

## 小样本SAR目标的双重一致性因果识别方法

王陈炜 罗思懿 黄钰林\* 裴季方 张寅 杨建宇

(电子科技大学信息与通信工程学院 成都 611731)

**摘要:** 在小样本条件下提升方法的泛化性能, 是合成孔径雷达自动目标识别(SAR ATR)的重要研究方向。针对该方向中的基础理论问题, 该文建立了一个SAR ATR因果模型, 证明了SAR图像中背景、相干斑等干扰在充足样本条件下可以被忽略; 但在小样本条件下, 这些因素将成为识别中的混杂因子, 在提取的SAR图像特征中引入虚假相关性, 影响SAR ATR性能。为了甄别和消除这些特征中的虚假效应, 该文提出一个基于双重一致性的小样本SAR ATR方法, 其中双重一致性包括类内一致性掩码和效应一致性损失。首先, 基于鉴别特征应具有类内一致和类间差异的原则, 利用类内一致性掩码, 捕获目标的类内一致鉴别特征, 甄别出目标特征中的混淆部分, 准确估计出干扰引入的虚假效应。其次, 基于不变风险最小化的思想, 利用效应一致性损失, 将经验风险最小化数据量需求转变为对效应相似度的度量需求, 降低虚假效应消除对数据量的需求, 消除特征中的虚假效应。因而, 所提基于双重一致性的小样本SAR ATR方法可实现特征提取中的真实因果, 实现准确的识别性能。两个基准数据集上的识别实验, 验证了该方法的合理性和有效性, 可提升小样本条件下SAR目标识别的性能。

**关键词:** 合成孔径雷达; 自动目标识别; 小样本; 因果推断

中图分类号: TN958

文献标识码: A

文章编号: 1009-5896(2024)10-3928-08

DOI: [10.11999/JEIT240140](https://doi.org/10.11999/JEIT240140)

## A Causal Interventional SAR ATR Method with Limited Data via Dual Consistency

WANG Chenwei LUO Siyi HUANG Yulin PEI Jifang  
ZHANG Yin YANG Jianyu

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

**Abstract:** Improving the generalization performance of methods under limited sample conditions is an important research direction in Synthetic Aperture Radar Automatic Target Recognition (SAR ATR). Addressing the fundamental problem in this field, a causal model is established in this paper for SAR ATR, demonstrating that interferences in SAR images, such as background and speckle, can be neglected under sufficient sample conditions. However, under limited sample conditions, these factors become confounding variables, introducing spurious correlations into the extracted SAR image features and affecting the generalization of SAR ATR. To accurately identify and eliminate these spurious effects in the features, this paper proposes a limited-sample SAR ATR method via dual consistency, which includes an intra-class feature consistency mask and effect-consistency loss. Firstly, based on the principle that discriminative features should have intra-class consistency and inter-class differences, the intra-class feature consistency mask is used to capture the consistent discriminative features of the target, subtracting the confounded part in the target features, and identifying the spurious effects introduced by interferences. Secondly, based on the idea of invariant risk minimization, the effect-consistency loss transforms the data requirement of empirical risk minimization into a need for labeling the similarity among effects of different samples, reducing the data demand for eliminating spurious effects and removing the spurious effects in the features. Thus, the limited-sample SAR ATR method proposed in this paper achieves true causal feature extraction and accurate recognition performance. Experiments on two benchmark datasets validate the effectiveness of this method which can achieve superior performance of SAR target recognition with limited sample.

收稿日期: 2024-03-06; 改回日期: 2024-08-28; 网络出版: 2024-09-01

\*通信作者: 黄钰林 [yulinhuang@uestc.edu.cn](mailto:yulinhuang@uestc.edu.cn)

基金项目: 四川省自然科学基金 (2023NSFSC1970)

Foundation Item: The Natural Science Foundation of Sichuan Province (2023NSFSC1970)

**Key words:** Synthetic Aperture Radar (SAR); Automatic target recognition; Limited data; Causal inference

### 1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)是一种重要的微波传感器,被广泛应用于各种民用和军事领域中,且不易受时间或天气条件影响,提供高分辨率的图像<sup>[1]</sup>。自动目标识别(Automatic Target Recognition, ATR)是SAR的关键应用,并已经发展了半个世纪。在过去十年中,由于深度学习技术的推动,SAR ATR的研究已经取得了丰富的成果<sup>[2-5]</sup>。

现有的SAR ATR深度学习方法通常需要大量地标注训练样本。然而,对于大多数SAR应用场景来说,收集和标注充足的SAR样本往往需要消耗较高的资源和成本。当面临有限的SAR训练数据,现有ATR方法的性能会急剧下降。近年来,这个问题在研究中受到了广泛的关注,被称为小样本条件下的SAR ATR<sup>[6-9]</sup>。其主要类型包括数据增强和专用模块设计并已经在有限的训练数据下提高了识别性能。尽管这个研究方向正在蓬勃发展,但小样本下识别性能差的原因仍然需要深入研究。例如,小样本在SAR ATR中到底引起了什么问题,导致SAR ATR方法的识别性能差?

本文基于因果推断理论<sup>[10]</sup>,发现提高小样本条件下SAR ATR识别性能的关键之一在于构建一个能够实现SAR图像 $I$ 与目标特征 $X$ 之间真实因果关系的特征提取模型。在充足的SAR图像条件下,模型可有效地估计干扰因子 $N$ 所引入的虚假效应影响,消除 $N$ 所引入的虚假效应影响,如图1(a)。然而,在小样本条件下,SAR ATR模型难以准确估

计 $N$ 所引入的虚假效应影响,无法消除 $N$ 所引入的虚假效应影响<sup>[11]</sup>,如图1(b)所示。

既然如此,为了提高小样本条件下SAR ATR的识别性能,是否可以通过消除前门路径 $I \rightarrow N \rightarrow X$ ,直接追求 $I$ 与 $X$ 之间的真实因果关系,即仅 $I \rightarrow A \rightarrow X$ ?在因果推论中,可利用反事实<sup>[12]</sup>来估计 $I \rightarrow N \rightarrow X \rightarrow Y$ 的虚假效应,再从 $I \rightarrow Y$ 的整体效应中减去所估计的虚假效应,即可实现 $I \rightarrow A \rightarrow X$ 的真实因果关系。然而,在SAR ATR中,由于以下两个问题,很难直接使用反事实精确地估计 $I \rightarrow N \rightarrow X \rightarrow Y$ 的虚假效应:(1)  $N$ 与 $A$ 的相互混淆:由于 $N$ 和 $A$ 都是 $I$ 的两条前门路径的中间因子, $N$ 与 $A$ 之间存在相互混淆的问题。同时,在SAR图像中存在相干斑、阴影等干扰,在小样本条件下,这些干扰也会影响目标鉴别信息的定位与提取。(2) 小样本条件下的经验风险最小化(Experience Risk Minimization, ERM)的限制:大多数识别方法的优化损失都基于ERM,需要大量的SAR数据才能有效,在小样本条件下有效性受限。

因此,为了克服上述难点,本文为SAR ATR提出了一种通过双重一致性在小样本条件下估计并消除 $I \rightarrow N \rightarrow X \rightarrow Y$ 虚假效应的因果特征提取方法。双重一致性包括一个用于精确估计 $I \rightarrow N \rightarrow X \rightarrow Y$ 效应的类内一致性掩码,和一个用于有效消除 $I \rightarrow N \rightarrow X \rightarrow Y$ 效应的环境一致性损失。因此,本文方法的创新点可以概括如下:

(1) 从结构因果模型(Structural Causal Model, SCM)开始,分析和解释小样本条件导致SAR ATR

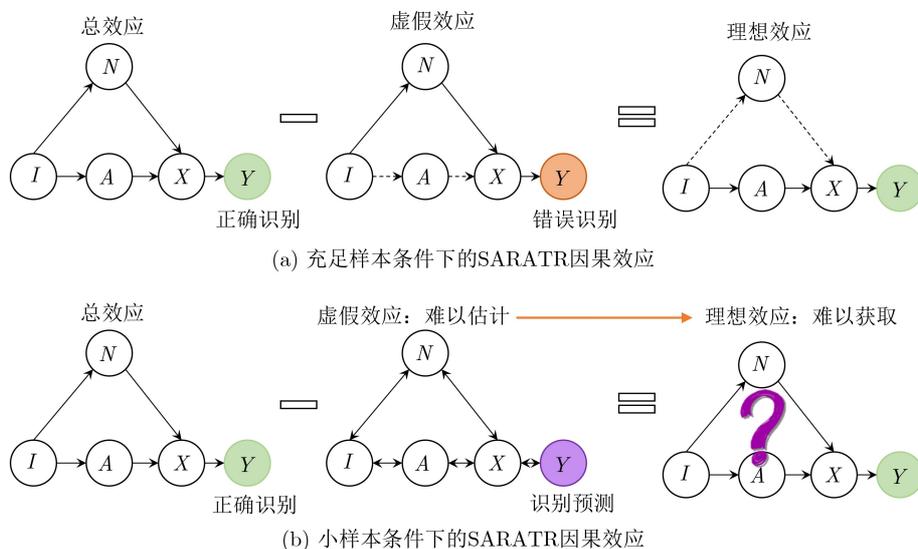


图1 有限SAR样本在ATR中引入的因果效应变化

性能差的关键问题。提出的SCM也可为提高小样本条件下的ATR模型的泛化能力提供有效的解决方案。

(2) 提出了包含类内特征一致性和效应一致性损失的双重一致性。在小样本条件下, 类内特征一致性通过计算每个样本正反掩码的类内一致性度量来解决 $N$ 和 $A$ 的混淆。效应一致性损失降低了有效消除干扰效应的数据量需求, 从而有效地消除了 $I \rightarrow N \rightarrow X \rightarrow Y$ 的干扰效应。

(3) 在小样本条件下, 本文方法在MSTAR和OpenSARship数据集上达到了较好的识别性能。并与其他针对小样本的方法进行对比, 验证了本文方法的有效性。

本文的其余部分按以下方式组织: 第2章中详细地给出了本文所提出的方法框架及细节。第3章中设计了实验, 验证了本文方法的有效性。第5章给出结论。

## 2 方法介绍

正如前文所述, 由于 $N$ 引入了假的相关性,  $X$ 同时包含了干扰因子 $N$ 和目标区域 $A$ 的信息, 通过 $X$ 预测的目标类型 $Y$ 同样会被 $N$ 所引入的虚假相关性影响, 导致在小样本条件下SAR ATR识别性能差。本节提出了一个使用双重一致性的因果解决方案, 估计 $I \rightarrow N \rightarrow X \rightarrow Y$ 效应, 并消除 $I \rightarrow N \rightarrow X \rightarrow Y$ 效应, 从而提高在小样本条件下SAR ATR的识别性能。接下来, 将详细描述双重一致性方法, 解释它如何准确估计并有效消除 $N$ 的影响。

### 2.1 整体框架

为了实现小样本条件下的准确识别, 本文提出包括类内一致性掩码和效应一致性损失的双重一致性, 来解决上文中实现 $I \rightarrow A \rightarrow X \rightarrow Y$ 间真实因果的两个问题: (1) $N$ 与 $A$ 的相互混淆; (2)小样本条件下ERM限制。类内一致性掩码利用特征类内不变的约束, 分辨 $N$ 和 $A$ 的效应, 估计 $N$ 引入的虚

假效应。效应一致性损失利用不变风险最小化准则, 降低优化过程中的数据量需求, 消除 $N$ 引入的虚假效应, 实现 $I \rightarrow A \rightarrow X \rightarrow Y$ 间的真实因果, 总体框架如图2所示。

首先, 本节构建一个基本的SAR ATR模型, 完成基本的识别, 并获取当前模型所关注的SAR图像区域。其次, 类内一致性掩码利用特征类内不变的约束, 针对每个样本, 利用类属和反转类属掩码分离 $N$ 和 $A$ 的效应, 利用类内一致性鉴别 $N$ 和 $A$ , 以解决 $N$ 和 $A$ 的混淆。最后, 效应一致性损失利用每个样本的类属掩码作为效应类型的标注, 将SAR图像按效应划分到不同效应相似度的子集中。接下来, 效应一致性损失确保各个类别特征的分布在不同子集中保持一致, 从而消除 $I \rightarrow N \rightarrow X \rightarrow Y$ 的干扰效应, 以实现 $I \rightarrow A \rightarrow X \rightarrow Y$ 的真实因果。

本文方法可用数学方式描述为: 给定一个类别为 $y_i$ 的SAR图像 $x_i$ , 通过基本的SAR ATR模型, 得到不同SAR图像的输出特征图 $\mathbf{M}(x_i) \in \mathbb{R}^{h \times w \times c}$ , 以及类别预测 $p(y = j | x_i)$ , 代表样本 $x_i$ 被分类为第 $j$ 类的概率, 并计算基本的识别损失 $L_r$ 。

然后, 类内一致性掩码利用预测 $p(y = j | x_i)$ 和特征图 $\mathbf{M}(x_i)$ , 并将当前模型关注的图像特征 $x_i^f$ , 作为类属掩码的初始化, 计算效应分离损失 $L_{es}$ 和效应鉴别损失 $L_{ed}$ , 优化类属掩码对 $N$ 和 $A$ 效应的分离和鉴别。

其次, 效应一致性损失利用优化后的类属掩码作为模型所获取的每类所有样本 $A$ 效应的标注, 度量 $A$ 效应之间的相似度, 并且根据所获得的相似度, 生成多个不同效应相似度的子集, 计算各个类别特征在不同子集中的分布, 得出效应一致性损失 $L_{ec}$ , 优化SAR ATR模型, 消除 $N$ 所引入的干扰效应。因此, 最终的损失计算为

$$L = L_r + L_{es} + L_{ed} + L_{ec} \quad (1)$$

本文模型通过基于损失 $L$ 计算梯度进行反向传

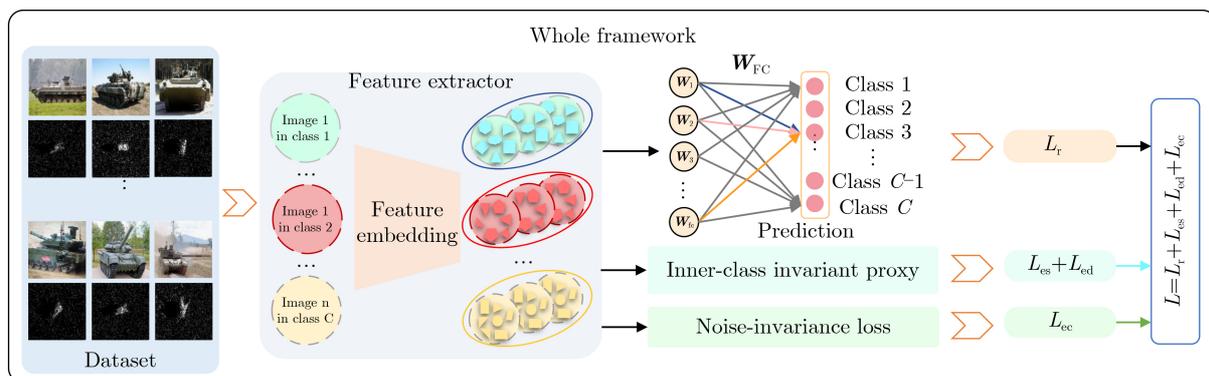


图2 本文方法的总体框架

播来更新。通过上述过程和优化目标,该模型在小样本条件下,准确地鉴别 $N$ 和 $A$ 的效应,消除 $N$ 所引入的虚假效应,获得 $I \rightarrow A \rightarrow X \rightarrow Y$ 的真实因果,以实现SAR图像的准确识别。

## 2.2 双重一致性

本节介绍所提出的双重一致性,其由类内特征一致性损失和效应一致性损失组成。本节展示类内一致性损失如何帮助模型准确分辨 $N$ 的效应,并且,解释效应一致性损失如何将降低干扰效应对数据量的需求,以有效地消除 $N$ 所引入的虚假效应。

### 2.2.1 类内特征一致性损失

为了在小样本条件下准确分辨 $N$ 和 $A$ 的效应,本文提出类内特征一致性损失,首先通过当前的识别结果,获取到SAR识别模型在完成识别时关注的SAR图像区域,二值化作为类属特征掩码的初始化。其次,类内特征一致性损失将类属特征掩码取反,得到反转类属掩码,利用特征的类内不变性,确保来自同一类别的类属掩码对应 $A$ 的效应,而反转类属掩码则可以对应 $N$ 的效应,实现 $N/A$ 效应的准确分离。

类内特征一致性损失主要分3步,类属特征掩码初始化, $N/A$ 效应掩码分离, $N/A$ 效应一致性鉴别损失。

给定输入的SAR图像 $\mathbf{x}_i$ ,其类别为 $y_i$ ,以及分类器前的特征图 $\mathbf{M}(\mathbf{x}_i) = \{\mathbf{M}_1(\mathbf{x}_i), \mathbf{M}_2(\mathbf{x}_i), \dots, \mathbf{M}_c(\mathbf{x}_i)\} \in \mathbb{R}^{c \times h \times w}$ 。

第1步,类属特征掩码初始化。特征图 $\mathbf{M}(\mathbf{x}_i)$ 经过全局平均池化,得到 $\mathbf{F}(\mathbf{x}_i) \in \mathbb{R}^{1 \times 1 \times c}$ ,而分类器的输出通过一个SoftMax得到 $x_i$ 的类别上的最终预测 $\mathbf{p}_i \in \mathbb{R}^{1 \times K}$ , $\mathbf{p}_i$ 被用来选择全连接层的相应权重 $\mathbf{W}_i$ ,其公式如下

$$\mathbf{W}_i = \mathbf{W}_{\text{FC}}[\text{argmax}(\mathbf{p}_i)] = [w_1, w_2, \dots, w_c] \quad (2)$$

其中, $[\text{argmax}(\cdot)]$ 是最大值的对应索引, $K$ 是目标的类别数, $w_1, w_2, \dots, w_c$ 是分类器的权重参数。因此,类属掩码的初始化为

$$\mathbf{m}(\mathbf{x}_i) = \text{resize} \left( \sum_{j=1}^c w_j \mathbf{M}_j(\mathbf{x}_i) \right) \quad (3)$$

其中, $\text{resize}(\cdot)$ 通过使用双线性插值,将这些局部特征调整为输入图像 $\mathbf{x}_i$ 的大小。

第2步, $N/A$ 效应掩码分离。首先,对于输入的SAR图像 $\mathbf{x}_i$ ,将初始化的类属掩码放缩至 $[0,1]$ 的范围,并对其取反,获得反转掩码 $\bar{\mathbf{m}} = \mathbf{1} - \mathbf{m}$ 。在初始化的类属掩码和反转类属掩码中,对于所有输入的图像 $\{\mathbf{x}_1^1, \mathbf{x}_1^2, \dots, \mathbf{x}_K^N\} \in \mathbb{R}^{K \times N \times H \times W}$ ,其中 $K$ 个类别和每个类别有 $N$ 个样本,并且类属和反转

类属掩码相似度采用余弦相似度。此步骤希望获得每类的类属掩码是 $A$ 所对应的类内不变特征,而所有类的反转类属掩码是 $N$ 效应所对应的虚假效应。因此, $N/A$ 效应分离损失可以计算为

$$L_{\text{es}} = - \sum_k^K \sum_n^N \exp(\text{sim}(\mathbf{m}(\mathbf{x}_k^n), \bar{\mathbf{m}}(\mathbf{x}_k^n))) \quad (4)$$

由此,类内特征一致性损失通过优化 $N/A$ 效应分离损失,以确保来自同一类别的类属掩码对应 $A$ 的效应,而反转类属掩码则可以对应 $N$ 的效应,实现 $N/A$ 效应的准确分离。

第3步, $N/A$ 效应一致性鉴别。这一步旨在通过保证类内掩码的一致性、不同类的类内掩码的分离性和不同类的反转类内掩码的相近性,将 $A$ 的效应与类内掩码对应, $N$ 的虚假效应与反转类内掩码对应,从而实现 $N$ 效应的准确鉴别,因此, $N/A$ 效应一致性鉴别损失 $L_{\text{ed}}$ 可以按以下方式计算

$$L_{\text{ed}} = - \sum_k^K \frac{\sum_{i \neq j, y_i = y_j, j=1,2,\dots,N} \exp(\text{sim}(\mathbf{m}(\mathbf{x}_i), \mathbf{m}(\mathbf{x}_j)))}{\sum_{i=j, j=1,2,\dots,N} \exp(\text{sim}(\mathbf{m}(\mathbf{x}_i), \mathbf{m}(\mathbf{x}_j)))} + \sum_k^K \left( \sum_{i=j, j=1,\dots,N} \exp(\text{sim}(\bar{\mathbf{m}}(\mathbf{x}_i), \bar{\mathbf{m}}(\mathbf{x}_j))) \right) \quad (5)$$

这样, $N/A$ 效应一致性鉴别损失可以实现对每个样本中 $N$ 效应的准确鉴别。

类内特征一致性损失的目的是在利用特征类内不变性,对 $N/A$ 效应进行准确的分辨。虽然类内特征一致性损失完成了 $N$ 效应的准确鉴别,但由于小样本的约束, $N$ 效应很难通过常规的ERM来消除。因此,本文设计了效应一致性损失,来消除 $N$ 所引入的虚假效应。

### 2.2.2 效应一致性损失

上一节已经完成了对 $N$ 所引入效应的估计,但现有的大多数优化目标是基于ERM的,这需要大量的SAR数据,在小样本条件下其有效性降低。因此,基于IRM的思想,本节提出了效应一致性损失,将每个类单独设置为一个主类别,进行不同样本之间效应相似度的度量,生成多个不同效应相似度的子集,最后计算效应不变性损失。效应一致性损失通过度量虚假效应,约束不同类特征在不同的虚假效应情况下保持分布一致,从而使得特征与虚假效应正交,可将ERM对数据量的需求转化为对效应相似度的需求,缓解优化过程对数据量的需求,消除 $N$ 的虚假效应。具体的流程可以总结如下。

步骤1 虚拟效应度量。将第 $k$ 类设为主类别, 对于不属于第 $k$ 类的样本, 特征 $\mathbf{f}$ 与主类别的类内不变特征之间的效应相似度 $d_v(\mathbf{f}, \mathbf{P}_k)$ 表示为

$$d_v(\mathbf{f}, \mathbf{P}_k) = \left( \frac{\mathbf{f}}{\|\mathbf{f}\|_2} - \frac{\mathbf{P}_k}{\|\mathbf{P}_k\|_2} \right) \odot \mathbf{P}_k \quad (6)$$

其中,  $\mathbf{P}_k = \frac{1}{N} \sum_n^N \mathbf{m}(\mathbf{x}_k^n)$ 。

据此, 通过计算不属于主类别的特征集 $D_{-k}$ 和 $\mathbf{P}_k$ 之间的相似度, 得到一个效应相似性列表 $S = \{d_v(\mathbf{f}_1^1, \mathbf{P}_k), d_v(\mathbf{f}_1^2, \mathbf{P}_k), \dots, d_v(\mathbf{f}_1^N, \mathbf{P}_k), \dots, d_v(\mathbf{f}_{k-1}^1, \mathbf{P}_k), d_v(\mathbf{f}_{k-1}^2, \mathbf{P}_k), \dots, d_v(\mathbf{f}_{k-1}^N, \mathbf{P}_k)\}$ 。通过上式, 可以得到不属于第 $k$ 类的所有样本与 $\mathbf{P}_k$ 之间的相似度, 完成了对 $N$ 所引入虚假效应的估计。

步骤2 不同效应相似度的子集生成。基于 $d_v(\cdot)$ 和 $S$ , 生成 $P$ 个效应相似度的子集。首先对 $S$ 进行降序排序, 并将排序后的 $S$ 个对应索引分成 $P$ 个相等的子表,  $S = \{s_1, s_2, \dots, s_P\}$ 。

然后, 特征 $D_{-k}$ 也划分为相应的 $P$ 个子集 $D_{-k} = \{D_{-k}^1, D_{-k}^2, \dots, D_{-k}^P\}$ 。

步骤3 计算效应一致性损失。首先计算在 $P$ 效应环境下第 $k$ 类的所有特征与其他不属于第 $k$ 类的特征之间的相对分布测度, 得到一个集合 $\{\text{Ld}_k^1, \text{Ld}_k^2, \dots, \text{Ld}_k^P\}$ 。Ld $_k^p$ 计算为

$$\text{Ld}_k^p = - \sum_n \ln \frac{ed_v(\mathbf{f}_k^n, \mathbf{P}_k)}{ed_v(\mathbf{f}_k^n, \mathbf{P}_k) + \sum_{\mathbf{f}_j \in D_{-k}^p} ed_v(\mathbf{f}_j, \mathbf{P}_k)} \quad (7)$$

其中,  $ed_v(\cdot, \cdot) = \exp d_v(\cdot, \cdot)$ 。然后, 对于第 $i$ 类, 计算不同效应相似度的子集中单一类型样本的一致性:

$$L_k = \sum_{p=1}^P \text{Ld}_k^p + \|\nabla \text{Ld}_k^p\|_2^2 \quad (8)$$

最后, 效应一致性损失计算为

$$L_{ec} = \sum_{k=1}^K L_k \quad (9)$$

效应一致性损失通过利用估计类属掩码作为效应相似度的度量, 降低了消除干扰效应的数据量需求, 从而有效地减轻了 $N$ 所引入的虚假效应。

同时, 本文还使用交叉熵损失作为基本识别损失 $L_r$ , 计算为

$$L_r = \sum_{n=1}^{KN} y_n \ln(p(y_n | \mathbf{x}_n)) \quad (10)$$

其中,  $y_n$ 为SAR样本 $\mathbf{x}_n$ 的类别标识。

本方法针对小样本SAR ATR, 分析了由 $N$ 引入的虚假效应是小样本条件下SAR ATR的主要问题。随后, 本文引入双重一致性来估计并消除 $N$ 的

影响。因此, 在小样本条件下, 本文提出的SAR ATR方法可以得到 $I$ 与 $Y$ 之间的真实因果关系, 实现准确的识别和良好的泛化性能。

### 3 实验验证

本节在小样本条件下设计识别实验, 以评估本文方法的有效性和鲁棒性。本节首先介绍MSTAR和OpenSARship数据集。然后, 设计不同样本数量的识别实验, 验证本文在不同数据集上的识别性能。最后, 通过消融实验验证了本文方法的有效性, 并将本文方法与其它针对小样本条件的SAR ATR方法比较识别性能。

#### 3.1 数据集介绍

为了在小样本条件下评估本文方法的识别性能, 本文使用了两个基准数据集: MSTAR数据集和OpenSARship数据集。

MSTAR数据集由美国国防高级研究计划局和空军研究实验室发布, 是评估SAR ATR性能的基准数据集。MSTAR数据是由桑迪亚国家实验室的STARLOS传感器平台, 在X波段进行收集的, 其分辨率为30 cm, 覆盖的方位角范围为 $0^\circ \sim 360^\circ$ 。

OpenSARship数据集旨在发展具有高性能和鲁棒性的SAR舰船类型识别算法。该数据集由41张Sentinel-1平台收集的SAR图像组成, 共包含17种不同类型的舰船, 对应11 346个舰船切片, 其分辨率为 $2.0 \text{ m} \times 1.5 \text{ m}$ 。

#### 3.2 识别性能验证

本节首先描述在MSTAR和OpenSARship数据集上的实验配置, 然后给出并分析相应的识别结果。

##### 3.2.1 MSTAR数据集下的识别结果

本节实验旨在验证, 在小样本条件下, 本文方法在MSTAR数据集上的识别性能。MSTAR数据集的所有的SAR图像训练集和测试集如表1所示。在

表1 MSTAR数据集下的训练集与测试集

类别	训练集		测试集	
	数量	俯仰角	数量	俯仰角
BMP2-9563	233		195	
BRDM2-E71	298		274	
BTR60-7532	256		195	
BTR70-c71	233		196	
D7-92	299	17°	274	15°
2S1-b01	299		274	
T62-A51	299		273	
T72-132	232		196	
ZIL131-E12	299		274	
ZSU234-d08	299		274	

本节实验中，训练集的俯仰角为 $17^\circ$ ，而测试集的俯仰角为 $15^\circ$ 。为了形成每类样本数量为 $K$ 的小样本训练集，本节通过在表1的完整训练集中进行随机抽取，并进行多次实验，每次识别实验将上一次抽取的小样本训练集放回，恢复完整的训练样本集，重新进行随机抽取，以保证多次识别实验的随机性和独立性。

表2给出了本文方法在MSTAR上，在小样本条件下的识别结果。第1行数字表示的是该次实验所使用的每类目标的训练样本数量。上述实验结果表明，当训练样本大于20个时，本文方法可有效识别地面目标。而当训练样本从较为稀少逐渐增加时，本文方法的识别性能可有效地提升。由此，通过本文方法在MSTAR数据集上的识别性能，可以验证本文识别方法的有效性。

### 3.2.2 OpenSARship数据集3类舰船目标的识别结果

OpenSARShip数据集由国际航运市场的主要舰船类型所组成，本文根据SAR舰船目标识别相关研究<sup>[13]</sup>，选取其中3类舰船目标，包括Bulk Carrier, Container Ship和Tanker，其训练集和测试集如表3所示。训练和测试图像的预处理方法与在MSTAR数据集上进行的实验过程相同。

表4展示了每类舰船目标10~200训练样本下的测试集识别性能。结果表明，本方法在3类SAR舰船目标识别中表现出较好的性能。当每个类别的训练样本数量在20~40时，本文方法对训练样本数量下降，仍能有效完成舰船识别任务。

由上述实验结果可以看出，本文方法在SAR舰船目标识别实验上，针对逐步下降的训练样本，仍能够有效识别，验证了本文方法的有效性。

表 2 MSTAR数据集不同训练样本数量下10类目标的识别性能(%)

类别	每类目标训练样本数								
	5	10	20	25	30	40	60	80	100
BMP2	73.33	83.59	92.31	94.87	95.90	97.95	98.97	97.44	98.46
BRDM2	77.74	94.89	93.80	96.72	97.08	98.18	99.27	99.64	98.91
BTR60	83.59	86.67	91.79	94.36	94.87	95.90	98.97	96.92	97.44
BTR70	70.92	90.82	92.35	95.92	96.94	98.47	97.96	98.98	98.98
D7	68.98	83.58	92.70	95.26	95.99	97.45	98.54	99.64	99.64
2S1	81.75	80.29	93.80	95.99	97.08	98.54	98.91	99.64	98.91
T62	74.36	90.11	92.67	95.60	97.07	98.53	97.44	99.63	99.63
T72	89.80	86.22	91.84	95.41	96.94	98.47	98.98	98.98	98.98
ZIL131	68.25	85.77	93.07	96.72	97.81	98.54	98.91	99.64	99.64
ZSU234	74.45	80.29	93.80	96.72	97.08	98.18	98.54	99.64	99.64
平均值	76.13	86.38	93.00	96.07	97.01	98.24	98.79	99.32	99.35

表 3 OpenSARShip数据集中训练与测试集

类别	成像条件	训练样本数	测试样本数	总样本数
Bulk Carrier	VH 和 VV, C 波段	200	475	675
Container Ship	分辨率=5~20 m 入射角=20°~45°	200	811	1011
Tanker	仰角=±11° Rg20 m×az22 m	200	354	554

表 4 OpenSARShip数据集不同训练样本数量下3类舰船目标的识别性能(%)

类别	每类训练样本数									
	10	20	30	40	50	60	70	80	100	200
Bulk Carrier	65.89	63.58	65.68	75.16	60.21	66.11	68.21	65.26	72.84	73.47
Container Ship	71.27	75.46	75.96	76.57	82.49	79.04	80.02	85.20	83.35	90.75
Tanker	79.10	82.77	81.92	74.01	84.46	86.16	84.46	81.92	78.81	82.77
平均值	71.51	73.75	74.41	75.66	76.58	76.92	77.66	78.86	79.41	84.12

### 3.3 方法有效性验证及性能对比

本小节将在小样本条件下, 首先进行消融实验, 验证方法的有效性。再在MSTAR数据集上比较本文方法与现有其他小样本SAR ATR方法的识别性能。

#### 3.3.1 方法有效性验证

本小节将在小样本条件下, 进行消融实验, 在MSTAR数据集上进行每类20张SAR图像的消融实验, 以验证方法的有效性。实验选取MSTAR数据库中俯仰角为17°的SAR图像, 每类随机采样20张样本, 利用MSTAR数据集中俯仰角为15°的全部SAR图像进行测试。由于效应一致性损失需要建立在类内特征一致性损失的基础上才可使用, 因此本节实验设置3种实验配置, V1, V2和V3。其中V1为没有使用双重一致性的基本SAR ATR识别模型, V2为仅使用类内特征一致性损失的SAR ATR模型, V3则为完整方法。表5中“特征”代表类内特征一致性损失; “效应”代表效应一致性损失。

根据上述的方法有效性消融验证实验结果, 本文所提出的双重一致性方法, 可有效地在V1的基础上逐步提升小样本SAR目标识别性能。在与V2的识别性能对比中, 本文方法消除了虚假效应, 可进一步提升识别性能, 验证了本文方法的有效性。

#### 3.3.2 MSTAR数据集上的比较

本小节在MSTAR数据集上比较本文方法与现

有其他小样本SAR ATR方法的识别性能。其中, 比较的方法主要有3类, (1)传统方法; (2)针对小样本SAR ATR的数据增强方法; (3)针对小样本SAR ATR的新颖模型。表6中的识别结果主要来源于不同方法汇报的MSTAR数据集上识别性能, 部分来源于文献[15,18]中识别性能对比。

通过上述的对比实验, 可以看出, 在不同的训练样本数量下, 本文方法达到了较好的识别性能。由此, 通过上述在MSTAR数据集上的识别实验对比, 可以看出, 在小样本条件下的识别性能对比, 本文方法在不同SAR目标类型上, 如地面目标与海面舰船, 均可达到较好的识别性能, 验证了本文方法的识别有效性。

## 4 结论

本文探索了SAR ATR在小样本条件下识别性能有效的关键问题之一。为了解决小样本SAR目标识别问题, 本文提出了基于双重一致性的小样本SAR ATR方法, 并通过MSTAR数据集上的识别实验和对比实验, 验证了本文方法的识别有效性。但仍然存在问题值得进一步研究与完善, 例如, 样本数量与SAR目标识别性能的定量约束边界, 即如何导出小样本SAR目标识别性能与样本数量、样本质量等因素间的定量约束边界。作者将在未来的研究中延续并深化当前的研究成果。

表5 消融实验: 20个训练样本下不同消融配置的识别性能(%)

方法配置	特征	效应	BMP2	BRDM2	BTR60	BTR70	D7	2S1	T62	T72	ZIL131	ZSU234	平均值
V1	×	×	80.51	75.91	74.87	80.10	73.72	76.28	78.75	82.14	84.31	86.86	79.59
V2	√	×	88.21	89.05	81.54	88.27	85.77	96.35	81.68	84.18	87.23	94.16	88.16
V3	√	√	92.31	93.80	91.79	92.35	92.70	93.80	92.67	91.84	93.07	93.80	93.00

表6 MSTAR数据集下SAR目标识别性能对比(%)

方法	每类样本数									
	10	20	40	55	80	110	165	220	All data	
传统方法	PCA+SVM [14]	-	76.43	87.95	-	92.48	-	-	-	94.32
	ADaboost [14]	-	75.68	86.45	-	91.45	-	-	-	93.51
	DGM [14]	-	81.11	88.14	-	92.85	-	-	-	96.07
数据增强	GAN-CNN [14]	-	81.80	88.35	-	93.88	-	-	-	97.03
	MGAN-CNN [14]	-	85.23	90.82	-	94.91	-	-	-	97.81
	Deep CNN [15]	-	77.86	86.98	-	93.04	-	-	-	95.54
新颖模型	Simple CNN [16]	-	75.88	-	-	-	-	-	-	-
	Dens-CapsNet [17]	80.26	92.95	96.50	-	-	-	-	-	99.75
	ASC-MACN [18]	62.85	79.46	-	-	-	-	-	-	99.42
	本文方法	86.38	93.00	98.24	-	99.32	-	-	-	-

## 参考文献

- [1] CURLANDER J C and MCDONOUGH R N. Synthetic Aperture Radar: Systems and Signal Processing[M]. New York: Wiley, 1991.
- [2] KREUCHER C. SAR-ATR using EO-based deep networks[C]. 2023 IEEE Radar Conference (RadarConf23), San Antonio, USA, 2023: 1–5. doi: [10.1109/RadarConf2351548.2023.10149584](https://doi.org/10.1109/RadarConf2351548.2023.10149584).
- [3] MAO Deqing, YANG Jianyu, ZHANG Yongchao, *et al.* Angular superresolution of real aperture radar with high-dimensional data: Normalized projection array model and adaptive reconstruction[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5117216. doi: [10.1109/TGRS.2022.3203131](https://doi.org/10.1109/TGRS.2022.3203131).
- [4] MAO Deqing, YANG Jianyu, TUO Xingyu, *et al.* Angular superresolution of real aperture radar for target scale measurement using a generalized hybrid regularization approach[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5109314. doi: [10.1109/TGRS.2023.3315310](https://doi.org/10.1109/TGRS.2023.3315310).
- [5] CHOI J H, LEE M J, JEONG N H, *et al.* Fusion of target and shadow regions for improved SAR ATR[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5226217. doi: [10.1109/TGRS.2022.3165849](https://doi.org/10.1109/TGRS.2022.3165849).
- [6] HUANG Zhongling, YAO Xiwen, LIU Ying, *et al.* Physically explainable CNN for SAR image classification[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2022, 190: 25–37. doi: [10.1016/j.isprsjprs.2022.05.008](https://doi.org/10.1016/j.isprsjprs.2022.05.008).
- [7] WANG Chenwei, LUO Siyi, PEI Jifang, *et al.* Crucial feature capture and discrimination for limited training data SAR ATR[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 204: 291–305. doi: [10.1016/j.isprsjprs.2023.09.014](https://doi.org/10.1016/j.isprsjprs.2023.09.014).
- [8] FENG Sijia, JI Kefeng, WANG Fulai, *et al.* PAN: Part attention network integrating electromagnetic characteristics for interpretable SAR vehicle target recognition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5204617. doi: [10.1109/TGRS.2023.3256399](https://doi.org/10.1109/TGRS.2023.3256399).
- [9] WANG Chenwei, LUO Siyi, HUANG Yulin, *et al.* SAR ATR method with limited training data via an embedded feature augmenter and dynamic hierarchical-feature refiner[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5216215. doi: [10.1109/TGRS.2023.3314501](https://doi.org/10.1109/TGRS.2023.3314501).
- [10] PEARL J. Causal inference in statistics: An overview[J]. *Statistics Surveys*, 2009, 3: 96–146. doi: [10.1214/09-SS057](https://doi.org/10.1214/09-SS057).
- [11] SCHÖLKOPF B, JANZING D, PETERS J, *et al.* On causal and anticausal learning[C]. Proceedings of the 29th International Conference on Machine Learning, Edinburgh, UK, 2012.
- [12] GREENLAND S, PEARL J, and ROBINS J M. Causal diagrams for epidemiologic research[J]. *Epidemiology*, 1999, 10(1): 37–48. doi: [10.1097/00001648-199901000-00008](https://doi.org/10.1097/00001648-199901000-00008).
- [13] ZHANG Tianwen, ZHANG Xiaoling, KE Xiao, *et al.* HOG-ShipCLSNet: A novel deep learning network with hog feature fusion for SAR ship classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5210322. doi: [10.1109/TGRS.2021.3082759](https://doi.org/10.1109/TGRS.2021.3082759).
- [14] ZHENG Ce, JIANG Xue, and LIU Xingzhao. Semi-supervised SAR ATR via multi-discriminator generative adversarial network[J]. *IEEE Sensors Journal*, 2019, 19(17): 7525–7533. doi: [10.1109/JSEN.2019.2915379](https://doi.org/10.1109/JSEN.2019.2915379).
- [15] MORGAN D A E. Deep convolutional neural networks for ATR from SAR imagery[C]. SPIE 9475, Algorithms for Synthetic Aperture Radar Imagery XXII, Baltimore, USA, 2015: 94750F. doi: [10.1117/12.2176558](https://doi.org/10.1117/12.2176558).
- [16] LI Yibing, LI Xiang, SUN Qian, *et al.* SAR image classification using CNN embeddings and metric learning[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4002305. doi: [10.1109/LGRS.2020.3022435](https://doi.org/10.1109/LGRS.2020.3022435).
- [17] WANG Quan, XU Haixia, YUAN Liming, *et al.* Dense capsule network for SAR automatic target recognition with limited data[J]. *Remote Sensing Letters*, 2022, 13(6): 533–543. doi: [10.1080/2150704X.2022.2044089](https://doi.org/10.1080/2150704X.2022.2044089).
- [18] FENG Sijia, JI Kefeng, WANG Fulai, *et al.* Electromagnetic Scattering Feature (ESF) module embedded network based on ASC model for robust and interpretable SAR ATR[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5235415. doi: [10.1109/TGRS.2022.3208333](https://doi.org/10.1109/TGRS.2022.3208333).

王陈炜：男，博士，研究方向为雷达目标识别、机器学习、雷达探测成像等。

罗思懿：女，硕士，研究方向为雷达目标识别、机器学习、雷达探测成像等。

黄钰林：男，教授，研究方向为雷达探测成像、雷达目标检测与识别、人工智能与机器学习等。

裴季方：男，副研究员，研究方向为雷达目标识别、机器学习、雷达探测成像等。

张寅：男，研究员，研究方向为新体制雷达、雷达信号处理、雷达成像等。

杨建宇：男，教授，研究方向为雷达探测与成像、信号检测与估计等。

责任编辑：马秀强