

文章编号: 2095-4980(2021)04-0556-06

## 迁移学习用于电磁目标识别

王美玉<sup>a</sup>, 田 乔<sup>\*b</sup>

(哈尔滨工程大学 a.信息与通信工程学院; b.计算机科学与技术学院, 黑龙江 哈尔滨 150001)

**摘要:** 迁移学习技术可以利用经验信息辅助当前任务, 已在计算机视觉和语音识别领域得到广泛应用, 但在电磁领域还没有取得明显的成就。电磁环境变化速度快, 源数据或分类器模型在新环境中性能会显著下降, 重新训练不仅需要大量的数据且费时费力。迁移学习技术与电磁目标识别任务十分相关, 本文采用实测电磁目标数据集, 探索迁移学习在解决电磁目标小样本问题中的几种应用, 包括同类目标迁移和异类目标迁移。实验结果表明, 通过将预训练模型迁移到目标域小样本识别任务, 当目标域为同类源且标记样本只有 20 个情况下, 相较于非迁移模型, 验证准确率提高 25%, 并且大大缩短了目标域训练时间; 当目标域为异类源时, 也能够保证识别准确率的同时使训练时间少于源域的 1/5。

**关键词:** 迁移学习; 电磁目标识别; 小样本

**中图分类号:** TP391.4

**文献标志码:** A

**doi:** 10.11805/TKYDA2021214

## Transfer learning for electromagnetic target recognition

WANG Meiyu<sup>a</sup>, TIAN Qiao<sup>\*b</sup>

(a.School of Information and Communication; b.School of Computer Science and Technology, Harbin Engineering University, Harbin, Heilongjiang 150001, China)

**Abstract:** Transfer learning technology can use experience information to assist current tasks. It has been widely used in the fields of computer vision and speech recognition, whereas it has not made obvious achievements in the electromagnetic field. The electromagnetic environment changes quickly, and the performance of the source data or the classifier model in the new environment will be significantly degraded. Retraining not only requires a lot of data but also takes time and effort. Transfer learning technology is very related to the task of electromagnetic target recognition. Based on the measured electromagnetic target data set, this paper explores several applications of transfer learning in solving the problem of small samples of electromagnetic targets, including the transfer of similar targets and the transfer of heterogeneous targets. Experimental results show that by migrating the pre-training model to the target domain small sample recognition task, when the target domain is a similar source and there are only 20 labeled samples, the verification accuracy is increased by 25% compared with the non-transfer model and the training time is greatly shortened; when the target domain is a heterogeneous source, the training time can be less than 1/5 that of the source domain while ensuring the recognition accuracy.

**Keywords:** transfer learning; electromagnetic target recognition; small samples

电磁目标识别<sup>[1]</sup>是认知电子战行动指令发布的前提信息保障, 对电子战决策的制定起着关键作用。然而, 随着用频设备的指数级增加, 电磁环境日益复杂<sup>[2]</sup>, 使电磁数据表现出数据清洗复杂度高以及可分析性差的特点, 给电磁数据集的标记共享以及电磁目标的精确识别带来巨大困难<sup>[3]</sup>。因此, 在有限数据集条件下进行电磁目标精确识别是一项挑战。

随着人工智能技术的发展, 越来越多的人工智能技术用于电磁环境目标识别的研究工作。其中, 深度学习技术由于其可以自动提取深层特征进而获得较高识别准确率而被广泛使用<sup>[4-5]</sup>。文献[6]提出基于深度学习的一

收稿日期: 2021-05-24; 修回日期: 2021-06-07

基金项目: 国家自然科学基金面上基金资助项目(61771154); 哈尔滨工程大学先进船舶通信与信息技术工业和信息化部重点实验室资助项目

\*通信作者: 田 乔 email:tianqiao@hrbeu.edu.cn

种空间奇异扩展方法，实现电磁信号中的雷达目标识别。文献[7]介绍了一种使用深度神经网络的生成信号来识别电磁信号发射源的方法。这些信号在电子识别接收器中进行测量，处理为数字信号，然后进行识别。卷积神经网络(Convolutional Neural Network, CNN)是经典的、重要的深度学习模型之一，结构简单，具有较好的可扩展性。CNN 已在电磁空间领域，特别是电磁目标识别领域取得了一些较好的效果，如 SAR 图像识别<sup>[8]</sup>。但基于深度学习的分类任务在训练时对数据的要求较高，除数据随时可用之外，其数据分布在训练和测试阶段也需保持不变，这在实际电磁环境中很难满足。此外，在实际应用中，许多现有的数据集没有被广泛提供和共享；标记和清理数据也很困难，这给深度学习方法的应用带来了额外的挑战。文献[9]对迁移学习在 6G 通信领域已取得的应用进行了详细的综述。迁移学习已经在频谱转换、基站节能等研究中取得一些应用，但其在电磁目标识别方面的研究几乎没有。迁移学习使基于深度学习的分类模型能够用于多种情况，有助于克服环境变化带来的挑战<sup>[10]</sup>。文献[11]采用迁移学习技术对电磁目标识别进行了初步尝试，但该文献采用的是美国的 DAPAR 数据集，此数据为非公开数据集。文献[12]基于射频指纹对广播式自动相关监视(Automatic Dependent Surveillance Broadcast, ADS-B)信号进行识别，但文献中实测的数据集目标类型较少，只有 5 个。因此，将迁移学习应用到电磁目标识别领域还需进一步探索和研究。本文在一个大型实测 ADS-B 数据集上训练分类识别模型，并在此基础上，结合迁移学习解决小样本场景电磁目标识别问题，展示了从可用的电磁目标数据集学习网络参数的潜力，并利用它们来分离训练期间不可用的电磁目标数据集。

## 1 实验数据

### 1.1 电磁目标数据采集

本文使用的电磁目标数据集为实测数据集，采用 1 090 MHz 全向天线接收空中 ADS-B 信号。采集设备为 SM200B(Signal Hound 公司)，采样频率为 50 MHz，中频为 0 Hz，中心频率为 1 090 MHz，带宽为 10 MHz，增益为 30 dB。利用 HP 笔记本电脑作为信号处理平台对信号进行解码、标记和存储。笔记本电脑的配置为 Intel(R) Core(TM)i7-10750H CPU@2.60 GHz、32 GB RAM 和 256 GB SSD 硬盘。

数据采集系统总体框架如图 1 所示。软件定义无线电(Software Defined Radio, SDR)装置用于检测和捕获 ADS-B 电磁信号的基带 I/Q 数据，并采用重采样技术以减少数据量，提高数据处理速度；利用报头搜索检测 ADS-B 信号的开始位置，在一定时间间隔内找到互相关输出的峰值来同步信号；根据 DO260B 标准，采用自动解码算法获取飞机的唯一识别码、状态、位置等信息，用于标记电磁信号；采用自动标记算法对基带 I/Q 数据进行相应飞机 ID 的标记，并采用奇偶校验确保每一个标记的电磁信号都是有效和准确的；重采样因子  $D_{factor}$  和位置指数  $L_D$  用于确定电磁信号的起始位置，即  $L_{start}=D_{factor} \times L_D$ 。根据信号长度，可以很容易地计算出电磁信号的结束位置；最后，将相同 ID 的数据整理到一个目录下。这样经过一段时间的 ADS-B 信号连续采集，就可以得到一个数据集。整个系统在不需要人工参与的情况下运行，大大节省了构建数据集的成本、时间和人力。

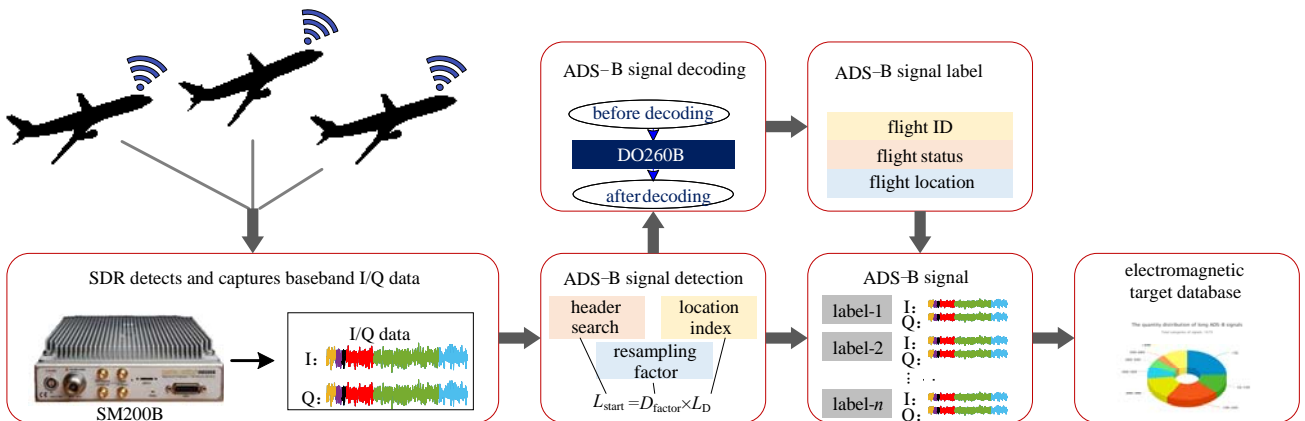


Fig.1 Data acquisition system framework  
图 1 数据采集系统框架

### 1.2 电磁目标数据预处理

#### 1.2.1 归一化处理

由于软件无线电设备 SM200B 中的自动增益控制(Automatic Gain Control, AGC)部件，ADS-B 基带信号幅

度并不能真实反映信号的真实幅度，且接收目标的距离也会对信号的幅度产生影响，因此在对数据进行分析和使用之前，需对接收到的原始数据进行归一化预处理，对接收到的同向、正交  $I(k), Q(k)$  两路信号：

$$\begin{cases} \tilde{I}(k) = \frac{I(k)}{\max(\sqrt{I^2(k)+Q^2(k)})} \\ \tilde{Q}(k) = \frac{Q(k)}{\max(\sqrt{I^2(k)+Q^2(k)})} \end{cases} \quad (1)$$

式中  $\tilde{I}(k), \tilde{Q}(k)$  为归一化之后的 IQ 信号。

1.2.2 数据切片

不同条件、不同环境、不同电磁目标所采集的数据集包含不同长度(I/Q 样本数)的无线电信号。为方便不同来源、不同类型电磁目标数据之间的迁移学习，训练统一的、固定长度的输入数据神经网络分类器。本文利用滑动窗口将每个信号转换成一系列长度相等的切片，用于原始信号相同的设备标识进行标记。数据切片操作如图 2 所示，最终这些等长的切片被输入到神经网络中。




Fig.2 Schematic diagram of sample data slice  
图 2 样本数据切片示意图

使用切片步长为  $L$  的滑动窗口对长度为  $M^{(k)}$  的 I/Q 样本进行分割，最终得到  $M^{(k)}-L+1$  个切片。

分类器训练过程中对这  $M^{(k)}-L+1$  个切片进行随机选择，并将它们用作神经网络的输入。随机选择切片的优势在于：首先，可以保证输入数据是固定大小的；其次，通过为每个设备学习移位不变的射频指纹提高神经网络的鲁棒性和可靠性。

在训练期间，每个电磁目标的样本  $k$  的切片数量  $n^{(k)}$  由式(2)的超参数  $\lambda$  控制：

$$n^{(k)} = \frac{M^{(k)} - L + 1}{L} \lambda \quad (2)$$

式中： $M^{(k)}$  为第  $k$  个样本中 I/Q 样本的总数； $L$  为切片大小。此外，改变参数  $\lambda$  有助于防止模型过拟合和降低计算成本。

最后，聚合多个切片的预测标签，推断电磁目标类型。

2 电磁目标识别迁移学习模型

2.1 预训练模型

卷积神经网络由多个处理层构成，包含卷积层、池化层和全连接层。模型训练过程中依靠损失函数计算误差，并以此更新网络各层的参数。模型测试过程中则直接利用获取到的数据源的测试集进行测试验证。

卷积层的功能是对信号进行特征提取，每层包含多个卷积核。卷积层计算公式为：

$$z_{i,j}^l = \sum_{m=0}^H \sum_{n=0}^W f_{m,n} x_{i+m,j+n}^l \quad (3)$$

式中： $x_{i+m,j+n}^l$  为卷积层  $l$  的输入张量； $f_{m,n}$  为维度为  $H \times M$  的卷积核； $z_{i,j}^l$  为卷积层  $l$  的输出张量； $(i,j)$  为张量的坐标值； $(m,n)$  为卷积核的坐标值。

池化层利用池化函数提高模型的泛化能力并减少计算量和参数。常用的池化函数有平局池化、最大池化和随机池化等。若采用最大池化函数和  $2 \times 2$  的池化窗口，则池化层的计算公式为：

$$f_{\text{pool}} = \text{Max}(s_{i,j}, s_{i+1,j}, s_{i,j+1}, s_{i+1,j+1}) \quad (4)$$

式中： $f_{\text{pool}}$  为池化后的结果； $s_{i,j}$  为特征张量  $(i,j)$  位置上的元素。

全连接层则是首先对卷积层与池化层提取的特征数据进行降维平铺，然后进行非线性变换，将变换结果输入分类器中进行分类。常用的激活函数有 sigmoid 函数、tanh 函数与 ReLU 函数，本模型采用 ReLU 激活函数。ReLU 函数相对于前 2 个函数，具有计算简单，收敛速度快等特点，其表达式为：

$$f_{\text{ReLU}}(t) = \begin{cases} 0 & (t < 0) \\ t & (t \geq 0) \end{cases} \quad (5)$$

式中  $t$  为 ReLU 函数的自变量。

### 2.2 迁移学习模型

预训练模型采用一种深度卷积神经网络模型，其模型包含 6 个卷积层、6 个池化层和 1 个全连接层。在源域中训练好一个分类识别模型需要大量的数据，即源域中的目标类型越多，标签越完整，预训练模型通过卷积层则可以获取到较为全面的电磁目标特征。此时提取的特征向量再经过全连接层就可以实现电磁目标的有效识别。当面对标注样本极少的目标域数据时，迁移学习模型具体流程如图 3 所示。

迁移学习方法一般冻结网络的前面几层的结构不变，因为此时的前几层已经有了提取目标特征的丰富经验，直接锁定其权重和参数，然后加载到目标域，结合冻结的网络层并训练网络的后几层，最终形成适合目标域环境的新的网络模型。迁移学习技术的优势在于：对新的网络模型稍加训练就可以处理新的分类识别任务，对数据量的要求小，并且节约了成本。

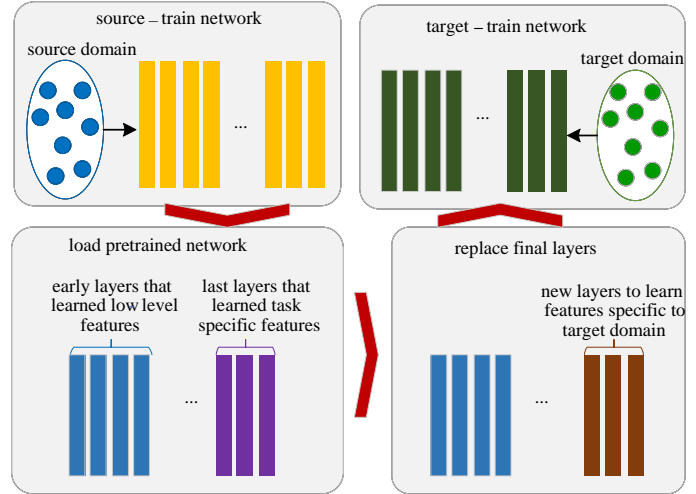


Fig.3 Transfer learning model  
图 3 迁移学习模型

## 3 模型训练与实验结果分析

### 3.1 预训练

预训练网络模型的层级结构如 2.1 节所描述，损失函数采用交叉熵损失函数，优化器采用动量梯度下降法 (Stochastic Gradient Descent with Momentum, SGDM)。初始学习率为 0.002，卷积核大小为 25，步幅为 1，mini-batch 为 256，最大训练轮次为 300 轮。为保证预训练模型能够学习到有效特征，本文实验在源域识别模型训练过程中，从实测数据集中抽取 128 类电磁目标，每类目标包含 300~400 个样本(截取前 100 个样本)，训练集：测试集：验证集=8:1:1，数据预处理中切片长度为 3 000。网络训练过程中引入学习率、动态调整机制和早停机制。从图 4 中可以看出，预训练模型最终迭代 19 340 次才达到收敛，最终验证准确率为 81.38%，损失函数值为 0.55。




Fig.4 Pre-training accuracy and loss function curve  
图 4 预训练准确率及误差曲线

### 3.2 迁移任务

为充分验证迁移学习模型在小样本电磁目标识别任务中的有效性，实验中目标域样本数量为 20 或 30，并设计了同类源迁移和异类源迁移。在同类源迁移中，目标域待识别目标类型是源域目标类型的子集；在异类源迁移中，目标域待识别目标类型与源域中目标类型完全不相同。不同的目标域具体为：a) 128 个同类，每类样本数为 20；b) 354 个异类，每类样本数目为 20 或 30；c) 39 个异类源，每类样本数目为 20 或 30。

### 3.3 实验结果与分析

对预训练模型迁移到不同目标域的识别分类结果进行展示和分析。图 5(a)为目标域仅有 20 个样本时迁移学习模型和非迁移学习模型的训练曲线，非迁移学习模型经过 3 667 次迭代才达到收敛，但迁移学习模型仅 768 次就达到收敛。并且从表 1 中可以看出，迁移学习模型最终的验证识别率为 87%，比非迁移模型高出 25%。

图 5(b)为目标域为异类源时迁移模型的训练曲线，可以看出，目标域类别数目会影响迁移模型的训练时长，类别越多，训练时间越长，这是非常合理的。值得一提的是，当目标域有 354 类目标时，迭代次数也不足源域模型的 1/5。

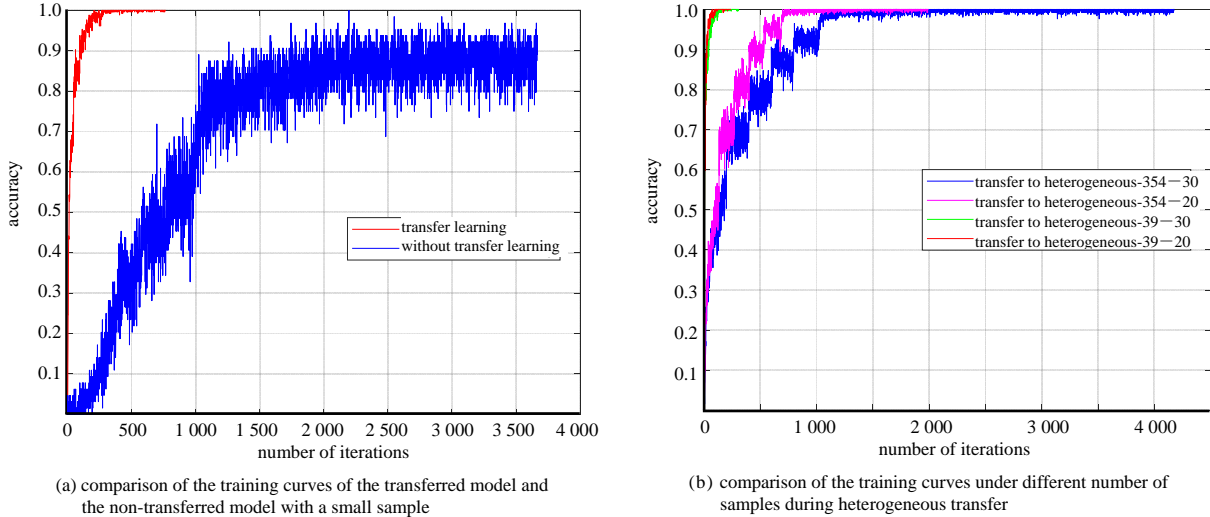


Fig.5 Training accuracy curves  
图 5 训练准确率曲线

表 1 中最后两列为异类源迁移时，不同目标域样本数目下的验证准确率。可以看出，对于异类源迁移，当目标域有 39 类目标时，样本数大于 20，识别率能达到 94%以上；甚至在目标域有 354 类目标时，样本数大于 20，识别率能到 76%以上。表 2 进一步对比了不同目标域在测试集上的最终损失函数值。表 1 和表 2 都体现出随着异类源目标域样本数量的减少，识别率反而升高且损失函数值降低，原因可能是验证过程中样本数目过少，其准确率存在上下浮动。

表 1 不同目标域的测试准确率

number of samples	without transfer	homologous-128	heterogeneous-354	heterogeneous-39
30	-	-	0.77	0.94
20	0.62	0.87	0.76	0.96

表 2 不同目标域的损失函数值

number of samples	without transfer	homologous-128	heterogeneous-354	heterogeneous-39
30	-	-	0.76	0.13
20	1.2	0.37	0.78	0.15

通过观察图 6 中不同目标域实验下的损失函数曲线可以发现，迁移模型的识别效果会随着目标域类别数量的变化有比较大的差异，但对于目标域类别所包含样本数量的敏感度不是很大。

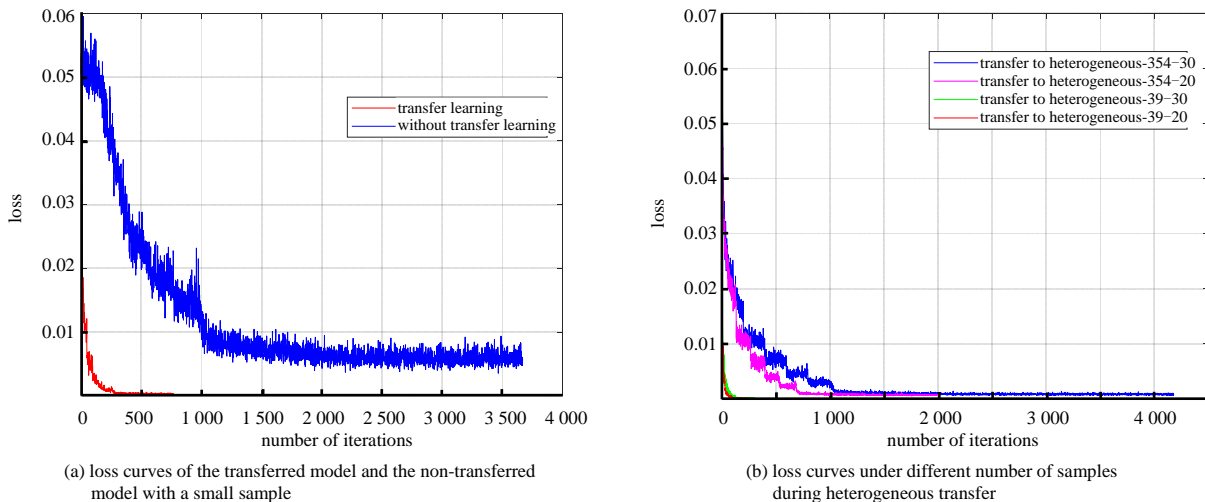


Fig.6 Loss function curves  
图 6 损失函数曲线

## 4 结论

本文将迁移学习技术用于电磁目标识别任务，以解决小样本情况下深度神经网络不能成功训练的问题。本文工作基于实测的具有大量标注样本的电磁目标数据集来训练深度神经网络识别模型，这是后续能够在多种小样本情形下实现模型成功迁移的重要基础。从实验结果可以看出，迁移学习模型可以在同类源样本数减少为原来的1/5的情况下，相较于未迁移模型识别准确率提高25%，在异类源、类别数大于350种且极少样本的情况下，识别率在75%以上。充分说明了迁移学习技术在电磁目标识别领域有非常明显的作用。未来，将会有更多类型的迁移学习方法应用到电磁目标识别领域，将会极大促进电磁空间研究的发展。

### 参考文献：

- [1] SEC MEN M, TASGETIREN M F. Ensemble of differential evolution algorithms for electromagnetic target recognition problem[J]. IET Radar, Sonar & Navigation, 2013, 7(7): 780–788.
- [2] 丁国如, 孙佳琛, 王海超, 等. 复杂电磁环境下频谱智能管控技术探讨[J]. 航空学报, 2021, 42(4): 200–212. (DING Guoru, SUN Jiachen, WANG Haichao, et al. Discussion on spectrum intelligent management and control technology in complex electromagnetic environment[J]. Acta Aeronautica Sinica, 2021, 42(4): 200–212.)
- [3] 陈国通, 刘琪, 孙敬. 复杂电磁环境下的高速频谱分析技术[J]. 太赫兹科学与电子信息学报, 2020, 18(6): 1020–1024. (CHEN Guotong, LIU Qi, SUN Jing. High speed spectrum analysis technology in complex electromagnetic environment[J]. Journal of Terahertz Science and Electronic Information Technology, 2020, 18(6): 1020–1024.)
- [4] GOODFELLOW I, BENGIO Y, COURVILLE A, et al. Deep learning[M]. Cambridge: MIT Press, 2016.
- [5] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436–444.
- [6] ALZAHED A M, ANTAR Y M M, MIKKI S M. Electromagnetic deep learning technology for radar target identification[C]// 2019 IEEE International Symposium on Antennas and Propagation and USNC-URSI Radio Science Meeting. Atlanta, GA, USA: IEEE, 2019: 579–580.
- [7] MATUSZEWSKI J, PIETROW D. Recognition of electromagnetic sources with the use of deep neural networks[C]// XII Conference on Reconnaissance and Electronic Warfare Systems. 2019: 110550D.
- [8] CHEN S, WANG H. SAR target recognition based on deep learning[C]// 2014 International Conference on Data Science and Advanced Analytics (DSAA). Shanghai, China: IEEE, 2014: 541–547.
- [9] WANG M, LIN Y, TIAN Q, et al. Transfer learning promotes 6G wireless communications: recent advances and future challenges[J]. IEEE Transactions on Reliability, 2021(99): 1–18.
- [10] 赵阳洋, 王振宇, 王佩, 等. 任务型对话系统研究综述[J]. 计算机学报, 2020, 43(10): 1862–1896. (ZHAO Yangyang, WANG Zhenyu, WANG Pei, et al. Summary of task-based dialogue system research[J]. Chinese Journal of Computers, 2020, 43(10): 1862–1896.)
- [11] KUZDEBA S, ROBINSON J, CARMACK J. Transfer learning with radio frequency signals[C]// 2021 IEEE 18th Annual Consumer Communications & Networking Conference (CCNC). Las Vegas, NV, USA: IEEE, 2021: 1–9.
- [12] ZHA H, TIAN Q, LIN Y. Real-world ADS-B signal recognition based on Radio Frequency fingerprinting[C]// 2020 IEEE 28th International Conference on Network Protocols (ICNP). Madrid, Spain: IEEE, 2020: 1–6.

### 作者简介：

王美玉(1992–)，女，黑龙江省鹤岗市人，在读博士研究生，主要研究方向为迁移学习、电磁目标识别、电磁频谱大数据。email: hrbeu\_meiyu@hrbeu.edu.cn.

田 乔(1991–)，女，哈尔滨市人，讲师，主要研究方向计算机体系结构性能优化、网络与信息安全、信号分析识别等。