

基于子域自适应的雷达复合干扰识别研究

黄文青¹ 王佳宾¹

HUANG Wenqing WANG Jiabin

摘要

针对复杂电磁环境下雷达复合干扰标签获取困难的问题,基于迁移学习中的子域自适应方法,提出了 SimAM-DSAN 雷达复合干扰识别算法。首先,将复合干扰信号划分为带标签样本的源域和不带标签样本的目标域,并将干扰信号输入模型;然后,通过引入 SimAM 注意力机制的 ResNet50 网络提取样本的深度特征,将特征映射到再生 Hilbert 空间,并基于 LMMD 准则对其相关子域的分布,扩展深度适应网络的特征表达能力;最后,结合 LMMD 自适应损失和交叉熵分类损失构造联合损失函数,通过不断迭代训练,最小化损失函数。仿真结果表明,SimAM-DSAN 算法在干噪比为 -2 dB 的情况下,对无标签复合干扰的识别率为 97.5%。通过与其他域适应算法对比,所提出的算法在不同数量样本下均表现出最高的准确率。

关键词

复合干扰;迁移学习;子域自适应;注意力机制;深度学习

doi: 10.3969/j.issn.1672-9528.2024.07.027

0 引言

雷达作为一种全天候的智能传感器,具备在各种武器系统上进行目标探测、定位、跟踪和制导的能力^[1]。近年来,电子战已成为现代战争中的重要组成部分,而雷达则是决定战争胜负的关键要素之一^[2-3]。因此,在日益复杂多变的电磁环境下,提高雷达的抗干扰能力变得愈发重要。雷达抗干扰流程一般包括四个步骤:干扰信号侦测、干扰认知识别、抗干扰措施释放和抗干扰效果评估^[4]。其中,干扰信号识别在提高雷达系统的抗干扰能力上发挥着关键的作用^[5-8]。

迁移学习利用不同数据集、任务或模型之间的相似性,将已有领域的知识迁移应用到新的领域。而迁移学习中的域自适应专注于将源域与目标域的数据映射到同一特征空间中,并且最小化两域中类别分布的差异,以增强模型对新环境下样本的识别与处理能力。近年来,有不少学者将迁移学习应用于雷达信号识别领域^[9-10]。

2020 年, Lin 等人^[11]设计了一种基于深度学习和线性加权决策融合的未知雷达信号识别模型。首先通过 CNN 对已知的雷达信号进行学习训练,然后基于迁移学习对 CNN 获得的神经元进行重构特征,最后通过结合随机森林分类器和短时自相关特征图像的方法,实现了对未知新类别的识别率达 80.31%,以及对已知雷达信号分类的准确率超过

99.15%。2021 年, LYU 等人^[12]针对小样本问题,提出了一种基于加权集成 CNN 和迁移学习的雷达有源欺骗干扰识别算法。该算法通过短时傅立叶变换获取干扰信号的时频分布图,构建多个数据集,最后采用集成神经网络模型实现 12 类干扰样本的识别。

1 雷达复合干扰信号

1.1 复合干扰信号生成

线性调频信号(linear frequency modulation, LFM)是现代雷达中最常用的信号类型之一,这种信号具有大带宽、长脉冲的特点。因此,本文采用 LFM 作为雷达的发射信号。雷达单一干扰选择新型雷达干扰中的切片转发(chopping and interleaving, C&I)干扰、间歇采样直接转发干扰(interrupted-sampling and direct repeater jamming, ISDJ)、梳状谱(comb spectrum, COMB)干扰、频谱弥散(smeared spectrum, SMSP)干扰、噪声卷积(noise convolution, NC)干扰和噪声乘积(noise product, NP)干扰。

复合干扰是多个单一干扰信号的线性组合,具有对目标雷达进行多维干扰的能力。本文采用加性复合方式,对 6 类单一干扰进行线性复合,可以得到 15 种不同特性的复合干扰信号,分别是 C&I+ISDJ、C&I+COMB、C&I+SMSP、C&I+NC、C&I+NP、ISDJ+COMB、ISDJ+SMSP、ISDJ+NC、ISDJ+NP、COMB+SMSP、COMB+NC、COMB+NP、SMSP+NC、SMSP+NP 和 NC+NP。

1. 哈尔滨工程大学 黑龙江哈尔滨 150001

1.2 复合干扰信号时频变换

时频变换在雷达干扰信号识别中起着关键作用, 通过将干扰信号转换为时频域, 提取时间域和频率域的联合分布信息。本文采用平滑伪维格纳 - 威利分布 (smoothed pseudo-wigner-ville distribution, SPWVD), 通过在变量 t 和 τ 上应用窗函数, 可以有效地减少交叉干扰项, 其表达式为:

$$S(t, \omega) = \int_{-\infty}^{\infty} g(u - \tau) \left[\int_{-\infty}^{\infty} h(\tau) s(t + \frac{\tau}{2}) s^*(t - \frac{\tau}{2}) e^{-j\omega\tau} d\tau \right] du \quad (1)$$

式中: $h(\tau)$ 、 $g(u - \tau)$ 表示时域和频域窗函数。图 1 为 15 类复合干扰在 JNR 为 10 dB 下进行 SPWVD 的时频图像。




图 1 复合干扰时频图

2 基于 SimAM-DSAN 的复合干扰识别模型

2.1 总体框架

本文提出了一种基于 SimAM-DSAN 的复合干扰识别方法。该方法在有标注源域数据的基础上, 利用未标注的目标域数据进行训练, 进而对目标域的复合干扰进行分类。SimAM-DSAN 模型选取残差神经网络作为特征提取的主干网络, 提取源域和目标域的特征信息; 然后基于 LMMD 对其相关子域的分布, 计算源域数据与目标域数据分布的距离, 扩展深度适应网络的特征表达能力, 实现对不同域中相关子域分布的调整; 最后, 将 SimAM 注意力机制模块加入到残差神经网络中, 在不增加额外参数的前提下, 提高模型提取干扰特征的能力。本节将 SimAM 模块和 DSAN 的子域自适应思想相结合进行复合干扰识别, 模型结构如图 2 所示。




图 2 SimAM-DSAN 结构图

2.2 特征提取模块

在基于迁移学习的复合干扰识别研究中, 特征提取对于模型性能至关重要。本章提出的 SimAM-DSAN 模型采用了 ResNet50 作为特征提取网络, 以解决网络过深引起的梯度消失问题。此外, 通过融入 SimAM 注意力机制, 增强网络的特征表征能力, 从而提高复合干扰识别的准确性。

改进后残差单元的具体实现方式如图 3 所示, 称为 Bottleneck。




图 3 改进的 Bottleneck 结构图

本文在 Bottleneck 的 3*3 的卷积层后加入 SimAM 模块, 这样可以在不增加网络参数的前提下提升特征学习能力。Bottleneck 的输入和输出的维度不同时, 无法直接使用短路连接。

为了解决这一问题, Bottleneck 设计中采用两个 1*1 的卷积, 一个用于减小维度, 一个用于恢复维度。具体而言, 将 256 维的时频图先压缩至 64 维, 通过 3*3 的卷积层再扩展回 256 维。这种方法既减少了参数量, 又缩短了模型训练时间。

2.3 SimAM 模块

SimAM 是 Yang 等人提出的一种新型注意机制模块, 不需要在原始网络中添加额外的训练层和参数, 能够评估每个神经元的重要性, 且具有较高的计算效率。定义每个神经元的能量函数公式为:

$$e_t(\omega_t, b_t, x_t, y) = (y_t - \hat{t})^2 + \frac{1}{M-1} \sum_{i=1}^{M-1} (y_0 - x_i^2) \quad (2)$$

式中: $\hat{t} = \omega_t t + b_t$ 和 $\hat{x}_i = \omega_i x_i + b_i$ 是 t 和 x_i 的线性变换, ω_t 和 b_t 为变换的权重和偏置, t 和 x_i 是目标神经元和同一通道中的其他神经元, M 为该通道上的神经元总数, y_0 和 y_t 为两个不同的值。

使用二进制标签并添加正则化项, 最终的能量函数为:

$$e_t(\omega_t, b_t, x_t, y) = \frac{1}{N-1} \sum_{i=1}^{N-1} (-1 - (x_i \omega_t + b_t))^2 + (1 - (\omega_t t + b_t))^2 + \lambda \omega_t^2 \quad (3)$$

其封闭形式的解为:

$$\omega_t = -\frac{2(t - \mu_t)}{(t - \mu_t)^2 + 2\sigma_t^2 + 2\lambda} \quad (4)$$

$$b_t = -\frac{1}{2}(t + \mu_t)\omega_t \quad (5)$$

最小能量可以通过以下公式计算:

$$e_t^{\min} = -\frac{4(\sigma_t^2 + \lambda)}{(t - \mu)^2 + 2\sigma^2 + 2\lambda} \quad (6)$$

式中: t 为目标神经, x_i 为同一个通道的其他神经元, N 为该通道上神经元的总数, μ_t 和 σ_t^2 为该通道上除 t 外所有神经元的均值和方差, μ 和 σ^2 为该通道所有神经元的均值和方差, λ 为正则化参数。

能量越低, 神经元 t 与周围神经元区别越大, 重要性也越高。将单个神经元的操作整合到端到端的框架中, 可以通过增强模型的线性可分性来提升其识别能力。

2.4 数据分布距离度量模型

本章采用 LMMD 的度量方式, 以捕获每个类别的细粒度信息, 实现子域对齐下的全局域适配。其公式定义如下:

$$d_H(P, Q) = E_c \left\| E_{P^{(c)}}[\phi(x^s)] - E_{Q^{(c)}}[\phi(x^t)] \right\|_H^2 \quad (7)$$

式中: x^s 和 x^t 表示源域 D_s 和目标域 D_t 中的样本, $E(\cdot)$ 表示该子类的数学期望, $P^{(c)}$ 和 $Q^{(c)}$ 分别表示 D_s 和 D_t 的概率分布, c 是 D_s 和 D_t 中的一种干扰类别。假设每个样本是根据权重 ω^c 进行分类, 则可以得到式 (6) 的无偏估计为:

$$\hat{d}_H(P, Q) = \frac{1}{C} \sum_{c=1}^C \left\| \sum_{x_i \in D_s} \omega_i^{sc} \phi(x_i^s) - \sum_{x_j \in D_t} \omega_j^{tc} \phi(x_j^t) \right\|_H^2 \quad (8)$$

式中: x_i^s 和 x_j^t 表示 D_s 和 D_t 中的样本, ω_i^{sc} 和 ω_j^{tc} 分别表示 x_i^s 和 x_j^t 属于子类 c 的权重。样本 x_i 的权重计算公式为:

$$\omega_i^c = \frac{y_{ic}}{\sum_{(x_j, y_j) \in D} y_{jc}} \quad (9)$$

式中: y_{jc} 为第 c 个类别的标签。对于源域样本, 使用真实标签的独热编码计算权重 ω_i^{sc} , 而对于无标签的目标域样本, 则使用网络输出的伪标签 y_j^t 来计算权重 ω_j^{tc} 。为了适应特征层, 需要获取各个层中的激活值。假设源域 D_s 具有 n_s 个带标签的样本, 目标域 D_t 具有 n_t 个无标签的样本。深层网络在 l 层中生成的激活值分别为 $\{z_{s_i}^l\}_{i=1}^{n_s}$ 和 $\{z_{t_j}^l\}_{j=1}^{n_t}$, 在 l 层采用 LMMD 计算自适应损失值为:

$$Loss = \min_f \frac{1}{n_s} \sum_{i=1}^{n_s} J(f(x_i^s), y_i^t) + \lambda \sum_{l=L} \hat{d}_l(P, Q) \quad (10)$$

式中: $\frac{1}{n_s} \sum_{i=1}^{n_s} J(f(x_i^s), y_i^t)$ 为交叉熵分类损失, $\sum_{l=L} \hat{d}_l(P, Q)$ 为

LMMD 自适应损失, λ 为权衡参数。

3 实验与分析

3.1 数据集

在仿真实验中, 回波信号的中心频率为 15 ~ 25 MHz, 带宽为 10 ~ 20 MHz, 脉冲宽度为 10 μ s, 采样频率为 100 MHz。源域为干噪比 10 dB 下带标签的复合干扰信号和真实回波, 目标域为干噪比 -2 dB 下无标签的复合干扰信号和真实回波。源域和目标域均由每类干扰 30 个样本组成, 各信号参数设置如表 1 所示。

表 1 干扰参数设置

干扰类型	参数设置	源域	目标域
C&I	采样时长/ μ s	2/2.5	2.2/3
	重复转发次数	4/5	3/6
ISDJ	采样时长/ μ s	2/2.5	2.2/3
	采样次数	4/5	3/6
COMB	频移个数	4/5	3/6
SMSP	调频斜率	4·k/5·k/6·k	4·k/7·k
	转发次数	4/5/6	4/7
NP	带宽/MHz	18~22	16~24
NC	带宽/MHz	18~22	16~24
复合干扰	相关参数	与各干扰分量相同	与各干扰分量相同

3.2 参数设置

本文实验的硬件设备包括 Inter i9-13900K CPU, 32 GB 内存, 以及 NVIDIA GTX 1650 显卡。软件环境方面, 使用的是基于 Python 3.9 的 PyTorch 2.0 学习框架, 并在 PyCharm 开发平台下进行开发。训练过程中算法参数设置如下: 优化算法为随机梯度下降法, 学习率为 0.1。

3.3 复合干扰识别性能分析

(1) SimAM-DSAN 网络性能分析

为了验证改进的 SimAM-DSAN 网络对复合干扰的识别性能, 将 SimAM-DSAN 网络与 DSAN 网络进行对比实验。实验结果如图 4 和图 5 所示。




图 4 实验损失值




图 5 实验准确率

从图 4 可以看出, SimAM-DSAN 网络的损失迅速下降并趋于稳定状态, 比 DSAN 网络更早达到较低损失值。从图 5 可以看出, 在训练过程中, SimAM-DSAN 网络的识别准确率高出 DSAN 网络, 特别是在训练初始阶段。这表明通过融合 SimAM 注意力机制使得网络能够有效提取和学习干扰特征, 从而能够更快地达到较高的准确率。随着训练的进行, 两个网络的准确率趋于稳定, DSAN 网络的准确率为 93.96%, 而 SimAM-DSAN 网络可以达到 97.5% 的准确率。综上所述, SimAM-DSAN 网络通过增强特征表达能力, 能够有效提升对复合干扰的识别准确率, 验证了改进 SimAM-DSAN 网络的有效性。

(2) 不同数量下复合干扰数据的迁移

为了探究模型在不同数量复合干扰数据集下的迁移学习性能, 本文将 SimAM-DSAN 算法与 DSAN、DAN、Deep Coral 和 MRAN 四个域适应算法进行对比实验。对比实验设置在四个不同数量的数据集下进行, 分布包含每类干扰 15、30、45 和 60 个样本, 实验结果如图 6 所示。




图 6 不同数量准确率对比

由图 6 可以看出, 随着样本数量的增加, 各个模型的识别准确率都呈现不断提升的趋势。其中, DAN 网络的识别效果与 Deep Coral 类似, 但整体准确率略高于 Deep Coral, 最终识别率只能达到 75.31%。MRAN 网络在样本数量较少时的准确率为 73.33%, 随着样本数量的增加, 最终可以达到 89.4% 的准确率。

DSAN 网络在样本数量较小时也能达到 91.25% 的准确率, 随着样本数量的增加, 准确率也逐渐上升并最终达到 97.5%。而改进的 SimAM-DSAN 算法在不同样本数量下均表现出最高的准确率, 而且在各类样本数量为 45 和 60 时, 识别准确率能达到 99% 以上。因此, 本文算法在小样本条件下能保持较高的准确率, 验证了 SimAM-DSAN 算法的优越性。

4 总结

本文针对复杂电磁环境下无标签复合干扰信号, 提出了一种基于子域自适应的 SimAM-DSAN 复合干扰识别算法。该算法利用 LMMD 计算各子域之间的分布差距, 通过不断优化损失函数, 缩小源域和目标域中干扰的子领域差距, 通过加入 SimAM 注意力机制, 提高模型提取干扰特征的能力。实验结果表明, SimAM-DSAN 算法在干扰比 -2 dB 下能够达到 97.5% 的准确率, 而且在不同数量下的性能均优于其他域自适应算法。

参考文献:

- [1] 赵国庆. 雷达对抗原理 [M]. 西安: 西安电子科技大学出版社, 2015.
- [2] ZHAO S, ZHOU Y, ZHANG L R, et al. Discrimination between radar targets and deception jamming in distributed multiple-radar architectures[J]. IET radar, sonar & navigation, 2017, 11(7): 1124-1131.

基于二人零和博弈的微电网多目标优化调度

梅 雨¹
MEI Yu

摘 要

随着全球对环境问题的重视程度不断提高,有效利用可再生能源的微电网得到了广泛的发展。为了经济地利用清洁能源,基于微电网的经济性和环保性建立了多目标优化模型,采用基于二人零和博弈的线性加权法平衡两个目标函数,并使用模拟退火粒子群优化算法求解多目标优化模型。仿真结果表明,多目标权重方法和优化算法可以减少不确定性因素的影响,提升微电网的经济性和环保性。

关键词

微电网;多目标优化;二人零和博弈;模拟退火粒子群优化算法

doi: 10.3969/j.issn.1672-9528.2024.07.028

0 引言

随着生产与生活对电能的需求不断增大,能源和环境问题成为当今世界重要的社会问题。传统的化石燃料会造成环境污染,且传统电网有成本高和效率低等缺点,故包含可再生能源和储能装置等设备的微电网受到了重视。并网型微电网有配电网的支撑,提高了微电网的可靠性,但配电网的能

量主要来源是化石能源,会对环境造成污染;微电网包含可再生能源,可以减少燃料的使用,但可再生能源存在间歇性及波动性,且装置成本较高,故如何经济且环保调度成为微电网的研究方向^[1-2]。

多目标优化问题的求解方法有多种,常用的是线性加权法,该方法将多目标进行加权转换为单目标优化问题^[3-4]。文献[5]用线性加权的方法将多个优化目标转换为一个优化目标,从设置不同权值分析调度结果,实验结果表明,通过改变权值能够改变调度的结果。常用的确定权重方法有层次分析法^[6]和专家打分法^[7]等,但是这些确定方法主观性太强,

1. 黔南民族师范学院计算机与信息学院 贵州都匀 558000
[基金项目] 贵州省教育厅高等学校科学研究项目(黔教技[2022] 383号)

- [3] 邵正途,许登荣,徐文利,等. 基于LSTM和残差网络的雷达有源干扰识别[J]. 系统工程与电子技术, 2023, 45(2): 416-423.
- [4] 檀鹏超. 雷达有源欺骗干扰多维特征提取与识别技术研究[D]. 成都: 电子科技大学, 2016.
- [5] 张顺生,陈爽,陈晓莹,等. 面向小样本的多模态雷达有源欺骗干扰识别方法[J]. 雷达学报, 2023, 12(4): 882-891.
- [6] 周红平,王子伟,郭忠义. 雷达有源干扰识别算法综述[J]. 数据采集与处理, 2022, 37(1): 1-20.
- [7] 李君. 雷达有源干扰信号识别技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2022.
- [8] 刘强. 基于深度学习的雷达干扰识别技术[D]. 成都: 电子科技大学, 2020.
- [9] ZHANG F, WANG Y C, NI J, et al. SAR target small sample recognition based on CNN cascaded features and AdaBoost rotation forest[J]. IEEE geoscience and remote sensing letters, 2020, 17(6): 1008-1012.
- [10] NIE X L, R. GAO R F, WANG R, et al. Online multiview

deep forest for remote sensing image classification via data fusion[J]. IEEE geoscience and remote sensing letters, 2021, 18(8): 1456-1460.

- [11] LIN A, MA Z, HUANG Z, et al. Unknown radar waveform recognition based on transferred deep learning[J]. IEEE access, 2020, 8(184): 793-807.
- [12] LYU Q Z, QUAN Y H, FENG W, et al. Radar deception jamming recognition based on weighted ensemble cnn with transfer learning[J]. IEEE transactions on geoscience and remote sensing, 2022, 60: 1-11.

【作者简介】

黄文青(1999—), 男, 江西赣州人, 硕士研究生, 研究方向: 雷达干扰识别。

王佳宾(2000—), 男, 黑龙江齐齐哈尔人, 硕士研究生, 研究方向: 雷达干扰识别。

(收稿日期: 2024-04-09)