

控制与决策

Control and Decision

结合二值化神经网络与知识蒸馏的轻量型水声目标识别算法

崔翰林, 褚晓晖, 徐立军, 祁兵兵, 胡润泽

引用本文:

崔翰林, 褚晓晖, 徐立军, 等. 结合二值化神经网络与知识蒸馏的轻量型水声目标识别算法[J]. *控制与决策*, 2025, 40(1): 128-136.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.0522>

您可能感兴趣的其他文章

Articles you may be interested in

[基于双分支特征融合的场景文本检测方法](#)

A scene text detection based on dual-path feature fusion

控制与决策. 2021, 36(9): 2179-2186 <https://doi.org/10.13195/j.kzyjc.2020.0002>

[基于MobileNet的多目标跟踪深度学习算法](#)

Deep learning algorithm based on MobileNet for multi-target tracking

控制与决策. 2021, 36(8): 1991-1996 <https://doi.org/10.13195/j.kzyjc.2019.1424>

[基于卷积神经网络的云雾遮挡舰船目标识别](#)

Obscured ship target recognition based on convolutional neural network

控制与决策. 2021, 36(3): 661-668 <https://doi.org/10.13195/j.kzyjc.2019.0781>

[基于DLSR的归纳式迁移学习](#)

DLSR based inductive transfer learning method

控制与决策. 2021, 36(12): 2982-2990 <https://doi.org/10.13195/j.kzyjc.2020.0703>

[基于改进卷积神经网络的动力下肢假肢运动意图识别](#)

Intent recognition of power lower-limb prosthesis based on improved convolutional neural network

控制与决策. 2021, 36(12): 3031-3038 <https://doi.org/10.13195/j.kzyjc.2020.0326>

结合二值化神经网络与知识蒸馏的轻量型水声目标识别算法

崔翰林, 褚晓晖, 徐立军, 祁兵兵, 胡润泽[†]

(北京理工大学 信息与电子学院, 北京 100081)

摘要: 基于深度学习的水下声学目标识别算法在水下平台部署时,通常面临计算资源短缺和水下声学环境复杂多变的挑战,提出一种结合二值化神经网络与知识蒸馏的轻量型水声目标识别算法(DSBNN_KD),旨在通过深度可分离卷积和权重参数二值化等手段实现模型的压缩和优化加速.同时,利用知识蒸馏技术将高性能高复杂度的教师模型的知识转移到轻量级学生模型上,从而缓解极端量化带来的性能损失,并确保模型的泛化性能.对DSBNN_KD的表现在两个实测水声数据集上进行全面评估,实验结果表明,相比当前主流的全精度轻量化模型,所提出DSBNN_KD在模型参数量、模型部署尺寸和计算量等方面均展现出显著的优势,同时在知识蒸馏技术的辅助下,量化后的模型依然可以保持与全精度模型接近的性能.

关键词: 水声目标识别; 知识蒸馏; 二值神经网络; 轻量型模型; 深度学习

中图分类号: TP391

文献标志码: A

DOI: 10.13195/j.kzyjc.2024.0522

引用格式: 崔翰林,褚晓晖,徐立军,等.结合二值化神经网络与知识蒸馏的轻量型水声目标识别算法[J].控制与决策,2025,40(1):128-136.

A lightweight underwater acoustic target recognition algorithm combined with binarized neural networks and knowledge distillation

CUI Han-lin, CHU Xiao-hui, XU Li-jun, QI Bing-bing, HU Run-ze[†]

(School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China)

Abstract: Underwater acoustic target recognition (UATR) algorithms based on deep learning often face the challenges of scarce computing resources and the complex and variable underwater acoustic environment when deployed on underwater platforms. Therefore, this paper proposes a lightweight UATR algorithm depthwise separable binarized neural network with knowledge distillation (DSBNN_KD), so as to achieve model compression and optimized acceleration through means of depth-separable convolution and weight parameter binarization. Meanwhile, the KD is utilized to transfer knowledge from high-performance, high-complexity teacher models to lightweight student models, thereby mitigating the performance loss caused by extreme quantization and ensuring the model's generalization performance. The performance of the DSBNN_KD is comprehensively evaluated on two observed underwater acoustic datasets. The experimental results indicate that, compared to current mainstream full-precision lightweight models, the proposed DSBNN_KD shows significant advantages in terms of model parameter volume, model deployment size, and computational load. With the assistance of the KD, the quantized model can still maintain performance close to that of full-precision models.

Keywords: underwater acoustic target recognition; knowledge distillation; binarized neural network; lightweight model; deep learning

0 引言

水声目标识别 (underwater acoustics target recognition, UATR) 根据接收到的声信号对目标进行分类,是水声工程领域的一个关键研究方向.传统的人工识别受生理和心理因素的限制,不仅需要长期训

练,而且在实际应用中效果并不稳定.因此,利用人工智能技术对水声信号进行自动识别已成为新的研究趋势.近年来,随着深度学习技术的不断发展,研究人员开始探索将其应用于UATR的可能性.其中,以多层感知机(MLP)^[1]、长短时记忆网络(LSTM)^[2]、卷积

收稿日期: 2024-04-30; 录用日期: 2024-08-24.

基金项目: 国家自然科学基金项目(62301041).

责任编辑: 闫敬.

[†]通讯作者. E-mail: hrzlpk2015@gmail.com.

神经网络(CNN)^[3]和注意力机制^[4]等典型模型为代表的深度学习方法,因其强大的特征提取能力而受到广泛关注.这些模型能有效建立水声信号与目标类别之间的高度非线性映射关系,为解决UATR问题提供了新的思路.

然而,由于水下平台各项资源受限以及海洋环境具有高复杂性,UATR面临重大的工程挑战,使得资源密集型的深度学习方法难以在水下平台上部署.为了应对这些挑战,网络重构、剪枝等模型轻量化策略日益受到重视.其中,知识蒸馏(knowledge distillation, KD)^[5]将复杂、高参数的深度网络(教师模型)的性能转移到更简单、低参数的轻量级网络(学生模型)上,成为一种在深度学习领域流行的轻量化方法.在教师模型的监督下,学生模型可以学习到教师模型的多样化知识和泛化能力,从而在保持较高准确率的同时使计算复杂度更小,运行速度更快,这为UATR任务提供了更大的灵活性和鲁棒性.

根据知识转移的形式,知识蒸馏通常可以分为两类:基于概率分布的知识蒸馏和基于特征图的知识蒸馏,其中基于概率分布的知识蒸馏与UATR任务非常契合.这种方法的重点是使用教师模型的概率分布(软目标)作为标签来训练学生模型.与传统的独热编码标签形式不同,这些软目标包含了实例到类的相似性信息,封装了所谓的“暗知识”.其对于UATR的优势在于能够为具有不同架构的模型之间的知识转移提供一个通用的框架,从而促进模型实用性与识别准确性之间更有效地平衡.然而,由于海洋环境的复杂多变性,基于概率分布的知识蒸馏在UATR应用中主要面临着两个关键挑战.

首先,在学生模型的结构设计方面,相较于在自然环境中能够正常部署的轻量化学生模型,复杂海洋环境对模型轻量化的要求更为苛刻,需要更低的计算复杂度及更高的模型稳健性.然而,当采用参数量更少、更简单的学生模型时,模型容量受到限制使学生模型难以吸收教师模型传递的大量知识,导致性能无法显著提升.因此,在设计学生模型时,如何有效平衡模型复杂度和识别准确性非常重要.

其次,在教师模型选择方面,虽然具有复杂结构的教师模型能够显著提升水下目标识别的准确性,但其与学生模型之间存在巨大的模型性能和参数容量差距,这导致知识传递的效率显著下降,并最终影响学生模型性能的提升.而轻量化条件下学生模型的设计方案较为局限,鉴于此,教师模型需要在保持高准确性的同时选择合理的结构,以缩小教师模型与学

生模型之间的容量差距,从而提高知识蒸馏过程的效率.

针对上述问题,本文重新设计教师模型和学生模型,提出一种结合二值化神经网络(binanzed neural network, BNN)与知识蒸馏的轻量型水声目标识别算法(depthwise separable binanzed neural network with knowledge distillation, DSBNN_KD).首先,选择基于ResNet18骨干网络设计教师模型,ResNet18是ResNet系列中参数量最小的模型,同时具有较高的准确率,在多项视觉识别任务中表现优异;在此基础上,添加CBAM(convolutional block attention module)注意力机制,赋予重要的通道特征和空间位置更高的权值,进一步提高教师模型的识别性能;其次,引入深度可分离二值化卷积,构建轻量化学生模型,深度可分离卷积对输入特征图的每个通道分别使用一个卷积核,能够有效降低模型的计算复杂度,同时保持模型的特征表征能力;此外,对深度可分离卷积进行二值化处理,进一步减少模型中的参数量,提高模型在水下环境下的部署能力;最后,采用基于概率分布的知识蒸馏框架,迫使学生模型学习教师模型的软逻辑输出,实现知识的转移.所提出算法分别在DeepShip和ShipsEar两个实测数据集上进行实验,验证了所提出算法的有效性.

1 相关研究

1.1 知识蒸馏

KD是一种神经网络压缩技术,旨在减小深度学习模型的存储和计算成本,同时尽量保持其性能.如图1所示,KD最初通过Hinton等^[5]提出的“教师-学生”架构实现,其中大型、复杂、高性能的教师网络指导更小、更简单的学生网络的训练,从而使学生网络能够更接近教师网络的性能.目前KD的研究主要集中在知识表示形式和学习方式两个方面.

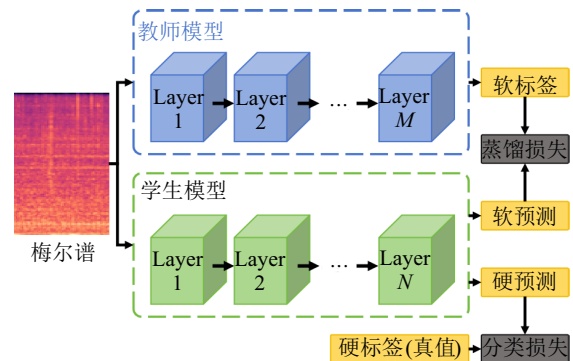


图1 知识蒸馏流程

在知识表示形式方面,KD的核心是将教师网络中的知识传递给学生网络.知识的表示形式不局限

于教师网络的输出概率分布^[6],还包括中间层的特征图^[7]、特征图的统计数据^[8]、特征图聚合^[9]和结构性知识^[10-12]等更丰富的信息。

在学习方式方面,KD的手段是通过不同的策略和结构实现知识的有效传递.选择合适的学习方式可以优化KD的效果,使学生模型在保持较小模型规模的同时达到更好的性能.例如:在线蒸馏^[13]、自蒸馏^[14]、多教师蒸馏^[15]、渐近式蒸馏^[16]和基于GAN的KD^[17]等.

此外,在训练中,Son等^[18]通过引入助教网络来缩小教师网络与学生网络之间的规模差异.Pan等^[19]提出了基于教师模型评价的动态权重知识蒸馏策略,通过动态平衡蒸馏和分类损失,实现对预训练大模型体积的有效压缩.而在网络结构调整方面,Liu等^[20]尝试将KD与网络架构搜索结合,动态调整网络结构.而Li等^[21]则结合神经网络剪枝去除网络中的冗余连接以实现网络压缩.

1.2 二值化神经网络

BNN是一种特殊的深度神经网络,其核心思想是将权重和激活函数量化为二进制值(+1或-1),而不是使用全精度的浮点数.BNN的概念最初由Hubara等^[22]提出,这种高效的模型压缩技术显著地降低了模型的大小,并加快了运算速度.然而,这种极端的量化方式也带来了信息损失,对网络的性能优化构成了挑战.目前,BNN的研究主要集中在模型的性能优化和资源受限设备的有效部署两个方面.

尽管BNN在准确性上通常低于全精度模型,但随着研究的深入,BNN在大型数据集上的准确性逐渐提高.Rastegari等^[23]通过在二值化卷积前引入增益项来补偿丢失的信息并减少量化误差,同时引入尺度因子以恢复信息.Lin等^[24]通过多重激活二值化和整体权重近似法,进一步改善了BNN的信息表达能力.Liu等^[25]在ResNet的基础上进行改进,通过引入广义激活函数和改进损失函数,提升了BNN的语义特征表达.Qin等^[26]创新性地将信息论引入BNN,通过优化正反向传播中信息流,进一步提升了二值化效果.Liu等^[27]提出了基于特征分布调整的二值量化方法,通过分组激励和特征精调模块动态调整激活分布的均值和方差,有效减少了BNN的信息损失.

在有效部署方面,现场可编程门阵列(FPGA)和专用集成电路(ASIC)受到了广泛的关注.如图2所示,这些平台可以针对BNN的特性进行特定的优化,通过XNOR和popcount操作代替乘法和加法运算,以实现更高的能效比和计算效率.Liang等^[28]通过引入

资源感知模型分析方法并优化了片上存储策略,显著地减少了FPGA部署BNN的硬件资源消耗,并保持了可接受的准确率.Moss等^[29]基于CPU+FPGA平台实现了高性能BNN加速器,取得了与高性能GPU接近的性能和更好的能效.




图2 二值化卷积处理流程

此外,Zhou等^[30]提出了可变宽度的量化方法,强调加快BNN的训练速度而非仅提高推理速度.Kim等^[31]将两个二值激活偶合成三值激活,以解决BNN的梯度失配问题.Xue等^[32]提出了自分布式BNN的概念,通过调整激活和权重的符号分布来改善BNN的性能.

2 结合二值化神经网络与知识蒸馏的轻量型水声目标识别算法

知识蒸馏技术在大多数人工智能应用场景下均取得较好的表现,是最主流的模型轻量化技术之一.通过结合知识蒸馏技术和神经网络二值化手段,并针对水下应用场景的特性,合理设计教师和学生模型,可以更有效地平衡识别模型的精度和复杂度.图3为所提出结合二值化神经网络与知识蒸馏的轻量型水声目标识别算法的整体框架,主要包括教师模型ResNet_CBAM、学生模型DSBNN_KD和基于输出概率分布的知识蒸馏3个部分.

2.1 教师模型ResNet_CBAM

知识蒸馏通过在训练时利用较为复杂的高性能教师模型指导轻量化的学生模型学习来将教师模型的知识传递给学生模型,从而提升小模型的性能和泛化能力,进而实现模型压缩.

本文教师模型ResNet_CBAM为结合了CBAM注意力机制的ResNet 18预训练模型.ResNet 18由多

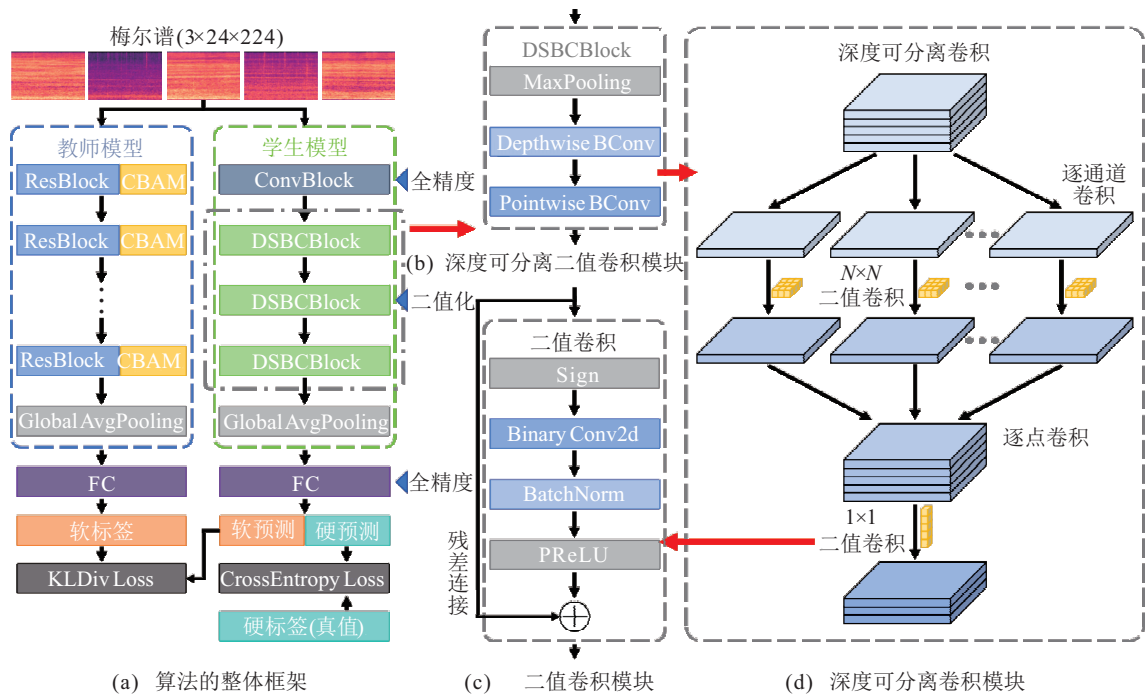


图3 算法整体框架

个基本的残差块级联组成,每个残差块内部包含两个连续的 3×3 卷积层. ResNet18 还引入跳跃连接来解决深度神经网络训练过程中的梯度消失问题,这使得 ResNet18 具有较深的网络结构和较高的准确性,在各类计算机视觉任务中表现出色.此外,为了帮助 ResNet18 更好地捕捉梅尔谱图中的重要信息,还将 CBAM 注意力机制引入残差块中.如图 4 所示, CBAM 注意力机制包括通道注意力模块和空间注意力模块两个部分.其中,通道注意力模块通过全局平均池化和全连接层动态调整特征图的通道权重,以增强有效特征的表达.而空间注意力模块通过

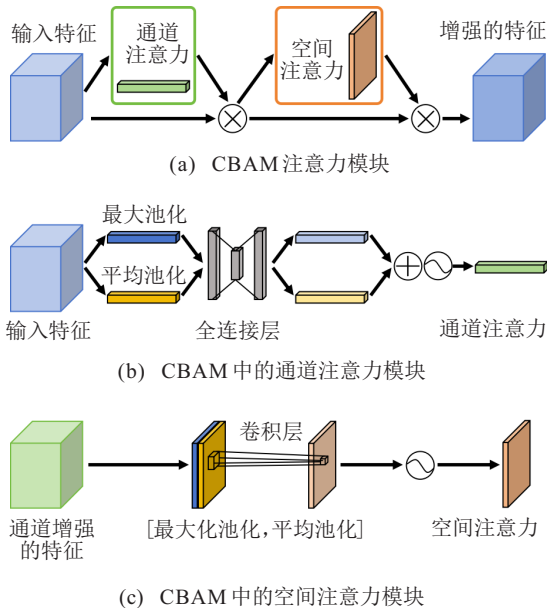


图4 CBAM 注意力模块

卷积操作来学习特征图的空间关系,从而增强感兴趣区域的表达.

2.2 学生模型 DSBNN_KD

学生模型 DSBNN_KD 为一个由 4 个卷积层和 1 个全连接层组成的轻量化模型.如图 3(a) 所示,为了确保对梅尔谱图特征提取的准确性,DSBNN_KD 的第 1 层卷积为使用单精度浮点型参数的标准卷积,而其余卷积层则均为使用二值化参数的深度可分离卷积,以减少模型参数的数量和对计算资源的占用.

如图 3(d) 所示,深度可分离二值化卷积中的深度可分离操作将标准卷积分解为两个独立的步骤:深度卷积和逐点卷积.其中深度卷积在每个输入通道上执行独立的空间卷积操作,而逐点卷积则利用 1×1 卷积在整个通道维度上进行线性组合.这种分解可以有效减少模型中的参数数量和计算量,并同时保持卷积层的表征能力和性能.深度可分离卷积与标准卷积参数量之比为

$$\frac{P_{DS}}{P_{Std}} = \frac{N \times K \times K + 1 \times 1 \times K \times K}{N \times M \times K \times K} = \frac{1}{M} + \frac{1}{K^2} \quad (1)$$

其中: P_{DS} 和 P_{Std} 分别为深度可分离卷积和标准卷积的参数量, N 为输入通道的数量, M 为输出通道的数量, K 为卷积核的尺寸.

同时,如图 3(c) 所示,为了进一步压缩学生模型,在深度可分离二值化卷积的前向推理中使用 Sign 函数对深度可分离卷积的权重参数和激活值进行二值

化,有

$$x_b = \text{Sign}(x) = \begin{cases} +1, & x \geq 0; \\ -1, & x < 0. \end{cases} \quad (2)$$

其中: x 为全精度参数, x_b 为二值化后的参数. 在前向推理阶段, 深度可分离二值化卷积采用二进制权重和激活函数替代标准的浮点数权重, 以实现模型内存占用和计算需求的显著压缩, 并大幅加快推理速度. 在反向传播过程中则通过二值化参数前向推理的结果来计算二值化参数的梯度, 并直接将其作为浮点数参数的梯度以更新浮点数权重. 即通过将 Sign 函数二值化操作的梯度估计为 1 来解决其不连续带来的梯度消失或不稳定的问题, 从而保持反向传播中的梯度流动, 确保学生模型 DSBNN_KD 能够有效学习和优化参数. 训练完成后, 对深度可分离二值化卷积中的浮点型参数进行最后一次二值化处理, 形成最终的学生模型 DSBNN_KD. 虽然卷积权重的二值化会给水下声学目标识别任务带来一定的精度损失, 但在一些资源受限的场景下具有很高的实用性.

2.3 基于输出概率分布的知识蒸馏

为了缓解卷积权重的二值化给模型带来的性能损失, 提升轻量化模型的泛化能力和准确性, 本文采用知识蒸馏来帮助轻量化的学生模型 DSBNN_KD 学习高性能教师模型 ResNet_CBAM 中的特征表示和参数分布. 如图 3(a) 所示, 教师和学生模型对输入数据各类别的原始预测分数通过 Softmax 函数转换为概率分布, 这些输出的类别概率分布用概率向量来表示, 其中每个元素对应一个类别的概率, 因此概率向量可以看作是对输入数据属于各个类别的置信度的度量. 在知识蒸馏中, 教师模型 ResNet_CBAM 的概率向量被用作辅助信息, 通过 KL 散度来衡量概率分布的差异并引导学生模型 DSBNN_KD 的概率向量尽可能地接近教师模型的输出, 以方便学生模型更好地复制教师模型的行为和决策逻辑, 从而达到蒸馏的目的. 为此, 在模型的训练过程中, 知识蒸馏的损失为

$$P(x) = \text{Softmax}\left(\frac{T(x)}{\tau}\right), \quad (3)$$

$$Q(x) = \text{Softmax}\left(\frac{S(x)}{\tau}\right), \quad (4)$$

$$L_{\text{KD}} = D_{\text{KL}}(P(x), Q(x)) \cdot \tau^2. \quad (5)$$

其中: $T(x)$ 和 $S(x)$ 分别为教师和学生模型的原始预测分数; $P(x)$ 和 $Q(x)$ 分别为教师和学生模型的概率向量输出; $D_{\text{KL}}(\cdot)$ 为 KL 散度损失函数; τ 为温度参数, 用于在知识蒸馏中控制输出概率向量的平滑程度, 进

而影响教师模型概率分布的尖锐程度, 使蒸馏过程更加平滑和稳定.

除知识蒸馏损失外, 还使用交叉熵损失来约束学生模型的输出, 以帮助学生模型更快地学习到教师模型的输出结果. 总的损失为

$$L_{\text{Total}} = (1 - \alpha) \cdot L_{\text{CE}} + \alpha \cdot L_{\text{KD}}. \quad (6)$$

其中: L_{CE} 为用于约束学生模型分类结果的交叉熵损失, L_{KD} 为衡量知识蒸馏效果的 KL 散度损失, α 为平衡多个损失函数的权重因子.

3 实验与分析

本节面向真实场景下的水声目标识别任务, 分别从模型精度和计算效率两个角度充分验证所提出方法的性能.

3.1 基准数据集

本文采用两个实测数据集 ShipsEar^[33] 和 DeepShip^[34]. 其中: ShipsEar 数据集包含 11 种不同类型的船舶的 90 条录音, 并根据不同的声学特征将其标注为 5 个类别; DeepShip 数据集包括 4 种类型 265 艘船共 47 小时 6 分钟的录音. 表 1 给出这两个数据集的详细参数. 本文将来自两个数据集的音频数据转换为针对 UATR 任务的梅尔谱图. 图 5 展示了 ShipsEar 数据集中梅尔谱图的示例图像.

表 1 ShipsEar 和 DeepShip 数据集参数

数据集	ShipsEar	DeepShip
数据量(梅尔谱图)	3 738	4 000
类别	5	4
采集位置	西班牙大西洋沿岸	加拿大乔治亚海峡
数据时长/h	3.08	47.06




图 5 ShipsEar 数据集中各类别梅尔谱图示例

3.2 梅尔谱图生成

将声信号转换为梅尔谱图是 UATR 任务中常见的预处理策略. 梅尔谱图是一种用来模拟人类听觉系统感知声音频率非线性特征的工具. 在生成梅尔谱图的过程中, 声音信号在频域上被转换为梅尔尺度, 并在该尺度上应用一系列的等距滤波器. 所得到的梅尔谱图可以更有效地捕捉人类对不同频率声音的敏感度, 特别是在低频范围的高灵敏度和在高频范围的低灵敏度. 梅尔谱图的生成流程如图 6 所示, 包括 4 个阶段.

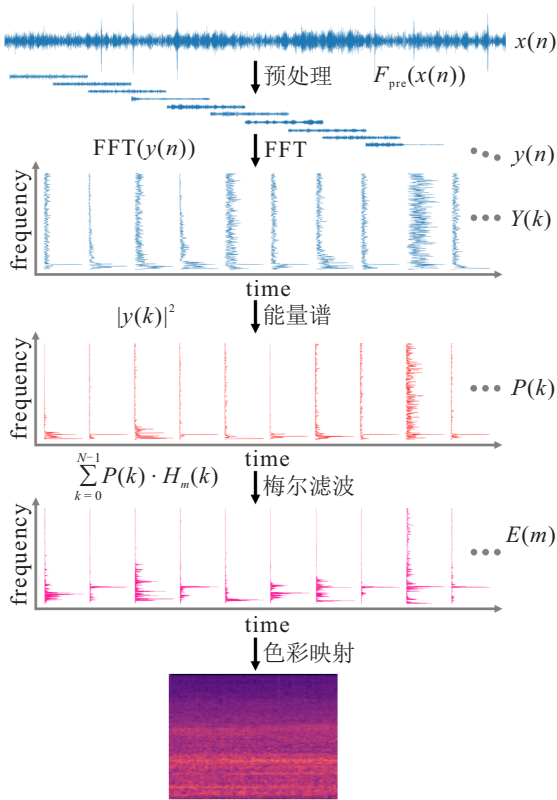


图 6 梅尔谱图生成流程

step 1: 水声信号通过降噪、预加重、分帧和加窗等操作进行预处理, 其中帧长选取为 512, 帧移选取为 256, 使用汉宁窗作为窗函数, 有

$$y(n) = F_{pre}(x(n)). \quad (7)$$

step 2: 利用快速傅里叶变换将水声信号从时域变换到时频域, 然后对变换后的信号进行平方, 得到信号在 Hz 频率尺度上的线性功率谱, 有

$$P(k) = |Y(k)|^2 = |\text{FFT}(y(n))|^2. \quad (8)$$

step 3: 应用梅尔滤波器组将线性功率谱转换为梅尔频率尺度上的非线性功率谱, 有

$$\text{Mel}(f) = 2595 \cdot \log_{10} \left(1 + \frac{f}{700} \right), \quad (9)$$

$$E(m) = \sum_{k=0}^{N-1} P(k) \cdot H_m(k), \quad m = 1, 2, \dots, M. \quad (10)$$

其中: $H_m(k)$ 为第 m 个梅尔滤波器的频域响应, M 为梅尔滤波器的数量, N 为每帧信号的采样点数, M 选取为 128, N 选取为 512.

step 4: 对梅尔滤波得到的非线性功率谱进行对数运算压缩, 并将其映射到频带上.

3.3 实验配置与训练

采用 Ubuntu 22.04 操作系统, GPU 为 Nvidia RTX 3090. 整个实验模型基于 PyTorch 2.2.2 框架构建, 使用 batchsize 为 32 的 Adam 优化器, 初始学习率设置为 1×10^{-3} , 并利用 CosineAnnealingWarmRestarts 函数进行动态调整. 对于每个数据集, 随机选择 80% 的样本进行训练, 剩余 20% 用于测试. 在模型训练和测试过程中, 输入的梅尔频谱图像尺寸固定为 224×224 .

同时, 使用目标识别任务中常用的 4 个评价指标 Top-1 准确率 (Top-1 acc)、精确率 (precision)、召回率 (recall) 和 F1-score 对所提出模型的性能进行评估. 4 个指标计算方法如下:

$$\text{Top-1 acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}, \quad (11)$$

$$\text{precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \quad (12)$$

$$\text{recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (13)$$

$$\text{F1-score} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}}. \quad (14)$$

其中: TP 为真正例 (true positive), 即实际为正类别且被预测为正类别的样本数; FP 为假正例 (false positive), 即实际为负类别但被错误地预测为正类别的样本数; TN 为真负例 (true negative), 即实际为负类别且被预测为负类别的样本数; FN 为假负例 (false negative), 即实际为正类别但被错误地预测为负类别的样本数.

3.4 实验结果与分析

为了验证所提出 DSBNN_KD 算法的有效性, 分别在 ShipsEar 数据集和 DeepShip 数据集上进行多组对比实验. 图 7 为蒸馏训练时模型 Top-1 准确率随 epoch 的变化曲线. 由图 7 可见, 随着训练 epoch 的增加, 知识蒸馏方法进一步提升了 DSBNN_KD 在两个数据集中训练和测试的 Top-1 准确率, 使其稳步增长, 并最终令 DSBNN_KD 的 Top-1 准确率达到更高水平.

将 DSBNN_KD 与全精度教师模型 ResNet_CBAM、未经知识蒸馏训练的 DSBNN 及对应的全精度算法 DSCNN (depthwise separable convolutional neural network) 在两个数据集上的性能进行对比, 以准确评估权重二值化和知识蒸馏对 DSBNN_KD

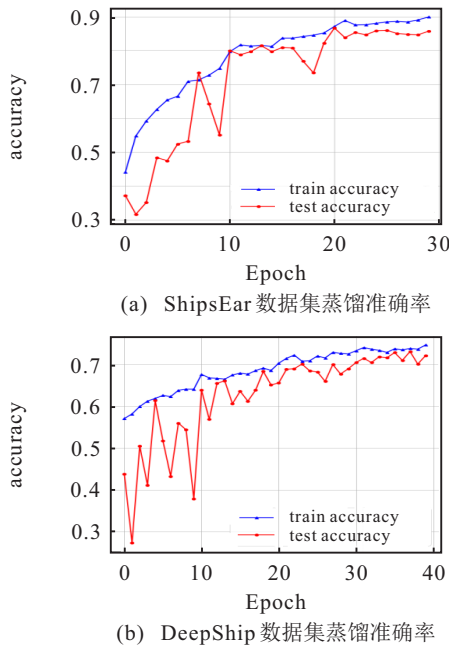


图7 蒸馏训练时模型Top-1准确率随epoch的变化曲线

表2 教师和学生模型在ShipsEar和DeepShip数据集中的性能对比

网络	权重位数 (bit)	ShipsEar / %				DeepShip / %			
		Top-1 acc	precision	recall	F1-score	Top-1 acc	precision	recall	F1-score
ResNet_CBAM	32	95.98	95.93	95.78	95.82	83.50	83.60	83.39	83.46
DSCNN	32	88.36	89.24	87.71	88.36	75.50	75.50	75.53	75.42
DSBNN	1/32	77.67	77.69	80.78	78.46	67.12	66.89	67.12	66.91
DSBNN_KD	1/32	86.63	88.97	84.82	86.46	73.13	73.13	73.10	73.08

同时,本文也评估了DSBNN_KD在模型轻量化方面的改进,表3显示了各模型的参数量、参数大小和每秒浮点运算次数.可以看出,相比教师模型ResNet_CBAM,轻量模型DSCNN和DSBNN在计算资源的占用方面展现出巨大的优势,在相同权重位数的条件下,DSCNN仅使用教师模型ResNet_CBAM约0.4%的参数量和参数大小,在Flops上便减少了92.2%.而相比DSCNN,内部大部分权重二值化的DSBNN在DSCNN模型简化的基础上,进一步将参数的大小缩减了88.6%,并在Flops上减少了59.9%,而且借助知识蒸馏技术使实际表现接近于全精度模型DSCNN.此外,权重位宽的降低也使得DSBNN_KD在计算资源受限的移动端设备和边缘设备上的部署获得了巨大的优势.

表3 教师和学生模型的参数对比

网络	权重位数 (bit)	参数量 (百万)	参数大小 (MB)	Flops (MFLOPS)
ResNet_CBAM	32	11.2669	42.9798	1820.0
DSCNN	32	0.0493	0.1880	142.8
DSBNN	1/32	0.0493	0.0215	57.3

为了进一步衡量DSBNN_KD的性能,本文与其他常用的轻量型深度学习模型进行对比,表4显

算法在水下声学目标识别任务中的性能影响.实验结果如表2所示,全精度的教师模型ResNet_CBAM在两个数据集上分别取得了95.98%、83.50%的Top-1准确率和95.82%、83.46%的F1-score,而全精度的DSCNN则分别取得了88.36%、75.50%的Top-1准确率和88.36%、75.42%的F1-score.可以看出,模型规模的缩减是造成水声目标识别性能下降的主要原因之一.在对学生模型内部的卷积层进行二值化后,DSBNN在两个数据集中的Top-1准确率相比DSCNN分别下降了10.69%和8.38%.为了解决由权重二值化导致的识别性能下降,利用教师模型ResNet_CBAM对DSBNN进行知识蒸馏.经过知识蒸馏的DSBNN_KD在两个数据集上取得了86.63%、73.13%的Top-1准确率和86.46%、73.08%的F1-score,实现了在内部卷积层权重二值化的情况下取得与全精度模型DSCNN较为接近的性能.

示了各轻量型模型在两个数据集中的性能.可以看出,MobileNet和EfficientNet在两个数据集中拥有最高的Top-1准确率和F1-score,而未经知识蒸馏训练的DSBNN性能表现最差,在Top-1准确率方面分别低于其他全精度轻量化模型11.31%~14.71%和8.63%~14.88%.而在经过知识蒸馏后,权重量化带来的性能损失得到缓解,在Top-1准确率方面仅低于其他全精度轻量化模型2.41%~5.75%和3.37%~8.85%.通过两个数据集中的实验结果可以看出,与DeepShip数据集相比,经过知识蒸馏训练后的学生模型DSBNN_KD在难度较小的ShipsEar数据集中展现出更为显著的性能提升,这验证了二值量化会对模型处理复杂任务的能力有所影响,使学习过程更富有挑战性.因此,对于资源受限的水下平台环境而言,如何平衡模型效率和识别性能显得尤为重要.

本文对各轻量化模型占用的计算资源进行分析.如表5所示,所提出的DSBNN在参数量和参数大小方面均达到了最低水平.这表明,尽管各种轻量化模型在网络结构上进行了诸多高效的设计,但权重位数的二值化和知识蒸馏仍能在保持水下声学目标识别性能的同时实现对模型的进一步压缩.此外,二值化的权重对于在FPGA和ASIC等硬件平台上的部署

表4 各轻量模型在ShipsEar和DeepShip数据集中的性能对比

网络	权重位数 (bit)	ShipsEar/%				DeepShip/%			
		Top-1 acc	precision	recall	F1-score	Top-1 acc	precision	recall	F1-score
MobileNet ^[35]	32	91.44	92.27	90.61	91.28	81.00	81.60	81.09	80.94
ShuffleNet ^[36]	32	89.04	90.01	87.64	88.56	76.63	77.58	76.51	76.68
GhostNet ^[37]	32	89.30	90.40	87.61	88.75	75.75	77.08	75.98	75.64
RegNet ^[38]	32	90.78	90.82	89.90	90.30	76.50	77.23	76.48	76.57
EfficientNet ^[39]	32	92.38	91.73	92.19	91.88	82.00	81.98	82.06	81.75
DSBNN	1/32	77.67	77.69	80.78	78.46	67.12	66.89	67.12	66.91
DSBNN_KD	1/32	86.63	88.97	84.82	86.46	73.13	73.13	73.10	73.08

还有着得天独厚的巨大优势,可以通过软硬件平台上的协同优化策略进一步加快模型的执行速度。

表5 各轻量模型的参数对比

网络	权重位数 (bit)	参数量 (百万)	参数大小 (MB)	Flops (MFLOPS)
MobileNet ^[35]	32	3.21	12.25	582.85
ShuffleNet ^[36]	32	0.35	1.32	42.63
GhostNet ^[37]	32	3.91	14.91	149.40
RegNet ^[38]	32	2.32	8.84	205.00
EfficientNet ^[39]	32	0.23	0.90	59.84
DSBNN	1/32	0.0493	0.0215	57.3

4 结论

本文提出了一种轻量化的水声目标识别算法DSBNN_KD,通过结合二值化神经网络和知识蒸馏技术,有效地降低了识别模型的复杂度并最小化模型的精度损失. 算法采用深度可分离卷积和权重参数的二值化来实现模型的压缩和加速,同时利用知识蒸馏技术将高性能教师模型ResNet_CBAM的知识转移到学生模型上,以提升模型的泛化性能并缓解由量化带来的性能损失. 实验结果表明,DSBNN_KD在参数量、参数大小和浮点运算次数上相比全精度模型展现出显著优势,同时在知识蒸馏的辅助下,达到了与全精度模型相近的性能水平. 此外,DSBNN_KD在与其他轻量型模型比较中也展现出了竞争力. 实验结果表明,DSBNN_KD在资源受限的水下平台部署中具有极高的实用性,为水下声学目标识别任务提供了一种有效的解决方案. 未来的工作将进一步探索更高效的模型量化压缩和知识蒸馏策略,以实现深度学习模型更高效的部署应用。

参考文献(References)

[1] Shi G Z, Hu J C, Da L L, et al. Target recognition study using SVM, ANNs and expert knowledge[C]. IEEE International Conference on Automation and Logistics. Qingdao, 2008: 1507-1511.

[2] Yang H H, Xu G H, Yi S Z, et al. A new cooperative deep learning method for underwater acoustic target recognition[C]. OCEANS 2019-Marseille. Marseille, 2019: 1-4.

[3] Wang B, Zhang W, Zhu Y N, et al. An underwater acoustic target recognition method based on AMNet[J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20: 3235659.

[4] Feng S, Zhu X Q. A transformer-based deep learning network for underwater acoustic target recognition[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.

[5] Hinton G, Vinyals O, Dean J. Distilling the knowledge in a neural network[J/OL]. 2015, arXiv: 1503.02531.

[6] Zhang Y C, Lan Z H, Dai Y C, et al. Prime-aware adaptive distillation[C]. European Conference on Computer Vision. Cham: Springer, 2020: 658-674.

[7] Zhou G R, Fan Y, Cui R P, et al. Rocket launching: A universal and efficient framework for training well-performing light net[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2018, 32(1): 1-8.

[8] Zagoruyko S, Komodakis N. Paying more attention to attention: Improving the performance of convolutional neural networks via attention transfer[J/OL]. 2016, arXiv: 1612.03928.

[9] Ji M, Heo B, Park S. Show, attend and distill: Knowledge distillation via attention-based feature matching[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(9): 7945-7952.

[10] Park W, Kim D, Lu Y, et al. Relational knowledge distillation[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, 2019: 3967-3976.

[11] Tung F, Mori G. Similarity-preserving knowledge distillation[C]. IEEE/CVF International Conference on Computer Vision. Seoul, 2019: 1365-1374.

[12] Zhu J G, Tang S X, Chen D P, et al. Complementary relation contrastive distillation[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, 2021: 9260-9269.

[13] Zhang Y, Xiang T, Hospedales T M, et al. Deep mutual learning[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 4320-4328.

[14] Zhang L F, Song J B, Gao A N, et al. Be your own teacher: Improve the performance of convolutional neural networks via self distillation[C]. IEEE/CVF International Conference on Computer Vision. Seoul,

- 2019: 3713-3722.
- [15] Liu Y A, Zhang W, Wang J. Adaptive multi-teacher multi-level knowledge distillation[J]. *Neurocomputing*, 2020, 415: 106-113.
- [16] Yang C L, Xie L X, Su C, et al. Snapshot distillation: Teacher-student optimization in one generation[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, 2019: 2859-2868.
- [17] Chung I, Park S, Kim J, et al. Feature-map-level online adversarial knowledge distillation[C]. *Proceedings of the 37th International Conference on Machine Learning*. Piscataway: IEEE, 2020: 2006-2015.
- [18] Son W, Na J, Choi J, et al. Densely guided knowledge distillation using multiple teacher assistants[C]. *IEEE/CVF International Conference on Computer Vision*. Montreal, 2021: 9395-9404.
- [19] Pan R D, Kong W J, Qi J. Legal judgment prediction based on pre-training model and knowledge distillation[J]. *Control and Decision*, 2022, 37(1): 67-76.
- [20] Liu Y, Jia X H, Tan M X, et al. Search to distill: Pearls are everywhere but not the eyes[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, 2020: 7539-7548.
- [21] Li T H, Li J G, Liu Z, et al. Few sample knowledge distillation for efficient network compression[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, 2020: 14639-14647.
- [22] Hubara I, Courbariaux M, Soudry D, et al. Binarized neural networks[Z]. *Advances in Neural Information Processing Systems*, 2016.
- [23] Rastegari M, Ordonez V, Redmon J, et al. XNOR-net: ImageNet classification using binary convolutional neural networks[C]. *European Conference on Computer Vision*. Cham: Springer, 2016: 525-542.
- [24] Lin X, Zhao C, Pan W. Towards accurate binary convolutional neural network[Z]. *Advances in Neural Information Processing Systems*, 2017.
- [25] Liu Z C, Shen Z Q, Savvides M, et al. ReActNet: Towards precise binary neural network with generalized activation functions[C]. *European Conference on Computer Vision*. Cham: Springer, 2020: 143-159.
- [26] Qin H T, Gong R H, Liu X L, et al. Forward and backward information retention for accurate binary neural networks[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, 2020: 2250-2259.
- [27] Liu C, Chen Y. Binary quantization method of deep neural network based on feature distribution adjustment[J]. *Control and Decision*, 2024, 39(6): 1840-1848.
- [28] Liang S, Yin S Y, Liu L B, et al. FP-BNN: Binarized neural network on FPGA[J]. *Neurocomputing*, 2018, 275: 1072-1086.
- [29] Moss D J M, Nurvitadhi E, Sim J, et al. High performance binary neural networks on the Xeon+FPGA™ platform[C]. *The 27th International Conference on Field Programmable Logic and Applications (FPL)*. Ghent, 2017: 1-4.
- [30] Zhou S, Ni Z, Zhou X, et al. Dorefa-net: Training low bitwidth convolutional neural networks with low bitwidth gradients[J/OL]. 2016, arXiv: 1606.06160.
- [31] Kim H, Kim K, Kim J, et al. Binaryduo: Reducing gradient mismatch in binary activation network by coupling binary activations[J/OL]. arXiv: 2002.06517.
- [32] Xue P, Lu Y, Chang J F, et al. Self-distribution binary neural networks[J]. *Applied Intelligence*, 2022, 52(12): 13870-13882.
- [33] Santos-Domínguez D, Torres-Guijarro S, Cardenal-López A, et al. ShipsEar: An underwater vessel noise database[J]. *Applied Acoustics*, 2016, 113: 64-69.
- [34] Irfan M, Zheng J B, Ali S, et al. DeepShip: An underwater acoustic benchmark dataset and a separable convolution based autoencoder for classification[J]. *Expert Systems with Applications*, 2021, 183: 115270.
- [35] Sandler M, Howard A, Zhu M L, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, 2018: 4510-4520.
- [36] Zhang X Y, Zhou X Y, Lin M X, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, 2018: 6848-6856.
- [37] Han K, Wang Y H, Tian Q, et al. GhostNet: More features from cheap operations[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, 2020: 1580-1589.
- [38] Radosavovic I, Kosaraju R P, Girshick R, et al. Designing network design spaces[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, 2020: 10428-10436.
- [39] Tan M, Le Q. EfficientNet: Rethink-ing model scaling for convolutional neural networks[C]. *Proceedings of the 36th International Conference on Machine Learning*. Long Beach, 2019: 6105-6114.

作者简介

崔翰林(1998—),男,博士生,主要研究方向为水下声学目标识别, E-mail: 3220245371@bit.edu.cn;
 褚晓晖(1997—),男,博士生,主要研究方向为水下目标识别、模型轻量化, E-mail: 3120225380@bit.edu.cn;
 徐立军(1977—),男,教授,博士,主要研究方向为水声信号处理、水声通信, E-mail: 6120210061@bit.edu.cn;
 祁兵兵(1987—),男,助理研究员,博士,主要研究方向为信号处理, E-mail: 6120230031@bit.edu.cn;
 胡润泽(1993—),男,副研究员,博士,主要研究方向为深度学习、信号处理, E-mail: hrzlpk2015@gmail.com.