

基于知识原型网络的小样本多功能雷达 工作模式识别

利 强^{1,2}, 张 伟^{1,3}, 金秋园¹, 姚 欣¹

(1. 电子科技大学信息与通信工程学院, 四川成都 611731; 2. 鹏城实验室, 广东深圳 518055;
3. 电子信息控制重点实验室, 四川成都 610036)

摘 要: 在认知电子战中,对多功能雷达工作模式的识别是至关重要的一环.在实际中,由于多功能雷达工作模式的多样性、隐藏性,能侦收到的不同工作模式脉冲样本数可能较少.因此,如何在少量样本条件下,准确识别多功能雷达的工作模式,对雷达对抗具有重要意义.针对此问题,本文提出了一种将模式先验知识与原型网络相融合的识别方法.该方法的核心是将雷达工作模式先验知识进行编码映射,并融入原型网络训练,实现知识在网络模型中的内嵌,以在少量训练样本条件下获得更好的识别性能.仿真结果表明,融入了先验知识的原型网络与不使用先验知识的原型网络、SVM分类器相比,识别准确率分别提升了2.9%和10.5%.

关键词: 小样本; 雷达模式识别; 原型网络; 先验知识融合

中图分类号: TP911.7; TP391

文献标识码: A

文章编号: 0372-2112(2022)06-1344-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20210932

Multi-Function Radar Working Mode Recognition with Few Samples Based on Knowledge Embedded Prototype Network

LI Qiang^{1,2}, ZHANG Wei^{1,3}, JIN Qiu-yuan¹, YAO Xin¹

(1. School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu, Sichuan 611731, China;

2. Peng Cheng Laboratory, Shenzhen, Guangdong 518055, China;

3. Science and Technology on Electronic Information Control Laboratory, Chengdu, Sichuan 610036, China)

Abstract: Multifunctional radar working mode recognition is important for cognitive electronic warfare. In practical applications, due to the diversity and concealment of multifunctional radar operating modes, the intercepted pulses for different operating modes is limited. Therefore, using only limited intercepted pulse records to accurately recognize the modes of the radar is a challenging but important task for radar countermeasures. To address the above problem, this paper proposes a novel recognition method by integrating the prior knowledge with the prototype network. The core of this method is to encode and embed the prior knowledge into prototype network training to obtain better recognition performance with few training samples. The simulation results show that compared with prototype networks and SVM that do not use prior knowledge, the recognition accuracy of the prototype network with prior knowledge is increased by 2.9% and 10.5%, respectively.

Key words: few samples; radar working modes recognition; prototype network; prior knowledge embedding

1 引言

随着电磁领域技术的发展,电子对抗技术已逐步成为现代战争的核心技术之一,其中多功能雷达(Multifunction Radar, MFR)工作模式的识别是电子对抗技术中的重要组成部分.通过对接收机截获到的雷达信

号进行处理,挖掘信号规律、识别雷达工作模式是后续进行雷达行为意图推理、威胁评估、决策干扰的基础.能否对MFR工作模式进行准确识别是雷达对抗成功与否的关键^[1].针对该问题,主流识别方法可以分为有监督识别^[2-7]和无监督识别^[8-11]两类.基于监督学习,文

献[2]通过构造脉内、脉间特征矩阵,再利用证据理论并结合雷达信号特征库实现雷达工作模式的识别;文献[3]使用基于特征提取的模式识别算法,通过提取雷达脉冲组的特征,使用神经网络对信号特征进行识别,并对不同时刻的识别结果进行融合决策;文献[4]将不同的工作模式建模为有限状态机的隐藏序列,以信号参数和目标信息作为观测序列构建隐马尔可夫模型(Hidden Markov Model, HMM),利用 HMM 求解算法进行训练,实现工作模式识别;文献[5,6]将雷达在不同工作模式下的信号建模为具有一定语法规则的语言,通过借鉴句法模式识别原理,提出基于多级匹配和有限状态机的雷达工作模式推理方法;文献[7]使用了基于时频分析和扩张残差网络的识别算法,将雷达时域波形信号转换成二维时频图像,构建扩张残差网络以提取雷达信号的时频特征并完成分类识别. 基于无监督学习的雷达工作模式识别,文献[8]使用基于序列比对的模式识别算法完成搜索工作模式的规律重建;文献[9]使用基于包络分析的模式识别算法,根据机载火控雷达不同工作状态的信号特点,提出一种具有工程意义的包络分析法,实现对雷达工作模式的识别和对编队飞机的识别;文献[10]将 HMM 模型替换为预测状态表示模型,利用预测状态表示模型的相关算法完成对模型的训练,实现对雷达工作模式的识别;文献[11]使用了基于数据增强和加权辅助分类生成对抗网络的识别算法,利用时间镜像数据增强方法扩充样本数据集,结合加权辅助分类生成对抗网络来优化判别器,提高判别器的识别效果和识别稳定程度. 总体而言,基于无监督学习的雷达工作模式识别研究较有监督学习模式少,且算法局限性较大. 但是,后者要取得较好识别性能通常需要大量带标注的数据样本来训练识别模型. 但在实际中,由于 MFR 工作模式的多样性、隐藏性,实际能够获取到的不同工作模式的样本数可能是极其有限的,现有基于大样本的算法难以直接应用于小样本场景下的工作模式识别^[12].

另外,由于雷达工作模式设计与其功能应用息息相关,遵循一定设计准则,且同一系列雷达的前后代不同型号间在工作模式上往往存在相似性和继承性,因此根据对雷达的长期监测和资料情报积累,对不同平台搭载的雷达的工作模式往往具有一定程度的先验知识. 将前期积累的相关先验知识与侦收的数据相结合,将有助于提升 MFR 工作模式的识别准确率,尤其是在数据样本不足的场景. 基于以上想法,本文提出数据和知识联合驱动的模式识别算法. 通过将先验知识嵌入网络模型训练之中,减轻模型对训练数据“量”的依赖,实现小样本条件下雷达工作模式的准确识别. 实验结果表明,融入了先验知识的原型网络较不使用先验知

识的原型网络识别性能有较大提升. 本文的主要创新点和贡献包含以下 3 点.

(1)提出了一种向量化编码映射方法,实现对 MFR 工作模式先验知识的映射表征. 通过对雷达脉冲描述字中各参数的变化范围和规律进行编码训练获得工作模式先验知识信息的高效表征.

(2)提出了一种融合先验知识和原型网络的小样本 MFR 工作模式识别方法. 结合雷达工作模式先验知识的高维表征,改进原型网络的度量函数,实现先验知识与样本数据在高维特征空间中的融合,使得不同工作模式的特征具有更好的类内聚合性和类间区分性.

(3)对 8 款雷达 55 种工作模式进行仿真测试,结果表明融入了先验知识的原型网络与不使用先验知识的原型网络、SVM 分类器相比,识别准确率分别提升了 2.9% 和 10.5%,初步验证了方法的可行性和有效性.

2 基于原型网络的小样本雷达工作模式识别

早在 2017 年,Snell 等人就提出原型网络结构来解决小样本场景下的学习问题^[13]. 其核心是通过度量学习将数据映射到高维特征空间,使得类内样本在高维空间中尽可能聚集,同时类间样本尽可能远离. 在识别过程中,以待测样本在高维特征空间中的特征向量与各原型中心之间的距离差值为依据实现分类. 针对多功能雷达工作模式识别,其原型网络架构如图 1 所示.

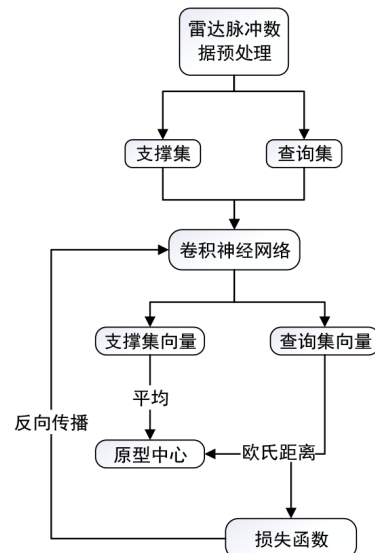


图 1 基于原型网络的雷达工作模式识别架构

2.1 雷达脉冲数据预处理

本文考虑将 MFR 不同工作模式下的脉冲重复间隔(PRI)、载波频率(RF)和脉冲宽度(PW)这 3 个维度的数据作为输入. 首先,对脉冲到达时间(TOA)进行逐差转换为脉冲重复间隔(PRI),并参考小样本图片分类方

法^[14,15],将脉冲数据的3个维度看作图片样本的3个通道,通道上的数值对应脉冲数据各维度上的参数值.然后,对一帧脉冲数据进行预处理,转化为三通道的图片样本,并按照通道进行归一化后作为原型网络的输入.在实现过程中,使用多层卷积神经网络提取脉冲数据特征.在原型神经网络结构中,记 f_θ 为原型网络的映射函数,那么图像样本 x 输入到原型网络后映射为高维空间中的特征向量 z 的过程则可表示为

$$f_\theta: x \in \mathbb{R}^{H \times W \times C} \rightarrow z \in \mathbb{R}^D \quad (1)$$

其中, H, W 表示原型网络输入图片样本的高度和宽度; C 表示图片样本的通道数; D 表示原型网络输出特征向量的维度; θ 表示原型网络参数.关于实验中原型神经网络的具体结构将在第3节中详细说明.

2.2 原型类中心

在小样本 MFR 工作模式识别过程中,使用多层卷积层作为原型网络的特征提取器,将支撑集中的雷达脉冲数据样本映射为高维特征向量,并按类别计算高维特征向量的均值获得原型中心向量,具体的计算过程为

$$C_k = \frac{1}{N_k} \sum_{i \in \mathcal{X}_k} f_\theta(x_i) \quad (2)$$

其中, \mathcal{X}_k 表示类别 k 的支撑集; N_k 表示支撑集中第 k 类工作模式的训练样本量.

2.3 损失函数与原型网络训练

原型网络通过在高维特征空间中度量待分类原本点与各原型中心向量间的距离,并经过 softmax 运算得到分类概率.对于训练样本对 $\{(x_i, y_i)\}_{i=1}^T$, $y_i \in \{1, 2, \dots, K\}$, $\forall i = 1, 2, \dots, T$,经过原型网络后,其判决为第 k 类工作模式的概率为

$$P(y = k | x_i, y_i) = \frac{\exp\left(-\|f_\theta(x_i) - C_k\|_2\right)}{\sum_{k'} \exp\left(-\|f_\theta(x_i) - C_{k'}\|_2\right)} \quad (3)$$

相应的,网络损失函数为

$$\text{Loss} = -\frac{1}{T} \sum_{i=1}^T \log\left(P(y = y_i | x_i, y_i)\right) \quad (4)$$

其中, T 表示训练样本总量.迭代训练过程中使用 Adam 随机梯度下降和反向传播更新原型网络参数 θ ,以最小化原型网络的损失,即最大化网络分类识别的准确率.当网络收敛时,同类样本经过原型网络的映射函数 f_θ 输出的特征向量在高维空间中聚成一簇,不同类别对应的簇间距离较远.完成训练后,输入待分类雷达脉冲数据 \hat{x} ,经过网络映射为 $f_\theta(\hat{x})$,按照式(3)计算分类概率,选择最大概率对应的类别作为分类结果.

3 融合先验知识的小样本雷达工作模式识别

本节给出一种在原型网络中融合先验知识的 MFR 模式识别方法,其主要原理如图2所示.




图2 知识原型网络原理

第一阶段,采用前一节所述方法,预训练原型网络,记录网络输出的不同工作模式所对应的原型中心向量.第二阶段,按照3.1节定义编码方法对先验知识进行编码,并连同第一阶段获得的原型网络中心向量作为标签,一同送入中心网络进行训练,当中心网络收敛时将输出的向量定义为预中心向量.第三阶段,以罚函数形式将第二阶段得到的预中心向量与网络 Loss 函数相结合,重新训练原型网络,完成先验知识与数据的深度融合.

测试阶段,将待分类 PDW 数据送入已训练的知识原型网络,实现对小样本雷达工作模式的识别.本文所提出的知识原型网络模型框架如图3所示,下面从先验知识编码、先验知识映射和先验知识融合这3个方面对知识原型网络的原理进行详细阐述.

3.1 先验知识编码

对于已知雷达,根据对抗经验以及掌握的情报知识,能够(大致)获知不同工作模式下 PDW 的各维度特征的变化规律,因此可以将 PDW 各参数变化范围和规律这一知识信息融入原型网络训练,以提升网络识别性能.由于本文主要考虑 PRI, RF 和 PW 这3个特征维度,其相应的知识定义为:在不同工作模式下,以上3个维度参数的变化范围及规律描述.

确定好训练过程中的先验知识后,需要将其进一步转化为便于计算和使用的形式.本文提出一种知识编码方式,可以将工作模式的 PRI, RF 和 PW 这3个维度上的参数变化范围及规律表征为一定长度的数值(知识)向量,具体实现如下:整个向量包含 a, b, c 这3个子段,每个子段刻画先验知识中的一个特征维度,分别对应 PRI, RF 和 PW 的变化规律,向量总维度为 $(a+b+c)$,如图4所示.

知识向量的 a, b, c 取值由先验知识中各维度参数变化范围及规律确定.具体而言,子段一的编码长度为能够完整表征每种工作模式下 PRI 特征参数取值和规律变化所需的最小长度.例如:先验知识记录了3类雷

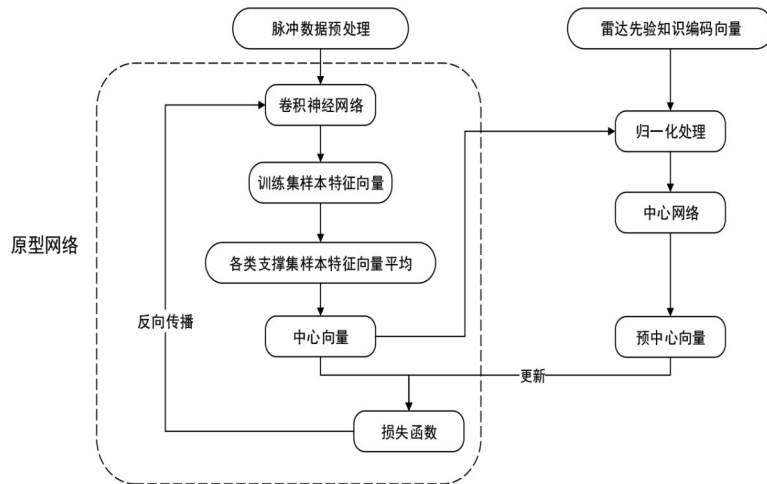


图3 知识原型网络框架




图4 知识编码向量

达工作模式的特征信息,如表 1 所示. 对于雷达工作模式 3,其 PRI 特征值有 3 个典型值,分别是 5 331,4 157 和 3 528,且取值按照 2,3,4 的组变形式进行变化,那么其 PRI 特征一次完整的变化可表示为[5 331,5 331,4 157,4 157,4 157,3 528,3 528,3 528,3 528],取值序列长度为 9,则 a 取值为 9. 同样地,对于雷达工作模式 1,PRI 特征一次完整的变化可表示为[8 431,3 953,3 953,3 953],取值序列长度为 4,则 a 取值为 4. 对于雷达工作模式 2,其 PRI 为固定,完整描述一次 PRI 特征规律只需要一个参数, a 取值为 1. 在确定各模式下 a 的大小后,选最大的 a 值为最终 PRI 维度的编码长度. 在上例中, a 取值为 9,而对于模式 1 和 2,由于其 PRI 编码长度小于 9,可以通过循环扩展为长度 9. 在上述例子中,对雷达工作模式 1 的知识信息进行编码得到向量的前 9 维是[8 431,3 953,3 953,3 953,8 431,3 953,3 953,3 953,8 431];同样地,对雷达工作模式 2 的知识信息进行编码得到向量的前 9 维是[3 061,3 061,3 061,3 061,3 061,3 061,3 061,3 061,3 061]. 类似地,知识向量的 b 和 c 值的确定取值为先验知识中各个工作模式 RF 和 PW 特征取值及变化规律能够完整表征一次的最小长度. 对于表 1 中记录的 3 类雷达工作模式, a, b, c 分别取值为 9,9,3. 对于表 1 记录的工作模式 3,编码知识信息得到向量的前 9 维是[5 331,5 331,4 157,4 157,4 157,3 528,3 528,3 528,3 528],中间的 9 维是[295,295,385,385,385,845,845,845,845],最后的 3 维是[70,85,110]. 根据上述编码方法,可以获取各类雷达工作模式先验知识信息对应的知识向量,为后续处理提供基础.

3.2 先验知识映射

通过建立知识向量到原型中心向量的映射关系,

表 1 雷达工作模式先验知识表

| 工作模式 | PRI/us | | RF/MHz | | PW/us | |
|------|--------|---------------------------|--------|---------------------|-------|-----------|
| | 类型 | 取值 | 类型 | 取值 | 类型 | 取值 |
| 1 | 组变 | 8 431,3 953 [1,3] | 参差 | [400/500/600] | 抖动 | 128±8 |
| 2 | 固定 | 3 061 | 固定 | 550 | 固定 | 78 |
| 3 | 组变 | 5 331,4 157,3 528 [2,3,4] | 组变 | 295/385/845 [2,3,4] | 多个 | 70/85/110 |

实现知识向量空间到原型网络特征空间的映射. 具体而言,通过 1 个多层全连接网络将知识向量映射为与第一阶段预训练原型网络的中心向量分布近似的向量,网络输出为融合了先验知识信息的原型中心向量,记为“预中心向量”. 该预中心向量将应用于第三阶段原型网络的重训练. 在本文中,上述多层全连接网络被称为“中心网络”,中心网络的处理流程如图 5 所示. 首先,将 2.1 节得到知识编码向量进行归一化,然后进行高斯随机化样本扩充,即,对每个知识向量重复多次加入均值为 0、方差为 σ^2 的独立同分布高斯噪声,得到中心网络的训练样本. 需要指出的是,高斯随机化过程在扩充训练样本空间、防止中心网络过拟合的同时,可以提高中心网络对知识编码向量扰动的鲁棒性. 中心网络以高斯随机化知识向量样本为输入,以预训练原型网络中心为标签,以 MSE 为损失函数进行回归. 网络输出为“预中心向量”,该向量将应用于原型网络的重训练. 中心网络的具体结构详见 4.2 节.

3.3 先验知识融合

原型网络的识别性能与原型中心向量对各类样本




图5 中心网络处理流程

特征的表征程度密切相关. 在小样本条件下, 仅通过有限的数据是难以准确提取出各类别的原型中心向量的. 因此, 以正则项的形式将中心网络输出的 $\{\bar{C}_1, \bar{C}_2, \dots, \bar{C}_K\}$ 引入到原型网络的距离度量中, 实现先验知识对原型中心向量的校正. 校正后的距离度量函数为

$$d_k(x) = \|f_\theta(x) - C_k\|_2 + \lambda \|f_\theta(x) - \bar{C}_k\|_2 \quad (5)$$

其中, \bar{C}_k 为工作模式 k 的预中心向量; $\lambda > 0$ 为权重, 经验取值为 $10^{-(\eta+1)}$, η 由训练样本与原型中心距离的量级决定. 相应地, 分类概率式(3)修正为

$$P(y=k|x_i) = \frac{\exp(-d_k(x_i))}{\sum_{k'} \exp(-d_{k'}(x_i))} \quad (6)$$

基于校正后的距离度量函数和分类概率式(6), 构建损失函数(4), 使先验知识信息内嵌到原型网络提取的样本特征中, 从而具有更好的类内聚合性及类间区分性. 完成原型网络的重训练后, 依据式(5)和式(6)计算待测样本分类概率, 得到模式分类结果.

4 仿真与结果分析

4.1 测试数据集

本文使用的雷达脉冲数据包含 8 款 MFR, 涵盖搜索、跟踪、边搜索边跟踪等 55 种工作模式. 每个雷达脉冲包含 TOA, RF 和 PW 这 3 维参数, 脉冲按照 TOA 大小顺次排列, 将连续的 84 个 PDW 处理转化为 $84 \times 84 \times 3$ 的图片数据, 对应一种工作模式下的一个样本. 为拟合小样本场景, 每个雷达工作模式包含 20 个图片样本(由于在小样本雷达模式识别领域, 对“小样本”的样本量的划定暂时还没有一个公认的数量级范围, 本文将样本量 ≤ 20 、单个样本脉冲数 ≤ 100 视为小样本场景), 其中支撑集和查询集各占一半.

4.2 仿真设置及实验结果分析

在实验中, 本文采用的原型网络中卷积神经网络结构如图 6 所示, 整个网络结构为 5 层, 卷积层的卷积核大小固定为 3×3 , 池化层的池化模板固定为 2×2 , 池化时的步长设定为 2, 3 层卷积层将通道数从 3 经由 32 和 64 增至 128. 最后一层池化层后连接两层全连接层, 输出维度分别设定为 128 和 55.

中心网络的网络结构如图 7 所示, 整个网络包含 4 层全连接层, 第 1~3 层激活函数为 ReLU, 第 4 层为 tanh. 实验中经过编码后得到 47 维知识向量, 经 4 层全连接层从 47 维经由 128, 256, 128 再降为 55 维. 在中心网络的训练过程中, 每个 batch 大小设置为 128, 迭代 2 000 轮.

首先, 考察中心网络的映射性能. 图 8 给出了在完成中心网络的回归训练后, 用高斯随机化样本测试中心网络映射的准确率. 该准确率由测试样本经中心网

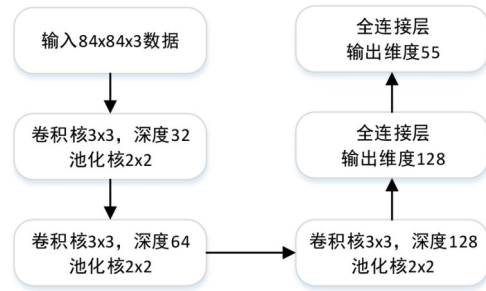


图6 卷积神经网络结构

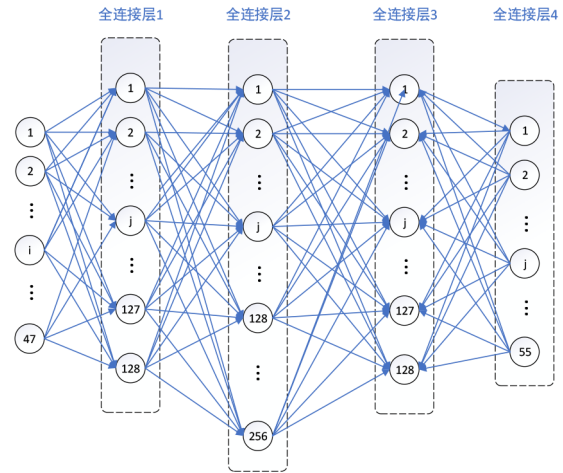


图7 中心网络结构

络映射后, 按与预中心向量的欧氏最小距离作为分类依据统计得到. 图 8 中蓝色曲线和橙色曲线分别表示训练和验证过程中的准确率. 由图 8 可以看出, 中心网络映射准确率约为 78%.




图8 中心网络映射准确率曲线

接下来考察先验知识的使用对原型网络识别准确率的影响. 知识原型网络每个 batch 大小设置为 16, 迭代 3 000 轮. 知识原型网络与经典原型网络在训练过程中识别准确率的对比结果如图 9 所示.

从图 9 可以看出, 在训练轮次较少的情况下, 融入先验知识有助于快速提升原型网络识别准确率, 并最




图9 知识原型网络与经典原型网络训练准确率对比曲线

终达到 96.7%。值得注意的是,图 9 中的训练曲线随着训练轮次的增加呈现较大的起伏,这一现象产生的原因可能是样本本身数据量小,在使用随机梯度下降法进行网络训练时,单次输入网络的随机样本量较小,致使反向传播算法在对网络参数更新过程中出现较大

起伏。

考虑到实际中先验知识可能存在误差,导致先验知识信息中各个参数值不准确,为此,分别在知识编码向量上加入不同程度的高斯噪声来模拟不同程度的先验知识误差。表 2 给出了在不同先验知识误差下,知识原型网络与支持向量机、经典原型网络的对比结果。其中,知识误差较小和较大场景对应的高斯噪声分别为 Gauss(5, 0.12)和 Gauss(50, 0.12)。从表 2 可以看出,当先验知识误差较小时,知识偏差对网络性能影响较小,融合先验知识的原型网络在训练和测试过程中的识别准确率分别为 95%和 94.7%;当先验知识误差较大时,知识偏差对网络性能影响较大,融合先验知识的原型网络在训练和测试过程中的识别准确率分别为 93.4%和 91.6%,均低于不使用任何先验知识的原型网络的准确率。该结果表明,较大误差的先验知识已不能很好地反映不同工作模式下参数变化的真实情况,将带有较大偏差的知识向量融入原型网络不但无法提升识别性能,甚至适得其反。

表 2 不同识别方案识别准确率对比统计

| | SVM | 原型网络 | 知识原型网络(无误差) | 知识原型网络(误差较小) | 知识原型网络(误差较大) |
|-------|---------|---------|-------------|--------------|--------------|
| 训练准确率 | 0.940 9 | 0.967 2 | 0.996 3 | 0.950 | 0.934 |
| 测试准确率 | 0.861 8 | 0.938 1 | 0.967 0 | 0.947 | 0.916 |

最后,考虑到实际中先验知识可能存在部分缺失的情况,针对该情况,知识向量缺失部分,可以采用填充全 0 或者随机数的方式来补充。补充后的知识向量仍然可以采用 3.2 节及 3.3 节的方式融入原型网络中,实现对小样本雷达工作模式的识别。表 3 给出了不同补充方式下的识别准确率统计结果。仿真结果表明,以随机的方式补充知识向量比全 0 补充方式稍好,其原因可能是,全 0 填充缺失的先验知识等价于将缺失的先验信息视为相同,从而导致不同模式的先验知识区分度变小。

表 3 基于部分先验知识的识别准确率统计

| | 以 0 填充 | 以随机高斯数填充 |
|-------|---------|----------|
| 训练准确率 | 0.993 6 | 0.995 2 |
| 测试准确率 | 0.934 5 | 0.945 0 |

5 结束语

本文针对小样本 MFR 工作模式识别问题,提出了一种融合先验知识的原型网络。通过对雷达工作模式先验知识编码、映射,将先验知识融入原型网络有效提升了识别准确率。在涵盖 8 款 MFR、55 种工作模式的小样本雷达数据上的仿真结果表明,相比于不使用先验知识的原型网络和 SVM 分类器,本文网络识别准确率分别提升了 2.9%和 10.5%。值得注意的是,在先验知识有较大误差的情况下,融合知识的网络识别性能会有较大下降,如何设计具有对知识误差鲁棒性的融合网


络是下一步值得研究的方向。

参考文献

- [1] LI Y J, ZHU M T, MA Y H, et al. Work modes recognition and boundary identification of MFR pulse sequences with a hierarchical seq2seq LSTM[J]. IET Radar, Sonar & Navigation, 2020, 14(9): 1343-1353.
- [2] 王玉冰,程嗣怡,周一鹏,等.基于 DS 证据理论的机载火控雷达空空工作模式判定[J].现代雷达,2017,39(5): 79-84. WANG Y B, CHENG S Y, ZHOU Y P, et al. Air-to-air operation modes recognition of airborne fire control radar based on DS evidence theory[J]. Modern Radar, 2017, 39(5): 79-84. (in Chinese)
- [3] 董晓璇,程嗣怡,周一鹏,等.基于时域模糊决策融合的雷达工作模式识别方法[J].空军工程大学学报(自然科学版),2018,19(6): 59-65. DONG X X, CHENG S Y, ZHOU Y P, et al. A recognition method of radar operation modes based on time-domain fuzzy decision fusion[J]. Journal of Air Force Engineering University(Natural Science Edition), 2018, 19(6): 59-65. (in Chinese)
- [4] 陈维高,贾鑫,朱卫纲,等.基于 HMM 的雷达状态转移估计方法[J].北京航空航天大学学报,2017,43(10): 2171-2180.

- CHEN W G, JIA X, ZHU W G, et al. Radar state transfer estimation method based on HMM[J]. Journal of Beijing University of Aeronautics and Astronautics, 2017, 43(10): 2171-2180. (in Chinese)
- [5] 刘海军. 雷达辐射源识别关键技术研究[D]. 长沙: 国防科学技术大学, 2010.
- LIU H J. Researches on Identification Key Technology for Radar Emitter[D]. Changsha: National University of Defense Technology, 2010. (in Chinese)
- [6] 负洁, 孙闽红, 官友廉. 基于雷达字建模的多功能雷达工作模式识别[J]. 杭州电子科技大学学报(自然科学版), 2020, 40(6): 19-25.
- YUN J, SUN M H, GUAN Y L. Recognizing multi-function radar working mode based on radar word modeling[J]. Journal of Hangzhou Dianzi University(Natural Sciences), 2020, 40(6): 19-25. (in Chinese)
- [7] 秦鑫, 黄洁, 查雄, 等. 基于扩张残差网络的雷达辐射源信号识别[J]. 电子学报, 2020, 48(3): 456-462.
- QIN X, HUANG J, ZHA X, et al. Radar emitter signal recognition based on dilated residual network[J]. Acta Electronica Sinica, 2020, 48(3): 456-462. (in Chinese)
- [8] 马爽. 多功能雷达电子情报信号处理关键技术研究[D]. 长沙: 国防科学技术大学, 2013.
- MA S. Research on ELINT Signal Processing Key Technologies for Multifunction Radar[D]. Changsha: National University of Defense Technology, 2013. (in Chinese)
- [9] 刘俊江. 机载火控雷达工作模式识别[J]. 电子测量技术, 2016, 39(2): 131-133, 146.
- LIU J J. Airborne fire control radar work modes recognition[J]. Electronic Measurement Technology, 2016, 39(2): 131-133, 146. (in Chinese)
- [10] OU J, CHEN Y G, ZHAO F, et al. Method for operating mode identification of multi-function radars based on predictive state representations[J]. IET Radar, Sonar & Navigation, 2017, 11(3): 426-433.
- [11] 朱克凡, 王杰贵, 刘有军. 小样本条件下基于数据增强和 WACGAN 的雷达目标识别算法[J]. 电子学报, 2020, 48(6): 1124-1131.
- ZHU K F, WANG J G, LIU Y J. Radar target recognition algorithm based on data augmentation and WACGAN with a limited training data[J]. Acta Electronica Sinica, 2020, 48(6): 1124-1131. (in Chinese)
- [12] 金秋园. 小样本雷达工作模式的识别研究[D]. 成都: 电子科技大学, 2021.
- JIN Q Y. Research of Radar Working Mode Recognition with few Samples[D]. Chengdu: University of Electronic Science and Technology of China, 2021. (in Chinese)
- [13] 赵凯琳, 靳小龙, 王元卓. 小样本学习研究综述[J]. 软件学报, 2021, 32(2): 349-369.
- ZHAO K L, JIN X L, WANG Y Z. Survey on few-shot learning[J]. Journal of Software, 2021, 32(2): 349-369. (in Chinese)
- [14] 刘颖, 雷研博, 范九伦, 等. 基于小样本学习的图像分类技术综述[J]. 自动化学报, 2021, 47(2): 297-315.
- LIU Y, LEI Y B, FAN J L, et al. Survey on image classification technology based on small sample learning[J]. Acta Automatica Sinica, 2021, 47(2): 297-315. (in Chinese)
- [15] 樊笛, 巨志勇. 基于原型网络的小样本图像识别方法[J]. 计算机与现代化, 2020, (3): 103-107.
- FAN D, JU Z Y. Method of small sample image recognition based on prototype network[J]. Computer and Modernization, 2020, (3): 103-107. (in Chinese)

作者简介



利 强 男, 1982 年出生, 四川成都人. 副教授, 博士生导师. 分别于 2005 年、2008 年在电子科技大学获得学士和硕士学位, 2012 年在香港中文大学获得博士学位. 主要研究方向为无线通信优化算法、电磁频谱智能感知等.

E-mail: lq@uestc.edu.cn



张 伟 男, 1985 年出生, 山东泰安人. 高级工程师, 博士研究生. 主要研究方向为非合作信号与信息处理、电子对抗等.



金 秋 园 女, 1996 年出生, 辽宁大连人. 2018 年在天津科技大学获得学士学位, 2021 年在电子科技大学获得硕士学位. 主要研究方向为小样本条件下的雷达模式识别.

E-mail: 948653552@qq.com



姚 欣 男, 1998 年出生, 湖北黄冈人. 2019 年在湖南大学获得学士学位, 目前在电子科技大学攻读硕士学位. 主要研究方向为雷达认知干扰决策.