



小样本下雷达复合干扰半监督迁移学习识别方法

王金强¹, 孙闽红¹, 唐向宏¹, 仇兆炀¹, 曾德国²

(1. 杭州电子科技大学通信工程学院, 浙江 杭州 310018;

2. 中国航天科工集团八五一—研究所, 江苏 南京 210007)

摘要: 针对雷达复合干扰信号种类越来越多以及训练样本过少难以令深度学习模型达到最优状态的问题, 提出一种在小样本下雷达复合干扰半监督迁移学习识别的方法, 通过未带标签样本来解决标签样本难以获取而导致网络训练精度不高的问题, 将在单一干扰数据集预训练后得到的特征提取器和分类器迁移到小规模复合干扰数据集上, 并利用权重印记和半监督学习对模型进行微调, 通过所提出的最近邻相关性损失 (nearest neighbor correlation loss, NNCL) 来优化模型参数。实验结果表明, 在干噪比为 10 dB、新类复合干扰信号带标签样本仅有 5 个时, 模型可达 93.20% 的识别准确率。

关键词: 雷达抗干扰; 复合干扰识别; 迁移学习; 权重印记; 半监督学习

中图分类号: TN975

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2023182

A semi-supervised transfer learning recognition method for radar compound jamming under small samples

WANG Jinqiang¹, SUN Minhong¹, TANG Xianghong¹, QIU Zhaoyang¹, ZENG Deguo²

1. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

2. China Aerospace Science and Technology Group 8511 Research Institute, Nanjing 210007, China

Abstract: Aiming at the problem that more and more kinds of radar compound jamming signals and too few training samples were difficult to make the deep learning model reach the optimal state, a semi-supervised transfer learning recognition method for radar compound jamming under small samples was proposed, which solved the problem of low network training accuracy caused by the difficulty in obtaining labeled samples through unlabeled samples. The feature extractor and classifier obtained after pre-training of single jamming data set were transferred to small-scale compound jamming data set, and the model was fine-tuning by using weight imprinting and semi-supervised learning. The model parameters were optimized by the proposed nearest neighbor correlation loss nearest neighbor correlation loss (NNCL). The experimental results show that the recognition accuracy of the model can reach 93.20% when the jamming-to-noise ratio is 10 dB and there are only 5 labeled samples of the new class of compound jamming signals.

Key words: radar anti-jamming, compound jamming recognition, transfer learning, weight imprinting, semi-supervised learning

收稿日期: 2023-06-07; 修回日期: 2023-09-06

基金项目: 国家自然科学基金资助项目 (No.61901149); 国防特色学科发展项目 (No.JCKY2019415D002)

Foundation Items: The National Natural Science Foundation of China (No.61901149), The National Defense Characteristic Discipline Development Project (No.JCKY2019415D002)



0 引言

在真实的电磁干扰环境中干扰样式多种多样^[1], 雷达复合干扰作为新型干扰样式, 给雷达带来了严重威胁^[2]。文献[3]指出复合干扰对现代雷达对抗系统的影响比传统的单一干扰更大, 其复合方式主要包括加性、乘性和卷积。文献[4]分析了不同复合干扰对雷达造成的威胁和不利影响, 并给出了不同复合方式产生复合干扰的方法。

近年来, 基于深度学习的复合干扰识别取得了一些成果。文献[4]提出了深度多标签的复合信号识别框架, 通过构造多标签卷积神经网络来对 6 种干扰类型的任何组合方式进行分类。文献[5]对 6 种单一干扰和两种单一干扰所产生的加性复合干扰进行时频分析和归一化处理, 将 YOLOv5 作为骨干网络, 利用目标检测的思想解决复合干扰识别问题。文献[6]对加性复合干扰进行建模, 提出基于残差网络的多标签分类模型 (ML-ResNet), 利用多标签技术来设计残差网络, 实现对加性复合干扰的分类。文献[7]将 4 种压制干扰进行两两卷积产生 6 种卷积复合干扰, 通过集成残差块和非对称卷积块, 解决特征退化问题并增强对细微特征的识别能力。以上研究所涉及的干扰均为单一干扰或单一复合干扰, 对于不同方式复合的干扰研究较少。

另外, 利用深度学习所进行的干扰识别问题往往需要利用大量的标签进行训练, 而在实际问题中可供训练的标签往往较难获得^[8]。针对该问题, 迁移学习将源域与目标域联系起来, 把从源域所学到的知识用于针对目标域的预测问题^[9], 可以有效解决目标域由于标签样本过少而产生训练效果不好的问题。但若源域与目标域的特征相差较大, 要寻找一个较好的特征表征方法来最小化域间差异。文献[10]针对训练样本采集量大、成本高的问题, 提出了一种基于神经网络的连体网络用于雷达干扰信号分类, 以解决训练样本有限

的问题。文献[11]利用迁移学习对雷达新型有源欺骗干扰进行研究, 针对小样本问题, 提出了一种基于加权集成卷积神经网络 (CNN) 和迁移学习的雷达有源欺骗干扰识别算法, 提高了模型的泛化性能。但目前所涉及的迁移学习只考虑了利用少量带标签样本对网络进行性能的改进, 而未带标签样本往往容易被忽略。

半监督学习可以利用带标签样本和不带标签样本共同来调整网络模型, 不带标签样本起到辅助作用来提高网络精确度。文献[12]利用不带标签样本, 基于 softmax 概率来迭代校正不带标签样本的预测标签, 实现更加精确的识别准确率。文献[13]提出一种新的半监督算法, 使用不确定性感知贝叶斯神经网络, 以尽量减少不带标签样本所造成的有害影响, 并提高了模型的泛化性能。但这些方法对于带标签样本和不带标签样本数量均有一定要求, 在样本数较少、仅有几个带标签样本时效果往往较差。

针对上述不足, 本文把半监督迁移学习运用到雷达复合干扰识别这一领域中, 考虑目前对多种复合方式的研究较少, 本文对加性、乘性、卷积 3 种复合方式所产生的复合干扰进行研究, 提出在小样本情况下雷达复合干扰半监督迁移学习的识别方法。采用深度宽残差网络作为特征提取的基网络, 对基类数据集进行预训练, 然后利用权重印记 (weight imprinting, WI)^[14]将支持集样本的平均特征嵌入分类器中, 得到一个更好的初始分类器, 以使得在基类数据集上所训练的模型更好地过渡到小数据集上。最后, 根据半监督学习利用带标签样本和不带标签样本对模型进行微调, 并提出最近邻相关性损失 (nearest neighbor correlation loss, NNCL) 函数来最优化网络模型, 得到更精确的识别结果。

1 系统模型

本节主要介绍雷达复合干扰的生成以及小样

本下半监督迁移学习的理论知识。

1.1 复合干扰信号生成

假设雷达的发射信号为线性调频信号，探测范围内有一个与雷达相距为 R 的目标，根据干扰的数学模型对欺骗和压制干扰进行生成，其中欺骗干扰包括距离欺骗 (range deception, RD) 干扰、距离-速度欺骗 (range-velocity deception, R-VD) 干扰、频谱弥散 (smeared spectrum, SMSP) 干扰；压制干扰包括噪声调幅 (amplitude modulation noise, AMN) 干扰、噪声调频 (frequency modulation noise, FMN) 干扰、梳状谱 (COMB) 干扰。

复合干扰是多个单一干扰信号的组合，一般的复合方式有加性、乘性和卷积，其中加性复合方式较为普遍，但乘性、卷积复合仍然是复合干扰的有效手段。本文重点研究欺骗干扰与压制干扰、压制干扰与压制干扰在这 3 种复合方式下得到的复合干扰识别，具体包括以下 12 种组合——RD-AMN、R-VD-AMN、SMSP-AMN、RD-FMN、R-VD-FMN、SMSP-AMN、RD-COMB、R-VD-COMB、SMSP-COMB、COMB-AMN、COMB-FMN、AMN-FMN 的加性、乘性和卷积复合，从

而可得 36 种复合干扰类型。

1.2 复合干扰信号预处理

在生成复合干扰信号之后对其进行时频变换，这里选用短时傅里叶变换 (short-time Fourier transform, STFT)，计算式为：

$$\text{STFT}(t, f) = \int j(\tau) g^*(\tau - t) e^{-j2\pi f \tau} d\tau \quad (1)$$

在训练集中选取 6 类单一干扰信号和回波信号的时频图如图 1 所示。

1.3 小样本下的半监督迁移学习思想

迁移学习可以通过预训练将在源域学到的知识迁移到目标域^[15]，因此可在基类数据集 D_{base} 上进行预训练，得到一个初始分类器并运用到新类数据集 D_{novel} 上。该过程能够提高新类数据集的泛化能力。

在实际环境下，有标签的样本获取较难，而无标签的样本获取较易，半监督学习可以利用带标签样本和不带标签样本对网络模型进行改善，更贴近真实情况。

本文根据迁移学习和半监督学习适用的范围，将迁移学习与半监督学习结合，提出在小样




图 1 干扰信号及回波信号的时频图



本下雷达复合干扰半监督迁移学习的识别方法。主要思想为：将单一干扰信号作为源域并进行预训练，把通过预训练得到的特征提取器和分类器迁移到复合干扰数据集（目标域）上，并在目标域进行半监督方式的微调操作。

2 半监督迁移学习的复合干扰识别方法

算法模型框架如图 2 所示，本文算法模型具体流程主要是：首先在带有标签的基类数据集上预训练一个基模型，该模型尽可能多地编码基类数据特征，以便后续在小样本数据集上提供先验信息，然后将其作为特征提取器对新的带有标签的支持集样本进行特征提取，初始化新类分类器的权值，为了减少特征的类内差异，本文采用 WI 的方法来生成分类器的权重，更好地初始化分类器。最后，引入半监督学习方法 MixMatch^[16]对分类器进行进一步的微调，并通过所提的 NNCL 函数来惩罚新类数据与基类数据在训练时所得分类器的差异性，利用未带标签数据来优化分类器的最终输出结果。

2.1 预训练特征提取

在基类数据集 D_{base} 上进行训练，得到一个基础网络模型，该模型尽可能多地编码 D_{base} 数据集

的特征信息，并且可为小样本学习后期提供先验信息。

2.2 权重印记法

由于基类数据集 D_{base} 与新类数据集 D_{novel} 存在一定差异，因此在 D_{base} 上预训练的网络模型不能直接用于 D_{novel} 上。为了解决这一问题，引入 WI 方法，更好地初始化分类器的权重，并且这也有利于分类器的微调。

WI 的原理为通过支持集中 N -way K -shot 样本的平均特征向量来设置分类器权重，其中特征是通过预训练阶段的模型而提取的。

在小样本学习中，通常用 N -way K -shot 来衡量其算法性能，即在 D_{novel} 数据集上抽取 N 类，每类采样 K 个样本，用 $\mathbf{x}_k^c$ 表示第 c 类第 k 个样本，则 $D_{\text{novel}} = \{\mathbf{x}_k^c | k=1, \dots, K, c=1, \dots, N\}$ ，用预训练阶段得到的特征提取器来提取 N -way K -shot 样本的特征，表示为 $f(\mathbf{x}_k^c)$ ，在得到 D_{novel} 上的特征之后，用印记的方法来生成分类器的权重，即：

$$\mathbf{w}_c = \frac{1}{K} \sum_{k=1}^K f(\mathbf{x}_k^c) \quad (2)$$

其中， $\mathbf{w}_c$ 为第 c 类所对应的分类器权重。

在得到每个类别的分类器权重之后，可以将 $\mathbf{w}_c$ 和特征向量 $\mathbf{x}$ 归一化到同一个单位球上，通过




图 2 算法模型框架

计算余弦距离的方式进行分类, 即:

$$f_{\text{novel}}(\mathbf{x}) = [\cos(\theta(\mathbf{w}_1, \mathbf{x})), \dots, \cos(\theta(\mathbf{w}_N, \mathbf{x}))]' \quad (3)$$

其中, $\theta(\mathbf{w}_i, \mathbf{x})$ 表示 $\mathbf{w}_i$ 和 $\mathbf{x}$ 之间的角度。对于给定样本 $\mathbf{x}$, 是基于计算每个 $\mathbf{w}_i$ 和 $\mathbf{x}$ 之间的余弦相似性, 并选择相似性最高的类别作为分类结果。

2.3 最近邻相关性损失函数

在基类数据集上预训练所得到的分类器与在新类上微调之后所得到的分类器应该较为相似, 因此二者的最优解也应较为相似。但由于新类数据集上带标签样本较少, 网络很难通过训练得到一个较好的分类器模型。可以将基类数据集上所得分类器迁移到新类数据集上, 并对其进行微调, 得到更优的新类分类器模型。当分类器最优时, 损失函数的梯度应该最小, 可通过求其梯度的最小值来求得分类器的最优解。基于该观点提出 NNCL 函数, 提高小数据集上分类器的泛化性。

假设大数据集用 D 表示, 小数据集用 S 表示, 在 D 上训练的最小化分类目标为^[17]:

$$\begin{aligned} \min_{\mathbf{w}, f} L_D(f, \mathbf{W}) &= \\ \min_{\mathbf{w}, f} \frac{1}{|D|} \sum_{(\mathbf{x}, y) \in D} L(\mathbf{W}, f(\mathbf{x}), y) &= \\ \min_{\mathbf{w}, f} \frac{1}{|D|} \sum_{(\mathbf{x}, y) \in D} -\log \frac{\exp(\mathbf{w}_y f(\mathbf{x}))}{\sum_{j=1}^N \exp(\mathbf{w}_j f(\mathbf{x}))} \end{aligned} \quad (4)$$

其中, $\mathbf{x}$ 表示样本, y 表示 $\mathbf{x}$ 对应的标签, f 和 $\mathbf{W}$ 分别表示在 D 上训练的特征提取器和分类器, $\mathbf{w}_j$ 表示第 j 列的分类器权重。

在 S 上训练的最小化分类目标为:

$$\begin{aligned} \min_{\mathbf{V}, f} L_S(f, \mathbf{V}) &= \\ \min_{\mathbf{V}, f} \frac{1}{|S|} \sum_{(\mathbf{x}, y) \in S} L(\mathbf{V}, f(\mathbf{x}), y) &= \\ \min_{\mathbf{V}, f} \frac{1}{|S|} \sum_{(\mathbf{x}, y) \in S} -\log \frac{\exp(\mathbf{v}_y f(\mathbf{x}))}{\sum_{j=1}^N \exp(\mathbf{v}_j f(\mathbf{x}))} \end{aligned} \quad (5)$$

其中, $\mathbf{V}$ 表示在 S 上训练的分类器。

要想将在 D 上训练的分类器更好的迁移到 S

上, 就需要式 (5) 的最小值与 $\mathbf{W}$ 相匹配, 即 $\mathbf{W}$ 最小化 $L_S(f, \mathbf{V})$ 。对于分类器 $\mathbf{V}$, 其损失函数 $L_S(f, \mathbf{V})$ 是凸函数, 则可以求其最优解, 最近邻相关性原理如图 3 所示, 而在最优解处梯度最小, 因此, 需要最小化式 (6):

$$\tilde{L}_S(f, \mathbf{W}) = \|\nabla_{\mathbf{V}} L_S(f, \tilde{\mathbf{V}})|_{\tilde{\mathbf{V}}=\mathbf{W}}\|^2 \quad (6)$$




图3 最近邻相关性原理

对于损失函数而言:

$$L_S(f, \mathbf{V}) = \frac{1}{|S|} \sum_{(\mathbf{x}, y) \in S} L(\mathbf{V}, f(\mathbf{x}), y) \quad (7)$$

$$L(\mathbf{V}, f(\mathbf{x}), y) = -\log p_y(\mathbf{V}, f(\mathbf{x})) \quad (8)$$

$$p_y(\mathbf{V}, f(\mathbf{x})) = \frac{\exp(\mathbf{v}_y f(\mathbf{x}))}{\sum_{j=1}^N \exp(\mathbf{v}_j f(\mathbf{x}))} \quad (9)$$

则 p_y 相对于 $\mathbf{v}_j$ 的梯度:

$$\begin{aligned} \nabla_{\mathbf{v}_j} p_y(\mathbf{V}, f(\mathbf{x})) &= \frac{\exp(\mathbf{v}_y f(\mathbf{x})) \delta_{yj} f(\mathbf{x})}{\sum_{j=1}^N \exp(\mathbf{v}_j f(\mathbf{x}))} - \\ &= \frac{\exp(\mathbf{v}_y f(\mathbf{x})) \exp(\mathbf{v}_j f(\mathbf{x})) f(\mathbf{x})}{\left(\sum_{j=1}^N \exp(\mathbf{v}_j f(\mathbf{x})) \right)^2} = \\ &= \left(p_y(\mathbf{V}, f(\mathbf{x})) \delta_{yj} - p_y(\mathbf{V}, f(\mathbf{x})) p_j(\mathbf{V}, f(\mathbf{x})) \right) f(\mathbf{x}) \end{aligned} \quad (10)$$

其中, $\delta_{yj} = \begin{cases} 1, & y = j \\ 0, & y \neq j \end{cases}$ 。

$L(\mathbf{V}, f(\mathbf{x}), y)$ 相对于 $\mathbf{v}_j$ 的梯度:



$$\begin{aligned} \nabla_{\mathbf{v}_j} L(\mathbf{V}, f(\mathbf{x}), y) &= -\frac{\nabla_{\mathbf{v}_j} p_y(\mathbf{V}, f(\mathbf{x}))}{p_y(\mathbf{V}, f(\mathbf{x}))} = \\ &= -\frac{(p_y(\mathbf{V}, f(\mathbf{x}))\delta_{yj} - p_y(\mathbf{V}, f(\mathbf{x}))p_j(\mathbf{V}, f(\mathbf{x})))f(\mathbf{x})}{p_y(\mathbf{V}, f(\mathbf{x}))} = \\ &= (p_j(\mathbf{V}, f(\mathbf{x})) - \delta_{yj})f(\mathbf{x}) \end{aligned} \quad (11)$$

$L_S(f, \mathbf{V})$ 相对于 $\mathbf{v}_j$ 的梯度:

$$\begin{aligned} \nabla_{\mathbf{v}_j} L_S(f, \mathbf{V}) &= \\ \frac{1}{|S|} \sum_{(\mathbf{x}, y) \in S} (p_j(\mathbf{V}, f(\mathbf{x})) - \delta_{yj})f(\mathbf{x}) \end{aligned} \quad (12)$$

$\mathbf{v}_j$ 代表第 j 列的分类器权重, 则共有 N 列权重, 可将 $\nabla_{\mathbf{V}} L_S(f, \mathbf{V})$ 写为:

$$\nabla_{\mathbf{V}} L_S(f, \mathbf{V}) = [h_1(f, \mathbf{V}), \dots, h_N(f, \mathbf{V})] \quad (13)$$

其中, $h_j(f, \mathbf{V}) = \frac{1}{|S|} \sum_{(\mathbf{x}, y) \in S} (p_j(\mathbf{V}, f(\mathbf{x})) - \delta_{yj})f(\mathbf{x})$ 。
则:

$$\begin{aligned} \tilde{L}_S(f, \mathbf{W}) &= \|\nabla_{\mathbf{V}} L_S(f, \tilde{\mathbf{V}})|_{\tilde{\mathbf{V}}=\mathbf{W}}\|^2 = \\ &= \|[h_1(f, \tilde{\mathbf{V}}), \dots, h_N(f, \tilde{\mathbf{V}})]\|^2 = \\ &= \frac{1}{|S|^2} \sum_{j=1}^N \left\| \sum_{(\mathbf{x}, y) \in S} (p_j(\mathbf{W}, f(\mathbf{x})) - \delta_{yj})f(\mathbf{x}) \right\|^2 = \\ &= \frac{1}{|S|^2} \alpha(\mathbf{W}, f(\mathbf{x}), y) \sum_{(\mathbf{x}, y) \in S} \|f(\mathbf{x})\|^2 \end{aligned} \quad (14)$$

其中, $\alpha(\mathbf{W}, f(\mathbf{x}), y) = \sum_{j=1}^N (p_j(\mathbf{W}, f(\mathbf{x})) - \delta_{yj})^2$ 。权重 α 越大, 说明该样本误分类的可能性越大, α 接近于 0 时, 则表示分类最接近真实标签。

2.4 半监督迁移学习

在通过 WI 得到充分吸收基类信息、初始化较好的分类器后, 利用不带标签样本的测试过程对该分类器进行微调。这个微调过程与半监督学习相同。这里选用 MixMatch 方法, 因为它是半监督学习领域利用不带标签样本的一种整体方法。在半监督学习中, 为了使模型具有更好的性能, 一般会在不带标签样本上加一个损失函数, 本文使用 NNCL 来代替 MixMatch 中原有的 l_2 损失。

MixMatch 在半监督学习方法基础上进行了

改进。在一个 batch-size 上, 令 $B = \{(\mathbf{x}_i, p_i)\}_{i=1}^B$ 表示 B 个带有标签 p_i 的样本, $U = \{\mathbf{x}_u\}_{u=1}^U$ 表示 U 个不带有标签的样本。可利用 WI 所得到的印记分类器来获得 U 中的估计标签, 记为 $f(\mathbf{x}_u)$ 。为了获得更好的鲁棒性, 在此将每个不带标签的样本扩充 M 个, 并且使用均值预测作为预测标签, 即:

$$\bar{p}_u = \frac{1}{M} \sum_{i=1}^M f(\mathbf{x}_u, i)$$

$$\text{预测结果: } p_u = \text{Sharpen}(\bar{p}_u, T) = p_u^{-\frac{1}{T}} / \sum_{j=1}^N (\bar{p}_u)_j^{\frac{1}{T}},$$

这里设置 T 表示温度参数。至此便得到未标签数据集 U 的预测标签。然后将 B 和 U 两个数据集进行混合并随机重排: $W = \text{Shuffle}(\text{Concat}(B, U))$, 再将 W 拆成两个新数据集: $\chi_1 = \{\text{MixUp}(B_i, W_i) | i \in 1, 2, \dots, B\}$ 、 $\chi_2 = \{\text{MixUp}(U_i, W_{i+B}) | i \in 1, 2, \dots, U\}$, 其中 MixUp 定义为:

$$\begin{aligned} \text{MixUp}((\mathbf{x}_1, p_1), (\mathbf{x}_2, p_2)) &= \\ ((\mu' \mathbf{x}_1 + (1 - \mu') \mathbf{x}_2, (\mu' p_1 + (1 - \mu') p_2)) \end{aligned} \quad (15)$$

其中, $\mu' = \max(\mu, 1 - \mu)$ 。 μ 是一个 0 到 1 之间的正数, 从 $\text{Beta}(\alpha, \alpha)$ 中随机生成。

最终最小化损失函数为:

$$l = l_1 + \lambda l_{\text{NNCL}} \quad (16)$$

其中, λ 为比例系数。

对数据集 χ_1 , 使用交叉熵 (cross-entropy) 损失, 即:

$$l_1 = \frac{1}{|\chi_1|} \sum_{(\mathbf{x}, y) \in \chi_1} (-\log p(f(\mathbf{x}))) \quad (17)$$

对数据集 χ_2 , 使用 NNCL, 即:

$$l_{\text{NNCL}} = \frac{1}{N \chi_2} \alpha(\mathbf{W}, f(\mathbf{x}), y) \sum_{(\mathbf{x}, y) \in \chi_2} \|f(\mathbf{x})\|^2 \quad (18)$$

而原本 MixMatch 中 l_2 损失为:

$$l_2 = \frac{1}{N \chi_2} \sum_{(\mathbf{x}, y) \in \chi_2} \|p_y(\mathbf{V}, f(\mathbf{x})) - f(\mathbf{x})\|^2 \quad (19)$$

2.5 深度宽残差网络

残差网络通过残差块的堆叠可以实现样本特征的有效提取, 并且其独特的残差结构, 可以较

好地克服网络过深而产生的梯度爆炸问题，但是过深的网络结构会导致特征丢失从而使提取到的特征利用率较低。为解决这个问题，宽残差网络（wide residual network, WRN）^[18]在残差网络（residual network）^[19]的基础上拓宽了网络的宽度，利用浅层的宽残差网络来代替深层的残差网络结构。残差结构如图 4 所示。




图 4 残差结构

图 4 中， x 表示输入， F 表示残差函数， $F(x)+x$ 表示输出。第 n 层与第 $n+1$ 层的关系可表示为：

$$x_{n+1} = x_n + F(x_n, w_n) \quad (20)$$

其中， w_n 为残差块参数， l 层到 L 层的学习过程可表示为：

$$x_L = x_l + \sum_{i=l}^{L-1} F(x_i, w_i) \quad (21)$$

由导数链式法则可求出损失函数的反向传播梯度为：

$$\begin{aligned} \frac{\partial \text{loss}}{\partial x_l} &= \frac{\partial \text{loss}}{\partial x_L} \cdot \frac{\partial x_L}{\partial x_l} = \\ \frac{\partial \text{loss}}{\partial x_L} [1 + \frac{\partial}{\partial x_l} \sum_{i=l}^{L-1} F(x_i, w_i)] \end{aligned} \quad (22)$$

由式 (22) 可知，由于表达式中有常数 1，所以无论梯度多么小，该层的梯度均不会消失，避免了网络较深时出现梯度爆炸问题。而宽残差网络的结构模型比普通残差网络更宽，故训练时获取的特征信息更加丰富，并且能防止特征丢失，更适合用于复合干扰时频图中由于回波远弱于干扰而回波显示不明显的情形。

本文使用 WRN-28-10^[20]来对基类数据集进行预训练，其中 28 表示卷积层总数，10 表示加宽因子，WRN-28-10 网络模型见表 1，并将网络分类器部分设置为全连接层。

表 1 WRN-28-10 网络模型

层名	输出维度	ResNet 块类型 $B(3,3)$
conv1	32×32	$[3 \times 3, 16]$
conv2	32×32	$\begin{bmatrix} 3 \times 3, 16 \times 10 \\ 3 \times 3, 16 \times 10 \end{bmatrix} \times 3$
conv3	16×16	$\begin{bmatrix} 3 \times 3, 32 \times 10 \\ 3 \times 3, 32 \times 10 \end{bmatrix} \times 4$
conv4	8×8	$\begin{bmatrix} 3 \times 3, 64 \times 10 \\ 3 \times 3, 64 \times 10 \end{bmatrix} \times 6$
avg-pool	1×1	$[8 \times 8]$

本文算法的训练伪代码如下。

输入 辅助训练集 D_{base} ， N -way K -shot 数据集 D_{novel}

随机初始化基网络 f 特征提取部分和分类器 W

for (x, y) in D_{base} do

提取特征 $f_{\text{base}}(f(x))$

end

for iterations in WI do

利用 $f(x)$ 来提取 D_{novel} 上的特征 f_{novel}

利用 $w_c = \frac{1}{K} \sum_{k=1}^K f(x_k^c)$ 来印记 $f_{\text{novel}}(f(x))$

的权重

end

数据集 $B = \{(x_i, p_i)\}_{i=1}^B$ 表示 B 个带有标签 p_i

的样本， $U = \{x_u\}_{u=1}^U$ 表示 U 个不带有标签的样本

for iterations in MixMatch do

for m from 1 to M do

对不带标签数据进行扩充：

$\hat{x}_{u,m} = \text{Augment}(x_u)$

end

根据 f_{novel} 得到未带标签样本的预测

标签： $\bar{p}_u = \frac{1}{M} \sum_{i=1}^M f(x_u, i)$

对预测标签进行锐化来增强预测结

果： $p_u = \text{Sharpen}(\bar{p}_u, T)$

将 B 和 U 两个数据集进行混合并随



机重排: $W = \text{Shuffle}(\text{Concat}(B, U))$

组成两个新数据集:

$$\chi_1 = \{\text{MixUp}(B_i, W_i) \mid i \in 1, 2, \dots, B\}$$

$$\chi_2 = \{\text{MixUp}(U_i, W_{i+B}) \mid i \in 1, 2, \dots, U\}$$

计算损失: $l = l_1 + \lambda l_{\text{NNCL}}$

更新网络参数 f_{novel}

end

输出 小数据集 N -way K -shot 分类器 f_{novel}

3 实验与分析

3.1 数据集与仿真参数设置

雷达接收信号包含 3 部分, 即真实目标回波、干扰信号和背景噪声, 具体的仿真参数设置见表 2。

表 2 仿真参数设置

信号参数	参数值
调制类型	LFM
脉宽/ μs	20
采样频率/MHz	40
RD 时延/ μs	2~4
SMSP 采样倍数	3~5
AMN/FMN 带宽/MHz	20~40
载频/MHz	20
信号带宽/MHz	10
脉冲重复间隔/ μs	100
欺骗速度/($\text{m}\cdot\text{s}^{-1}$)	100~300
COMB 谱个数	4~6
FMN 调频斜率/($\text{MHz}\cdot\text{V}^{-1}$)	2

对于预训练阶段的基类数据集, 使用仿真产生的 6 类单一干扰信号, 分别为距离欺骗 (RD)、距离-速度欺骗 (R-VD)、频谱弥散 (SMSP)、噪声调幅 (AMN)、噪声调频 (FMN)、梳状谱 (COMB)。每种干扰信号在干噪比 (JNR) 为 -16~10 dB, 每隔 2 dB 采样一次, 每个 JNR 下 500 个样本。

对于 WI 和半监督微调阶段, 根据 3 种复合方式, 将第 1.1 节得到 36 种复合干扰作为新类, 每类复合干扰信号转换成时频图, 利用神经网络对其进

行时频域特征的提取。在 JNR 为 -16~10 dB, 每隔 2 dB 采样一次, 每个 JNR 下 50 个样本。每次随机选择 K 个样本作为少数带标签样本, U 个样本作为不带标签样本, 其余再选择 Q 个样本作为测试样本。在实验中, 采用 N -way K -shot 来进行试验, 设定 $N=5$ 、 $K=1$ 或 5、 $Q=15$, 验证不同 U 值对实验结果的影响。在测试时, 重复测试 100 次, 并取其 95% 置信区间记录平均准确度。

本文所设计的标签是将 6 类单一干扰信号的标签与 36 类复合干扰信号的标签分开设计的, 即共有 42 类独立标签。先用 6 类单一干扰信号进行预训练, 得到初始网络模型, 再将得到的网络模型迁移到复合干扰数据集上, 将 36 类复合干扰信号作为新类数据集, 每次从中抽取 5 类 (即 5-way) 来对迁移过来的网络模型进行权重印记及微调操作。

另外, 初始学习率设置为 0.001, 每经过 10 个 epochs 学习率下降为原来的 0.1, 并使用 momentum 为 0.9 的随机梯度下降 (SGD) 优化器。对于微调阶段, 将 MixMatch 的参数设置如下: 将 M (扩增次数) 设置为 2, T (温度参数) 设置为 0.5, λ (损失函数的权重) 设为 5, α (Beta 分布中的参数) 设为 0.75。深度学习框架: Python 版本为 3.8.13, Pytorch 版本为 1.8.1。数据仿真部分通过 MATLAB 2021b 编程实现。实验平台为 Intel(R) Core(TM) i9-9900K CPU @ 3.60 GHz; GPU 采用 NVIDIA GeForce RTX 2080。

3.2 算法性能分析

3.2.1 未带标签样本数量不同时的对比试验

为探讨未带标签样本的数量对算法的影响, 在 JNR=0 dB 时, 设置不同数量的不带标签的样本进行试验, 未带标签样本数量不同时的识别准确率见表 3。可以看出, 随着未带标签样本数的增加, 识别结果逐渐改善, 但当每类未带标签样本数量到 20 时, 识别准确率逐渐稳定, 网络模型达到较好的识别能力。

表3 未带标签样本数量不同时的识别准确率

未带标签样本数	5-way 1-shot	5-way 5-shot
5	74.21%±0.77%	82.15%±0.86%
10	77.82%±0.75%	85.69%±0.78%
15	80.12%±0.61%	88.51%±0.72%
20	81.56%±0.46%	88.74%±0.53%
30	81.32%±0.39%	89.06%±0.32%

3.2.2 不同干噪比下识别效果对比试验

不同干噪比下识别准确率曲线如图5所示。在每类不带标签样本数为20时,对3种复合方式的干扰分别进行5-way 1-shot和5-way 5-shot的对比试验,如图5(a)、图5(b)所示。可以看出,随着JNR的增加,3种复合方式的干扰识别准确率均呈现增加趋势,其中在低JNR时卷积干扰识别准确率最低,加性干扰识别准确率最高。这是由于,在低JNR下,空间传输损耗较高,干扰信号受传输噪声的影响较为严重,通过加性、乘性和卷积之后,将这种损耗加大,其中通过卷积方式所得损耗最大,加性方式所得损耗相对较小。而在高JNR时,乘性干扰识别准确率最低,卷积干扰识别准确率最高。图5(c)中实线是将3种复合方式所产生的干扰信号混合在一起进行识别的结果,虚线为3种方式平均之后的识别准确率。可以看出对于混合后的识别准确率并不是将3种单一复合方式的识别准确率进行平均。在低JNR下,由于噪声扰动较大,对干扰信号影响较为严重,网络模型区分不出3种复合方式的明显特征,识别准确率低于平均水平;在高JNR下,3种复合方式所产生的干扰区分较为明显,网络模型能较好地地区分每种干扰类型,且保持在平均水平。

在3种复合方式中,加性复合最为常见。为了能够更加准确地观察到每类干扰具体的识别准确率,以加性干扰为例,在5-way 5-shot时,给出12种加性复合干扰的识别准确率结果,不同干噪比下加性复合干扰识别性能如图6所示。可以看出,在12种加性干扰中,AMN+FMN的识别准确率较低,但在JNR为6 dB时,网络模

型对于所有加性复合干扰的识别准确率均能达到90%以上。




图5 不同干噪比下识别准确率曲线

实际情况下,复合干扰中不同干扰分量的功率大小常不相同。以欺骗干扰与压制干扰的加性复合干扰为例,仿真分析了不同干扰分量在不同JNR下对识别性能的影响。JNR比值不同时的识别性能见表4,设定欺骗干扰与压制干扰的JNR




图6 不同干噪比下加性复合干扰识别性能

表4 JNR 比值不同时的识别性能

复合干扰类型	JNR 比值		
	1:1	1:5	1:10
RD+AMN	92.62%±0.51%	88.63%±0.61%	81.55%±0.32%
RD+FMN	92.07%±0.16%	88.33%±0.56%	81.16%±0.82%
SMSP+AMN	93.14%±0.35%	89.20%±0.24%	82.87%±0.48%
SMSP+FMN	93.67%±0.64%	89.52%±0.37%	82.64%±0.94%
R-VD+AMN	92.85%±0.72%	87.79%±0.58%	80.86%±0.16%
R-VD+FMN	92.04%±0.64%	87.06%±0.35%	81.21%±0.42%

比值分别为 1:1、1:5 和 1:10。可以看出随着 JNR 比值的增加, 识别准确率逐渐降低, 这是由于当压制干扰逐渐增强时会对欺骗干扰有所影响, 但由于本文利用单一干扰信号进行预训练, 在压制干扰较强时网络模型也能保持 80% 以上的识别准确率。

3.2.3 算法消融对比

本方法在从基类数据集预训练之后添加了 WI, 并在微调过程中将 NNCL 和半监督学习方法 MixMatch 相结合, 为了验证所提算法的有效性, 在预训练基础上, 将所有干扰种类混合, 复合干扰数据集设置 JNR=10 dB, 每类不带标签样本为 20 时, 分别进行对应的消融实验。消融实验对比见表 5。

表5 消融实验对比

方法	5-way 1-shot	5-way 5-shot
WI ^[14]	69.84%±0.86%	78.92%±0.62%
MixMatch ^[16]	64.62%±0.77%	81.65%±0.74%
MixMatch+NNCL	71.68%±0.79%	88.36%±0.48%
WI+MixMatch	77.63%±0.91%	89.86%±0.42%
WI+MixMatch+NNCL	84.31%±0.68%	93.20%±0.55%

从表 6 中可以看出, 本文所提算法比 WI 及半监督 MixMatch 方法均有较大提升。直接将 MixMatch 用于小样本设置中并不合适, 尤其在 1-shot 时, 这是由于缺乏带标签样本, 在测试期间难以微调分类器。然而, 本文所提算法通过 WI 模块可以获得一个较好的初始化, 从而提升识别准确率。而将 NNCL 与 MixMatch 相结合, 可以

较好地减少基类与新类数据的分类器差异,使之最大限度地匹配预训练的特征,也可以较好地提升模型识别准确率。而本文所提方法将 WI 与半监督学习相结合,并且利用 NNCL 来改进半监督学习,使之更加适合复合干扰的识别,识别准确率也有一定的提升。

固定 JNR 为 10 dB,每类不带标签样本数为 20,在 5-way 5-shot 下迭代 100 次进行试验,将本文损失函数 NNCL 与 MixMatch 原有的 l_2 损失函数进行对比,网络的训练损失和识别准确率如图 7 所示。可看出,本文所提的 NNCL 通过梯度下降找到最优梯度,并利用预训练所达到的较好的分类器作为初始分类器,通过未带标签样本对其进行微调,使结果较为稳定,经过 60 次左右迭代,

就能达到较好的状态,最终识别准确率趋于 93.20%。而原有的 l_2 损失函数只是寻找了新类分类器的最小值,并没有利用梯度下降来将最小值与预训练分类器进行匹配,因此损失函数波动较明显,网络模型的稳定性没有所提算法高。

3.2.4 不同算法性能对比

为了进一步验证本文所提算法的优越性,另选 3 种有代表性的相关算法进行对比,其中文献[21]介绍了一种迁移学习微调(Fine-tuning)算法,与本文利用半监督学习方式微调进行对比;文献[22]介绍了一种 Pseudo-Labeling 半监督学习,与本文 MixMatch 半监督学习进行对比;文献[23]介绍了一种 Baseline++的小样本学习方法,与本文算法进行对比,看本文算法是否更适合小样本

表 6 不同算法性能对比

算法模型	特征提取网络	5-way 1-shot	5-way 5-shot
Fine-tuning ^[21]	ResNet 34	54.41%±0.89%	63.09%±0.72%
	WRN-28-10	58.63%±0.75%	66.21%±0.69%
Pseudo-Labeling ^[22]	ResNet 34	73.33%±0.96%	84.30%±0.91%
	WRN-28-10	75.16%±0.63%	85.21%±0.80%
Baseline++ ^[23]	ResNet 34	67.54%±0.82%	74.68%±0.89%
	WRN-28-10	69.66%±0.74%	75.54%±0.52%
本文算法	ResNet 34	82.75%±0.71%	91.02%±0.65%
	WRN-28-10	84.31%±0.68%	93.20%±0.55%




图 7 训练损失及识别准确率



情形。另外,文献[21-23]中网络模型均为残差网络,为公平起见,在实验时均使用 ResNet34 和 WRN-28-10 网络进行特征的提取。在 JNR=10dB, 每类不带标签样本为 20 时,不同算法性能对比见表 6。可看出,本文所提算法在 5-way 1-shot 和 5-way 5-shot 时都有较好的识别效果;另外,本文所使用的特征提取网络 WRN-28-10 相较普通残差网络结构更宽,使识别效果有一定的提升。在文献[21]基于迁移学习的 Fine-tuning 中,直接在预训练模型上进行微调,使得网络产生负迁移现象,而且复合干扰样本数较少会加重这种现象,效果最差,用 WRN-28-10 网络进行特征充分提取并运用之后,会轻微改善这种现象。为了探讨本文所用半监督方式的优势,将半监督方式替换为 Pseudo-Labeling^[22],即利用伪标签技术得到与标签置信度较高的样本之后再行训练,可以看出这种算法也会取得较好的效果。但在未带标签量只有 20 时,本文算法明显优于文献[22]算法,这是因为伪标签技术在不带标签样本较少时筛选出来的置信度高的样本也较少,对模型改进不如本文半监督方式。为了证明本文算法较适用于小样本情况,与文献[23]所提算法 Baseline++进行对比,该算法利用预训练之后的网络将支持集与查询集数据进行度量学习,但由于样本数的限制,网络模型很难找到一个较好的度量空间,导致识别准确率较低。本文算法克服了这种缺点,利用少数带标签样本进行特征权重印记,之后再利用带标签样本和不带标签样本进行微调训练,使网络的初始状态更符合所识别的特征,可以进一步提高识别准确率。

3.2.5 不同算法时效性对比

为了验证算法的时效性,将本文算法与文献[21-23]方法进行时效性对比,记录各个方法中模型训练、样本测试所用的时间。在试验时均使用 WRN-28-10 网络作为基网络。当 JNR=10 dB,

每类未带标签样本为 20,采用 5-way 5-shot,不同算法时效性对比见表 7。其中,为了比较不同模型的训练及测试时间,将每种模型迭代 100 次,记录每次训练平均耗时时间,测试时间为单次平均识别时间。

表 7 不同算法时效性对比

算法模型	单次训练 平均时间/s	单次识别 平均时间/s
Fine-tuning ^[21]	0.330	0.208
Pseudo-Labeling ^[22]	0.289	0.126
Baseline++ ^[23]	0.355	0.061
本文算法	0.409	0.059

由表 7 可看出,本文算法训练时间比其他 3 种算法略高,这是由于本文算法引入了半监督学习,会对比算法多进行一步微调操作。另外,本文算法的单次识别时间最短,其原因在于测试阶段不需要进行半监督操作,体现了更优的算法时效性。

4 结束语

针对在小样本下雷达复合干扰信号的识别问题,本文提出了基于半监督迁移学习的算法,通过将单一欺骗干扰和压制干扰进行加性、乘性、卷积方式复合,仿真生成 36 种不同类型的复合干扰,对各种干扰进行时频域的变换来产生仿真数据集。将单一干扰作为基类进行预训练,得到预训练网络模型,利用少量带标签的复合干扰样本进行权值印记,使网络有一个较好的初始化模型,利用半监督方式将带标签和不带标签的数据进行再次微调,并且引入 NNCL 损失函数,将不带标签数据与已训练的网络模型进行最大化匹配,使之更准确地识别出测试样本。通过仿真验证了本文所提算法的可行性以及相较其他算法在同样较少样本下的性能优势,且模型泛化性较高。

参考文献:

- [1] ADAMY D. EW101: 电子战基础[M]. 王燕, 朱松, 译. 北京: 电子工业出版社, 2009.
ADAMY D. EW101: fundamentals of electronic warfare[M]. Translated by WANG Y, ZHU S. Beijing: Publishing House of Electronics Industry, 2009.
- [2] 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.
ZHOU H P, WANG Z W, GUO Z Y. Overview on recognition algorithms of radar active jamming[J]. Journal of Data Acquisition and Processing, 2022, 37(1): 1-20.
- [3] FU R R. Compound jamming signal recognition based on neural networks[C]//Proceedings of the Sixth International Conference on Instrumentation & Measurement, Computer, Communication and Control (IMCCC). Piscataway: IEEE Press, 2016: 737-740.
- [4] ZHU M, LI Y, PAN Z, et al. Automatic modulation recognition of compound signals using a deep multi-label classifier: a case study with radar jamming signals[J]. Signal Processing, 2019, 169(9): 107393.
- [5] ZHANG J X, LIANG Z N, ZHOU C, et al. Radar compound jamming cognition based on a deep object detection network[J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59(3): 3251-3263.
- [6] 李浩. 基于多标签学习的雷达复合干扰识别研究[D]. 成都: 电子科技大学, 2021.
LI H. Radar compound jamming recognition based on multi-label learning[D]. Chengdu: University of Electronic Science and Technology, 2021.
- [7] QU Q, WEI S, LIU S, et al. JRNet: jamming recognition networks for radar compound suppression jamming signals[J]. IEEE Transactions on Vehicular Technology, 2020, 69(12): 15035-15045.
- [8] 庞伊琼, 许华, 张悦, 等. 基于迁移元学习的调制识别算法[J]. 兵工学报, 2022. doi: 10.12382/bgxb.2022.0583.
PANG Y Q, XU H, ZHANG Y, et al. Modulation recognition algorithm based on transfer meta-learning[J]. Acta Armamentarii, 2022. doi: 10.12382/bgxb.2022.0583.
- [9] 季鼎承, 蒋亦樟, 王士同. 基于域与样例平衡的多源迁移学习方法[J]. 电子学报, 2019, 47(3): 692-699.
JI D C, JIANG Y Z, WANG S T. Multi-source transfer learning method by balancing both the do-mains and instances[J]. Acta Electronica Sinica, 2019, 47(3): 692-699.
- [10] SHAO G, CHEN Y, WEI Y. Convolutional neural network-based radar jamming signal classification with sufficient and limited samples[J]. IEEE Access, 2020(8): 80588-80598.
- [11] 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.
- [12] CHUNG H, LEE J. Iterative semi-supervised learning using softmax probability[J]. Materials & Continua, 2022, 72(3): 5607-5628.
- [13] BAE J, LEE M, KIM S B. Safe semi-supervised learning using a bayesian neural network[J]. Information Sciences, 2022, 6(12): 453-464.
- [14] PASSALIS N, IOSIFIDIS A, GABBOUJ M, et al. Hyper-sphere-based weight imprinting for few-shot learning on embedded devices[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(2): 925 -930.
- [15] ZHUANG F, QI Z, DUAN K, et al. A comprehensive survey on transfer learning[J]. Proceedings of the IEEE, 2020, 109(1): 43-76.
- [16] BERTHELOT D, CARLINI N, GOODFELLOW I, et al. Mix-Match: a holistic approach to semi-supervised learning[J]. Advances in Neural Information Processing Systems, 2019, 32(454): 5050-5060.
- [17] LI P, ZHAO G, XU X. Coarse-to-fine few-shot classification with deep metric learning[J]. Information Sciences, 2022(610): 592-604.
- [18] QIAO S Y, LIU C X, SHEN W, et al. Few-shot image recognition by predicting parameters from activations[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway: IEEE Press, 2018: 7229-7238.
- [19] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway: IEEE Press 2016: 770-778.
- [20] HAFIZ A M, BHAT R A, HASSABALLAH M. Image classification using convolutional neural network tree ensembles[J]. Multimedia Tools and Applications, 2023, 82(5): 6867-6884.
- [21] LI T W, LEE G C. Performance analysis of fine-tune transferred deep learning[C]//Proceedings of the 2021 3rd Eurasia Conference on Communication and Engineering. Piscataway: IEEE Press, 2021: 315 -319.
- [22] HIGUCHI Y, MORITZ N, ROUX J L, et al. Momentum pseudo-labeling: semi-supervised ASR with continuously improving pseudo-labels[J]. IEEE Journal of Selected Topics in Signal



Processing, 2022, 16(6): 1424 -1438.

- [23] CHEN W Y, LIU Y C, KIRA Z, et al. A closer look at few-shot classification[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2019: 1904. 04232.

[作者简介]



王金强（1998- ），男，杭州电子科技大学硕士生，主要研究方向为雷达信号处理及抗干扰。



唐向宏（1962- ），男，博士，杭州电子科技大学教授、博士生导师，主要研究方向为图像处理与传输、通信与信息系统、信息安全。



仇兆炀（1987- ），男，博士，杭州电子科技大学讲师、硕士生导师，主要研究方向为信号采样、复杂信号处理和宽带接收。



孙闽红（1974- ），男，博士，杭州电子科技大学教授、博士生导师，主要研究方向为信号处理、信息对抗、雷达系统与成像技术。



曾德国（1985- ），男，博士，中国航天科工集团八五一一研究所研究员，主要研究方向为信号识别与新型接收机结构。