

深度学习在水声目标识别中的应用研究

王培兵, 彭 圆

(水下测控技术重点实验室, 辽宁 大连 116013)

摘要 水声目标识别技术是水声信号处理的重要组成部分,是水声信息获取与水声信息对抗的重要技术支撑。针对水声目标识别时探测数据量大、自动化程度不高、识别效率低下等问题,研究了深度学习在水声目标识别中的应用。首先,介绍了水声目标识别技术的研究现状及当前形势下面临的挑战。然后,对深度学习的网络结构原理及改进型进行了分析,并分别对深度学习在水声声信号识别领域和水声图像信号识别领域的应用现状做了阐述。最后,指出了由于受当前技术条件和水下复杂环境的制约,此方法尚且存在着不足之处。该方法为进一步优化深度学习算法、拓展深度学习技术应用范畴、提升水声目标识别效率提供了参考。

关键词 水声目标识别;深度学习;声信号;图像信号

中图分类号 TP391

文献标识码 A

文章编号 2096-5753-(2020)01-0011-07

DOI 10.19838/j.issn.2096-5753.2020.01.003

Research on Application of Deep Learning in Underwater Acoustic Target Recognition

WANG Peibing, PENG Yuan

(Key laboratory of Underwater Test and Control Technology, Dalian 116013, China)

Abstract Underwater acoustic target recognition technology is an important part of underwater acoustic signal processing and an important technical support for underwater acoustic information acquisition and underwater acoustic information countermeasures. Aiming at the problems of large amount of detection data, low automation degree and low recognition efficiency in underwater acoustic target recognition, the application of deep learning in underwater acoustic target recognition was studied. First, the research status and the current challenges of underwater acoustic target recognition technology are introduced. Then, the network structure principle and improved form of deep learning are analyzed, and the application statuses of deep learning in underwater acoustic signal recognition and underwater acoustic image signal recognition are explained respectively. Finally, it is pointed out that due to the constraints of current technical conditions and the complex underwater environment, this method still has shortcomings. This method provides a reference for further optimization of deep learning algorithms, expansion of the scope of deep learning technology applications, and improvement of underwater acoustic target recognition efficiency.

Key words underwater acoustic target recognition; deep learning; acoustic signal; image signal

0 引言

水声目标识别技术在反潜、鱼雷防御、海底地形勘探等领域应用广泛。但随着潜艇降噪技术

的进步、水下无人航行器的迅速发展、鱼雷等水下武器的多样化以及不断恶劣的水下复杂环境都使人们对目标识别精度有了更高的要求,所以研究更加自主、智能、高效的水声目标识别技术刻

收稿日期: 2019-11-29

作者简介: 王培兵(1987-),男,硕士生,主要从事水声信号与信息处理研究。

基金项目: 国防基础科研项目(JCKY2017207B042)。

不容缓。深度学习是由 Hinton 等人^[1]于 2006 年提出来的具有多层结构的深度神经网络算法,因采用多个隐藏层相互叠加的结构特点,使其具有强大的数据特征自学能力,并可以从数据中挖出其内在的变化规律^[2]。

本文就近年来深度学习在水声目标识别中的应用进行了较为系统的研究,总结了深度学习在处理水声声信号和图像信号应用中的优越性。相比于传统的识别算法,其更能提高目标识别的效率。同时,也指出了深度学习在水声目标识别应用中的不足之处,为后续改进提供参考。

1 水声目标识别技术的研究现状及面临的挑战

1.1 水声目标识别技术研究现状

水声目标识别主要依据目标的特征信息。目标特征信息是目标原始数据中包含或者可提取的一种能精确和简化表明目标状态和身份的信息^[3]。水声目标主要包括噪声、运动、尾流、几何结构等特征信息^[4]。

随着水声目标识别越来越受到人们的重视,国内外众多学者也开展了很多的研究工作。例如 Rajgopal 等^[5]在研制的水声目标识别专家系统中所使用的特征包括:螺旋桨桨叶数、螺旋桨转速、推进器类型、目标壳体辐射低频噪声、活塞松动产生的谐音基频喷嘴噪声、注水器噪声、最大速度、槽极噪声、传动装置类型等。Lourens^[6]在识别特征分析中重点强调了螺旋桨转速、主机类型、齿轮噪声线谱等特征。Arnab 等^[7]在分类识别特征分析中归纳了谱中心、谱形、谱起伏、窄带与宽带谱特征、倒谱特征、Mel 倒谱参数、音调频率参数等统计时频域特征。AR 模型系数、非线性融合特征等也常被作为水声目标辐射噪声识别的特征量^[8-12]。国内学者对船舶辐射噪声的调制谱、功率谱、低频线谱以及高阶谱、小波变换、混沌分形、听觉感知等特征和特性的分析也开展了很多研究工作^[13-20],例如励荣峰等人研究了各类水声目标的功率谱分析,提取了目标的视频特征,并通过实际数据分析进行了可分性验

证。彭圆等人研究了基于双谱的方法对水中目标辐射噪声进行特征提取与分类,同样也取得了很好的效果。

1.2 新技术为水声目标识别技术带来的挑战

随着水声探测技术的发展和降噪水平的提高,传统识别技术的性能正在逐渐下降,这为水声目标识别技术带来了新的挑战^[21]。

1.2.1 声呐信号带宽对识别能力的影响

目标特征量的提取都是基于一定带宽的声呐传感器得到的。根据香农公式,对于1个带宽为 B Hz 的信道,信道的最大信息传送速率为

$$C = B \log_2 \left(1 + \frac{S}{N} \right)$$

式中: S 为信号功率, W ; N 为噪声功率, W 。

也就是说,等功率强度的信号带宽和信道的信息容量成正比,宽带信号可以比窄带信号携带更多的信息。

1.2.2 低频探测对线谱识别性能的影响

为了达到提高探测距离的目标,低频探测成为当下主流的趋势,带来的问题是波束宽度的增加。对于作用距离为 100 km 的声呐来说,波束宽度内目标很可能不是单个目标。因此,对于利用低频探测来进行线谱识别,检测到的低频线谱是否就是关注的水声目标的低频线谱特征有着很大的不确定性。

1.2.3 减震降噪对识别性能的影响

对于水中目标来说,减震降噪是永恒不变的主题和最终的目标。减震降噪使得低频线谱特征显著降低,而线谱特征都可以通过结构设计、工艺设计、使用减震装置等不断降低。最终这些线谱特征都有可能被消除或者减得很弱,那么基于线谱探测的识别技术将失去意义。

2 水声目标识别中深度学习的研究及应用

2.1 深度学习常用的开发工具

深度学习常用的开发工具主要有 TensorFlow、Torch、Caffe、Theano, 以下详细探讨这 4 种。除此之外, Deeplearning4j、MXNet 等开发工具也都有着广泛的应用。

1) TensorFlow 开发工具。

优势: ①机动性: 并不是一个规则的 neural network, 定义新的操作只需要写 1 个 Python 函数; ②可使用性强: 可以应用在不同的设备上, 如 cpus、gpu 移动设备、平台等; ③自动差分: TensorFlow 的自动差分能力对很多基于 Graph 的机器学习算法有益; ④多种编程语言可选: 有 Python 接口和 C++ 接口, 其他语言可以使用 SWIG 工具使用接口; ⑤最优化表现: 充分利用硬件资源, TensorFlow 可以将 Graph 的不同计算单元分配到不同的设备执行。

特点: TensorFlow 灵活的架构可以部署在 1 个或者多个 CPU、GPU 的台式以及服务器中, 或者使用单一的 API 应用在移动设备中, 开源之后几乎可以适用各个领域。

2) Torch 开发工具。

优势: 构建模型简单, 高度模块化, GPU 快速高效。具有丰富的索引、切片和 transposing 的例程, 支持 LuaJIT 接入 C 数值优化程序等, 可移植嵌入到 iOS、Android 和 FPGA 后端的接口。

特点: Torch 拥有 Facebook 为其开源的大量深度学习模块和扩展, 并采用了编程语言 Lua。

3) Caffe 开发工具。

优势: ①上手快: 模型与相应优化都是以文本形式而非代码形式给出; ②速度快: 能够运行最好的模型与海量的数据; ③模块化: 方便扩展到新的任务和设置上; ④开放性: 公开的代码和参考模型用于再现; ⑤社区好: 可以通过 BSD-2 参与开发与讨论。

特点: Caffe 是开源的, 核心语言是 C++, 支持命令行、Python、MATLAB, 既可以在 CPU 上运行也可以在 GPU 上运行。

4) Theano 开发工具。

优势: ①集成 NumPy 的基于 Python 实现的科学计算包, 可以与稀疏矩阵运算包 SeiPy 配合使用, 全面兼容 NumPy 库函数; ②易于使用 GPU 进行加速, 具有比 CPU 实现相对较大的加速比; ③具有优异的可靠性和速度优势; ④可支持动态 C 程序生成; ⑤拥有测试和自检单元, 可方便检测和诊断

多类型错误。

特点: Theano 派生出大量的深度学习 Python 软件包, 最著名的有 Blocks 和 Keras, 其核心是 1 个数学表达式的编译器。

2.2 深度学习几种典型的网络结构原理及改进

2.2.1 深度置信网络 DBN 原理及改进

DBN^[22] (Deep Belief Network) 由多个受限玻尔兹曼机 RBM 和 1 层反向传播网络 BP 堆叠而成。其网络结构如图 1 所示, 图 1 中: h 为隐藏层数; v 为可视层数; W 为连接权值矩阵。

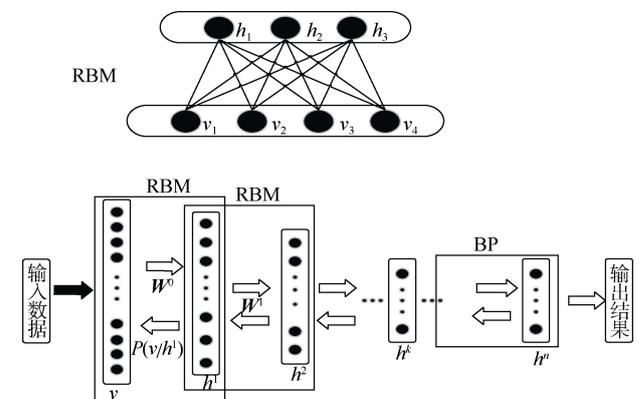


图 1 深度置信网络结构图

Fig. 1 Block diagram of DBN

DBN 的训练过程为 2 部分: 预训练和微调整训练。预训练就是对每层的每个 RBM 进行训练, 而在微调整阶段则采用反向传播算法将训练误差逐层向后传播。其改进型网络有 CRBM-DBN^[23], 即首先使用有高斯分布的连续受限玻尔兹曼机 (CRBM) 的 DBN 模型对数据的输入量进行特征学习, 然后利用对比散度算法进行抽样以获取高层次的特征。此外还有稀疏受限玻尔兹曼机 (SRBM)^[24]、稀疏组受限玻尔兹曼机 (SGRBM)^[25] 等改进型深度置信网络。

2.2.2 卷积神经网络 CNN 原理及改进

CNN^[26] (Convolutional Neural Network) 通过结合局部感知区域、共享权重、空间或时间上的池化降采样 3 大特点来充分利用数据本身包含的局部性等特征, 优化网络结构, 并且保证一定程度上的位移不变性^[27]。其网络结构如图 2 所示。

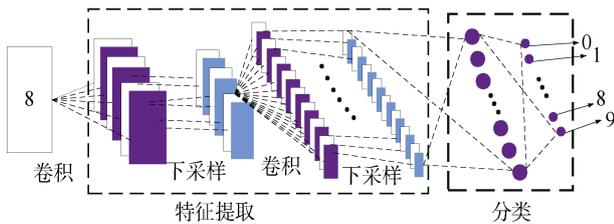


图 2 卷积神经网络结构图
Fig. 2 Block diagram of CNN

随着 CNN 网络的不断发展,也出现了一些新的深层卷积网络。其改进的过程实质就是用深度学习模型来替代浅层机器学习模型的过程,实现端到端的训练,速度也越来越快。例如 R-CNN^[28]: 物体检测目标是将图片中所有物体用方框框出来。首先是生成方框将物体框出来,然后对框出来的物体进行分类判断。Fast R-CNN^[29]将 R-CNN 中 CNN 提取特征、SVM 分类、回归这 3 个过程放在一起,形成端到端整体的模型,速度和准确率都得到提升。再如 Faster R-CNN^[30]: Faster R-CNN 首先用卷积层、池化层处理整张图片得到特征图,在此特征图上用 region proposal network 来生成方框,其余的操作跟 Fast R-CNN 如出一辙。即 Faster R-CNN 将生成方框的方法也换成了深度学习模型,并由原来在整张图上生成改成在更小的特征图上生成,使得模型训练速度进一步加快。此外比较常用的还有 Mask R-CNN^[31]等改进型卷积神经网络。

2.2.3 循环神经网络 RNN 原理及改进

RNN (Recursive Neural Network) 亦称递归神经网络,其最大特点在于神经网络各隐层之间的节点是具有连接的。其网络结构如图 3 所示,图中: X 为输入层; H 为隐藏层; O 为输出层; Y 为神经网络的主体结构。

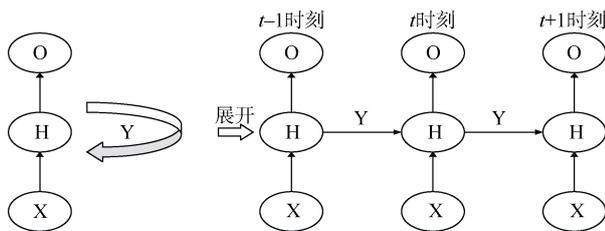


图 3 循环神经网络结构图
Fig. 3 Block diagram of RNN

RNN 的优点是可以处理序列数据,缺点则是容易随迭代的进行,历史输入对隐含层作用会逐渐减小乃至消失,即出现梯度消失问题。针对这个问题,研究者相继提出了一些 RNN 的变种,其中最著名的包括 Hochreiter 等人^[32]提出的长短时记忆网络 (Long Short-Term Memory, LSTM) 和 Cho 等人^[33]提出的门限循环单元 (Gated Recurrent Unit, GRU)。长短时记忆网络用 LSTM 单元替代 RNN 中的神经元,在输入、输出、忘记过去信息上分别加了输入门、输出门、遗忘门来控制允许多少信息过。LSTM 有单元状态 (cell state) 和隐藏状态 (hidden state) 2 个传输状态。GRU 是 LSTM 的轻量级变体,只有 2 个门——更新门和重置门。更新门决定保留过去多少信息,以及从输入层输入多少信息;重置门与 LSTM 里的遗忘门类似。GRU 没有输出门,所以总是输出完整状态。除此之外,还有分层 RNN、双向 RNN、多维 RNN、神经图灵机等改进型循环神经网络,在处理实际任务时都表现出了很好的效果。

实际的使用中,常采用多个模型相结合的方式,用于规避各模型缺点,充分发挥模型优势,以达到目标识别、现象预测等研究目的。

2.3 深度学习在水声目标识别中的应用

2.3.1 深度学习在水声图像识别中的应用

传统的水声图像目标识别方法大多数是基于局部特征的识别。但是,这种特征匹配在局部特征匹配中仅作为低级表示,对复杂背景进行特征提取时鲁棒性不足,没有足够的特征来防止假匹配,使得图像识别率也较低。这主要是由于传统目标识别算法语义分割鲁棒性较差。

卷积神经网络是深度学习在处理图像时的主要工具,可以帮助提取图像的特征。主要方式是通过使用若干个卷积核对图形进行滤波,得到原图像的多幅特征图,从各个角度提取图像的特征。利用权值共享使得只需要训练较少的卷积参数,就可以提取图像的多个特征。例如: Perez 等人^[34]提出了一种基于深度学习的水声图像增强方法,其基本原理就是利用卷积神经网络对采集到的水声图像进行处理。Kim 等人^[35]提出以水声声视觉图像中的

阴影作为识别特征, 基于卷积神经网络的方法对水声声视觉图像进行目标识别与分类。该方法成功地对 4 类水声目标的声视觉图像进行了准确分类。2015 年, Orenstein 等人^[36]采用卷积神经网络对 340 万个浮游生物图像进行了训练和分类, 结果表明: 该方法在时间和精度方面都优于传统人工分类筛选方法, 对大量浮游生物图像的分类效果较好。胡炎等^[37]在 Faster R-CNN 框架下构建了 1 个仅 3 层的卷积神经网络, 并对 4 种不同海洋杂波环境的宽幅 SAR 图像进行测试, 取得了较好的检测结果。林明旺^[38]设计了一种基于卷积神经网络的鱼类图像分类系统, 对鱼类图像的识别准确率达到 96%, 实现了预期效果。赵亮等^[39]结合 CNN 提取的特征、HOG 算法提取的边缘特征和 HSV 算法得到的颜色特征, 较好地实现了船舶目标识别。张清博等人^[40]提出利用基于卷积神经网络的深度学习方法对水下光电图像进行优化图像质量的研究。王博^[41]通过选通式水下激光成像系统在不同的光照、水质、距离、成像参数条件下采集水下目标的光学图像, 分别用在线 Adaboost 方法、BFSPM 方法、DCNN 方法对样本图像进行水下目标识别性能的比较和分析。王念滨等人^[42]在卷积神经网络的基础上引入特征图多维加权层, 构造了一个集特征提取和分类器训练于一体的端到端网络, 有效地提高了目标的识别精度。

2.3.2 深度学习在水声声信号识别中的应用

由于深度学习在语音识别上取得的突破性进展和自主学习的能力, 使得学者们在处理水声声信号的时候又有了新的思路: 利用计算机自动分析复杂的水声声信号, 通过合理的深层神经网络结构的训练得到信号的特征信息, 再配合高效率的分类器, 完成分类任务, 以提高识别的准确度。例如: 英国科学家 Sheppard 和 Gent 利用神经网络技术开发的被动声呐分类系统, 不仅采用窄带分析, 还采用宽带分析、DEMON 分析和瞬态分析方法。由于采用神经网络方法提高了系统的容错能力, 使训练不平衡系统有较好的性能, 从而能更好地完成对声音的分类与识别。王强等人^[43]从实测水声数据库中提取梅尔倒谱特征以及傅里

叶变换特征, 用 10 个声音片段作为训练样本, 5 个声音片段作为测试样本, 比较了 DBN、CNN、SVM(支持向量机 Support Vector Machines, SVM) 的识别率, 结果 DBN 和 CNN 的识别率均好于 SVM。Xu CAO 等人^[44]使用 21 850 个水声声信号片段作为训练样本, 用 8 550 个声音片段作为测试样本, 使用自动编码器与 SVM 和概率神经网络作比较, 识别 3 种类别的结果均是自动编码器较好, 而且都达到了 92% 以上。严韶光^[45]等人对 3 类目标在不同工况和水文气象条件下采集的 5 段长度为 32 768 s 的实录辐射噪声作为原始信号, 提出了一种基于卷积神经网络的舰船噪声分类器。通过数据仿真实验表明, CNN 的分类效果要好于 BP 神经网络的分类效果。赵安邦等人^[46]将高阶累积量用于希尔伯特变换特征提取中, 通过对舰船目标辐射噪声信号进行采集, 得到舰船目标噪声信号, 进而提取目标辐射信号各阶模态的相邻平均瞬时频率比、相对标准差、中心频率、平均强度、高阶矩和高阶累积量等作为特征, 最终利用神经网络来实现对 2 类舰船目标的分类识别。程锦盛等人^[47]从被动声呐目标识别出发, 用 4 种监督学习模型对 A 和 B 类水声目标、不同次海试、不同信噪比数据中提取的 MFCC 特征样本进行了识别研究, 其中 CNN 和 DBN 模型的识别率最高。

3 深度学习在水声目标识别应用中的研究展望

1) 数据库构建。

对于以数据为驱动深度学习, 获取好的水声数据信息显得尤为重要。但就目前水声目标识别的研究现状来看, 由于水声环境的复杂性, 对于水声声信号的识别, 研究人员仍会更多地参照深度学习对空气中声音的识别方法。而对水声图像的识别, 则会采用以往的图像处理算法和相关的深度学习理论。所以, 应建立完备的数据库, 从水声声信号与水声图像信号中提取预识别的水声目标的有效特征并发现其变化规律, 训练水声目标识别模型或分类器, 进而提高水声目标识别模型的准确性、信噪比鲁棒性和泛化性。

2) 数据预处理方法。

复杂的海洋环境,需要花费大量的时间为深度学习模型提取理想的样本,并按照模型要求的图像大小构造训练数据。由于处理大数据的规模所带来的大样本,使得数据呈现高维属性和多样性,故而数据预处理方法的优劣对模型的构建有重要的影响。深度学习在未来的数据处理方面应面向多种数据格式,以期减少数据预处理所耗费的大量时间,从而提高深度学习整体模型建立效率。

3) 模型构建。

深度学习模型算法众多,但当面对具体的水声目标识别问题时,没能及时给出最优的模型算法。其大都是对现有的模型进行改造或者多模型相结合,在模型的构建过程中通过大量实验对比才能建立更加准确的模型。同时,面对这些问题还需要构建新的学习模型,提高模型在面对不同类型的水声目标信号时的通用性,从而提升模型的适用范围。

4 结束语

本文首先对水声目标识别技术的研究现状及面临的挑战进行了描述。同时,介绍了深度学习的典型网络结构、改进型网络以及常用的几种开发工具,并对深度学习在水声目标识别中的实际应用情况进行了阐述。肯定了深度学习在水声目标识别应用中的优势,也指出了其中的不足之处,并给出了相应的解决思路。可以预见,未来水声目标识别技术发展方向主要是非声探测、多传感器信息融合、智能目标识别等。人工智能技术与水声目标识别技术有机结合将是今后水声目标识别研究的重要方向。

参考文献

- [1] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313 (5786): 504-507.
- [2] 陈越超, 徐晓男. 基于降噪自编码器的水中目标识别方法[J]. *声学与电子工程*, 2018, 1 (1): 30-32.
- [3] 柳革命, 孙超, 杨益新. 基于特征融合的被动声呐目标识别[J]. *计算机仿真*, 2009, 26 (8): 326-329.
- [4] 徐慧. 水声目标被动识别相关技术研究[D]. 武汉: 中国舰船研究院, 2017.
- [5] RAJAGOPAL R, SANKARANARAYANAN B, RAO P R. Target classification in a passive sonar—an expert system approach[C]// *International Conference on Acoustics*. US: IEEE, 2002.
- [6] LOURENS J G. Classification of ships using underwater radiated noise[C]// *Conference on Communications & Signal Processing*. US: IEEE, 1988.
- [7] ARNAB D, ARUN K, RAJENDAR B. Feature analyses for marine vessel classification using passive sonar[C]// *International Conference on Acoustics*. US: IEEE, 2005.
- [8] MAKSYM J N, BONNER A J, DENT C A, et al. Machine analysis of acoustical signal[J]. *Pattern Recognition*, 1983, 16 (6): 615-625.
- [9] FARROKHROOZ M, KARIMI M. Ship noise classification using probabilistic neural network and AR model coefficients[C]// *Oceans UDT. Europe*: IEEE, 2005.
- [10] TANMAY R, ARUN K, RAJENDAR B. Estimation of a nonlinear coupling feature for underwater target classification[C]// *Oceans UDT. Europe*: IEEE, 2002.
- [11] VACCARO R J. The past, present, and the future of underwater acoustic signal processing[J]. *IEEE Signal Processing Magazine*, 1998, 15 (4): 21-51.
- [12] LENNARTSSON R K, PERSSON L, ROBINSON J W C, et al. Passive underwater signature estimation by bispectral analysis[J]. *IEEE*, 2000, 20 (8): 281-285.
- [13] LI Q H, WAN J L, WEI W. An application of expert system in recognition of radiated noise of underwater target[C]// *Oceans UDT. Europe*: IEEE, 1995.
- [14] 王娜, 陈克安. 听觉感知特征在目标识别中的应用[J]. *系统仿真学报*, 2009, 21 (10): 3128-3132.
- [15] 彭圆, 申丽然, 李雪耀, 等. 基于双谱的水声目标辐射噪声的特征提取与分类研究[J]. *哈尔滨工程大学学报*, 2003, 24 (4): 390-394.
- [16] 章新华, 王骥程, 林良骥. 基于小波变换的舰船辐射噪声特征提取[J]. *声学学报*, 1997, 22 (2): 139-144.
- [17] 樊养余, 孙进才, 李平安, 等. 基于高阶谱的舰船辐射噪声特征提取[J]. *声学学报*, 1999, 24 (6): 611-616.
- [18] 章新华, 张晓明, 林良骥. 船舶辐射噪声的混沌现象研究[J]. *声学学报*, 1998, 23 (2): 134-140.
- [19] 徐新洲, 罗昕炜, 方世良, 等. 基于听觉感知机理的水声目标识别研究进展[J]. *声学技术*, 2013, 32 (2): 151-156.
- [20] 曹红丽, 方世良. 舰船辐射噪声的响度和音色特征模型[J]. *东南大学学报: 自然科学版*, 2013, 43 (2):

- 241-246.
- [21] 程玉胜, 邱家兴, 刘振, 等. 水声被动目标识别技术挑战与展望[J]. 应用声学, 2019, 38 (4): 654-655.
- [22] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313 (5786): 504-507.
- [23] CHEN H, MURRAY A. A continuous restricted Boltzmann machine with a hardware amenable learning algorithm[C]// Artificial Neural Networks-ICANN 2002. Berlin: Springer, 2002.
- [24] LEE H, EKANADHAM C, NG A Y. Sparse deep belief net model for visual area V2[C]// Proceedings of the Advances in neural information processing systems. Europe: IEEE, 2008.
- [25] LUO H, SHEN R, NIU C, et al. Sparse group restricted Boltzmann machines[C]// Proceedings of the AAAI. US: AAAI, 2011.
- [26] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[C]// Proceedings of the IEEE. Europe: IEEE, 1998.
- [27] IMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. [2015-03-25]. <http://www.cs.utexas.edu>.
- [28] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2014.
- [29] GIRSHICK R. Fast R-CNN[C]// International Conference on Computer Vision. Piscataway: IEEE, 2015.
- [30] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[C]// Annual Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2015.
- [31] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]// International Conference on Computer Vision. Piscataway: IEEE, 2017.
- [32] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9 (8): 1735-1780.
- [33] CHO K, MERNENBOER B, BAHDANAU D, et al. On the properties of neural machine translation: Encoder-decoder approaches[EB/OL]. [2014-05-23]. <http://www.engi-neering.purdue.edu>.
- [34] PEREZ J, ATTANASIO A C, NECHYPORENKO N, et al. A deep learning approach for underwater image enhancement[C]// International Work-Conference on the Interplay Between Natural and Artificial Computation. Europe: IEEE, 2017.
- [35] WON K T, YU S C, YUH J K. Neural network-based underwater image classification for autonomous underwater vehicles[C]// Proceedings of the 17th World Congress, International Federation of Automatic Control. US: IFAC, 2008.
- [36] ORENSTEIN E C, BEJBOM O, PEACOCK E E, et al. Whoi-plankton-A large scale fine grained visual recognition benchmark dataset for plankton classification[J]. Proceedings of the IEEE, 2015, 8 (26): 2357-2368.
- [37] 胡炎, 单子力, 高峰. 基于 Faster R-CNN 和多分辨率 SAR 的海上舰船目标检测[J]. 无线电工程, 2018, 48 (2): 96-100.
- [38] 林明旺. 深度学习在鱼类图像识别与分类中的应用[J]. 数字技术与应用, 2017, 5 (4): 96-97.
- [39] 赵亮, 王晓峰, 袁逸涛. 基于深度卷积神经网络的船舶识别方法研究[J]. 舰船科学技术, 2016, 38 (15): 119-123.
- [40] 张清博, 张晓晖, 韩宏伟. 一种基于深度卷积神经网络的水下光电图像质量优化方法[J]. 光学学报, 2018, 38 (11): 4-8.
- [41] 王博. 自主水下航行器的光视觉认知技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2017.
- [42] 王念滨, 何鸣, 王红滨, 等. 基于卷积神经网络的水下目标特征提取方法[J]. 系统工程与电子技术, 2018, 40 (6): 14-20.
- [43] 王强. 深度学习方法及其在水声目标识别中的应用[J]. 声学技术, 2015, 34 (2): 138-140.
- [44] CAO X, ZHANG X M, YU Y, et al. Deep learning-based recognition of underwater target[C]// DSP2016. Beijing: DSP, 2016.
- [45] 严韶光, 康春玉, 李军, 等. 基于功率谱特征的 CNN 被动声呐目标分类方法[J]. 声学技术, 2017, 36 (5): 441-443.
- [46] 赵安邦, 沈广楠, 陈阳, 等. HHT 与神经网络在舰船目标特征提取中的应用[J]. 声学技术, 2012, 31 (3): 272-276.
- [47] 程锦盛, 杜选民, 周胜增, 等. 基于目标 MFCC 特征的监督学习方法在被动声呐目标识别中的应用研究[J]. 船舶科学技术, 2018, 40 (9): 116-121.

(责任编辑: 曹晓霖)