

doi: 10.7690/bgzdh.2024.01.008

基于深度学习的小样本目标检测综述

李海军¹, 孔繁程¹, 魏嘉彧², 林云³(1. 海军航空大学岸防兵学院, 山东 烟台 264001; 2. 中国人民解放军 92192 部队, 浙江 宁波 315100;
3. 烟台大学教务处, 山东 烟台 264005)

摘要: 针对在小样本情况下目标检测的问题, 对当前小样本条件下的目标检测方法进行归纳总结。列举 4 类小样本学习方法并介绍其优缺点, 介绍目前这几类方法的典型算法; 进行小样本目标检测实验设计, 通过分析各方法的特点得出其可应用方向; 对目前的小样本图像目标检测存在的问题进行讨论。结果表明, 该分析能为相关领域的研究者提供更多的思路。

关键词: 深度学习; 小样本; 目标检测

中图分类号: TP301.6 文献标志码: A

A Survey of Small Sample Object Detection Based on Deep Learning

Li Haijun¹, Kong Fancheng¹, Wei Jiayu², Lin Yun³(1. College of Coast Guard, Naval Aviation University, Yantai 264001, China;
2. No. 92192 Unit of PLA, Ningbo 315100, China;
3. Office of Academic Affairs, Yantai University, Yantai 264005, China)

Abstract: Aiming at the problem of target detection under the condition of small samples, the current target detection methods under the condition of small samples are summarized. This paper lists four kinds of small sample learning methods, introduces their advantages and disadvantages, and introduces the typical algorithms of these methods at present; carries out the experimental design of small sample target detection, and obtains the application direction by analyzing the characteristics of each method; discusses the existing problems of current small sample image target detection. The results show that the analysis can provide more ideas for researchers in related fields.

Keywords: deep learning; small sample; object detection

0 引言

精确的目标检测既是军事领域中实现获取敌方情报的手段^[1], 又是保护我国民用领域自动驾驶、人脸识别^[2]的基础。近年来, 随着深度学习持续发展, 不断提出新的目标检测模型, 从 AlexNet^[3]到 ResNet^[4]以及 GoogleNet^[5]等。为了追求精度, 这些模型往往运算量巨大, 且需要大量的标注图像来进行模型训练^[6]。在现实中应用深度学习检测算法时, 会存在很多问题。现实中的图像背景总会比公开数据集中的更为复杂, 如各个目标相互的遮挡、环境的干扰、目标不断变化的角度等问题。公开数据集中只能覆盖现实场景中的少部分, 只有动用大量的人力、物力进行目标数据采集并且进行标注^[7], 才能获取到覆盖面如此之广、物体种类丰富齐全的数据集。随着物体的类型不断增多, 使用深度学习算法检测识别新型目标时, 必须提供大量高质量标注数据, 这对情报获取能力要求较高。可见, 使用小样本少标签数据对深度学习模型进行训练很重要。近年来, 基于小样本的目标检测技术不断受到

关注, 不需要监督学习中利用大量标注数据进行模型的训练, 只通过少量新类别的标注数据, 对模型结构重新设计, 进而实现迁移到新领域的目标。小样本模型的训练更类似于人类的学习过程^[8], 不需要长时间计算, 整个过程是轻量的, 只需要通过几个样本的学习就可以识别检测出目标^[9-10]; 因此, 设计出更合理的算法, 解决在数据不足的条件下, 保证目标检测识别的性能, 具有重要的实用价值。

基于小样本的图像目标检测是将小样本学习^[11-14]技术应用至当前目标检测技术中, 能够通过小样本训练出具有一定泛化能力的模型。笔者对小样本目标检测的任务进行描述, 对现有的小样本学习算法进行介绍, 对当前存在的问题提出建议及展望, 以期为相关领域的研究者提供更多的思路。

1 小样本目标检测算法

小样本目标检测主要解决在标注数据不足的情况下, 能在图像中确定目标种类并精准定位目标。这里可以看到问题是集中在数据上的, 现有的解决

收稿日期: 2023-09-20; 修回日期: 2023-10-25
第一作者: 李海军(1965—), 男, 山东人, 博士。

方法本质上可以看成是通过构建数据、模型和算法之间的联系，在有限的标注数据基础上完成检测任务。按照目前网络结构和思想来划分，主要包括：基于数据增强的方法、基于度量学习的方法、基于微调的方法和基于元学习的方法。

1.1 基于数据增强的方法

数据增强在提高模型的性能上具有很好的作用，尤其数据量不足、类别不丰富的情况下，通过数据增强的手段能够很好地解决。利用新类别的数据进行数据增强^[15]，生成伪数据来补充原数据集，以此构建常规数据集，再利用该数据集进行模型训练，将小样本目标检测问题转变为常规目标检测问题。目前，按照伪数据的生成方式可划分为 3 种。

1.1.1 常规图像生成

通过简单的图像变换，例如添加高斯噪声，对图像进行剪切^[16]、旋转^[17]、翻转^[18]标注框变换等基础操作，从而使原数据集图像更加丰富；但是这些简单的传统图像变换在对新类别数据操作时，数据量过少，无法真正有效地帮助模型区分出新类别数据间的差异，难以提升小样本目标检测任务的性能。

1.1.2 基于生成式对抗网络图像生成

生成对抗网络(generative adversarial network, GAN)主要是通过生成器和判别器相互博弈的过程，双方不断进行优化，最终能够实现将高斯噪声变成类似于原数据集中的图像。过程通常如下：将高斯噪声以及类别确定的图片输入至生成式对抗网络或者其变形，循环一致生成式对抗网络、条件生成对抗网络等，然后根据图像的类别进行损失函数的设计。英伟达公司在 2019 年提出了继 ProGAN^[19]后又一能够生成高分辨率图像的网络模型 StyleGAN^[20]，性能远优于前者。该方法通过输入可学习常量，能够控制多尺度条件下图像特征的变化。经实验证明，该算法在高分辨率图像生成以及风格迁移等任务中均有较好的表现。文献[21]提出了一种解决小样本问题的通用框架 MetaGAN，该方法将生成式对抗网络与小样本学习结合，无论是在有监督还是半监督的条件下，都能改善小样本学习的模式，使不同类别有更好的决策边界。

1.1.3 基于语义空间增强的图像生成

有些算法将利用语义完成增强^[22-24]，通过将图像的类别语义信息作为先验信息，利用语义空间来

对图像进行数据增强。文献[25]设计了能够将视觉特征同语义特征相互转换编码结构，对主干网络提取出的多级特征进行编码，经过一系列操作将特征映射到语义空间并进行标签对齐；然后在语义空间中对相近语义特征施加高斯噪声后，输入至解码器进行解码，再进行卷积、最大池化等操作，最终得到伪数据。文献[26]提出基于 GauGAN 的语义图像合成方法，其结构如图 1 所示，通过语义图和自然图像一起训练网络，由图像编码器完成隐空间的生成，再同语义图一起生成图像。

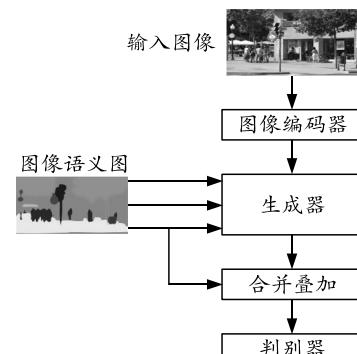


图 1 GauGAN 网络结构

综合来讲，数据增强的方法非常直观、容易理解，通过对模型进行伪图像的生成，将其作为数据的一部分，再对扩充后的数据进行训练，以此获得更优的检测效果。数据增强的方法还具有很大的潜力，针对不同的背景，如何设计更加合理图像生成方法，如何融入其他算法能够充分利用原数据集等问题都值得探索。

1.2 基于度量学习的方法

度量学习^[27]是通过求解数据的相似程度的小样本学习方法。求解数据的相似程度是聚类以及分类等机器学习任务中重要一环；因此，度量学习的研究十分重要。度量学习的思路是通过每一类的小样本数据，得到特征空间，空间中可以更好地获得样本之间的相似度。不同的任务中会用不同的目标函数，如使用孪生网络(siamese network)^[28]、原型网络^[29]、匹配网络^[30]等，为合理表示相互匹配度量标度，分别使用 L_1 距离、欧式距离和余弦相似度进行度量标度不同的度量。

1.2.1 孪生网络

孪生网络是一项仅需要少量学习的监督模型，能够量化输入图像间的相似度。其结构如图 2 所示，通过输入 2 幅比较相似的图像，利用孪生网络中 2 组相同的卷积神经网络进行分类，其本质上等同于

二分类器, 利用标签值为0~1之间, 0和1分别表示不同类和同类。孪生网络一般采用 L_1 距离度量2幅图像在特征空间中的相似度:

$$d = \mu \left(\sum_{i=1}^n k_n |y_1^{(n)} - y_2^{(n)}| \right). \quad (1)$$

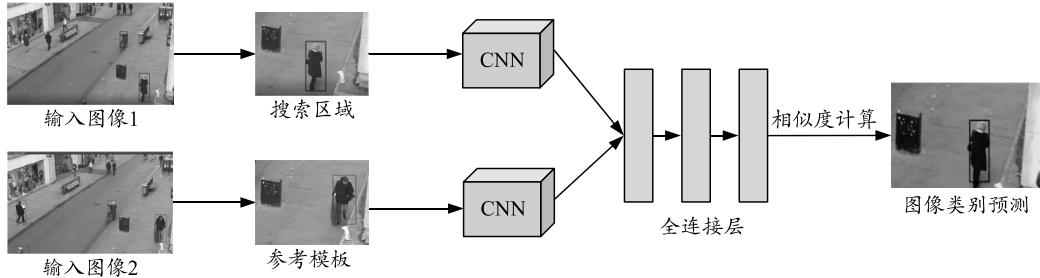


图2 孪生神经网络结构

1.2.2 原型网络

Snell 提出新的度量学习模型—原型网络 (prototype network)。首先将支持集中的样本利用一个嵌入函数进行图像空间到特征空间映射的学习; 再将特征空间映射回原型空间中, 将其作为样本的原型, 对图像进行测试时, 借助欧式距离对比每个中心的距离得出类别的结论; 随后尝试将其应用在零样本学习中。与小样本学习正好相反, 这一类问题一般不提供数据信息, 但是会提供目标域的语义信息。零样本学习不用数据集中的图像监督信息, 通过提供的语义信息找到每一类别的语义向量, 将其作为该类别的原型, 后续过程同小样本学习一致; 因此, 原型网络相似度求解过程分为2步: 1) 获取数据中的每一类特征原型; 2) 对待检测图像进行距离度量得到分布概率。

原型网络相对于其他小样本学习方法更简单, 易于实现, 模型可以看作是广义线性模型, 在通用数据集有较好的效果; 因此, 小样本目标检测可以借鉴其相似度度量的研究成果。

1.2.3 匹配网络

匹配网络 (match network) 模型创新地将记忆网络和注意力机制引入其中, 网络的学习速度得到大大加快, 匹配网络的主要思路是通过一个通用的框架将图像映射至一个被封装了标签的嵌入空间, 通过双向长短时记忆网络^[31]来对数据的特征进行更有效的表示, 通过注意力机制建立待测数据以及训练集间的联系, 对少量已标注数据和大量无标注数据进行训练, 通过训练数据来模仿目标进行小样本学习任务的过程, 以此确保训练测试场景等条件相同, 利用余弦相似度作为度量方法, 完成图像分类

式中: d 为图像的相似度; μ 为归一化系数; n 为特征空间中包含的特征个数; k_n 为比例系数。通常孪生网络会根据任务背景对损失函数重新设计, 在损失函数中引入了正则项, 使网络训练得到的特征空间能够让同类型样本的相似度更接近 1。

和检测任务。

基于度量学习的方法通过把目标集和支持集映射至同一空间中, 引入基于距离的损失函数或者求解相似度对目标进行分类, 并能实现小样本图像目标检测。在实现度量学习的同时, 一般亦可实现增量式学习, 即可在训练之后学习到在旧任务中学到的先验知识, 可以共享其中的参数, 模型的性能得到进一步提升。

1.3 基于微调的方法

当前, 目标检测算法都需要在规模较大的数据集上进行训练, 通过预训练模型训练别的数据集, 再使用迁移学习^[32]进行微调后, 将预训练学习到的先验知识弥补小样本学习时缺失数据, 会导致模型训练出现问题。近几年来, 人工智能方法的检测效果越来越好, 下面对微调方法的有效性^[33]以及如何在小样本学习中应用进行描述。

目标检测领域中卷积神经网络是构成网络结构中基础的结构, 卷积神经网络是由卷积层和全连接层等堆叠而成, 网络结构的复杂度由网络深度决定^[34], 从图像的浅层开始由浅到深提取特征, 浅层提取出图像的通用特征; 因此, 对于目标检测的任务来说, 通用特征基本一致, 相关的网络参数可以共享, 深层提取出图像的特定特征, 表征各幅图像的特点, 后续又会进行任务的编码, 不可再使用预训练模型参数。下面对当前基于小样本微调方法进行介绍。

基于微调的方法是先将大量样本集作为训练集进行预训练, 然后通过目标域构建的支持集以及源域数据的训练集, 确定底层不变参数的层数, 对在预训练模型上的网络高层进行微调。小样本数据集

的监督信息很少，如此操作模型非常容易导致过拟合^[35]，造成目标检测的精度大幅降低。文献[36]和[37]通过一系列操作降低模型过拟合程度但效果不够明显，文献[38]提出一种新的基于小样本的微调方法(low shot transfer detector, LSTD)，将正则化与微调相结合，通过正则化的约束有效降低模型过拟合造成的影响，通过提出知识迁移和背景抑制正则化，分别利用源领域和目标领域的目标知识，以进一步增强对少量目标图像的微调，使用的损失函数如下：

$$L_{\text{total}} = L_{\text{main}} + \lambda_{BD} L_{BD} + \lambda_{TK} L_{TK}。 \quad (2)$$

式中： L_{total} 为多层边界框回归和目标分类的损失总和； L_{main} 为基于微调造成的损失； L_{BD} 和 L_{TK} 分别为背景抑制损失项和知识迁移损失项； λ_{BD} 和 λ_{TK} 分别为 L_{BD} 和 L_{TK} 的系数。经实验证明，在小样本分类和检测的问题上，基于背景抑制正则化和知识迁移的方法性能表现更佳。

文献[39]提出一种将对比学习引入至建议目标框编码中，通过感知对象来提高检测到对象分类的精度，在进行小样本目标检测时仍存在着由于新类别特征不足无法将其与基类中的样本区分出来，然后被划归为一类的问题。本文中通过引入对比建议编码的损失函数解决了此问题。损失函数如下：

$$L_{\text{CPE}} = \frac{1}{N} \sum_{i=1}^N f(x_i) \cdot L_{y_i}; \quad (3)$$

$$L_{y_i} = \frac{1}{1 - N_{z_i}} \sum_{j=1, j \neq i}^N \Pi\{z_i = z_j\} \cdot \log \frac{\exp(\tilde{y}_i \cdot \tilde{y}_j / \tau)}{\sum_{k=1}^N \Pi_{k \neq i} \cdot \exp(\tilde{y}_i \cdot \tilde{y}_k / \tau)}。 \quad (4)$$

式中： N 为一个小批量的样本数； i 为图像中第 i 个区域； x_i 为相匹配的检测框； y_i 为第 i 个区域对比头部编码特征； Z_i 为标注框的标签； N_{z_i} 为与 Z_i 相同标签的个数； τ 为超参数温度。由于对比建议编码损失能够提高实例中类内的紧密程度以及各类间的方差大小，以此来解决该问题。

基于微调及其改进的方法相对简单，训练有效，在基于小样本条件下能够获得良好的性能，但此种方法仍存在一些缺点：

1) 通过何种方法来确定类内区分以及同类别无关的参数和模型的超参数。

2) 随着网络不断变深，模型的编码信息变得更复杂，微调部分的确定也会变得更复杂，文献[40]提出搜索的方法，基于进化搜索算法找到最佳策略，以此来解决哪些需要微调、哪些不需要的问题。

1.4 基于元学习的方法

笔者希望通过人工智能来学习能够具有泛化能力的技能，而不是每次任务都需要从头开始训练，即能根据以前技能学习时积累的经验，汲取知识快速获取新技能，此方法称为元学习。元学习是机器学习中的一个重要分支。从其定义看，元学习既需要能够在记忆中可靠稳定地表达，又要保证可以选择性访问确定信息。

文献[41]在文中提出递归记忆模型(memory augmented neural network, MANN)，模型结构如图 3 所示。该模型基于神经图灵机的思想，具有较大内存容量的体系结构，通过外部存储提供短时记忆的功能，然后缓慢进行权值更新至长时记忆，以此来将学习到的知识存入记忆模块；同时，利用余弦相似度度量，通过这些知识来进行预测分布。基于神经图灵机的思想不仅能够实现快速编码，而且可加强检索新信息的能力。

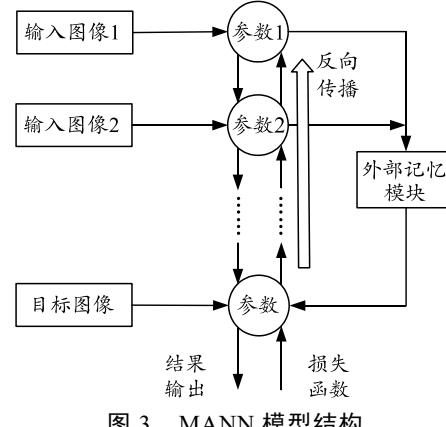


图 3 MANN 模型结构

文献[42]将元学习的方法引入到当前目标检测最流行的算法 DETR 中，提出基于元学习的小样本目标检测算法 Meta-DETR。Meta-DETR 专注于图像层面，没有区域建议框，不会存在不准确建议的情况；同时，在前馈网络中，可同时处理多类别以保证类间相关性的获取，减少相似类别误分类的情况。

基于元学习的方法是当前机器学习研究的热点之一，但目前仍存在问题。基于元学习的算法调参较难，再进行任务更替不断训练模型时，任务之间的相关数据分布不相同，如不对模型的参数进行调整，模型可能存在不收敛的情况。

2 实验对比

当前公开数据集中主要使用 PASCAL VOC 数据集^[43]和 MSCOCO 数据集^[44]进行小样本图像的目标检测，VOC 数据集有 VOC 2007 和 VOC 2012

2种。本次实验采用 VOC 2007 版本, 数据集中共包含数据类型 20 种, 图像数量 9 963 张, 目标数量 24 640 个。笔者将 20 个种类的数据进行划分, 将鸟类、船、自行车、瓶子 4 类作为验证集, 将公交车、猫、汽车、椅子 4 类作为测试集, 其余各类作为训练集。表 1 对比了当前典型小样本目标检测算

法在 VOC 数据集上的性能表现。表中的基本架构是模型的神经网络框架, a -way b -shot 的数据类型^[45]含义是训练集中随机抽取总共 a 个种类, 每个类别的标注数据有 b 个情形下构成模型的支撑集。表 1 中的检测精度值均经过 3 次实验取平均值得到最终结果。

表 1 典型小样本目标检测模型检测结果

| 方法 | 模型 | 基本架构 | 1-way 1-shot | 1-way 5-shot | 5-way 1-shot | 5-way 5-shot |
|------|-------------------|-----------|--------------|--------------|--------------|--------------|
| 数据增强 | GauGAN | Conv-4 | 49.2 | 64.3 | 43.7 | 58.8 |
| | Siamese Network | Conv-4 | 47.4 | 56.2 | 40.1 | 53.2 |
| 度量学习 | Prototype Network | Conv-4 | 44.9 | 57.4 | 38.5 | 56.7 |
| | Match Network | Conv-4 | 43.0 | 52.4 | 34.8 | 47.3 |
| 微调 | LSTD | WRN-28-10 | 51.2 | 68.7 | 46.0 | 61.9 |
| 元学习 | MANN | Conv-4 | 47.8 | 60.1 | 38.9 | 55.3 |

从上表中的实验结果可得, 在进行不同模型且使用不同架构的情况下, 对小样本数据进行深度特征提取, LSTD 的检测精度要比其他算法略高一些; 所以, 通过正则化的约束能够有效解决模型的过拟合问题, 并且由于其基本架构为 WRN-28-10, WRN-28-10 是一种深度卷积模型, 基于 ResNet 模型的架构进行改进, 其算法性能尤其是算法检测速度方面有着优异的表现, 表中的结果亦能看出其表现最突出。从表中可以发现: 其余模型的基本架构均为 Conv-4, 更具对比价值, Conv-4 是一种小样本学习结构, 通过使用 4 层卷积层以及进行归一化等操作构成的简单模型来实现小样本学习的迁移学习功能; 基本架构为 Conv-4 中基于度量学习中 Siamese Network 的总体表现最好, 且在 1-way 5-shot 和 5-way 1-shot 的背景下精度较高。而 Prototype Network 在 1-way 5-shot 和 5-way 5-shot 的背景下, 相对来说检测精度有较好的结果。从表中可以看出基于元学习的方法, 取得了不错的效果, 因此, 可以通过改善训练的不稳定性来提升模型的整体性能。

3 应用前景展望

3.1 Sar 图像小样本目标检测

Sar 图像的生成是通过一种微波遥感传感器来完成, 其特点是不受光照和天气影响, 保持全天时、全天候和多尺度的目标检测能力; 因此, 在军事背景下的舰船目标检测任务或是民用背景下在海洋监控等任务中被广泛应用。遥感数据集的获取难度较大, 如何能够在减少对样本数量的情况下也能保持较高水平的检测能力; 因此, 通过小样本学习来降低对样本的依赖程度具有较高实用价值。在军事背

景下, 可供进行目标检测任务的标注数据较少, 针对新的军事检测目标, 通过常规的数据获取手段需要耗费大量的人力、物力。通过小样本图像检测的手段进行模型设计, 可通过数据增强的手段进行数据扩充或是基于迁移学习的方法对模型进行在线微调, 仅需少量的标注样本即可完成任务。

3.2 多模态信息融合检测

当前针对小样本问题, 大多是以单一模态的信息完成检测任务。多模态是表示不同类型的信息, 比如文本、图像、音频等, 还有一些是通过多模态的信息完成小样本的目标检测, 如文献[46]基于一种对齐变分自编码器来融合信息, 其将语义信息中的标签、属性、自然语言描述同图像一起融合, 最终得到更好的重建结果, 即通过部分视觉模态信息, 然后在文本中又会有关于图像信息的描述, 这样就能够增加检测时的先验知识, 并可以提供图像数据的监督信息。

3.3 工业缺陷检测

在数据充足的条件下, 缺陷检测算法已比较成熟, 算法精度基本能够满足需求, 但工业应用的背景中, 经常出现样本缺失的情况; 因此, 基于小样本的条件下缺陷检测十分重要。文献[47]提出生成医学图像的方法, 在基于 DCGAN 的架构下, 完成对数据种类以及数量的扩充。这种小样本缺陷检测的解决思路通过进行样本生成, 将问题转化成常规问题。还有一类通过无监督学习基于特征的缺陷检测方法。文献[48]提出新的缺陷检测方法—深度支持向量数据描述 (deep support vector data description, DSVDD), 通过引入一类无监督分类目标, 优化数据封闭的输出空间然后提取出公共变异

因子，计算出样本边界得到缺陷样本。

4 存在的问题及发展趋势

小样本学习在图像分类和识别的研究发展较快，并取得一些成果，目标检测相关任务不需要获取语义信息，还要得到位置信息，所以目标检测相关任务难度相对大一些，目前应用还相对较少，相关领域的研究仍处于探索状态，并存在一些问题没有解决。

1) 理论缺乏可解释性。

在使用迁移学习进行微调以及使用元学习来解决小样本问题时均存在如何使用理论来解释算法有效性的问题^[49]。神经网络也存在这个问题^[50]，如无法通过理论进行指导，在小样本条件下如何能够更好地得到位置信息，在特征提取时如何能够保证语义信息的获取更加准确。通过针对目标检测特有的问题来进行研究，然后再对理论进行完善。

2) 缺少目标检测数据集。

相对于数据分类以及其他深度学习问题的数据集，针对目标检测数据集的研究较少，导致使用迁移学习进行微调时可供选择的数据集有限。目前，多数研究首先进行数据扩充之后完成小目标检测任务。如文献[51]提出将数据增强作为离散优化问题，引入了维护检测框位置和失真图像之间一致性的额外复杂性用来完成数据扩充。

3) 元学习难以实践应用。

元学习十分重视对于任务和数据的双重采样，通过算法在训练和学习解决任务过程中得到的经验，但如果训练时的任务和最终任务关联不强，或者是需要高成本来确定任务关联性的情况下，通过元学习学习的经验可能会使效果适得其反。另外，如何保证模型不会遗忘之前任务学习到的信息也是个问题^[52]，一般随着元学习模型不断进行迭代，保留的信息会越来越少。再者，进行多目标检测时使用元学习的方法效果较差，泛化能力不强。需要在理论以及在实践应用中多进行探索发展，可借鉴注意力机制等方法提升性能。

5 结论

目前，小样本学习研究逐渐被研究人员所关注，其应用领域众多，发展前景广阔，但现有小样本学习技术难以满足现实需求，性能有待提高。笔者将当前基于小样本学习的目标检测方法划分为基于数据增强、度量学习、微调、元学习 4 类，对各类方

法的应用情况以及应用场景举例进行叙述，对小样本在目标检测方向上的应用前景进行展望，分析小样本当前在各个层次存在的问题并提出改进方法。

参考文献：

- [1] 张方宇. 机器视觉技术军事应用文献综述[J]. 兵工自动化, 2019, 38(2): 16-20.
- [2] TAIGMAN Y, YANG M, RANZATO M A, et al. Deepface: Closing the gap to human-level performance in face verification[C]// Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2014: 1701-1708.
- [3] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]// Advances in Neural Information Processing Systems. NIPS, 2012: 1097-1105.
- [4] 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. IEEE, 2016: 770-778.
- [5] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2015: 1-9.
- [6] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. MIT press, 2016.
- [7] WANG Y, GIRSHICK R, HEBERT M, et al. Low-shot learning from imaginary data[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 18326085.
- [8] VANSCHOREN J. Meta-learning: A survey[J]. ArXiv, 2018(10): 1810. 03548.
- [9] TURK M A, PENTLAND A P. Face recognition using eigenfaces[C]// Proceeding of 1991 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 1991: 585-591.
- [10] KINGMA D P, MOHAMED S, REZENDE D J, et al. Semi-supervised learning with deep generative models[C]// Advances in Neural Information Processing Systems. NIPS'14, 2014: 3581-3589.
- [11] GARCIA V, BRUNA J. Few-shot learning with graph neural networks[J]. ArXiv, 2017: 1711. 04043v1.
- [12] DUAN Y, ANDRYCHOWICZ M, STADIE B, et al. One-shot imitation learning[C]// Advances in Neural Information Processing Systems. ArXiv, 2017: 1087-1098.
- [13] ORECHKIN B, LOPEZ P R, LACOSTE A. Tadam: Task dependent adaptive metric for Improved few-shot learning[C]// Advances in Neural Information Processing Systems. NIPS, 2018: 721-731.
- [14] REN M, TRIANTAFILLOU E, RAVI S, et al. Meta-learning for semi-supervised few-shot classification[J]. ArXiv, 2018(3): 1803. 00676v1.
- [15] VAN D D A, MENG X L. The art of data augmentation[J]. Journal of Computational and Graphical Statistics, 2001,

- 10(1): 1–50.
- [16] SHYAM P, GUPTA S A. Attentive recurrent comparators[C]// Proceedings of the 34th International Conference on Machine Learning. IEEE, 2017: 3173–3181.
- [17] GARCIA V, BRUNA J. Few-shot learning with graph neural networks[J]. ArXiv, 2017(11): 1711. 04043.
- [18] QA H, BROWN M, LOWE D G. Low-shot learning with imprinted weights[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 5822–5830.
- [19] KARRAS T, AILA T, LAINE S, et al. Progressive growing of gans for improved quality, stability, and variation[J]. ArXiv, 2017(11): 1710. 10196.
- [20] KARRAS T, LAINE S, AILA T. A style-based generator architecture for generative adversarial networks[C]// Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. IEEE, 2019: 4401–4410.
- [21] ZHANG R, CHE T, GHAHRAMANI Z, et al. Metagan: An adversarial approach to few-shot learning[C]// NIPS'18: Proceedings of the 32nd International Conference on Neural Information Processing Systems. NIPS, 2018: 2371–2380.
- [22] RAHMAN S, KHAN S H, BARNES N, et al. Any-shot object detection[C]// Proceedings of the Asian Conference on Computer Vision. IEEE, 2020: 89–106.
- [23] WU A, HAN Y, ZHU L, et al. Universal-prototype augmentation for few-shot object detection[J]. ArXiv, 2021(3): 2103. 01077.
- [24] ZHU C, CHEN F, AHMED U, et al. Semantic relation reasoning for shot-stable few-shot object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 8782–8791.
- [25] CHEN Z, FU Y, ZHANG Y, et al. Multi-level semantic feature augmentation for one-shot learning[J]. IEEE Transactions on Image Processing, 2019, 28(9): 4594–4605.
- [26] PARK T, LIU M Y, WANG T C, et al. Semantic image synthesis with spatially-adaptive normalization[C]// Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. IEEE, 2019: 2337–2346.
- [27] DAVIS J V, KULIS B, JAIN P, et al. Information-theoretic metric learning[C]// Proceedings of the 24th international conference on Machine learning. IEEE, 2007: 209–216.
- [28] KOCH G, ZEMEL R, SLAKHUTDINOV R. Siamese neural networks for one-shot image recognition[C]// ICML deep learning workshop. ICML, 2015: 1–8.
- [29] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C]// NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems. NIPS, 2017: 4080–4090.
- [30] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[C]// NIPS'16: Proceedings of the 30th International Conference on Neural Information Processing Systems December. NIPS, 2016: 3637–3645.
- [31] HUANG Z, XU W, YU K. Bidirectional LSTM-CRF models for sequence tagging[J]. ArXiv, 2015(8): 1508. 01991.
- [32] LU H, ZHANG L, CAO Z, et al. When unsupervised domain adaptation meets tensor representations[C]// Proceedings of the IEEE international conference on computer vision. IEEE, 2017: 599–608.
- [33] WANG X, HUANG T, GONZALEZ J, et al. Frustratingly simple few-shot object detection[C]// Proceedings of the 37th International Conference on Machine Learning. IEEE, 2020: 9919–9928.
- [34] LEE H, GROSSE R, RANGANATH R, et al. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations[C]// Proceedings of the 26th annual international conference on machine learning. IEEE, 2009: 609–616.
- [35] ZHANG J Y, CHEN Z L, HUANG J Y, et al. Few-shot domain adaptation for semantic segmentation[C]// Proceedings of the ACM Turing Celebration Conference. ACM, 2019: 1–6.
- [36] KKANG B Y, LIU Z, WANG X, et al. Few-shot object detection via feature reweighting[C]// IEEE/CVF International Conference on Computer Vision. IEEE, 2019: 8419–8428.
- [37] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 779–788.
- [38] CHEN H, WANG Y, WANG G, et al. Lstd: A low-shot transfer detector for object detection[C]// Proceedings of the AAAI conference on artificial intelligence. AAAI, 2018: 1–6.
- [39] SUN B, LI B, CAI S, et al. FSCE: few-shot object detection via contrastive proposal encoding[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 7352–7362.
- [40] SHEN Z, LIU Z, QIN J, et al. Partial is better than all: Revisiting fine-tuning strategy for few-shot learning[C]// Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2021: 9594–9602.
- [41] SANTORO A, BARTUNOV S, BOTVINICK M, et al. Meta-learning with memory-augmented neural networks[C]// International conference on machine learning. PMLR, 2016: 1842–1850.
- [42] ZHOU X, WANG D, KRÄHENBÜHL P. Objects as points[J]. ArXiv, 2019(4): 1904. 07850.
- [43] EVERINGHAM M, VAN G L, WILLIAMS C K I, et al. The pascal visual object classes (VOC) challenge[J]. International Journal of Computer Vision, 2010, 88(2): 303–338.
- [44] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft COCO: common objects in context[C]// Proceedings of the European Conference on Computer Vision. Cham: Springer, 2014: 740–755.

- [45] HILLIARD N, PHILLIPS L, HOWLAND S, et al. Few-shot learning with metric-agnostic conditional embeddings[J]. ArXiv, 2018(2): 1802. 04376.
- [46] SCHWARTZ E, KARLINSKY L, FERIS R, et al. Baby steps towards few-shot learning with multiple semantics [J]. ArXiv, 2019: 1906. 01905.
- [47] FRID A M, KLANG E, AMITAI M, et al. Synthetic data augmentation using GAN for improved liver lesion classification[C]// 2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018). IEEE, 2018: 289–293.
- [48] RUFF L, VANDERMEULEN R, GOERNITZ N, et al. Deep one-class classification[C]// International conference on machine learning. PMLR, 2018: 4393–4402.
- [49] FRANCESCHI L, FRASCONI P, SALZO S, et al. Bilevel programming for hyperparameter optimization and
-

(上接第 22 页)

以此参数进行开合弹及批量实弹装药 CT 检查, 未发现肉眼可见装药缺陷, 装药质量和装药密度稳定可靠。

同理, 对于另一更大口径型号弹药, 求得该 DNAN 基熔铸炸药在弹药中圆柱部与头弧部交界处冷却液面上升速度的近似解为:

$$v_{\text{液}} = 0.005k. \quad (11)$$

取 k 值为 9.6, 可以得出 DNAN 基熔铸炸药在该型弹药中梯度护理凝固的部分参数如表 3 所示。

表 3 部分梯度护理凝固计算参数 mm/s

| 梯度位置 | 冷却液面上升速度 |
|------|----------|
| 尾部 | 0.048 |
| 圆柱部 | 0.048 |
| 头弧部 | 0~0.048 |

受限于工装、设备等因素, 未进行该种弹药的装药验证, 但对比与其性质类似的 B 炸药装药, 该参数值是相差不大的, 也可说明参数的合理性。

6 结论

通过梯度划分, 采取控制冷却液面上升速度、温度等手段, 使装药在易产生装药缺陷的位置不产生装药缺陷, 进而得到高质量药柱的梯度护理凝固技术方法, 是可行的, 其装药质量稳定可靠; 基于该方法, 装药技术人员可以较快得到关键的工艺参数, 完成装药工艺设计或仿真。

需指出的是, 本文中所有试验及数据分析均基于悬浮液混合炸药注装的基础上进行, 对于纯液态注装、块装, 结果可能会有所偏差, 但仍可为其工艺设计提供参考, 为预防和消除装药疵病, 提高产

Meta-learning[C]// Proceedings of the 35th International Conference on Machine Learning. ArXiv, 2018: 1568–1577.

- [50] WU M, HUGHES M, PARBHOO S, et al. Beyond sparsity: Tree regularization of deep models for interpretability[C]// Proceedings of the AAAI conference on artificial intelligence. AAAI, 2018: 1–9.
- [51] ZOPH B, CUBUK E D, GHISIA G, et al. Learning data augmentation strategies for object detection[C]// European Conference on Computer Vision. IEEE, 2020: 566–583.
- [52] KIRKPATRICKA J, PASCANU R, RABINOWITZ N, et al. Overcoming catastrophic forgetting in neural networks[J]. Proceedings of the National Academy of Sciences of the United States of America, 2017, 114(13): 3521–3526.
-

品质量提供一定帮助。

参考文献:

- 陈国光. 弹药制造工艺学[M]. 北京: 北京理工大学出版社, 2004: 185–190.
- 金志明, 翁春生, 张国强. 膳炸模式及其机理分析[J]. 兵工学报, 2001, 22(4): 448–451.
- 高丰, 黄求安, 王冠一. 熔注炸药低比压顺序凝固生长规律研究[J]. 兵器装备工程学, 2020, 41(8): 126–130.
- 徐更光, 刘德润, 王廷增, 等. 熔态炸药低比压顺序凝固技术[J]. Journal of Beijing Institute of Technology(English Edition), 1993(1): 90–97.
- 罗一鸣, 张蒙蒙, 杨斐, 等. 压力对 DNAN 凝固过程的影响[J]. 科学技术与工程, 2020, 20(8): 3048–3052.
- 胡菲, 刘玉存, 袁俊明, 等. 炸药熔铸装药成型质量监测技术研究进展[J]. 兵器装备工程学报, 2021, 42(9): 1–6.
- 陈朝轶. 冶金反应工程学[M]. 北京: 冶金工业出版社, 2021: 77–80.
- 周阳, 李奕学, 钱文, 等. 纳米颗粒形状、尺寸、含量及颗粒级配对炸药悬浮液粘度影响的 DPD 模拟[J]. 含能材料, 2018, 26(1): 66–74.
- 刘玉东, 李夔宁, 童明伟, 等. TiO₂-水纳米流体的粘度修正公式[J]. 重庆大学学报(自然科学版), 2006(9): 52–55, 67.
- 国防科学技术工业委员会. 迫击炮弹装药、装配通用规范: GJB 1050A—2005[S]. 北京: 中国标准出版社, 2005: 4.
- 崔庆忠. 高能炸药与装药设计[M]. 北京: 国防工业出版社, 2019: 185–190.
- 朱锦书, 朱德运, 王继章. 一种 DNAN 基熔铸炸药的装药工艺探究[J]. 山东化工, 2020, 49(12): 84–85, 87.