

基于物理可解释自编码模型的雷达目标方位 稳健识别算法

廖磊瑶^{1,2}

(1. 南京邮电大学通信与信息工程学院, 江苏南京 210003;
2. 西安电子科技大学雷达信号处理国家重点实验室, 陕西西安 710071)

摘要: 现有基于深度神经网络的高距离分辨(High Range Resolution, HRR)雷达目标识别方法是纯数据驱动模型, 是 1 个飞行事故记录器结构, 特征不具可解释性, 在方位缺失情况下特征泛化性差, 模型识别率急剧下降。对此, 本文设计了一种物理可解释自编码模型(Physical Interpretable Auto-Encoder Model, PIAEM), 解码网络结合雷达目标的散射点模型, 利用编码网络挖掘雷达数据具有明确物理含义的散射中心特征, 从成像角度描述目标的物理结构特性, 如尺寸、轮廓等, 在方位缺失情况下具有稳健的物理特性。设计了基于最小重构误差的分类准则, 实现雷达目标识别。基于实测高距离分辨雷达回波数据的实验结果表明, 本文方法提取的特征具有明确物理含义, 且在方位缺失 4/5 的情况下, PIAEM 比现有基于传统目标识别方法的准确率提升了 10.27%, 验证了本文方法具有方位稳健识别性能。

关键词: 雷达目标识别; 可解释网络; 散射点模型; 变分推断; 自编码网络; 最小重构误差

基金项目: 南京邮电大学引进人才科研启动基金(自然科学)(No.NY223135)

中图分类号: TN959.1+7 **文献标识码:** A **文章编号:** 0372-2112(2024)11-3847-11

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

DOI: 10.12263/DZXB.20240024

High-Range Resolution Radar Target Recognition Based on Deep Interpretable Probabilistic Auto-Encoder Model

LIAO Lei-yao^{1,2}

(1. College of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu 210003, China;
2. National Key Laboratory of Radar Signal Processing, Xidian University, Xi'an, Shaanxi 710071, China)

Abstract: Existing neural network-based high range resolution (HRR) radar target recognition methods are data-driven models that are of black-box structure, which makes it hard to interpret or assess the hidden representations of data. In the case of incomplete target-aspect, neural network-based methods are faced with the issues of poor feature generalization ability and rapid degradation of recognition performance. To access the issues, this paper develops a physical interpretable auto-encoder model (PIAEM). In detail, by incorporating the scattering center model of radar targets into networks, the PIAEM is a physical interpretable model that learns scattering center features with physical meanings. Specially, since the scattering center features reflect the target structure based on radar imaging theory, they are robust under the case of incomplete target-aspect. Moreover, this paper designs a recognition scheme to predict the category of test samples based on the minimum reconstruction error criterion. The experiments on the measured HRR radar dataset validate the effectiveness of our model on learning interpretable features and robust recognition performance, and our PIAEM improves 10.27% rates comparing with traditional radar target recognition methods.

Key words: radar target recognition; interpretable neural network; scattering center model; variational inference; auto-encoder; minimum reconstruction error

Foundation Item(s): Natural Science Research Start-up Foundation of Recruiting Talents of Nanjing University of Posts and Telecommunications (No.NY223135)

1 引言

雷达目标识别在精确制导和态势感知等军事领域有重要作用,在雷达感知技术研究中受到越来越多关注^[1-3]. 宽带雷达体制下,高距离分辨雷达目标回波即复高分辨距离像(High Resolution Range Profile, HRRP)可视为多个目标散射点子回波沿着雷达视线方向投影的向量和,它具有较高分辨率,包含丰富的目标细节信息,比如目标的散射特性、尺寸和结构等,这些信息有利于对目标的类别或属性进行判别. 因此,高距离分辨雷达目标识别是雷达感知领域中的研究热点.

目前雷达目标识别方法可分为传统识别算法和深度识别网络两大类. 传统识别算法通过线性变换提取雷达回波的特征,代表性算法包括:主成分分析(Principal Component Analysis, PCA)^[4]、K奇异值分解(K-Singularly Valuable Decomposition, K-SVD)^[5]和因子分析(Factor Analysis, FA)^[6]等,采用支持向量机(Support Vector Machine, SVM)或者贝叶斯分类器(Bayesian Classifier, BC)等方式将提取的特征用于目标识别. 由于深度神经网络具有强大的特征挖掘能力,基于深度神经网络的雷达目标识别方法得到不断发展,典型的识别网络包括:堆栈相关自编码器(Stacked Corrective Auto-Encoder, SCAE)^[7]、分解判别条件变分自编码器(Factorized Discriminative Conditional Variational Auto-Encoder, FDCVAE)^[8]和目标方位循环注意力网络(Target-Aware Recurrent Attentional Network, TARAN)^[9]等,挖掘雷达 HRRP 的非线性深层特征或者不同距离单元之间的时序特征,设计非线性分类器实现目标识别. 然而,这些基于深度神经网络的识别方法是纯数据驱动模型,网络是1个飞行事故记录器结构,提取的特征不具有物理含义,特征稳健性较差,模型在目标方位缺失时识别率将会下降. 文献[10]分析了稀疏自编码器的深层特征与散射中心特征的关联性,说明采用稀疏自编码网络学习得到的隐层特征与采用传统算法提取得到的散射中心特征具有相似特性,包含相似的散射中心位置和强度分布. 本文分析了稀疏自编码网络的网络权值系数相乘后与散射中心的距离域傅里叶基具有强相关性. 文献[10]说明了自编码网络能提取具有明确物理含义的隐层特征.

本文基于雷达复 HRRP 的物理生成机制,构建了物理可解释自编码模型(Physical Interpretable Auto-Encoder Model, PIAEM)用于雷达目标方位的稳健识别. 该模型的解码网络结合了雷达目标的物理模型,编码网络从复 HRRP 数据中学习具有明确物理含义的隐特征,即代表目标散射中心的位置和幅度. 另外,考虑到复 HRRP 的方位敏感性,本文方法将各类数据按照一定方位角划分为多个方位帧,每帧回波采用独立的自

编码网络进行精细描述. 考虑到每帧回波位置相似、幅值起伏的分布特性,所提模型采用位置参数共享、幅值参数独立的学习方式准确学习每帧回波的物理特征. 因此,本文方法提取的散射中心特征反映了目标的结构和尺寸信息,对不同方位帧数据具有稳健的物理特性. 基于 PIAEM,设计了基于最小重构误差的分类准则. 采用实测雷达复 HRRP 数据的实验结果验证了所提算法的有效性. 本文方法 PIAEM 与文献[10]所提方法具有一定相关性,且网络结构、学习隐层特征相似. 但仍然存在以下几个较大区别:(1)本文考虑对不同方位角目标 HRRP 数据进行精细的特征挖掘,将全方位角的训练样本进行分帧,考虑到每1帧样本的散射中心位置分布相似、强度起伏的物理特性,设计了位置共享、幅值独立的学习策略,利用编码网络更加准确地学习散射中心特征;(2)本文 PIAEM 不仅仅考虑散射中心的特征提取,且构建了多帧编码-解码的识别框架,设计了基于最小重构误差的分类机制;(3)本文实验结果验证了基于散射中心特征学习的识别模型在方位角缺失情况下具有稳健特性.

2 雷达目标散射点模型

雷达系统的发射信号一般采用线性调频(Linear Frequency Modulation, LFM)信号,表达式为

$$\begin{aligned} x_t(t) &= s(t) e^{j2\pi f_c t} \\ &= \text{rect}\left(\frac{t}{T_p}\right) \exp(j\pi\mu t^2) \exp(j2\pi f_c t) \end{aligned} \quad (1)$$

其中, $s(t) = \text{rect}\left(\frac{t}{T_p}\right) \exp(j\pi\mu t^2)$ 表示信号包络, j 表示虚部单元, $\text{rect}\left(\frac{t}{T_p}\right)$ 表示带宽为 T_p 的矩形脉冲波形, f_c 表示雷达中心频率, μ 表示 LFM 的系数,并且带宽可以表示为 $B = \mu T_p$.

根据去载频^[11,12]、匹配滤波^[13]和离散化^[14]等操作之后,雷达回波的频率响应表示为

$$y(l) = \sum_{k=1}^L w(k) \exp\left(-j2\pi \frac{2R_{ik}}{c} (l-1) \Delta f\right) \quad (2)$$

其中, $y(l)$ 表示第 l 个频率响应, $l \in \{1, 2, \dots, L\}$, 且 L 表示频率成分的个数, $w(k)$ 表示第 k 个距离单元的散射系数, R_{ik} 表示雷达第 i 个距离单元中的第 k 个散射点之间的径向距离, Δf 表示相邻频点之间的频率间隔. 宽带雷达系统中,目标回波近似为沿着雷达视线各目标散射点子回波的相关叠加,接收的信号沿着雷达视线方向按照距离分辨率 ΔR 的大小划分为多个距离单元,表达式为 $\Delta R = c/2B$, 其中, c 表示光速, B 表示带宽. 假设 R_{ik} 是 ΔR 的整数倍,那么式(2)可以进一步表示为

$$y(l) = \sum_{k=1}^K w(k) \exp\left(-j2\pi \frac{2r_k}{c} (l-1) \Delta f\right) \quad (3)$$

其中, $\{r_k\}(k=1, 2, \dots, K)$ 表示 K 个距离单元的位置, 且 $r_k = k \cdot \Delta R$. 考虑实际情况存在噪声, 式(3)可以表示为

$$y(l) = \sum_{k=1}^K w(k) \exp\left(-j2\pi \frac{2r_k}{c} (l-1) \Delta f\right) + \eta(l) \quad (4)$$

其中, $\{\eta(l)\}(l=1, 2, \dots, L)$ 表示噪声成分. 式(4)给出了雷达回波信号的频率响应表达式. 另外, 假设

$$\begin{cases} \phi(r_k) = \left[1, \exp(-j4\pi \frac{r_k}{c} \Delta f), \dots, \exp(-j4\pi \frac{r_k}{c} (L-1) \Delta f)\right]^T \\ \Phi = [\phi(r_1), \phi(r_2), \dots, \phi(r_K)] \end{cases} \quad (5)$$

因此, 式(4)可以表示为式(6)的向量-矩阵形式:

$$\mathbf{y}_n = \Phi \mathbf{w}_n + \boldsymbol{\eta}_n \quad (6)$$

其中, $\mathbf{y}_n = [y_n(1), y_n(2), \dots, y_n(L)]^T$ 定义为雷达回波, 即复 HRRP, $\mathbf{w}_n = [w_n(1), w_n(2), \dots, w_n(K)]^T$ 表示散射系数, $\boldsymbol{\eta}_n = [\eta_n(1), \eta_n(2), \dots, \eta_n(K)]^T$ 表示噪声向量. Φ 表示傅里叶基, 当 $K=L$ 时, Φ 为 1 个完备正交基; 当 $K>L$ 时, Φ 为 1 个过完备的基矩阵.

3 实验装置

3.1 物理可解释自编码模型

根据散射点模型理论^[6], 高分辨距离像的各分量是由同一距离单元中多个散射点回波相关叠加而成. 当目标相对于雷达视线的姿态变化时, 散射点之间的相对径向距离发生变化. 参考文献[15]中介绍, 散射点不发生越距离单元走动的转角范围表示为 $\delta \leq \Delta R/L$, 其中, ΔR 表示距离分辨率, L 是目标的横向长度. 根据规则, 对全方位角的目标回波样本进行方位帧划分. 根据

方程(6), 来自目标 d 的第 m 个方位帧的第 n 个样本的信号可以表示为

$$\mathbf{y}_n^{(d,m)} = \Phi \mathbf{w}_n^{(d,m)} + \boldsymbol{\eta}_n^{(d,m)} \quad (7)$$

其中, $n \in \{1, 2, \dots, N\}$, 且 N 表示 1 个方位帧内的样本数, $m \in \{1, 2, \dots, M_d\}$, 且 M_d 表示目标的方位帧数, $d \in \{1, 2, \dots, D\}$, 且 D 表示目标的类别数.

考虑目标散射中心的稀疏分布特性, 本文方法将散射系数分解为 $\mathbf{w}_n^{(d,m)} = \hat{\mathbf{w}}_n^{(d,m)} \cdot \mathbf{s}_n^{(d,m)}$, 其中, \cdot 表示向量点乘, $\hat{\mathbf{w}}_n^{(d,m)}$ 表示所有距离单元中的散射点系数向量, 而 $\mathbf{s}_n^{(d,m)}$ 则表示所有距离单元中的散射点位置向量且该变量为 1 个二值向量. 根据文献[11]的分析, 1 个方位帧内信号的散射中心位置是 1 个稳定项, 不随目标方位角变化, 而信号的幅度存在较大波动. 为了直观说明复 HRRP 的这种物理特性, 图 1 显示了来自目标雅克-42 的 HRRP 在较小方位角范围 (1 帧) 内的 2 个例子. 根据图 1 可知, 对于 1 帧内的信号, 强散射点的位置基本相同, 幅度变化非常大. 基于这种物理特性, 定义 1 帧内的信号其散射点位置共享、幅度独立: $\mathbf{w}_n^{(d,m)} = \hat{\mathbf{w}}_n^{(d,m)} \cdot \mathbf{s}_n^{(d,m)}$. 因此, 可表示为

$$\mathbf{y}_n^{(d,m)} = \Phi (\hat{\mathbf{w}}_n^{(d,m)} \cdot \mathbf{s}_n^{(d,m)}) + \boldsymbol{\eta}_n^{(d,m)} \quad (8)$$

其中, $\mathbf{s}_n^{(d,m)}$ 表示目标 d 的第 m 帧中信号的共享位置参数.

将式(8)中所示的物理模型嵌入自编码网络^[16], 本文构造了 1 个物理可解释自编码模型 (Physical Interpretable Auto-Encoder Model, PIAEM) 对每 1 帧复 HRRP 建模, 基本结构如图 2 所示. 所提模型包括 1 个编码网络和 1 个解码网络, 接下来将详细介绍所提模型这 2 部分的结构.




图 1 来自雅克-42 目标不同方位角范围的 HRRP 示例

根据图 2 所示 PIAEM 的整体结构示意图, 编码网络学习从观测数据 $\mathbf{y}_n^{(d,m)}$ 到隐含变量 $\{\hat{\mathbf{w}}_n^{(d,m)}, \mathbf{s}_n^{(d,m)}\}$ 之间的非线性映射关系, 通过向量点乘得到观测数据的散

射系数 $\mathbf{w}_n^{(d,m)}$. 由于概率网络通过推断位置变量的后验分布参数, 相比于点估计的方式, 学习的变量具有更强的泛化性和准确性. 因此, 所提 PIAEM 中的推断网络

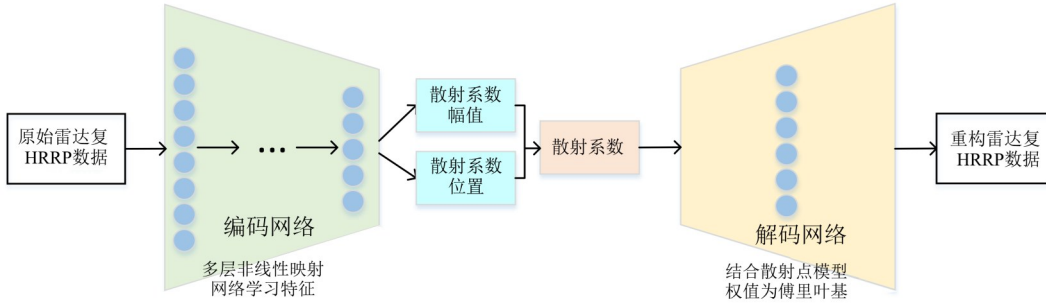


图2 所提PIAEM整体结构示意图

采用概率网络,推断 $\{\hat{\mathbf{w}}_n^{(d,m)}, \mathbf{s}^{(d,m)}\}$ 的后验分布参数.

根据中心极限定理,随机变量之和近似服从高斯分布.由于1个距离单元中的信号为多个散射点子回波的叠加,每个距离单元中的信号近似服从高斯分布,那么复HRRP的实部和虚部分别假设服从高斯分布.因此,系数 $\hat{\mathbf{w}}_n^{(d,m)}$ 是1个 K 维的复高斯分布:

$$\hat{\mathbf{w}}_n^{(d,m)} \sim \text{CNorm}(\boldsymbol{\mu}_0, \boldsymbol{\Sigma}_0) \quad (9)$$

其中, $\text{CNorm}(\cdot)$ 表示复高斯分布; $\boldsymbol{\mu}_0, \boldsymbol{\Sigma}_0$ 分别表示高斯分布的均值和方差.为了实现变量 $\mathbf{s}^{(d,m)}$ 的稀疏性,第 j 个维度的变量采用伯努利分布进行建模:

$$\mathbf{s}_0^{(d,m)}(k) \sim \text{Bernoulli}(\rho_0) \quad (10)$$

其中, $k \in \{1, 2, \dots, K\}$,且 K 表示该稀疏向量的维度, ρ_0 表示伯努利先验分布的参数,且决定变量的稀疏度.根据文献[4]中的描述,飞机目标复HRRP中的噪声通常假设为零均值、未知方差的复高斯分布,且方差通常可由预处理方法^[5]估计得到.那么对噪声变量建模为

$$\boldsymbol{\eta}_n^{(d,m)} \sim \text{CNorm}(0, \sigma^2 \mathbf{I}) \quad (11)$$

在编码网络中, $\hat{\mathbf{w}}_n^{(d,m)}$ 近似后验分布建模为

$$q(\hat{\mathbf{w}}_n^{(d,m)} | \mathbf{y}_n^{(d,m)}) = \text{CNorm}\left(\boldsymbol{\mu}_n^{(d,m)}, \text{diag}\left(\left(\sigma_n^{(d,m)}\right)^2\right)\right) \quad (12)$$

类似地,对于服从伯努利分布的位置稀疏变量 $\mathbf{s}_n^{(d,m)}$,其后验分布表示为

$$q(\mathbf{s}_n^{(d,m)} | \mathbf{y}_n^{(d,m)}) = \text{Bernoulli}(\boldsymbol{\rho}^{(d,m)}) \quad (13)$$

因此,编码网络包含多个非线性层推断未知变量 $\{\hat{\mathbf{w}}_n^{(d,m)}, \mathbf{s}_n^{(d,m)}\}$ 的后验分布参数 $\{\boldsymbol{\mu}_n^{(d,m)}, (\sigma_n^{(d,m)})^2, \boldsymbol{\rho}^{(d,m)}\}$.

根据编码网络推断得到的散射系数变量 $\{\hat{\mathbf{w}}_n^{(d,m)}, \mathbf{s}_n^{(d,m)}\}$,将其输入解码网络中,输出观测数据的分布预测 $\hat{\mathbf{y}}_n^{(d,m)}$.具体地,隐含变量 $\{\hat{\mathbf{w}}_n^{(d,m)}, \mathbf{s}_n^{(d,m)}\}$ 输入到解码网络的隐层中,数据 $\hat{\mathbf{y}}_n^{(d,m)}$ 的生成过程为

$$\tilde{\mathbf{h}}_n^{(d,m)} = \boldsymbol{\Phi}(\hat{\mathbf{w}}_n^{(d,m)} \cdot \mathbf{s}_n^{(d,m)}) \quad (14)$$

$$\mathbf{y}_n^{(d,m)} \sim p_\theta(\tilde{\mathbf{h}}_n^{(d,m)}, \boldsymbol{\eta}_n^{(d,m)}) \quad (15)$$

根据式(9)可知,解码网络由单个线性层的多层感知器结构组成,其中,网络参数 θ 固定为傅里叶基 $\boldsymbol{\Phi}$.如

果傅里叶基 $\boldsymbol{\Phi}$ 是完备正交基矩阵,隐特征的维度与输入数据的维度相同;如果傅里叶基 $\boldsymbol{\Phi}$ 是1个过完备矩阵,此时解码网络可以挖掘数据的超分辨特征.在方程(10)中,为了推断简便,所提方法对生成数据的分布 $p_\theta(\cdot)$ 采用复高斯分布假设.

3.2 基于PIAEM的雷达目标识别

观测数据包含来自 D 个目标的复HRRP $\{\mathbf{y}_n^{(d,m)}\}$,其中, $d \in \{1, 2, \dots, D\}$, $m \in \{1, 2, \dots, M_d\}$, $n \in \{1, 2, \dots, N\}$,所提模型对每1帧的复HRRP独立建模,模型包含 $\sum_{d=1}^D M_d$ 个编码网络.基于所提PIAEM设计了1种基于最

小重构误差的识别机制,即根据 $\sum_{d=1}^D M_d$ 个方位帧对应的

位置模板 $\{\mathbf{s}^{(d,m)}\}$,采用模板匹配法对测试样本进行识别.图3给出了所提模型的结构示意图,将训练数据的每类数据按照一定方位角范围(不发生越距离单元走动)划分为多个方位帧,每个方位帧采用独立的帧编码网络描述该帧数据的散射点分布特性,利用结合雷达目标散射点模型的解码网络对输入数据进行重构.所提方法实现了信号模型与识别模型的统一,挖掘出物理可解释的识别特征,提升识别性能.为了降低模型参数,不同方位帧数据对应的编码网络采用部分隐层参数共享方式.

PIAEM模型的目标函数推导得到:

$$\text{LB} = \sum_{d=1}^D \sum_{m=1}^M \sum_{n=1}^N \text{E} \left[\log p(\mathbf{y}_n^{(d,m)} | \mathbf{w}_n^{(d,m)}) \right] - \sum_{d=1}^D \sum_{m=1}^M \sum_{n=1}^N \left\{ \text{KL} \left[q(\hat{\mathbf{w}}_n^{(d,m)} | \mathbf{y}_n^{(d,m)}) \parallel p(\hat{\mathbf{w}}_n^{(d,m)}) \right] - \text{KL} \left[q(\mathbf{s}_n^{(d,m)} | \mathbf{y}_n^{(d,m)}) \parallel p(\mathbf{s}_n^{(d,m)}) \right] \right\} \quad (16)$$

其中, $\text{KL}(q(\cdot) \parallel p(\cdot)) = \int q(\cdot) \ln(p(\cdot)/q(\cdot))$ 表示KL散度,用于衡量后验分布 $q(\cdot)$ 和先验分布 $p(\cdot)$ 之间的差异性,它是1个非负的值,且当且仅当 $q(\cdot) = p(\cdot)$,KL散度等于0.方程(16)等式右边第1项表示对数似然 $\log p(\mathbf{y}_n^{(d,m)} | \mathbf{w}_n^{(d,m)})$ 的期望,等式右边的第2、3项分别表

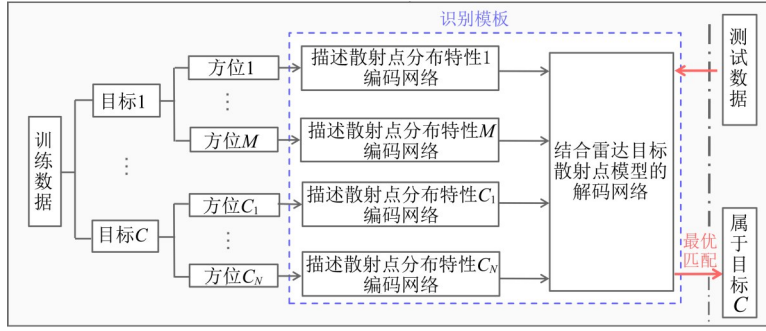


图3 所提基于PIAEM的雷达目标识别模型整体结构示意图

示高斯分布 $q(\hat{\mathbf{w}}_n^{(d,m)}|\mathbf{y}_n^{(d,m)})$ 和伯努利分布 $q(\mathbf{s}^{(d,m)}|\mathbf{y}_n^{(d,m)})$ 的KL约束项。所提模型基于随机梯度下降算法推导了复数的后向传播算法用于网络参数优化,模型的整体训练过程如算法1所示。

算法1 所提模型的训练过程

1. 设置模型的结构,包括隐特征的维度和隐层个数
2. 初始化编码网络参数 ϕ ,固定解码网络的参数为傅里叶基 Φ
3. While 网络未收敛 do
4. 从原始数据集的第 d 个目标第 m 个方位帧中随机取一部分数据 $\mathbf{Y}^{(d,m)} = \{\mathbf{y}_n^{(d,m)}\}$,其中 $n \in \{1, 2, \dots, N_1\}$
5. 从标准高斯分布中随机采样得到噪声变量 $\{\epsilon_n^{(d,m)}\}$,执行再参数化操作
6. 从分布 $\text{CNorm}(\boldsymbol{\mu}_n^{(d,m)}, \text{diag}((\boldsymbol{\sigma}_n^{(d,m)})^2))$ 中得到隐变量 $\hat{\mathbf{w}}_n^{(d,m)}$ 的采样值
7. 从分布 $\text{Bernoulli}(\boldsymbol{\rho}^{(d,m)})$ 中得到隐变量 $\mathbf{s}^{(d,m)}$ 的采样值
8. 从分布 $p_\theta(\tilde{\mathbf{h}}_n^{(d,m)}, \boldsymbol{\eta}_n^{(d,m)})$ 中得到生成数据 $\hat{\mathbf{y}}_n^{(d,m)}$ 的采样值
9. 根据式(16)采用随机梯度上升算法更新网络参数 ϕ
10. end while

对于1个测试样本 \mathbf{y}^* ,对应的系数参数 $\hat{\mathbf{w}}^{*(d,m)}$ 在已训练好的网络中,通过前向传播从分布 $q(\hat{\mathbf{w}}^{*(d,m)}|\mathbf{y}^*)$ 中采样得到。基于某1帧的位置模板 $\mathbf{s}^{(d,m)}$,可得到测试样本在该模板下的散射系数 $\mathbf{w}^{*(d,m)} = \hat{\mathbf{w}}^{*(d,m)} \cdot \mathbf{s}^{(d,m)}$,将得到的散射系数输入解码网络中,通过前向传播得到网络的输出 $\hat{\mathbf{y}}^{*(d,m)}$,即该帧模板下得到的重构数据。对于 $\sum_{d=1}^D M_d$ 个位置模板,可计算得到1组重构样本 $\{\hat{\mathbf{y}}^{*(1,1)}, \dots, \hat{\mathbf{y}}^{*(d,m)}, \dots, \hat{\mathbf{y}}^{*(D,M)}\}$ 。计算原始测试样本和1组重构样本之间的重构误差,基于最小重构误差准则,将测试样本划分为第 d^* 类:

$$d^* = \underset{d \in \{1, 2, \dots, D\}, m \in \{1, 2, \dots, M_d\}}{\text{arg min}} \left\| \mathbf{y}^* - \hat{\mathbf{y}}^{*(d,m)} \right\|_2^2 \quad (17)$$

模型的整体识别过程如算法2所示。

因此,综合上述训练和测试阶段的介绍,PIAEM在

算法2 所提模型的测试过程

1. 根据已训练好的网络得到网络参数 ϕ
2. 获取测试样本 \mathbf{y}^*
3. For $d = 1:D$
4. For $m = 1:M_d$
5. 将测试数据输入到第 d 个目标的第 m 帧对应的编码网络中,通过前向传播以及再参数化技巧获得隐变量 $\hat{\mathbf{w}}^{*(d,m)}$
6. 将获得的系数 $\hat{\mathbf{w}}^{*(d,m)}$ 和位置模板 $\mathbf{s}^{(d,m)}$ 点乘得到散射系数 $\mathbf{w}^{*(d,m)}$
7. 将散射系数输入解码网络 $\hat{\mathbf{w}}^{*(d,m)}$ 中,通过前向传播得到网络的输出,即重构样本 $\hat{\mathbf{y}}^{*(d,m)}$
8. 计算原始测试样本和重构样本之间的重构误差 $\left\| \mathbf{y}^* - \hat{\mathbf{y}}^{*(d,m)} \right\|_2^2$
9. end for
10. end for
11. 基于最小重构误差准则,根据方程(17)获得测试样本的类别预测 d^*

训练和测试阶段的模型如图4所示。在训练阶段,首先将训练数据根据不同目标的方位角信息划分为多个方位帧,每1帧包含若干样本。然后,将每1帧对应的样本输入到独立的编码网络中,学习样本对应的散射系数。最后,将学习的散射系数输入结合雷达目标散射点模型的解码网络中,实现每1帧训练样本的重构。此时,已训练好的多个帧编码网络参数固定,得到1组识别模板。在测试阶段,如图5所示,不同帧编码网络和解码网络的参数固定,用虚线框表示,将测试样本 \mathbf{y}^* 输入不同帧编码网络中,得到不同帧网络前向推断得到的1组散射系数,并将其输入参数固定的解码网络中,得到1组重构样本,最后基于最小重构误差准则实现类别预测。为降低模型的参数量,所提方法在模型构建阶段,共享了不同帧对应编码网络的前几层网络参数,仅在最后1层进行独立映射,具体结构示意图如图5所示。这种参数共享策略可有效缓解由于不同帧对应编码网络个数增多带来的模型参数量急剧上升的问题,提升模型对实际全空间任意角度场景数据进行建模的实用性。

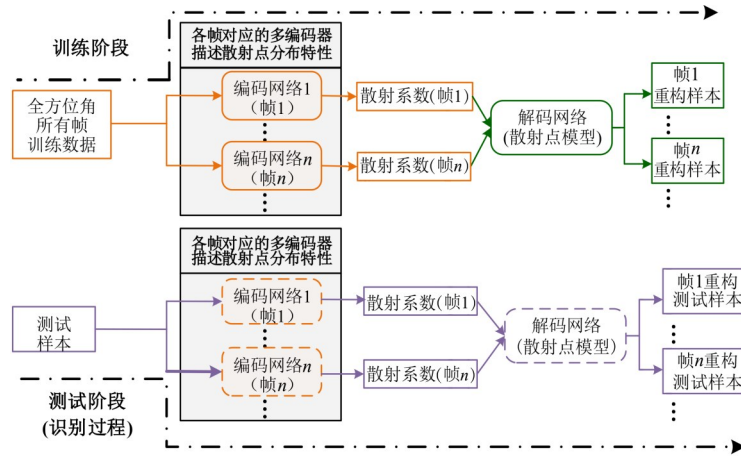


图4 PIAEM在训练和测试阶段的模型技术框图

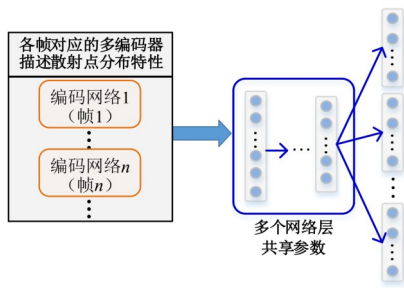


图5 PIAEM编码网络部分参数共享示意图

4 实验结果与分析

4.1 实验数据介绍

本文中雷达目标识别实验采用的实测雷达数据集是国内某研究所ISAR雷达测得的飞机目标回波数据^[1]。获得该实测数据的雷达传感器工作在C频带,发射信号为线性调频波。该数据集中包含3类目标,分别是中型螺旋桨飞机安-26(An-26)、小型喷气式飞机奖状(Cessna Citation S/II)和大型喷气式飞机雅克-42(Yak-42),表1给出

雷达参数	中心频率/MHz		
	5 520		
	脉冲重复频率/Hz		
	400		
Dechirp后采样频率/MHz			
10			
信号带宽/MHz			
400			
飞机	机长/m	机宽/m	机高/m
安-26	23.80	29.20	9.83
奖状	14.40	15.90	4.57
雅克-42	36.38	34.88	9.83




图6 3类目标飞行航迹的二维投影

对于每个目标的数据,将其划分为多个子集,每个子集称为1个方位帧。对于本文采用的雷达目标回波数据,带宽 B 为400 MHz, $\Delta R=0.375$ m, 设 L 为10 m, 则 $\delta\varphi$ 大约 2° 。如果散射点横向分布的主要部分接近中央, 两侧分布很少(如飞机类目标), 该条件还可以放宽。根据参考文献^[15~17], 本文将1 024个样本划分为1帧,

了3类目标形状参数和雷达工作参数。图6展示了3类目标的飞行轨迹沿地平面的投射曲线, 根据图6的飞行轨迹图, 估计飞机的远角。在该数据集中每个信号为1个雷达回波样本, 即称为复HRRP, 其幅值为HRRP。该雷达数据集是合作条件下测量获得, 即是在高信噪比($SNR \approx 40$ dB)且无干扰条件下获得的。因此, 基于该数据的识别实验可以忽略噪声和杂波的影响。

对采用的数据集, 安-26目标回波中1 024个样本的方位角变化大概为 0.92° , 奖状的目标回波1 024个样本的方位角变化大概为 0.54° , 雅克-42目标回波1 024个样本的方位角变化大概为 0.34° 。因此, 本文将1 024个样本划分为1帧, 满足帧内的样本不发生越距离单元走动的 δ 约束条件。因此, 3类目标雅克-42、奖状和安-26包含

的样本帧数分别为 35、50 和 50, 即 $D=3$, $M_1=35$, $M_2=M_3=50$, 每帧包含 1 024 个样本, 即 $N=1\ 024$, 总的训练样本共 138 240 个, 样本维度为 256, 即 $L=256$.

本文模型的编码网络结构为: 当 $K=L$ 时, 256-300-400-256; 当 $K=2L$ 时, 256-300-400-512. 本文采用 3 类实测飞机数据集, 识别模型包含 135 个 ($M_1+M_2+M_3$) 编码网络. 不同帧数据对应的编码网络, 其前 2 层的网络参数共享. 在模型训练阶段, 从标准高斯分布中采样, 对所提 PIAEM 模型的网络参数初始化, 且偏置初始化为 0. 采用随机梯度下降算法优化时, batch-size 设置为 32, 学习率设为 10^{-3} . 当目标函数相邻 2 次迭代的变化率小于 10^{-3} 时, 迭代终止, 网络训练收敛. 本文采用单次迭代所需的时间乘上总迭代次数作为收敛速度衡量指标.

4.2 实验结果分析

4.2.1 方位完备时的实验分析

目前大部分基于深度神经网络的识别方法均为飞行事故记录器结构, 学习不可解释的抽象特征. 本文模型结合雷达回波的物理生成机制, 可以学习具有物理

含义的隐特征, 接下来进行相关实验验证所提方法的特征提取性能.

图 7 给出了所提模型对来自不同目标雷达回波学习得到的散射系数图, 其中, 有值的地方表示提取出散射点的位置, 像素值大小表示散射点强度. 从图 7 可以看出, 大部分散射中心位于支撑区部分, 且不同目标的散射系数位置和幅值具有一定差别. 基于训练的模型, 对测试样本提取散射系数, 图 8(a) 给出了 2 个测试样本推断得到的散射特征, 图 8(b) 和图 8(c) 为 2 个对比方法的实验结果, 其中, 第 1 行和第 2 行的 3 幅图中红点分别表示 3 种方法对第 1 和第 2 个测试样本学习的散射特征, 蓝线表示原始 HRRP 的样本. 所提方法提取的特征可准确表征信号中强散射点的位置和幅度信息, 表明模型提取的特征具有物理可解释性. RELAX (Relaxation)^[18] 和 OMP (Orthogonal Matching Pursuit) 算法^[14] 对迭代终止门限较为敏感, 通常难以准确设置终止门限参数, 极大影响对测试样本散射点的提取效果, 导致无法准确提取散射点. 所提方法基于深度学习机制推断散射系数的后验分布参数, 可自动确定散射点个数, 模型的灵活性和泛化性更强, 散射点提取效果更好.




图 7 所提方法对不同目标的不同帧训练数据学习得到的散射系数

训练数据方位角完备时, 将本文模型和相关对比方法在测试集的平均识别率上进行对比, 实验结果如表 2 所示. 深度模型具有比浅层模型更好的识别性能, 且所提方法相比于其他深度方法具有更优的识别性能, 尤其是 $K=2L$ 时, 模型的识别率具有明显优势. 由于神经网络可以从观测数据中学习更有表征性的特征, 而且模型结合了雷达回波的散射中心模型, 充分挖掘对识别有利的物理特征, 达到较好的识别性能. 另外, 本文方法采用过完备的傅里叶基时, 对观测信号学习更精细的物理特征, 实现更优的识别性能.

为了衡量所提方法的效率, 接下来给出不同方法的训练和测试时间对比结果, 如表 3 所示, 其中传统方法包括 PCA^[4]、FA^[17] 和 K-SVD^[5], 深度方法包括 SCAE^[7] 和本文方法 PIAEM. 首先分析不同方法的训练用时, 表 3 中传统算法 PCA、FA 和 K-SVD 给出整个训练过程的用时, 神经网络 SCAE 方法和所提方法 PIAEM 给出

网络迭代 1 次的训练用时. 由于所提方法包含多个帧网络, 在模型训练阶段, 所需时间相对较长, 尤其是对于 $K=2L$ 的模型. 在实际应用中, 对于离线学习的模型, 测试阶段的时间成本对评估模型的实用性非常重要. 在测试阶段, 相比传统方法, 所提方法直接通过前向传播推导得到预测结果, 具有更高的时间效率. 因此, 表 3 的实验结果表明, 所提方法在模型训练结束之后, 对测试样本的类别预测阶段具有较好的时间效率和实用性.

4.2.2 方位不完备时的实验分析

在实际非合作场景中, 一些目标方位角的回波往往存在缺失, 无法获取这部分数据, 导致训练数据集的目标方位角不完备. 在这些情况下, 模型的泛化能力是评估模型实用性的重要标准. 因此, 接下来进行实验验证所提模型在方位角缺失情况下仍具有稳健的识别性能.

首先, 图 9 给出所提方法对不同雷达目标相邻方位

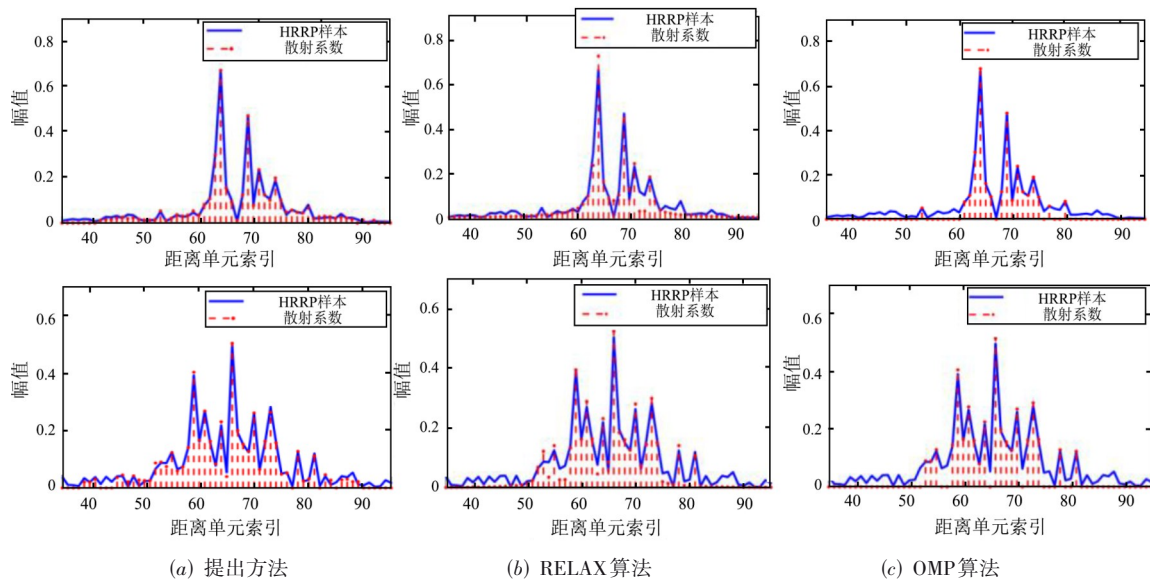


图8 不同方法对2个测试样本提取的散射特征

表2 不同方法在测试集上的平均识别率 单位:%

方法	平均识别率
LDA ^[19]	82.16
K-SVD ^[5]	85.32
LSVM ^[11]	85.63
AGC ^[20]	87.08
PCA ^[4]	89.92
HD-OMP(K=L) ^[13]	87.08
HD-OMP(K=2L) ^[13]	87.18
Bayesian-model(K=L) ^[21]	85.72
Bayesian-model(K=2L) ^[21]	90.01
NN	90.20
SDAE ^[22]	90.04
SCAE ^[7]	92.03
TARAN ^[9]	90.10
DPmTRNN ^[15]	92.54
FDCVAE ^[23]	93.25
PIAEM(K=L)	92.37
PIAEM(K=2L)	94.75

注:加粗数据表示所有方法中性能最好的结果。

表3 不同方法的模型参数量以及训练、测试用时 单位:s

方法	训练阶段用时	测试阶段测试1个样本用时
PCA ^[4]	8.899 4	0.364 7
FA ^[17]	39.632 8	0.375 0
K-SVD ^[5]	3.669 9	0.123 6
SCAE ^[7]	50.454 2	0.016 7
PIAEM(K=L)	123.836 5	0.009 4
PIAEM(K=2L)	131.342 7	0.012 4

注:加粗数据为本文提出的更优模型数据。

帧数据学习得到的散射系数,其中第1行的5幅图从左至右分别表示所提模型对来自Yake-42目标的第24、28、29、31和35帧数据推断的散射系数.根据图9第1行的实验可知,第29帧数据的散射系数与相邻28帧和31帧的散射系数十分相近,包括散射点的位置和幅度信息,但随着帧间隔增大,散射系数表示的散射点位置和幅度信息差别逐渐变大.图9第2和第3行对奖状和安-26目标的第24、28、29、31和35帧数据推断的散射系数也同样验证了上述结论.因此,图9说明相邻几个方位帧的散射特征具有一定的稳健特性,随着帧的间隔增大,散射系数特性的差别逐渐变大,但仍有一定接受范围,验证了散射中心特征是一种方位稳健的物理特征.

为了进一步从数据重构角度说明所提方法的方位稳健特性,图10给出了基于不同帧数据训练的模型对2个测试样本的重构结果.首先,从方位角完备的训练数据中以相邻帧间隔为1、3和5得到3组方位角不完备的训练数据,利用这3组训练数据训练模型,得到3组已训练的深度学习可解释自编码模型.从测试样本的其他帧(不包含训练数据所在帧)中随机选取2个复HRRP样本作为测试数据,图10的3行分别表示3个已训练模型对2个测试样本的重构结果,2列分别表示2个测试样本的重构结果.根据图10看出,除了部分距离单元中的峰值信号重构效果不精细,这3个模型均能较好地重构2个测试样本的主要目标信号,验证所提模型具有较好的方位稳健重构性能.但随着相邻帧间隔增大,第2和第3行的重构效果相比于第1行逐渐变差,对测试样本的样本峰值重构效果与原始样本差别增大,这说明随着方位缺失严重,模型对样本的精细重构能力下降.为了定量衡量模型的重构结果,表4给出了3个模型对2个测试样本的重构误差值,结果同样验证了上述结论.

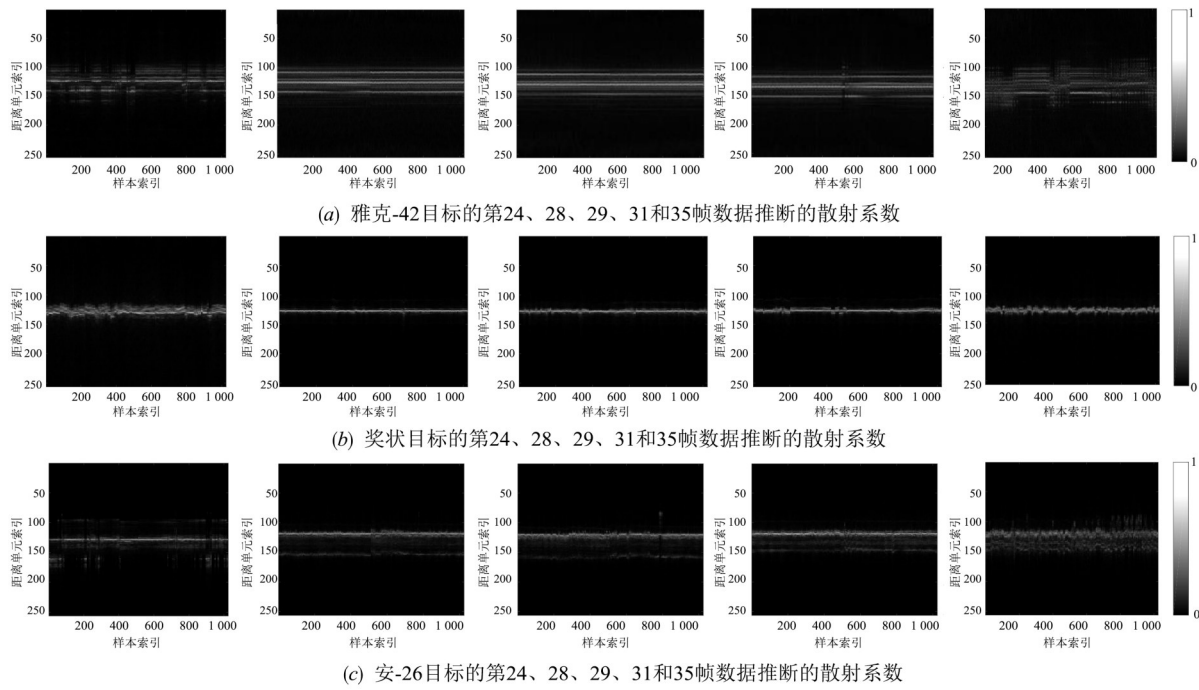


图9 所提方法对不同帧数据学习的散射特征

表4 3个模型对2个测试样本的重构误差值

重构误差值	模型1	模型2	模型3
测试样本1	0.127 3	0.292 1	0.362 9
测试样本2	0.145 3	0.304 5	0.420 8

接下来,在训练数据的方位角缺失的情况下,进行相关识别实验验证模型的方位稳健识别性能.考虑到实际环境中,接收回波数据时可能存在不同情况的方位角缺失方式,本文考虑了方位角等间隔缺失和连续缺失这2种情况,其中等间隔缺失包括相邻方位帧的间隔步幅为1、2、3、4、5和6,连续缺失包括每类连续减少5、10、15、20、25和30帧.表5和表6分别给出了不同

方法在这2种方位缺失情况下的识别对比结果.根据表5和表6的实验可知,随着训练数据的方位角间隔越来越大,所有方法的识别率均下降.浅层方法包括K-SVD、AGC(Adaptive Gaussian Classifier)、PCA和HD-OMP(Hausdorff Distance-Orthogonal Matching Pursuit)等,性能随着间隔步幅的增加而迅速下降,尤其是K-SVD和HD-OMP.由于AGC和PCA是贝叶斯概率模型,通过提取概率统计特征具有较好的模型泛化性,它们对训练数据集方位帧的缺失更稳健.对于深度方法,NN(Neural Network)随着方位帧缺失间隔步幅的增加而迅速下降,SCAE和所提模型仍然可以保持

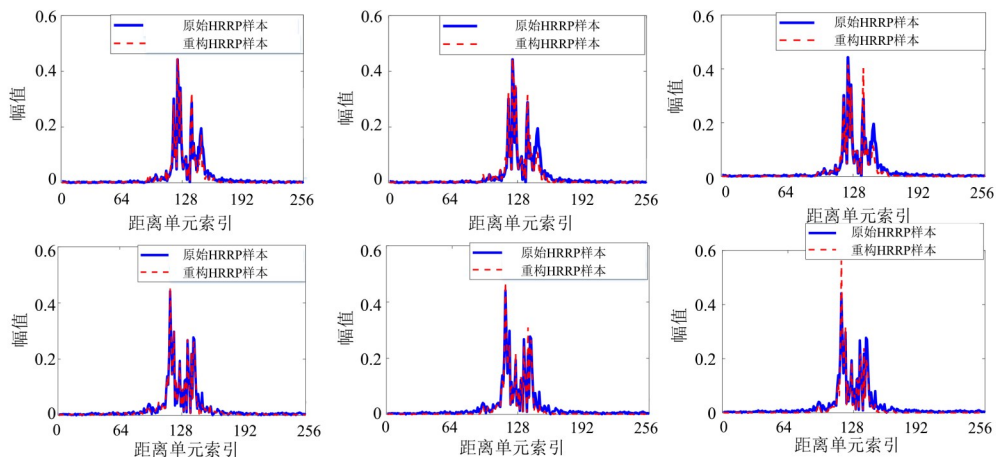


图10 3个已训练模型对2个测试样本的重构

较好的性能. 由于 SCAE 和所提模型均是对每个方位帧的数据精细建模, 从而对观测数据进行更精确描述, 提取泛化性较好的隐特征, 提高模型的泛化性. 另外, 所提模型结合了雷达目标的散射中心模型, 挖掘

雷达回波的物理特征, 这种物理特征相比抽象特征, 对不同方位角的数据有较好的物理泛化特性, 可获得更好的识别性能, 验证模型在方位角缺失情况下的强大稳健识别能力.

表 5 不同方法在训练数据的相邻方位帧间隔不同情况时的识别率

方法	K-SVD	AGC	PCA	SCAE	HD-OMP ($K=L$)	HD-OMP ($K=2L$)	所提方法 ($K=L$)	所提方法 ($K=2L$)
相邻方位帧间隔 1	0.853 2	0.870 8	0.902 7	0.920 3	0.871 8	0.871 8	0.923 7	0.947 5
相邻方位帧间隔 2	0.826 4	0.861 5	0.888 7	0.902 7	0.852 4	0.855 7	0.906 9	0.932 6
相邻方位帧间隔 3	0.813 1	0.856 9	0.872 2	0.899 6	0.819 9	0.824 8	0.906 3	0.925 5
相邻方位帧间隔 4	0.731 3	0.845 8	0.871 8	0.892 6	0.815 7	0.817 4	0.905 0	0.920 9
相邻方位帧间隔 5	0.719 6	0.829 6	0.862 9	0.887 0	0.811 7	0.815 8	0.904 8	0.920 4
相邻方位帧间隔 6	0.715 5	0.811 5	0.853 3	0.874 9	0.795 9	0.807 1	0.884 1	0.914 2

注: 加粗数据表示所有方法中性能最好的结果.

表 6 不同方法在训练数据的每类目标方位帧连续减少不同帧数时的识别率

方法	K-SVD	AGC	PCA	SCAE	HD-OMP ($K=L$)	HD-OMP ($K=2L$)	所提方法 ($K=L$)	所提方法 ($K=2L$)
每类连续减少 5 帧	0.830 7	0.868 0	0.846 6	0.896 5	0.856 8	0.858 9	0.908 8	0.928 4
每类连续减少 10 帧	0.771 0	0.853 8	0.794 3	0.828 6	0.800 8	0.812 3	0.905 3	0.921 2
每类连续减少 15 帧	0.767 3	0.853 7	0.773 7	0.797 4	0.791 7	0.794 2	0.905 1	0.916 3
每类连续减少 20 帧	0.758 6	0.823 4	0.775 8	0.758 6	0.787 1	0.790 1	0.901 1	0.912 1
每类连续减少 25 帧	0.738 1	0.798 2	0.725 4	0.686 1	0.759 8	0.762 1	0.897 2	0.908 9
每类连续减少 30 帧	0.750 2	0.726 7	0.605 0	0.527 9	0.664 9	0.668 2	0.891 9	0.904 5

注: 加粗数据表示所有方法中性能最好的结果.

5 结论


本文提出一种基于物理可解释自编码模型的雷达目标方位稳健识别算法, 通过结合雷达目标物理模型提升网络的可解释性, 且学习稳健的散射中心特征, 在雷达目标回波存在方位缺失的情况下具有稳健的目标识别性能. 该方法基于传统自编码网络结构, 编码网络学习物理特征, 解码网络结合散射中心模型, 整个模型是 1 个端到端的识别网络, 基于最小重构误差准则实现测试样本的类别预测. 基于实测雷达回波数据的实验验证了所提方法学习的特征, 具有目标明确的结构特性, 达到较高的识别准确率, 而且在方位缺失的情况下, 依然具有稳健的识别性能.

参考文献

- [1] 翟颖, 陈渤. 基于稳健变分自编码模型的雷达高分辨距离像目标识别算法[J]. 电子学报, 2020, 48(6): 1149-1155. ZHAI Y, CHEN B. Robust variational auto-encoder for radar HRRP target recognition[J]. Acta Electronica Sinica, 2020, 48(6): 1149-1155. (in Chinese)
- [2] 张云, 化青龙, 姜义成, 等. 基于混合型复数域卷积神经网络的三维转动舰船目标识别[J]. 电子学报, 2022, 50(5): 1042-1049.
- [3] 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).
- [4] DU L, LIU H, BAO Z, et al. Radar automatic target recognition using complex high-resolution range profiles[J]. IET Radar, Sonar & Navigation, 2007, 1(1): 18.
- [5] BO F, DU L, LIU H W, et al. Radar HRRP target recognition based on K-SVD algorithm[C]//Proceedings of 2011 IEEE CIE International Conference on Radar. Piscataway: IEEE, 2011: 642-645.
- [6] DU L, LIU H W, WANG P H, et al. Noise robust radar HRRP target recognition based on multitask factor analysis with small training data size[J]. IEEE Transactions on Sig-

- nal Processing, 2012, 60(7): 3546-3559.
- [7] FENG B, CHEN B, LIU H W. Radar HRRP target recognition with deep networks[J]. Pattern Recognition, 2017, 61: 379-393.
- [8] DU C, CHEN B, XU B, et al. Factorized discriminative conditional variational auto-encoder for radar HRRP target recognition[J]. Signal Processing, 2019, 158: 176-189.
- [9] XU B, CHEN B, WAN J W, et al. Target-aware recurrent attentional network for radar HRRP target recognition[J]. Signal Processing, 2019, 155: 268-280.
- [10] 霍超颖, 闫华, 冯雪健, 等. HRRP 稀疏自编码器深层特征与散射中心特征的关联性研究[J]. 系统工程与电子技术, 2021, 43(11): 3040-3053.
- HUO C Y, YAN H, FENG X J, et al. Correlation research between deep features of HRRP sparse auto-encoder and scattering center features[J]. Systems Engineering and Electronics, 2021, 43(11): 3040-3053. (in Chinese)
- [11] DE FREITAS A, DE VILLIERS J P. Multiple scatterer tracking in high range resolution radar[C]//2012 15th International Conference on Information Fusion. Piscataway: IEEE, 2012: 1683-1688.
- [12] KELLER J B. Geometrical theory of diffraction[J]. Journal of the Optical Society of America, 1962, 52(2): 116-130.
- [13] DU L, HE H, ZHAO L, et al. Noise robust radar HRRP target recognition based on scatterer matching algorithm[J]. IEEE Sensors Journal, 2016, 16(6): 1743-1753.
- [14] LIAO L Y, DU L, CHEN J. Class factorized complex variational auto-encoder for HRR radar target recognition[J]. Signal Processing, 2021, 182: 107932.
- [15] 杜兰. 雷达高分辨距离像目标识别方法研究[D]. 西安: 西安电子科技大学, 2007.
- DU L. Study on Radar HRRP Target Recognition[D]. Xi'an: Xidian University, 2007.
- [16] LI C, DU L, DENG S, et al. Point-wise discriminative auto-encoder with application on robust radar automatic target recognition[J]. Signal Processing, 2020, 169: 107385.
- [17] HU J, DU L, HE H, et al. Noise-robust radar HRR target recognition based on complex Gaussian statistical models[C]//2016 CIE International Conference on Radar (RADAR). Piscataway: IEEE, 2016: 1-4.
- [18] LI J, STOICA P. Efficient mixed-spectrum estimation with applications to target feature extraction[J]. IEEE Transactions on Signal Processing, 1996, 44(2): 281-295.
- [19] YU H, YANG J. A direct LDA algorithm for high-dimensional data—With application to face recognition[J]. Pattern Recognition, 2001, 34(10): 2067-2070.
- [20] CHANG C C, LIN C J. LIBSVM: A library for support vector machines[J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 27.
- [21] DU L, WANG P H, ZHANG L, et al. Robust statistical recognition and reconstruction scheme based on hierarchical Bayesian learning of HRR radar target signal[J]. Expert Systems with Applications, 2015, 42(14): 5860-5873.
- [22] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11: 3371-3408.
- [23] CHEN W C, CHEN B, PENG X J, et al. Tensor RNN with Bayesian nonparametric mixture for radar HRRP modeling and target recognition[J]. IEEE Transactions on Signal Processing, 2021, 69: 1995-2009.

作者简介



廖磊瑶 女, 1996年4月出生, 江西抚州人. 南京邮电大学通信与信息工程学院讲师. 主要研究方向为深度学习、雷达信号处理、雷达目标检测识别、雷达通信感知一体化等. 中国电子学会会员编号: E190159131M.
E-mail: 20230117@njupt.edu.cn