

## SAR目标增量识别中基于最大化非重合体积的样例挑选方法

李斌 崔宗勇 汪浩瀚 周正 田宇 曹宗杰\*

(电子科技大学信息与通信工程学院 成都 611731)

**摘要:** 为了确保合成孔径雷达(SAR)自动目标识别(ATR)系统能够迅速适应新的应用环境,其必须具备快速学习新类的能力。目前的SAR ATR系统在学习新类时需要不断重复训练所有旧类样本,这会造成大量存储资源的浪费,同时识别模型无法快速更新。保留少量的旧类样例进行后续的增量训练是模型增量识别的关键。为了解决这个问题,该文提出基于最大化非重合体积的样例挑选方法(ESMNV),一种侧重于分布非重合体积的样例选择算法。ESMNV将每个已知类的样例选择问题转化为分布非重合体积的渐近增长问题,旨在最大化所选样例的分布的非重合体积。ESMNV利用分布之间的相似性来表示体积之间的差异。首先,ESMNV使用核函数将目标类别的分布映射到重建核希尔伯特空间(RKHS),并使用高阶矩来表示分布。然后,它使用最大均值差异(MMD)来计算目标类别与所选样例分布之间的差异。最后,结合贪心算法,ESMNV逐步选择使样例分布与目标类别分布差异最小的样例,确保在有限数量的样例情况下最大化所选样例的非重合体积。

**关键词:** SAR目标增量识别; 样例挑选; 非重合体积; 最大均值差异; 贪心算法

中图分类号: TN957.52

文献标识码: A

文章编号: 1009-5896(2024)10-3918-10

DOI: 10.11999/JEIT240217

## Exemplar Selection Based on Maximizing Non-overlapping Volume in SAR Target Incremental Recognition

LI Bin CUI Zongyong WANG Haohan ZHOU Zheng  
TIAN Yu CAO Zongjie

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

**Abstract:** To ensure the Synthetic Aperture Radar (SAR) Automatic Target Recognition (ATR) system can quickly adapt to new application environments, it must possess the ability to rapidly learn new classes. Currently, SAR ATR systems require repetitive training of all old class samples when learning new classes, leading to significant waste of storage resources and preventing the recognition model from updating quickly. Preserving a small number of old class examples for subsequent incremental training is crucial for model incremental recognition. To address this issue, Exemplar Selection based on Maximizing Non-overlapping Volume (ESMNV) is proposed in this paper, an exemplar selection algorithm that emphasizes the non-overlapping volume of the distribution. ESMNV transforms the exemplar selection problem for each known class into an asymptotic growth problem of the Non-overlapping volume of the distribution, aiming to maximize the Non-overlapping volume of the distribution of the selected exemplars. ESMNV utilizes the similarity between distributions to represent differences in volume. Firstly, ESMNV uses a kernel function to map the distribution of the target class into a Reconstructed Kernel Hilbert Space (RKHS) and employs higher-order moments to represent the distribution. Then, it uses the Maximum Mean Discrepancy (MMD) to compute the difference between the distribution of the target class and the selected exemplars. Combined with a greedy algorithm, ESMNV progressively selects exemplars that minimize the difference in distribution between the selected exemplars and the target class, ensuring the maximum Non-overlapping volume of the selected exemplars with a limited number.

收稿日期: 2024-03-28; 改回日期: 2024-08-21; 网络出版: 2024-08-30

\*通信作者: 曹宗杰 zjcao@uestc.edu.cn

基金项目: 国家自然科学基金(62271116)

Foundation Item: The National Natural Science Foundation of China (62271116)

**Key words:** SAR target incremental recognition; Exemplar selection; Non-overlapping volume; Maximum Mean Discrepancy (MMD); Greedy algorithm.

## 1 引言

合成孔径雷达自动目标识别(SAR Automatic Target Recognition, SAR ATR)技术在传感器数据处理领域扮演着至关重要的角色<sup>[1-3]</sup>。借助机器学习算法, SAR ATR系统能够对传感器捕获的数据进行智能分析, 从而实现精确的目标识别, 并广泛应用于农业、海洋监测以及军事目标定位等领域。

随着传感器数据的不断积累, 有效处理和利用新类别的数据已成为迫切需要解决的问题。在传统的SAR目标识别模式中, 为了使模型能够同时识别新旧类别, 需要进行全局联合训练<sup>[4]</sup>。然而, 联合训练需要在每次模型更新时重复访问以前的数据, 这不仅会导致大量存储资源的消耗, 还会阻碍模型的快速更新。仅利用新类别数据来更新旧模型则可能引发灾难性遗忘问题<sup>[5]</sup>。灾难性遗忘的发生是因为模型在训练过程中只拟合当前数据的分布, 导致其失去了对旧类样本的识别能力。

增量学习<sup>[6]</sup>是解决灾难性遗忘的有效技术。与传统的联合训练相比, 增量学习具有多个优点。首先, 增量学习能够根据新数据或任务的特点灵活调整模型, 以适应不同的场景和需求。其次, 通过不断增加新的数据或任务, 增量学习可以扩展模型的功能, 提供更广泛的应用范围。从保留旧任务数据的角度来看, 增量学习方法可分为基于样例的方法和无样例方法。基于样例的方法通过直接保留原有的旧任务数据或者使用生成模型生成旧任务数据, 并与新任务数据一起训练。在增量学习过程中, 旧类样例能够有效代表旧类的分布, 因此保留少量旧类样例可以还原旧类的分布, 从而避免新模型对旧类知识的遗忘。无样例方法则通常使用基于正则化或参数隔离的方法。

本文聚焦于基于样例的增量学习方法。当前的SAR ATR模型存在着稳定性-可塑性困境, 即模型在学习新知识方面表现出色, 但在巩固旧知识方面表现较差。SAR ATR模型增量识别的关键在于保持对先前类别样本的识别能力。然而, 由于内存有限, 模型只能保留少量旧类别样本用于未来的模型更新。因此, 在增量学习过程中, 样例挑选成为了关注的焦点。目前, 主流的样例挑选方法<sup>[7-9]</sup>主要关注类别的局部分布。然而, 如果样例选择仅考虑类别的局部分布, 可能会影响模型的训练, 并最终影响模型的泛化能力。由于局部信息忽略了类别的整体结构, 这将不利于模型后续的训练。

与先前的研究相比, 本文提出了基于最大化分布非重合体积的样例选择方法(Exemplar Selection based on Maximizing Non-overlapping Volume, ESMNV)。与传统的基于局部分布的样例选择方法不同, ESMNV方法旨在利用类别的整体分布信息。它通过选择少量的样例来最大化所选样例的非重合体积, 从而实现对目标分布的最大覆盖。由于SAR图像独特的成像机制, 相较于光学图像, SAR图像存在类间差异小、类内差异大的特性。在增量学习的过程中, 类别之间的相似性会严重影响增量过程。因此, 相较于光学图像, SAR图像的增量学习更具挑战性。若能挑选出每个类别最具代表性的样例进行增量学习, 则能增大类间差异, 从而促进SAR图像的增量学习。

因此, 针对SAR目标类间差异小的特性, 本文提出了ESMNV。一方面采用了基于固定类别中心的增量学习框架, 在增量的过程中实现了SAR目标类内紧密和类间可分。另一方面, 通过最大化样例分布的非重合体积来最小化样例分布与目标类别分布之间的差异, 从而挑选出最具代表性的样例, 增大类间差异。

综上所述, 本文的主要贡献体现在以下4个方面:

(1) 提出分布的非重合体积概念, 并将样例挑选问题转化为最大化所选样例分布的体积问题。

(2) 通过使用分布之间的相似性来表示体积之间的差异, 并采用贪心算法逐步选择能最小化样例分布与目标类别分布之间差异的样本, 从而最大化所选样例分布的体积。

(3) 提出使用凸包和维诺图来分析所选样例的分布。

(4) 发现使用样例分布来逼近目标类别分布的本质是基于目标拓扑结构的均匀采样。

## 2 相关工作

### 2.1 类别增量学习

类别增量学习(Class Incremental Learning, Class-IL)是一项机器学习任务, 其目标在于系统学习新类别的同时不显著影响先前类别的学习, 并有效地扩展现有模型。类别增量学习方法可以分为基于重演、正则化和参数隔离的不同策略<sup>[10]</sup>。基于重演的方法通常直接保留样例, 假定先前训练的一些样本可以作为保留的样例, 并在随后的增量训练中使用。基于正则化的方法通常从模型本身出发, 关

注增量过程中的参数变化<sup>[11]</sup>。基于正则化的方法通常涉及添加正则化项或使用知识蒸馏来限制模型参数的变化。基于参数隔离的方法<sup>[12]</sup>则使用额外的网络结构来适应新任务。

## 2.2 样例挑选

样例选择方法可以分为基于模型和基于分布的方法。基于模型的样例选择方法通常依赖于分类器对样例的评分,如概率输出<sup>[13]</sup>、预测误差<sup>[14]</sup>等。基于分布的方法则根据样本在特征空间中的分布挑选样例。考虑到位于类别中心的样本更具代表性,文献<sup>[9]</sup>提出了基于羊群的样例挑选方法,该方法逐渐选择接近类别中心的样本作为样例。为了有效地保持类别的拓扑信息,文献<sup>[7]</sup>引入了一种基于边界的样例选择方法,该方法主要选择类别边界上的样本以保持分类边界。考虑到挑选的样例应具有多样性,文献<sup>[8]</sup>使用随机采样来挑选样例。由于训练类别的增加和输入数据分布的时间变化已成为导致分类器性能随时间下降的主要原因,因此本文主要关注基于数据分布的样例挑选方法。

## 3 基于最大化非重合体积的样例挑选

### 3.1 基于固定类别中心的增量学习框架

假设数据流由样本集合 $(X_1, X_2, \dots, X_{s+t})$ 组成,其中 $X_y$ 包含来自类别 $y$ 的所有图像。对于新任务 $T$ ,增量数据包含了来自新类别集合 $X_{\text{new}} = (X_{s+1}, X_{s+2}, \dots, X_{s+t})$ 的完整样本,以及来自先前类别的少量样例数据 $P_{\text{old}} = (P_1, P_2, \dots, P_s)$ ,模型将对所有已见过的类别进行分类。本文中的增量学习框架采用了基于固定类别中心的增量学习框架类别增量固定聚类(Incremental Class Anchor Clustering, ICAC)<sup>[15]</sup>。首先,ICAC在分类空间中建立了一个维度等于类别数量的坐标系。然后,ICAC为每个类别分配一个坐标系,并在其上设置一个固定点,即固定类别中心。固定类别中心可视为标准的独热向量,其集合 $C$ 定义为

$$C = (c_1, c_2, \dots, c_N) = (\eta \cdot e_1, \eta \cdot e_2, \dots, \eta \cdot e_N) \quad (1)$$

$$e_1 = (1, 0, \dots, 0)^T, e_N = (0, \dots, 0, 1)^T \quad (2)$$

其中, $\eta$ 表示固定类别中心在坐标轴上的位置。在训练过程中,每个类别的样本将聚集到对应的固定类别中心附近。当出现新类别时,ICAC会增加坐标系的维度,并为新类别添加一个新的固定类别中心。模型通过类别固定聚类(Class Anchor Clustering, CAC)损失减小类内距离,同时最大化类间距离来实现所有类别的有效分离。一方面,为了减小类内距离,向量 $f(x)$ 与对应的固定类别中心 $c_y$ 之间的距离应该尽可能小,因此固定位置损失项定义为

$$\mathcal{L}_A(x, y) = d_y = \|f(x) - c_y\|_2 \quad (3)$$

另一方面,为了最大化 $f(x)$ 到其他固定类别中心的距离,区分损失的定义为

$$\mathcal{L}_D(x, y) = \log_e \left( 1 + \sum_{j \neq y}^N e^{d_y - d_j} \right) \quad (4)$$

通过结合固定位置损失和区分损失,类固定聚类损失的定义为

$$\mathcal{L}_{\text{CAC}}(x, y) = \mathcal{L}_D(x, y) + \lambda \cdot \mathcal{L}_A(x, y) \quad (5)$$

其中, $\lambda$ 是一个超参数,用于平衡这两个损失项。通过使用类锚定聚类损失,模型在增量的过程中就能实现SAR目标类内紧密,类间分离。

### 3.2 基于非重合体积的样例挑选

本文的任务是在选择固定数量的样例的条件下,尽可能地保留原始类别的最大信息。假设从某个类别中选择样例,而这个特定的类别被称为目标类别。设 $q$ 为目标类别的分布,本文将 $q$ 视为具有分布体积 $N$ 的全集 $S$ 。假设样例分布的体积为 $V$ ,显然 $V \leq N$ ,当选择目标类别中的所有样本作为样例时,等式成立。因此,样例选择的目标是在选择固定数量的情况下最大化非重合体积,使得 $V$ 接近 $N$ ,从而实现集合 $S$ 的最大覆盖。本文将每个数据点视为 $S$ 的一个子集,其单位体积为1,并且由于样本之间的相似性,数据点之间存在分布重叠。因此,本文定义非重合体积如下:

**定义1(非重合体积)** 非重合体积是考虑样本之间相似性的分布的实际体积。根据非重合体积的定义,所选样例分布 $q$ 与候选样本分布 $e$ 之间的关系如图1所示。

从图1可以观察到,分布 $q$ 与分布 $e$ 之间存在3种关系:完全分离、部分重叠和完全重叠。分布的并集区域决定了分布 $q$ 的非重合体积,如图2所示。

从图2可以观察到,在每个样例的选择过程中,随着 $q$ 与 $e$ 之间的重叠变得越来越大, $q$ 的非重合体积就会变得越来越小。由于对于给定的类别,样本之间通常存在一定程度的相似性。因此,第1和第3种情况很少发生。样本之间的分布往往处于部分重叠的状态。假设样例选择后 $q$ 的体积为 $V_{\text{end}}$ ,目标分布为 $S$ ,则样例选择的目标可以转化式6的优化目标函数。

$$\left. \begin{aligned} \min \|N - V_{\text{end}}\|_{\mathcal{H}} \\ \text{s.t. } \{V_{\text{end}} = m\} \end{aligned} \right\} \quad (6)$$

其中, $m$ 表示每个类别选择的样例数量。假设来自目标类别的样本数量为 $n$ ,其中 $m$ 远小于 $n$ 。由于样本之间存在未知的体积重叠,因此不可能直接计算分布 $q$ 的体积。根据式(6),无需直接计算分布的具体体积,只需计算分布之间的体积差异即可。由于体积差异可以通过间接使用分布之间的差异来表示,




图 1 所选样例分布 $q$ 与候选样本分布 $e$ 之间的3种关系类型




图 2 所选样例非重合体积的示意图

因此, 下一步是计算分布之间的体积差异。分布的信息通常由概率分布函数 $h(x)$ 描述。在高维空间中, 由于特征的不规则性, 使用概率分布函数来准确表示特征分布变得具有挑战性。考虑到分布的矩有效地捕捉了分布信息, 特征函数成为了在高维空间中描述分布的可行方法。分布函数 $\varphi_x(t)$ 的定义为

$$\begin{aligned} \varphi_x(t) &= E[e^{itx}] \\ &= E\left(1 + \frac{itx}{1} - \frac{t^2x^2}{2!} + \dots + \frac{(it)^n x^n}{n!}\right) \\ &= E(1) + E\left(\frac{itx}{1}\right) - E\left(\frac{t^2x^2}{2!}\right) + \dots \\ &\quad + E\left(\frac{(it)^n x^n}{n!}\right) \\ &= E(1) + \frac{itE(x)}{1} - \frac{t^2E(x^2)}{2!} + \dots + \frac{(it)^n E(x^n)}{n!} \end{aligned} \quad (7)$$

式(7)表明, 特征函数包含分布的所有矩, 因此可以通过特征函数 $\varphi_x(t)$ 来表示分布。因为特征函数需要计算高阶矩, 又核函数 $\phi(x)$ 可以用于计算高阶矩, 所以可以通过核函数对应的映射函数 $\mathbf{f}(x)$ , 将分布映射到一个无限维的再生核希尔伯特空间(Reproducing Kernel Hilbert Space, RKHS)中。分布 $p$ 的高阶矩可以表示为

$$\begin{aligned} E_p[\mathbf{f}(x)] &= \int_x p(dx)\mathbf{f}(x) \\ &= \int_x p(dx)\langle\phi(x), \mathbf{f}\rangle_{\mathcal{H}_k} \\ &= \left\langle \int_x p(dx)\phi(x), \mathbf{f} \right\rangle_{\mathcal{H}_k} \\ &\doteq \langle u_p, \mathbf{f} \rangle_{\mathcal{H}_k} \end{aligned} \quad (8)$$

由于 RKHS 的再生性质, RKHS 等式第2行中的函数 $\mathbf{f}(x)$ 可以表示为无限维向量 $\phi(x)$ 与基向量 $\mathbf{f}$ 的内积。最后, 分布 $p$ 可以通过 RKHS 中的核均值嵌入 $u_p$ 来描述。因此, 最大均值差异<sup>[16]</sup>(Maximum Mean Discrepancy, MMD) 可以用来衡量两个分布之间的相似性。当样本大小有限时, 必须限制函数域, 否则总是可能找到一个使两个分布之间的MMD值无限大的函数。假设 $x$ 的分布为 $p$ ,  $y$ 的分布为 $q$ ,  $p$ 和 $q$ 之间的 MMD 值可以表示为

$$\begin{aligned} \text{MMD}[F, p, q] &= \sup_{\|\mathbf{f}\|_{\mathcal{H}} \leq 1} (E_p[\mathbf{f}(x)] - E_q[\mathbf{f}(y)]) \\ &= \sup_{\|\mathbf{f}\|_{\mathcal{H}} \leq 1} (E_p[\langle\mathbf{f}, \phi(x)\rangle_{\mathcal{H}}] \\ &\quad - E_q[\langle\mathbf{f}, \phi(y)\rangle_{\mathcal{H}}]) \\ &= \sup_{\|\mathbf{f}\|_{\mathcal{H}} \leq 1} [\langle\mathbf{f}, \mu_p - \mu_q\rangle_{\mathcal{H}}] \end{aligned} \quad (9)$$

这里 $F$ 是一组函数,  $\sup$ 表示在函数集合上取上确界。根据内积的性质, 可以推导出

$$\langle\mathbf{f}, \mu_p - \mu_q\rangle_{\mathcal{H}} \leq \|\mu_p - \mu_q\|_{\mathcal{H}} \|\mathbf{f}\|_{\mathcal{H}} \quad (10)$$

又由于

$$\|\mathbf{f}\|_{\mathcal{H}} \leq 1 \quad (11)$$

因此, 分布 $p$ 和 $q$ 之间的不相似性可以表示为

$$\text{MMD}[F, p, q] = \|\mu_p - \mu_q\|_{\mathcal{H}} \quad (12)$$

由于均值是期望的无偏估计, 它可以用于计算核均值嵌入。假设分布 $p$ 包含 $n$ 个样本, 分布 $q$ 包含 $m$ 个样本, 式(12)可以表示为

$$\text{MMD} = \frac{1}{n} \sum_{i=1}^n \phi(x_i) - \frac{1}{m} \sum_{j=1}^m \phi(y_j) \quad (13)$$

又因为核技巧能间接表示两个向量的内积, 所

以可以对 MMD 进行平方并简化，以使用核函数表示内积，如式(14)所示

$$\begin{aligned}
 \text{MMD}^2[F, p, q] &= \left\| \frac{1}{n} \sum_{i=1}^n \phi(x_i) - \frac{1}{m} \sum_{j=1}^m \phi(y_j) \right\|_{\mathcal{H}}^2 \\
 &= \left\| \frac{1}{n^2} \sum_{i=1}^n \sum_{i'=1}^n \phi(x_i) \phi(x_{i'}) \right. \\
 &\quad - \frac{2}{nm} \sum_{i=1}^n \sum_{j=1}^m \phi(x_i) \phi(y_j) \\
 &\quad \left. + \frac{1}{m^2} \sum_{j=1}^m \sum_{j'=1}^m \phi(y_j) \phi(y_{j'}) \right\|_{\mathcal{H}} \\
 &= \left\| \frac{1}{n^2} \sum_{i=1}^n \sum_{i'=1}^n k(x_i, x_{i'}) \right. \\
 &\quad - \frac{2}{nm} \sum_{i=1}^n \sum_{j=1}^m k(x_i, y_j) \\
 &\quad \left. + \frac{1}{m^2} \sum_{j=1}^m \sum_{j'=1}^m k(y_j, y_{j'}) \right\|_{\mathcal{H}} \quad (14)
 \end{aligned}$$

从式(14)可以得出，通过求解 MMD 值，可以衡量两个分布之间的差异。因此，样例选择问题可以转化为一个分布度量问题。设  $p$  表示目标类的分布， $q$  表示所选样例的分布。因此，式(6)可以转化为式(15)的目标函数

$$\begin{cases} \min \|\mu_p - \mu_q\|_{\mathcal{H}}, \\ \text{s.t. } \{|q| = m\} \end{cases} \quad (15)$$

使用式(13)，分布之间的 MMD 值可以用来表示分布体积的差异。由于一次性选择所有最优样例集并不可行，所以样例选择的过程应该逐步进行。贪心算法是一种在每一步选择中都采取当前状态下最优决策的算法策略。贪心算法每一步选择都考虑局部最优解，以期望通过一系列局部最优解达到全局最优解。假设目标类的所有样本的集合为  $X = \{x_1, x_2, \dots, x_n\}$ ，当前选择的样例集合为  $Y = \{y_1, y_2, \dots, y_n\}$ ， $Y \subseteq X$ ，那么可以使用贪心算法获取候选样例  $y^*$

$$y^* = \arg \min_{y \neq x \in Y} \|\mu_X - \mu_{Y \cup y}\|_{\mathcal{H}} \quad (16)$$

通过贪心算法，可以逐步获得最小化当前样例分布与目标分布之间差异的样例。即使当前样例分布的体积达到最大，从而近似最优样例集的解集。

在本文中，由于MMD值的取值为正，因此MMD值的倒数可以表示两个分布之间的相似性。MMD值越小，其倒数值越大，相似性也越高。图3一方面展示了提出方法在MSTAR数据集的2S1类上的样本选择可视化结果，同时也展示了所选样本分布与目标分布之间的相似性变化。其中图3(b)、图3(c)和图3(d)分别表示在选择的样本数量为10, 20和30时的分布可视化结果，其中红色点表示选择的样本，绿色点表示目标类别的所有样本。从图3可以看出，样例分布和目标分布之间的相似性随着所选样本的数量增加而逐渐增加。从所选样本的分布可以看出，选择样本的过程近似于实现目标分布的均匀覆盖的过程。

凸包是一个包含给定点集的最小凸多边形或凸多面体。其可用于数据分析中的边界描述或者计算几何中的形状近似等。维诺图在数学和计算几何中用于划分空间，将点集中的每个点分配到最近的区域。为了进一步分析所选样本的分布，图4展示了所选样本的拓扑以及邻域分布，并利用凸包和维诺图对挑选样例的分布进一步进行了分析。

在图4(b)中。首先，将位于目标分布最外围的样本用于绘制目标分布的凸包，接着利用挑选样例中的最外围样本绘制定定样例的凸包。然后，逐个绘制剩余样本形成的凸包，直至绘制完所有样例。该图的目的在于展示所选样本的分布从外到内是如何变化的，即显示所选样本的拓扑结构。显然，ESMNV有效地考虑了目标的整个分布，不仅关注类的外部分布，而且充分考虑了类内部的分布。通过观察最外围凸包的变化，可以看出所选样本的凸包逐渐接近目标分布的凸包，表明所选样本外围的分布逐渐向目标的外围分布收敛。随着凸包的数量

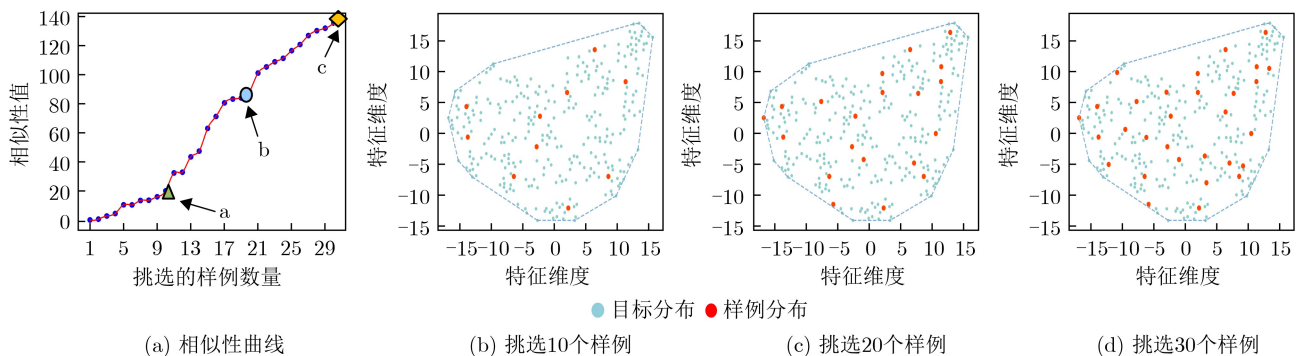


图 3 ESMNV在MSTAR数据集类2S1上的示例性选择可视化结果

逐渐增加,最里面的凸包逐渐接近目标的中心,表明所选样本的内部分布也逐渐接近目标类别的内部分布。综上所述,ESMNV在样本选择中保持了目标分布的全面性和一致性。为了进一步探索挑选样例的邻域分布,本文使用维诺图分析所选样本与目标类之间的分布关系。选取的样本用于构造维诺图,维诺图与目标分布的凸包所形成的面积表示样本分布在目标类别上的覆盖范围。如图4(c)所示,每个样本所在区域的面积差距较小,表明样本实现了目标分布的均匀覆盖。

## 4 试验验证与分析

### 4.1 试验数据集

合成孔径雷达(SAR)具有全天候、全天时的特点,在目标识别领域得到了广泛的应用。为了验证所提出的方法的有效性,本文在移动和静止目标采集和识别(Moving and Stationary Target Acquisition and Recognition, MSTAR)数据集, SAR-AIRcraft-1.0数据集<sup>[17]</sup>和OpenSARShip数据集<sup>[18]</sup>上一共3个数据集上进行了实验。

### 4.2 验证准则和试验细节

本文采用的增量验证指标是平均增量准确率。

平均增量准确率在每个增量阶段测试模型之前遇到的所有类别,然后计算平均准确率。网络训练的epoch为100, batch size为16,使用的优化器是自适应矩估计(Adam)优化器,学习率为0.000 1。在数据预处理阶段,所有图像的大小调整为64×64。

### 4.3 比较的方法

本文比较了增量学习中当前最先进的样例挑选方法,包括基于羊群的样例挑选(Herding)<sup>[9]</sup>,随机挑选(Random)<sup>[8]</sup>,以及基于类边界的样例挑选(Class Boundary exemplar selection-based Incremental Learning, CBesIL)<sup>[7]</sup>和基于密度覆盖的样例选择(Density Coverage-Based Exemplar Selection, DCBES)<sup>[19]</sup>。

### 4.4 和先进方法的比较试验

#### 4.4.1 在不同数量的初始训练类别条件下

在探究初始类的数量对增量识别的影响方面,本文比较了不同初始类别数下各增量学习方法与提出方法ESMNV的效果。实验设计中,初始类数设定为 $N = \{3, 4, 5\}$ ,每次增量学习一类,每个类保留的样例数为 $m = 15$ 。图5展示了在不同数量的初始训练类下,所提出的ESMNV方法与其他方法相比的结果。不难看出,ESMNV在所有初始类下都

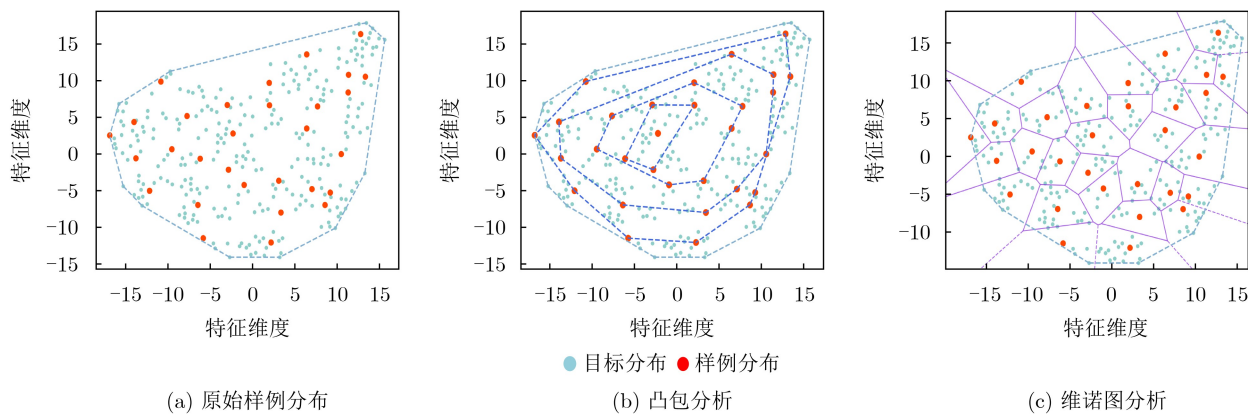


图4 所选样例分布的进一步分析




图5 各方法在不同初始训练类数N下的平均增量准确度

表现最好，凸显了其在保持目标整体分布方面的优异表现。紧随其后的是DCBES方法，该方法使用密度覆盖策略来确保样本选择的多样性。基于羊群效应的方法能够选择最具代表性的样本，但在样本多样性方面略有不足。随机选择方法确保了一定程度的样本多样性，但稳定性稍差。最后，CBesIL方法是基于边界样本的选择，这使得它很难很好地代表整个类别，因此表现不佳。

4.4.2 在不同增量步长条件下

该实验对比了不同增量学习方法在不同增量步长  $T = \{1, 2, 3\}$  下的识别性能。实验中初始训练类别设为4类。从图6可以明显看出，随着增量步长  $T$  的增加，各种样本挑选方法之间的性能差异逐渐减小。这主要是因为随着增量步数的增加，新引入类别在总样本中的比例上升，使得新类样本对整体识别性能的影响更加显著。在这种情况下，样本选择方法之间的性能差异主要由新引入的类别决定，因此表现出相对较小的差异。

4.4.3 在不同保存样例条件下

考虑到增量学习的存储空间有限，本节在有限样本存储条件下进行了增量学习的研究。本实验设定了3种不同的样本存储数量，即每类保留的样例数量  $m$  分别为5, 10和15。表1-表3分别展示了当样例数量  $m$  为5, 10和15时，各种方法的增量识别率表现。

根据表1的数据，与CBesIL, Random, Herding和DCBES等方法相比，所提ESMNV方法的增量识别率分别提高了10.37%, 7.53%, 5.99%和4.60%。这一结果显示了ESMNV在样本数量较少时，能够更有效地保留和利用样本信息，显著提升模型的识别性能。

从表2可以看出，当每类保留的样本数量增加到10时，ESMNV方法相比于CBesIL, Random, Herding和DCBES的增量识别率分别提高了8.90%, 7.08%, 5.21%和4.60%。尽管相比于  $m=5$  的情况，提升幅度有所减小，但ESMNV仍然表现出明显的优势。

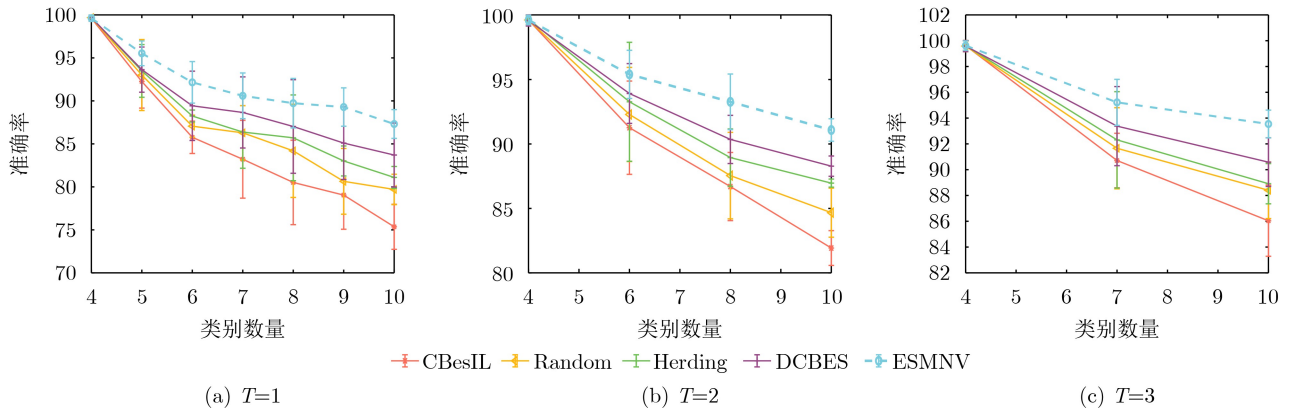


图6 各方法在不同增量步长  $T$  条件下的平均增量准确率

表1 保留样例数量为5时的增量识别准确率(%)

模型	4	5	6	7	8	9	10
CBesIL	99.62	79.96	67.23	58.44	53.88	47.93	41.88
Random	99.62	83.32	69.98	61.56	56.73	49.96	47.21
Herding	99.62	83.92	71.77	61.95	58.67	52.16	51.04
DCBES	99.62	83.09	71.90	65.07	59.54	55.27	54.42
ESMNV	99.62	87.15	75.60	69.32	66.95	61.90	60.49

表2 保留样例数量为10时的增量识别准确率(%)

模型	4	5	6	7	8	9	10
CBesIL	99.62	89.13	80.10	74.44	70.58	68.63	65.31
Random	99.62	90.09	80.46	78.05	73.25	70.38	68.68
Herding	99.62	89.68	83.64	79.08	76.20	74.33	71.10
DCBES	99.62	91.33	85.08	81.67	79.12	77.69	75.97
ESMNV	99.62	92.87	86.03	85.40	83.53	81.62	81.05

表3的结果进一步验证了这一趋势。当每类保留的样本数量增至15时，ESMNV方法相对于CBesIL, Random, Herding和DCBES的增量识别率分别提高了6.92%, 4.80%, 3.80%和2.43%。

接下来是关于SAR-AIRcraft-1.0以及OpenSARShip数据集的试验。由于这两个数据集类别数量较少，所以只进行不同保留样例下的试验。首先关于SAR-AIRcraft-1.0数据集，由于该数据集与其他两个数据集相比具有更大的类内变化，因此本文选择保留更多的样本，例如 $m = 10, 20, 30$ ，以提高基线识别率。

增量试验从4类开始，然后增量学习到6类。图7展示了各方法增量识别率的比较情况。从图7可以

看出，由于该数据集属于关于飞机的细粒度SAR数据集，因此类间变化更小，并且由于SAR图像的高类内变化，增量方法在该数据上的表现不如MSTAR。然而与其他样例选择方法相比，所提方法ESMNV仍然实现了最佳结果。对于OpenSARShip数据集，由于该数据集只有4个类，因此初始训练类设置为2类，然后模型增量训练到4类。图8展示出在不同保存样例数量 $m = 5, 10, 15$ 下每种方法的增量识别准确率。从中可以看出，所提方法ESMNV仍然达到了最好的结果。

综上所述，ESMNV方法在不同数量的初始类别、不同增量步长和不同样例保存条件下均表现出最佳效果。相较于其他算法，ESMNV的有效性主

表 3 保留样例数量为15时的增量识别准确率(%)

模型	4	5	6	7	8	9	10
CBesIL	99.62	92.25	85.76	83.21	80.51	79.04	75.35
Random	99.62	93.00	87.06	86.28	84.19	80.64	79.70
Herding	99.62	93.48	88.24	86.37	85.70	83.01	81.10
DCBES	99.62	93.63	89.42	88.65	87.02	85.09	83.70
ESMNV	99.62	95.53	92.15	90.59	89.73	89.28	87.31




图 7 各方法在SAR-AIRcraft-1.0上不同保存样例 $m$ 条件下的平均增量准确度




图 8 各方法在OpenSARShip上不同保存样例 $m$ 条件下的平均增量准确率

要体现在其从全局分布的角度出发,通过最小化挑选样例的分布与目标分布之间的差异,确保了其在增量学习任务中的优异性。考虑到类别信息主要由类别分布决定,ESMNV采用了基于MMD相似性的挑选框架,通过基于贪心算法的挑选策略,旨在实现挑选样例的分布与目标类别分布之间的最小差异,这有助于充分还原原始类别分布,并确保挑选样例的多样性。

## 5 结论

针对SAR目标增量识别中的样例挑选问题,本文提出一种基于最大化非重合体积的样例挑选算法(ESMNV)。本文将样例挑选问题转化为样本体积的逐渐增长问题,并通过贪心算法实现样例非重合体积的最大化。与其他方法相比,ESMNV方法能最大限度地保留目标类的分布信息。为了验证所提方法的有效性,本文在MSTAR, SAR-AIRcraft-1.0和OpenSARShip 3个数据集上进行了实验,实验表明所提出的方法ESMNV在所有条件下都优于其他样例挑选方法。为了更形象地展示挑选样例的分布,本文利用凸包和维诺图分析了所选样本的分布,并发现最大化样例非重合体积的本质上是基于目标拓扑的均匀采样。

## 参考文献

- [1] LI Jianwei, YU Zhentao, YU Lu, *et al.* A comprehensive survey on SAR ATR in deep-learning era[J]. *Remote Sensing*, 2023, 15(5): 1454. doi: [10.3390/rs15051454](https://doi.org/10.3390/rs15051454).
- [2] WANG Chengwei, 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).
- [3] 徐丰, 王海鹏, 金亚秋. 深度学习在SAR目标识别与地物分类中的应用[J]. *雷达学报*, 2017, 6(2): 136–148. doi: [10.12000/JR16130](https://doi.org/10.12000/JR16130).  
XU Feng, WANG Haipeng, and JIN Yaqiu. Deep learning as applied in SAR target recognition and terrain classification[J]. *Journal of Radars*, 2017, 6(2): 136–148. doi: [10.12000/JR16130](https://doi.org/10.12000/JR16130).
- [4] CARUANA R. Multitask learning[J]. *Machine Learning*, 1997, 28(1): 41–75. doi: [10.1023/A:1007379606734](https://doi.org/10.1023/A:1007379606734).
- [5] MCCLOSKEY M and COHEN N J. Catastrophic interference in connectionist networks: The sequential learning problem[J]. *Psychology of Learning and Motivation*, 1989, 24: 109–165. doi: [10.1016/S0079-7421\(08\)60536-8](https://doi.org/10.1016/S0079-7421(08)60536-8).
- [6] CHAUDHRY A, DOKANIA P K, AJANTHAN T, *et al.* Riemannian walk for incremental learning: Understanding forgetting and intransigence[C]. Proceedings of the 15th European Conference on Computer Vision (ECCV), Munich, Germany, 2018: 556–572. doi: [10.1007/978-3-030-01252-6\\_33](https://doi.org/10.1007/978-3-030-01252-6_33).
- [7] DANG Sihang, CAO Zongjie, CUI Zongyong, *et al.* Class boundary exemplar selection based incremental learning for automatic target recognition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(8): 5782–5792. doi: [10.1109/TGRS.2020.2970076](https://doi.org/10.1109/TGRS.2020.2970076).
- [8] MITTAL S, GALESSO S, and BROX T. Essentials for class incremental learning[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, USA, 2021: 3528–3517. doi: [10.1109/CVPRW.53098.2021.00390](https://doi.org/10.1109/CVPRW.53098.2021.00390).
- [9] REBUFFI S A, KOLESNIKOV A, SPERL G, *et al.* iCaRL: Incremental classifier and representation learning[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, USA, 2017: 5533–5542. doi: [10.1109/CVPR.2017.587](https://doi.org/10.1109/CVPR.2017.587).
- [10] DE LANGE M, ALJUNDI R, MASANA M, *et al.* A continual learning survey: Defying forgetting in classification tasks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(7): 3366–3385. doi: [10.1109/TPAMI.2021.3057446](https://doi.org/10.1109/TPAMI.2021.3057446).
- [11] LI Zhizhong and HOIEM D. Learning without forgetting[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(12): 2935–2947. doi: [10.1109/TPAMI.2017.2773081](https://doi.org/10.1109/TPAMI.2017.2773081).
- [12] RUSU A A, RABINOWITZ N C, DESJARDINS G, *et al.* Progressive neural networks[J]. arXiv: 1606.04671, 2016. doi: [10.48550/arXiv.1606.04671](https://doi.org/10.48550/arXiv.1606.04671).
- [13] RUDD E M, JAIN L P, SCHEIRER W J, *et al.* The extreme value machine[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(3): 762–768. doi: [10.1109/TPAMI.2017.2707495](https://doi.org/10.1109/TPAMI.2017.2707495).
- [14] SHAO Junming, HUANG Feng, YANG Qinli, *et al.* Robust prototype-based learning on data streams[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 30(5): 978–991. doi: [10.1109/TKDE.2017.2772239](https://doi.org/10.1109/TKDE.2017.2772239).
- [15] LI Bin, CUI Zongyong, CAO Zongjie, *et al.* Incremental learning based on anchored class centers for SAR automatic target recognition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5235313. doi: [10.1109/TGRS.2022.3208346](https://doi.org/10.1109/TGRS.2022.3208346).
- [16] BORGWARDT K M, GRETTON A, RASCH M J, *et al.* Integrating structured biological data by kernel maximum mean discrepancy[J]. *Bioinformatics*, 2006, 22(14): e49–e57. doi: [10.1093/bioinformatics/btl242](https://doi.org/10.1093/bioinformatics/btl242).

- [17] 王智睿, 康玉卓, 曾璇, 等. SAR-AIRcraft-1.0: 高分辨率 SAR飞机检测识别数据集[J]. 雷达学报, 2023, 12(4): 906–922. doi: [10.12000/JR23043](https://doi.org/10.12000/JR23043).  
WANG Zhirui, KANG Yuzhuo, ZENG Xuan, *et al.* SAR-AIRcraft-1.0: High-resolution SAR aircraft detection and recognition dataset[J]. *Journal of Radars*, 2023, 12(4): 906–922. doi: [10.12000/JR23043](https://doi.org/10.12000/JR23043).
- [18] HUANG Lanqing, LIU Bin, LI Boying, *et al.* OpenSARShip: A dataset dedicated to Sentinel-1 ship interpretation[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(1): 195–208. doi: [10.1109/JSTARS.2017.2755672](https://doi.org/10.1109/JSTARS.2017.2755672).  
coverage-based exemplar selection for incremental SAR automatic target recognition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5211713. doi: [10.1109/TGRS.2023.3293509](https://doi.org/10.1109/TGRS.2023.3293509).
- [19] LI Bin, CUI Zongyong, SUN Yuxuan, *et al.* Density

李 斌: 男, 博士生, 研究方向为SAR目标增量学习.

崔宗勇: 男, 博士, 研究方向为SAR目标检测.

汪浩瀚: 女, 硕士生, 研究方向为SAR目标增量学习.

周 正: 男, 博士生, 研究方向为小样本SAR目标检测.

田 宇: 男, 博士生, 研究方向为增量SAR目标检测.

曹宗杰: 男, 博士, 研究方向为SAR目标成像与识别.

责任编辑: 余 蓉