避免重复计算共享层中的特征, 有效提升推理速度。最重要的是, 当多个相关联的任务之间共享互补的信息, 或彼此作为约束机制发挥作用时, 这些任务具备提升整体性能的潜力^[13]。文献 [14] 将多任务学习运用到无线通信领域来实现自动调制分类和无线信号分类任务, 利用两个分类任务的相关性, 并通过多任务

学习网络共享表示, 能够有效提升调制信号和无线信号的分类准确率及分类效率。文献 [15] 提出了一个用于增强指纹识别性能的跨领域注意力多任务架构 xDom, 能够实现对 Wi-Fi 和蓝牙设备的联合指纹识别。对于干扰信号认知过程, 希望智能干扰系统在检测识别干扰信号的同时, 能够对信号关键参数进行估计。因此, 本文提出能够同时实现干扰识别和干扰参数估计的多任务干扰认知方法。

一方面, 考虑到干扰信号的一些参数特征, 如频点、带宽、JNR 等都可作为干扰分类的依据, 且不同干扰信号之间可能有着频点、带宽上的重合; 另一方面, 来自同一干扰源的不同信号, 具有使用深度学习方法提取相似深层特征的潜在可能, 如时频、相位等特征可能具有一定的相关性。因此, 本文首先利用共享层网络提取不同干扰信号之间相似的微观特征, 力求对不同干扰信号类型和参数之间的关联建立共通的模型。但又由于不同干扰信号类型及其参数之间的差异性, 如若识别出的干扰为单音干扰, 则可直接估计出带宽; 若识别为其他干扰信号, 则无法直接对信号带宽进行估计, 因此, 本文通过特定的任务层, 来提取信号之间的差异特征。

基于硬参数共享的多任务干扰学习认知算法模型如图 1 所示^[13]。首先, 利用采集到的时域 IQ 两路信号构成一个 $2 \times 1 \times 1024$ 维的实数张量, 以便神经网络处理。随后, 通过共享层卷积网络挖掘识别任务和参数估计任务之间潜在的相关信息, 并对两类任务间的共同参数进行共享, 减少模型参数量和计算复杂度。最后, 因两类任务优化差异性而分别采用不同的全连接网络对共享层输出的特征进行优化, 最终同时实现对干扰信号类型的识别及信号关键参数的估计。




图 1 多任务学习干扰认知算法模型

虽然多任务学习在联合学习任务中有着独特的优势, 但是对于优化过程, 需要对所有的联合学习任务进行平衡, 以避免一个或多个任务在网络权重中占主导地位的情况。假设 w_i 为特定任务权重, L_i 为特定任务损失, 则多任务目标的优化问题可表

示为:

$$L_{\text{MTL}} = \sum_{i=1}^N w_i L_i \quad (10)$$

若采用随机梯度下降算法对式 (10) 进行优化, 则共享层的参数优化可表示为:

$$W_{\text{sh}} = W_{\text{sh}} - \alpha \sum_{i=1}^N w_i \frac{\partial L_i}{\partial W_{\text{sh}}} \quad (11)$$

式中, W_{sh} 表示共享层网络参数; N 表示任务数; α 表示步长。由式 (11) 可知, 当某一个任务的梯度值较大时, 共享层参数值的更新会被其主导, 从而导致其他任务无法很好地进行优化。

对于识别任务和参数估计任务, 本文分别采用交叉熵损失 L_c 和均方误差损失 L_p 进行优化, 整体的多任务损失 L_m 表示为两个任务损失的加权和:

$$L_m(\theta_{\text{sh}}, \theta_c, \theta_p) = \omega_c L_c(\theta_{\text{sh}}, \theta_c) + \omega_p L_p(\theta_{\text{sh}}, \theta_p) \quad (12)$$

式中, ω_c 和 ω_p 分别表示分类损失权重和参数估计损失权重, 二者加权和为 1。整体的多任务损失函数由共享参数 θ_{sh} 和特定任务参数 θ_c 、 θ_p 共同参数化, 整个多任务学习网络的训练优化可定义为:

$$\theta^* = \arg \min_{\theta_{\text{sh}}, \theta_c, \theta_p} L_m(\theta_{\text{sh}}, \theta_c, \theta_p) \quad (13)$$

由式 (13) 可知, 识别任务和参数估计任务的权重会影响整个多任务网络的优化过程。在传统的多任务学习中, 为了使得多任务网络性能最优, 需要手动平衡不同任务的权重。但多个任务难易程度未知, 且不同任务在不同时刻的学习情况也不同, 这种静态的简单线性加权方式将不利于多任务网络优化。基于干扰识别任务和参数估计任务在难易程度上的不确定性, 以及不同任务对网络平衡学习的需求, 本文选择采用多梯度下降算法上界 (multi-task descent gradient algorithm-up boundary, MGDA-UB)^[16] 算法实现对多任务网络更为高效的优化。该算法通过动态调整任务之间的学习权重, 优化多任务网络的整体性能。与传统方法相比, MGDA-UB 的显著优势在于其无须对每个任务的梯度进行多次计算, 仅对共享层最后一层的网络参数进行梯度计算, 有效降低了计算复杂度, 减少了总体计算开销, 提升了模型的学习效果。

2 参数设置

2.1 多任务网络参数设置

为了能够充分挖掘干扰识别和参数估计任务间

的相关信息, 本文在共享层采用了 13 层卷积网络。由于共享层卷积网络层数较深, 为了防止网络梯度消失和退化, 本文采用残差网络 (residual networks, ResNet) 对共享层网络结构进行优化。ResNet 允许特征通过网络在多个规模和深度下操作, 能够有效解决深层网络中梯度消失和退化的问题。本文的共享层网络结构如表 1 所示。由于分类任务与参数估计任务之间的特殊性及优化目标的差异性, 需要利用不同的网络对共享层提取到的信号特征分别进行优化。因共享层提取到的信号特征已经较为明显, 同时为了降低认知算法的复杂度, 本文仅采用单层全连接神经网络来分别实现分类任务优化和回归任务优化。

表 1 共享层网络结构

层	卷积核大小	步长	输出尺寸
Input	—	—	1×2×1 024
Conv, BN, ReLU	7×1	2	64×1×512
Max Pooling	3×1	1	64×1×512
Basic Block	3×1	1	64×1×512
Basic Block	3×1	1	64×1×512
Down Block	3×1	2	128×1×256
Basic Block	3×1	1	128×1×256
Down Block	3×1	2	256×1×128
Basic Block	3×1	1	256×1×128
Average Pooling	3×1	1	256×1
FC Layer	—	—	128×1

共享层网络包括 1 个卷积层、4 个 Basic Block、2 个 Down Block、1 个最大池化层、1 个平均池化层和 1 个全连接层。其中, Basic Block 和 Down Block 是两种不同的残差块结构, 如图 2 所示。Basic Block 为基本残差块, 包含两个卷积层, 卷积核大小都为 3×1, 步长都为 1。Down Block 为下采样残差块, 包括 3 个卷积层, 其中一个为旁路卷积层。在 Down Block 中, 3 个卷积层的卷积核大小都为 3×1, 第 1 个卷积层步长为 2, 第 2 个为 1, 旁路卷积层的步长为 2。Basic Block 要求输入和输出的数据特征维度相同, Down Block 允许输入和输出的数据特征维度不同, 能够对输入数据进行下采样。两种残差块虽然对输入输出特征维度的要求不同, 但在深层网络中, 都能够起到防止梯度消失的作用。在共享层网络中, 每个卷积层后都进行批量归一化, 以加速网络收敛, 并通过 ReLU 激活函数来进行非线性变换。

因分类任务和参数估计任务的差异性, 在特定任务层, 本文也是采用不同的单层全连接层网络结

构来分别实现 2 类任务。干扰分类任务全连接层包含 4 个神经元, 并使用 Softmax 激活函数输出 4 类干扰信号的预测概率。参数估计任务全连接层包含 2 个神经元, 并通过 Sigmoid 激活函数输出中心频率和带宽归一化的估计值。

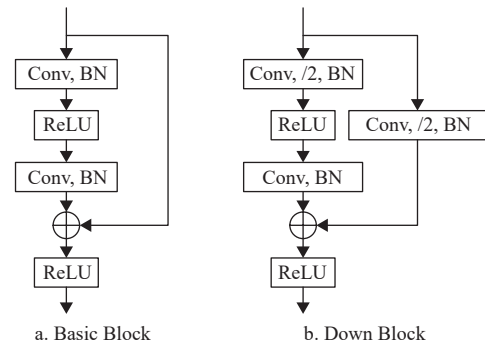


图 2 残差块结构

2.2 数据集参数设置

仿真中设定训练次数为 15, 采用 Adam 优化器, 每次训练所取批样本数为 64。学习率初始值设为 0.001, 每训练 5 轮, 学习率衰减为原来的 85%。与恒定学习率相比, 采用变化的学习率能够使得网络更稳定地到达最优解。

本文通过 MATLAB 产生了 4 种典型压制式干扰信号类型: 单音干扰、线性调频干扰、噪声调频干扰、部分频带噪声干扰。4 类干扰信号参数设置如表 2 所示。本文设置干扰信号采样频率为 10 MHz, 采样点数为 1 024, JNR 范围为 -10~30 dB, 间隔 5 dB 取值。每种干扰样式在每个 JNR 下生成 2 500 个样本, 并按照 4:1 的比例随机划分为训练集和测试集。

表 2 干扰信号中心频率和带宽参数

信号类型	占用带宽/MHz	中心频率/MHz
单音干扰	0	-5~5
线性扫频干扰	1~3	-1~1
噪声调频干扰	1~3	-1~1
部分频带噪声干扰	1~3	-1~1

由于接收到干扰信号的功率大小不同, 若直接输入到神经网络中, 会使得网络难以收敛, 故需要对采集到的复基带干扰信号 r 进行功率归一化, 归一化公式为:

$$\overline{r(n)} = \frac{r(n)}{\sqrt{\frac{1}{N} \sum_{i=1}^N |r(n)|^2}} \quad (14)$$

为加速网络模型收敛及减小参数估计误差, 需要对干扰信号中心频率和带宽归一化。中心频率的归一化公式为:

$$\hat{f}_c = \frac{f_c + f_s/2}{f_s} \quad (15)$$

式中, \hat{f}_c 表示归一化后的中心频率; f_c 表示干扰信号的中心频率; f_s 表示采样频率。假设多任务网络模型的中心频率预测值为 \hat{f}_c , 通过上式的逆运算便可以得到干扰信号的中心频率 f_c 。干扰信号的带宽归一化公式为:

$$\hat{B}_{\text{jam}} = \frac{B_{\text{jam}} + f_s/2}{f_s} \quad (16)$$

式中, \hat{B}_{jam} 表示归一化后的干扰信号带宽; B_{jam} 表示干扰信号带宽; f_s 表示采样频率。

本文采用归一化均方根误差 (normalized root mean square error, NRMSE) 来衡量干扰信号参数估计的性能。本文干扰信号参数估计任务整体 NRMSE 的计算公式为:

$$\hat{P}_{\text{NRMSE}} = \sqrt{\frac{1}{N_c N_s} \sum_{c=1}^{N_c} \sum_{i=1}^{N_s} |P_c(i) - \hat{P}_c(i)|^2} \quad (17)$$

式中, $P_c(i)$ 表示第 c 类信号的第 i 个样本关键参数归一化后的真实值; $\hat{P}_c(i)$ 则表示对应的估计值。 N_c 表示干扰信号类型数, 本文对 4 类干扰信号进行估计, 故 $N_c = 4$ 。 N_s 表示每个干扰比下每类干扰信号测试样本数目, 本文中 $N_s = 500$ 。

3 仿真结果与分析

为验证多任务干扰认知算法性能, 本文将多任务算法与单任务算法、传统算法进行对比。为了能够体现对比的公平性, 本文构建的单任务分类任务网络为多任务网络的共享层加上全连接分类层网络, 单任务参数估计网络为共享层加上全连接参数估计层网络。在分别对比单一任务性能的基础上, 使用单任务分类和单任务参数估计两个环节构建单任务干扰认知过程, 进行认知时效性的对比。本文所有算法均在同一硬件平台上运行, 平台配置如下: 处理器为 Intel(R) Core(TM) i7-11700F CPU @ 2.50GHz, 配备 NVIDIA GeForce GTX 1660 SUPER, 内存为 32 GB DDR4, 操作系统为 Windows 10, 编程环境为 Python 3.9, 并使用 TensorFlow 2.4 框架。

3.1 不同权重分配方式

虽然多任务学习在联合学习任务时, 有着独特的优势, 但是对于优化过程, 需要平衡所有任务的

联合学习, 以避免一个或多个任务在网络权重中占主导地位的情况。较好的权重比分配能够有利于多任务网络优化, 提升网络性能。由于任务的权重越大, 其加权的损失在多任务损失中的占比就越大, 所获得的梯度也就越大, 因此, 在进行梯度优化时可以得到更好的优化结果。本文测试了不同权重下两类任务的性能, 分类任务权重从 0 增加至 1, 参数估计任务权重从 1 减小至 0, 权重每次变化步长为 0.1, 两类任务权重之和始终为 1。图 3 为静态线性加权算法不同权重比下参数估计任务和分类任务性能。




图3 静态线性加权算法不同权重比下识别与参数估计性能

仿真结果表明, 当分类任务权重为 0 时, 整个多任务网络优化效果相当于单任务网络, 只优化其参数估计任务。此时, 参数估计任务整体 NRMSE 最小, 为 0.0618, 而识别任务准确率最差, 为 26.62%。随着分类权重的不断增加, 识别性能基本稳定, 识别准确率基本保持在 96.50%。即使分类任务在权重较小时, 也能够保持较高的识别性能。然而, 对于参数估计任务, 随着参数估计权重减小, 其性能急剧恶化。当分类任务权重为 1 时, 参数估计任务 NRMSE 接近 0.5, 参数估计任务未得到优化。

综上所述, 参数估计任务相比于识别任务, 优化过程更为复杂, 需要分配更高的任务权重才能保证估计性能。而仿真结果也表明, 这种简单的线性权重分配方法难以确定多个任务最优的训练权重比, 从而无法保证多任务网络模型整体性能。

为了能够平衡两类任务损失的权重, 避免多任务学习被分类任务主导, 本文基于 MGDA-UB 算法, 赋予两种任务动态权重。MGDA-UB 算法利用不同任务的梯度信息, 将多任务优化问题转变为多目标优化问题, 在所有任务中找到一个 Pareto 最优

解, 能够有效地对多任务学习网络模型进行优化。图 4 为基于 MGDA-UB 动态权重分配算法与静态权重分配算法的对比。

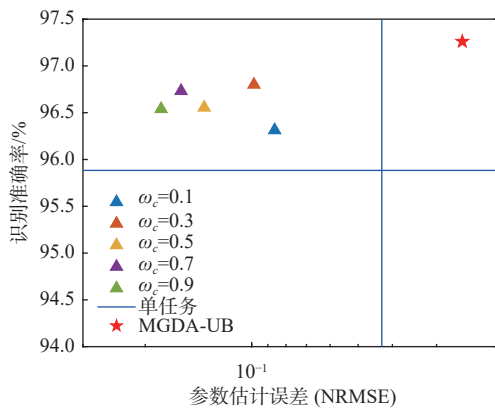


图 4 不同权重分配方法下分类任务与参数估计任务性能

从图 4 可知, 对于静态线性加权算法, 虽然在不同分类权重下, 多任务网络的分类性能都优于单任务, 但参数估计性能却都差于单任务。这表明, 虽然静态线性加权算法可以通过设置不同任务权重, 使多任务网络倾向于对某一个任务的优化, 但是这种简单的权重分配方式很难保证整个多任务网络性能。对于 MGDA-UB 算法, 其利用任务梯度信息, 动态调整学习权重的方式, 能够保证整个多任务整体性能最优。

基于 MDGA-UB 算法的多任务网络识别任务总体准确率为 97.19%, 参数估计任务总体 NRMSE 为 0.025 4, 分类任务和参数估计任务性能优于各自的单任务性能。仿真结果表明, MGDA-UB 算法能够充分利用不同任务间的梯度信息, 动态调整任务学习权重, 使得多任务网络性能整体最优。

为了进一步验证权重对多任务网络性能的影响, 本文对 MGDA-UB 算法最后一轮训练得到的权重进行分析。MGDA-UB 算法最后的分类权重 $\omega_c = 0.001$, 参数估计任务权重 $\omega_p = 0.999$ 。仿真结果表明, 参数估计任务训练难度要远大于分类任务, 为了能够使得估计任务得到较好的优化, 网络为其分配了更大的权重系数。综上所述, 与静态线性加权算法相比, MDGA-UB 算法能够充分利用不同任务之间的梯度信息, 使共享网络权值沿着不同任务梯度的共同方向更新, 使得整个多任务网络的性能达到最优。

3.2 分类任务

BP 神经网络和 SVM 这两种典型的传统机器学习分类算法, 常用于干扰信号识别, 本文将多任务学习方法与之进行对比。由于干扰信号输入数据

维度较高, 若采用 BP 神经网络和 SVM 这两种分类算法, 则需要先进行人工提取得到低维特征参数。提取的特征参数需要对不同干扰信号有区分性、对 JNR 有鲁棒性, 以便 BP 神经网络和 SVM 进行干扰识别。因此, 本文在时域、频域以及变换域提取了 7 种干扰信号特征, 包括时域矩峰度系数、频域矩峰度系数、频域矩偏度系数、平均频谱平坦系数、频域峰值聚集度、包络变化系数、分数阶傅里叶域能量聚集度。为了进一步凸显所提出算法的优势, 本次仿真对比了 LSTM^[17] 和 SKNet^[18] 两个基于深度学习的信号识别算法。不同干扰信号识别算法的分类准确率如图 5 所示。

基于深度学习的单任务和多任务分类算法与基于 BP、SVM 传统分类算法相比, 分类准确率更高。观察图 5 可以发现, 多任务学习算法在各 JNR 下均有较好的识别准确率, 且在低 JNR 下性能改善效果更明显。JNR 在 -10 dB 附近时, 不同分类算法有较大的性能差距, 相比传统算法, 多任务学习可以提升噪声容限 5~6 dB; 与单任务算法相比, 多任务学习可以提升噪声容限 2~3 dB。基于深度学习的分类算法在低 JNR 下, 较传统算法提升了约 15%~20% 的分类性能。主要原因是, 与传统的人工特征提取方法相比, 深度学习方法通过卷积、池化等操作, 能够更有效地对干扰信号的特征进行提取。相比于单任务, 多任务学习算法的分类任务能够有效利用参数估计任务共享的信号带宽、频点等特征信息来提升分类性能, 在 JNR 为 -10 dB 时, 多任务算法能够提升 9.55% 的分类性能, 在 -5 dB 能够提升 2.20%。同时, 相比于 LSTM 和 SKNet 等深度学习算法, 多任务学习识别性能在 JNR < -5 dB 条件下有较为明显的优势, 体现出算法较好的鲁棒性。在高 JNR 下, 由于干扰信号功率更大, 特征更明显, 更容易区分, 多任务算法在 0 dB 以上干扰信号识别准确率接近 100%, 而传统算法需要在 5 dB 以上才能接近 100%, 相比于传统算法, 多任务算法能提升噪声容限 5 dB 左右。为了比较不同识别算法对不同信号的具体识别性能, 本文绘制了多任务、单任务、LSTM、SKNet 这 4 类识别算法在 JNR = -10 dB 时的混淆矩阵, 具体仿真结果如图 6 所示。

仿真结果表明, 在低 JNR 时, 多任务算法对 NFM 信号的识别准确率能够达到 75.0%, 远优于其他识别算法。其次, 对于 LFM 干扰信号, 多任务算法性能也有一定的提升。

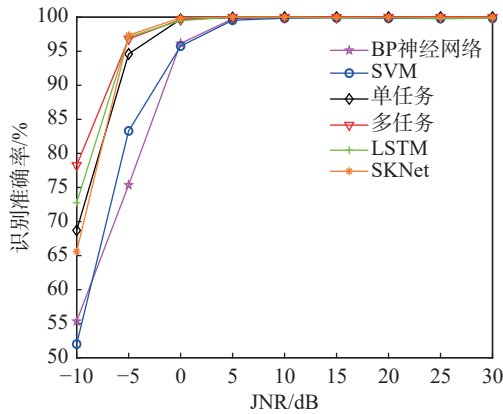


图 5 不同分类方法识别准确率

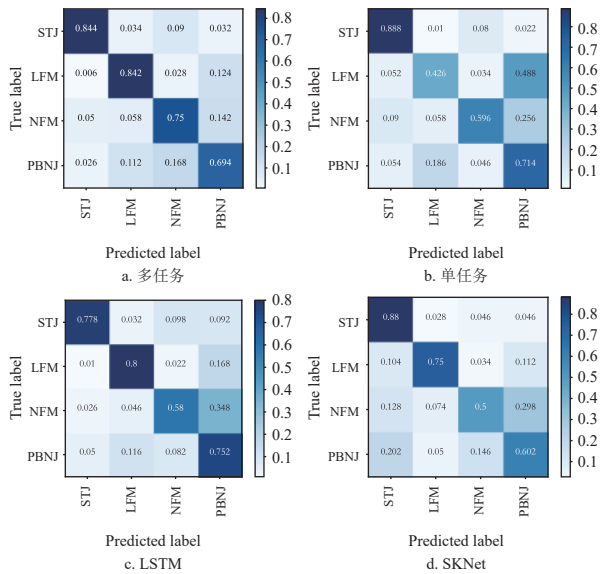


图 6 不同识别算法混淆矩阵 (JNR=-10 dB)

3.3 参数估计任务

传统参数估计算法需要依据干扰类型和关键参数类型设计参数估计算法。仿真中对单音干扰和线性扫频干扰, 采用基于 DFT 的估计算法, 对部分频带和噪声调频干扰, 采用文献 [19] 中的估计算法。

图 7 为传统算法、单任务学习、多任务学习 3 种算法参数估计的性能对比。得益于复杂的非线性变换, 神经网络具有强大的特征提取和表达能力, 并且多任务算法能够有效利用共享层共同提取的特征信息, 因此在参数估计方面的整体性能要优于传统算法和单任务算法。从仿真结果可以看出, 对于中心频率参数估计, 多任务算法性能在仿真测试的所有 JNR 下均优于单任务和传统算法, JNR > 10 dB 时, 估计误差 NRMSE 约为 10^{-2} , 要远小于传统算法的 NRMSE。在对带宽参数估计时, 多任务算法的性能同样优于单任务和传统算法。从图 7b 可以看出, 传统算法的带宽估计误差随 JNR 增加呈现先减小后增大的趋势, 根本原因在于加窗

引发的干扰能量泄露, 会影响信号主瓣的展宽和旁瓣的能量分布, 导致误判信号边界, 从而出现带宽过估计的现象。单任务和多任务算法对加窗效应表现出良好的鲁棒性, 通过端到端学习, 能够直接从原始信号中提取有效特征, 而不依赖于加窗后的频谱分析, 因此不会出现高 JNR 下带宽估计误差增大的现象。对于 JNR 参数估计, 多任务算法在低 JNR 下相较于传统算法、单任务算法性能提升明显, JNR=-10 dB 时, 相较于单任务估计误差降低了 30%; 在 JNR > 15 dB 条件下, 多任务估计误差小于 0.05, 能够较为精确地实现对干扰信号 JNR 参数的估计。




图 7 不同参数估计算法性能对比

综上所述,与单任务相比,多任务算法能够有效利用共享的特征信息来提高参数估计的整体性能。同时,多任务算法不需要设置门限来进行带宽和频点判决,算法具有更强的鲁棒性,能够适应更加复杂的电磁干扰环境。

3.4 认知过程时效性

在传统干扰认知过程中,参数估计任务需要分类任务的识别结果,这导致两类任务无法并行,从而造成整个干扰过程的时效性无法得到保障。针对算法时效性问题,本文从算法计算复杂度和算法实际运行时间两方面进行分析。利用文献 [20] 中提出的卷积层计算复杂度公式:

$$O\left(\sum_{l=1}^d n_{l-1} s_l^2 n_l m_l^2\right) \quad (18)$$

式中, l 是卷积层的索引; d 是卷积层的深度; n_l 是第 l 层中滤波器的数量; n_{l-1} 是第 l 层的输入通道数; s_l 是滤波器的大小; m_l 是输出特征图的空间大小。根据表 1 中给出的共享层网络结构参数代入式 (18) 可得基于多任务的干扰认知网络整体计算复杂度约为 $O(105440N)$ 。其中, N 为采样点数,本文中 N 取 1 024。传统方法主要是对频域信息处理,其计算复杂度要小于多任务网络。由于单任务干扰认知网络为共享层网络加上各自的独立任务层网络,故单任务干扰认知复杂度约为多任务的 2 倍,即 $O(210880N)$ 。

在算法实际运行时间方面,本文假设 4 类干扰信号随机出现,统计测试集中每个信号从开始分类到参数估计完成所用的平均时间,不同认知算法实际运行时间如表 3 所示。

表 3 不同认知算法实际运行时间

认知算法	分类任务	参数估计任务	总时间/ms
传统方法	SVM: 0.151	1.545	1.696
	BP: 0.123	1.545	1.668
单任务	0.364	0.334	0.698
多任务	—	—	0.424

仿真结果表明,多任务学习单个信号从开始分类到参数估计完成所用的平均时间要低于传统算法和单任务干扰认知算法。虽然多任务网络计算复杂度要高于传统算法,但是得益于多任务并行处理能力,整体认知过程的时效性要高于传统方法,干扰认知时间降低了 60%。相比于单任务认知算法的实际运行时间 0.698 ms,多任务学习方法通过共享模型参数和特征表示,有效降低了模型的复杂度,干

扰认知时间降低了 40%。综上所述,多任务学习网络并行处理的方式能够有效提升整个干扰认知过程的时效性。

4 结束语

本文利用干扰识别任务与参数估计任务之间的相关性,提出了基于多任务学习的干扰认知算法,为干扰信号认知的过程提供了新思路。本文从分类任务性能、参数估计任务性能以及认知过程的时效性 3 个方面验证所提的多任务算法的有效性。仿真结果表明,与传统算法和单任务认知算法相比,本文所提出的多任务认知算法,在识别任务中能够有效利用参数估计任务共享的特征信息,提高 4 类压制式干扰信号分类的准确率;在参数估计方面,多任务算法能够同时实现对多种干扰信号带宽和中心频率估计,有效提升了估计算法的鲁棒性,使得算法可应用于更为复杂的电磁干扰环境;从整个认知过程来看,多任务网络共享模型参数和特征表示,减少了模型的复杂度,且并行处理任务的方式使得整个认知过程的时间比单任务方法减少 40%,有效提升了干扰认知过程的时效性。

参考文献

- [1] 王世练, 骆俊杉, 魏鹏, 等. 认知通信抗干扰[M]. 北京: 国防工业出版社, 2023: 10-20.
WANG S L, LUO J S, WEI P, et al. Cognitive communication for anti-jamming[M]. Beijing: National Defense Industry Press, 2023: 10-20.
- [2] MOON S, KIM K. Performance of satellite communication system with FH-MFSK under various jamming environments[C]//MILCOM Proceedings Communications for Network-Centric Operations: Creating the Information Force. McLean: IEEE, 2001: 659-663.
- [3] SLEPIAN D. Estimation of signal parameters in the presence of noise[J]. Transactions of the Ire Professional Group on Information Theory, 2012, 3(3): 68-89.
- [4] HASSANPOUR S, PEZESHK A M, BEHNIA F. Automatic digital modulation recognition based on novel features and support vector machine[C]//12th International Conference on Signal-Image Technology & Internet-Based Systems. Naples: IEEE, 2016: 172-177.
- [5] HE Z W. Communication signal modulation recognition based on time-frequency domain analysis and Bayesian optimized decision tree algorithm[C]//International Conference on Data Science and Computer Application. Dalian: IEEE, 2021: 69-73.
- [6] FANG Z, SHEN J J, ZHOU X Q. Research on digital modulation recognition based on BP neural network [C]//6th Information Technology and Mechatronics Engineering Conference. Chongqing: IEEE, 2022: 1813-1817.

- [7] 张博轩, 王圣举. 基于 CNN 网络的通信干扰信号识别[J]. *数字通信世界*, 2022(9): 59-61.
ZHANG B X, WANG S J. Communication interference signal identification based on CNN network[J]. *Digital Communication World*, 2022(9): 59-61.
- [8] ZHANG Y, DING X H, LI G Y, et al. Offline real-world wireless interference signal classification algorithm utilizing denoising diffusion probability model[J]. *IEEE Signal Processing Letters*, 2023, 30: 1132-1136.
- [9] WANG P Y, MA K, BAI Y S, et al. Wireless interference recognition with multimodal learning[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(12): 18576-18591.
- [10] 王鹏宇, 程郁凡, 徐昊, 等. 基于卷积神经网络联合多域特征提取的干扰识别算法[J]. *信号处理*, 2022, 38(5): 915-925.
WANG P Y, CHENG Y F, XU H, et al. Jamming classification using convolutional neural network-based joint multi-domain feature extraction[J]. *Journal of Signal Processing*, 2022, 38(5): 915-925.
- [11] VARTIAINEN J, LEHTOMAKI J J, SAARNISAARI H. Double-threshold based narrowband signal extraction [C]//Vehicular Technology Conference. Stockholm: IEEE, 2005: 1288-1292.
- [12] CAI C, XU K, SHI B X. Application of three-threshold FCME and extended interpolation algorithm in narrowband interference suppression[C]//7th International Conference on Computer Science and Network Technology. Dalian: IEEE, 2019: 413-416.
- [13] VANDENHENDE S, GEORGOULIS S, GANSBEKE V W, et al. Multi-task learning for dense prediction tasks: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(7): 3614-3633.
- [14] JAGANNATH A, JAGANNATH J. Multi-task learning approach for automatic modulation and wireless signal classification[C]//International Conference on Communications. Montreal: IEEE, 2021: 1-7.
- [15] JAGANNATH A, KANE Z, JAGANNATH J. RF fingerprinting needs attention: Multi-task approach for real-world WiFi and bluetooth[C]//Global Communications Conference. Rio de Janeiro: IEEE, 2022: 4607-4612.
- [16] SENNER O, KOLTUN V. Multi-task learning as multi-objective optimization[C]//32nd Conference on Neural Information Processing Systems. Montréal: IEEE, 2018: 525-536.
- [17] RAJENDRAN S, MEERT W, GIUSTINIANO D, et al. Deep learning models for wireless signal classification with distributed low-cost spectrum sensors[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2018, 4(3): 433-445.
- [18] LI X, WANG W, HU X, et al. Selective kernel networks[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 510-519.
- [19] 李雪迎. 恶意干扰信号检测系统 FPGA 实现研究[D]. 成都: 电子科技大学, 2021.
LI X Y. Research on FPGA implementation of malicious jamming signal detection system[D]. Chengdu: University of Electronic Science and Technology of China, 2021.
- [20] HE K, SUN J. Convolutional neural networks at constrained time cost[C]//Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015: 5353-5360.

编辑 刘飞阳