

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

翟颖¹, 陈渤²

(1. 西安导航技术研究所, 陕西西安 710068; 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: 对于雷达高分辨距离像的识别问题, 传统深层网络通常忽略了 HRRP 自身的目标特性, 不利于学习有效的分类特征, 导致其识别性能受到限制. 针对这一问题, 本文提出了一种基于稳健变分自编码模型的目标识别算法. 该算法结合 HRRP 数据特性, 利用平均像在散射点不发生越距离单元走动的方位帧内具有稳健物理特性的性质, 基于变分自编码器构建了稳健变分自编码模型. 该模型不仅能够获取稳健有效的识别特征, 而且在一定程度上保存了数据的帧内结构信息, 较大地提高了目标的平均识别率. 基于实测 HRRP 数据验证了所提算法的有效性.

关键词: 雷达自动目标识别; 高分辨距离像; 特征提取; 稳健变分自编码模型

中图分类号: TN95 **文献标识码:** A **文章编号:** 0372-2112 (2020)06-1149-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.06.015

Robust Variational Auto-Encoder for Radar HRRP Target Recognition

ZHAI Ying¹, CHEN Bo²

(1. Xi'an Research Institute of Navigation Technology, Xi'an, Shaanxi 710068, China;

2. National Laboratory of Radar Signal Processing, Xidian University, Xi'an, Shaanxi 710071, China)

Abstract: Traditional deep networks used for radar High-Resolution Range Profile (HRRP) target recognition usually ignore the inherent characteristics of the target, which results in the limited capability to learn effective features for classification task. To address this issue, a novel nonlinear feature learning method, called Robust Variational Auto-Encoder model (RVAE) is proposed. According to the stable physical properties of the average profile in each HRRP frame without migration through resolution cell, RVAE is developed based on variational auto-encoder, and such model is able to not only explore the latent representations of HRRP but also reserve structure characteristics of the HRRP frame. We use the measured HRRP data to show the effectiveness and efficiency of our algorithm.

Key words: radar automatic target recognition (RATR); high-resolution range profile (HRRP); feature extraction; robust variational auto-encoder (RVAE)

1 引言

雷达高分辨距离像(HRRP)是用宽带雷达信号获取的目标散射点回波在雷达射线上投影的矢量和. 它包含散射点分布、目标尺寸等重要结构信息, 并且易于获取和快速处理, 对目标识别与分类十分有价值, 如今已是雷达自动目标识别(RATR)领域的一个重要研究方向^[1~6].

对于 RATR 而言, 一个好的特征不仅可以消除回波中的冗余分量和噪声分量, 而且能在改变数据维度的同

时尽量保留样本类别信息, 从而改善识别效率和精度^[2,3]. 因此, 不少学者对 HRRP 目标特征提取技术进行了广泛而深入的研究. 文献[2]提出了基于实 HRRP 双谱特征的识别算法以抑制噪声的影响. 此类算法物理意义明确且计算简单, 但通常依赖于研究人员对数据的认知以及长时间的经验积累, 因此在一些缺乏先验知识的特定应用中性能难以得到保证. 文献[3]基于主成分分析(Principal Component Analysis, PCA)获得样本子空间投影特征, 通过构建最小化重构误差准则实现 HRRP 的目标识别. 文献[4]利用冗余字典对 HRRP 的稀疏表示特征

进行学习,并在应用中获得了较好的泛化性能.此类算法特征是基于数学模型得到的,物理含义明确,且具有较好的推广性^[5].然而,由于其方法大多采用浅层线性模型结构,难以获取目标层次化的特征表示,对数据的描述能力有限,因此,识别性能受到了限制.

近年来,随着深度学习的快速发展,深层网络被广泛应用于机器学习任务,并获得优异的性能表现,其代表有深层置信网络(Deep Belief Networks, DBN)^[7],堆栈降噪自编码器(Stacked Denoising Autoencoders, SDAE)^[8]等.深层网络与浅层模型最大的区别在于,具备大量的分层特征以及独特的无监督逐层贪婪学习思想,尽量“让数据自己说话”,通过层次化的非线性网络结构从数据中学习到底层抽象的特征,从而发现数据的内在结构,改善分类识别性能^[5].

然而,针对雷达高分辨距离像目标识别任务,传统深层网络通常忽略了 HRRP 自身的目标特性,导致其在实际应用中无法取得令人满意的结果.针对这一问题,本文提出了一种基于稳健变分自编码模型的目标识别算法.利用平均像在散射点不发生越距离单元走动的方位帧内具有稳健物理特性的性质,构建了稳健变分自编码模型(Robust Variational Auto-Encoder, RVAE).该模型旨在利用平均像的逼近约束,学习单个距离像的稳健隐表示,使其不仅可以表示自身样本信息,同时可有效反映出其对应平均像的稳健特点.另外,作为变分自编码器的扩展模型,RVAE 不仅能够有效提取目标的分类特征,同时还具备较好的生成性能.基于实测 HRRP 数据的实验结果验证了本文算法的有效性.

2 自编码模型

2.1 自编码模型(Auto-Encoder, AE)

自编码模型是一种尽可能复现输入信号的神经网络,由编码器和解码器两部分组成.编码器通过确定的映射函数将输入数据 x 变换到隐层表示 h .典型形式为仿射映像后叠加非线性映射,即 $h = \text{sigm}(W^T x + b)$.解码器的作用是将隐层表示 h 重新投影到原始信号空间,得到重构信号 $\hat{x}$,其典型形式为 $\hat{x} = Wh + c$ 或 $\hat{x} = \text{sigm}(Wh + c)$ ^[5].

自编码模型基于最小化重构误差准则对模型进行优化,原理简单,易于实现.但存在的问题是,该模型无法对数据的概率分布进行描述.

2.2 变分自编码模型(Variational Auto-Encoder, VAE)

变分自编码模型^[9]是由概率统计与深层神经网络结合所得到的概率生成模型.该模型由判别过程和生成过程两部分构成,运用变分贝叶斯方法,在概率图模型框架下,以最大化变分下界构建目标函数.采用重参

技术获取目标函数可微的近似估计,利用反向传播算法和随机梯度算法更新模型参数,从而解决了早期基于概率的自编码模型难以计算的问题.如图 1 所示是 VAE 模型结构示意图.其中,实线表示生成模型 $p_\theta(z)$ $p_\theta(x|z)$,虚线表示隐变量的真实后验 $p_\theta(z|x)$ 的变分估计 $q_\phi(z|x)$.




图1 变分自编码模型结构示意图

3 基于稳健变分自编码模型的 HRRP 目标识别

3.1 HRRP 敏感性预处理与平均像

由于雷达 HRRP 数据存在平移、幅度敏感性问题,不能直接作为模型的输入,所以需要先对数据进行相应的敏感性预处理.本文采用质心法对齐对平移敏感性进行补偿,利用 l_2 范数归一化,消除样本的幅度敏感性.

根据文献[3,4,10],将散射点不发生越距离单元走动的方位角定义为一个方位帧,并将方位帧内 HRRP 样本的平均像定义如下:

$$m = \left[\frac{1}{N} \sum_{n=1}^N |x_{n1}|, \frac{1}{N} \sum_{n=1}^N |x_{n2}|, \dots, \frac{1}{N} \sum_{n=1}^N |x_{nD}| \right]^T$$

$$= \frac{1}{N} \sum_{n=1}^N |x_n| \quad (1)$$

其中, $x_n = [x_{n1}, x_{n2}, \dots, x_{nD}]^T$ 表示该方位帧内第 n 个样本, D 表示样本维度.

图 2 展示了“安-26”飞机的单个 HRRP 样本及其对应平均像.从图中可以看出,相比于单个样本,平均像信号更加平滑且结构信息更加明确,能够更好地反映当前方位帧目标的散射特性.另外,文献[10]从物理机理的角度进一步验证了平均像的稳健性,表示其不仅能够提高信号的信噪比,而且可以有效抑制幅度扰动、闪烁效应和奇异样本,可以在一定程度上缓解 HRRP 的方位敏感性问题.在后续内容中,我们将结合 HRRP 平均像构建更加稳健的目标识别方法.

3.2 稳健变分自编码模型(Robust Variational Auto-Encoder, RVAE)

对于 HRRP 目标识别而言,好的特征不仅可以有效恢复原始观测,而且能够保留数据中的结构信息^[5].为此,本节提出一种稳健变分自编码模型(RVAE)实现对 HRRP 目标的特征提取. RVAE 模型包含特征提取和数据生成两个过程,其中生成过程又分为两部分:一部分




图2 “安-26”飞机的单个HRRP样本和对应平均像

是对单个 HRRP 样本的细节信息进行生成,令重构样本最大限度地匹配原始数据;另一部分是对当前训练样本的平均像进行生成,令生成样本与该训练样本对应帧的平均像尽可能一致。

RVAE 模型旨在利用平均像的逼近约束,学习单个 HRRP 样本的稳健隐表示,使其不仅包含样本的细节信息,同时可有效反映出其对应平均像的稳健特点. RVAE 在原始 VAE 模型的基础上加入了 HRRP 方位帧与平均处理,这样的模型结构有利于提取目标稳健有效的分类特征. 图 3 是 RVAE 模型结构示意图。




图3 稳健变分自编码模型结构示意图

其中, $W^1 = \{W^{11}, W^{12}, W^{13}\}$ 是特征提取的参数, $W^2 = \{W^{21}, W^{22}, W^{23}\}$ 是重构原始数据的参数, $W^3 = \{W^{31}, W^{32}, W^{33}\}$ 是生成训练样本对应平均像的参数。

将训练样本集 X 等间隔划分为 P 个方位帧 $\{X_p\}_{p=1}^P$, 其中 X_p 为第 p 帧的样本, $x_{p,n}$ 是第 p 帧中的第 n 个样本. RVAE 模型的数学描述为如下。

特征提取过程:

$$h_{p,n}^1 = \text{Relu}(x_{p,n} W^{11} + b^{11}) \quad (2)$$

$$\begin{cases} \mu_{\mathcal{Z}_{p,n}} = h_{p,n}^1 W^{12} + b^{12} \\ \log \sigma_{\mathcal{Z}_{p,n}} = h_{p,n}^1 W^{13} + b^{13} \end{cases} \quad (3)$$

$$\mathcal{Z}_{p,n} = \mu_{\mathcal{Z}_{p,n}} + \sigma_{\mathcal{Z}_{p,n}} \cdot \varepsilon \quad (4)$$

其中, $h_{p,n}^1$ 表示第 p 帧中第 n 个样本在 H^1 层中的隐层表示, $\varepsilon \sim N(0, 1)$ 。

单个 HRRP 样本重构过程:

$$h_{p,n}^2 = \text{Relu}(\mathcal{Z}_{p,n} W^{21} + b^{21}) \quad (5)$$

$$\begin{cases} \mu_{\hat{x}_{p,n}} = h_{p,n}^2 W^{22} + b^{22} \\ \log \sigma_{\hat{x}_{p,n}} = h_{p,n}^2 W^{23} + b^{23} \end{cases} \quad (6)$$

其中, $h_{p,n}^2$ 表示第 p 帧中第 n 个样本在 H^2 层中的隐层表示, $\hat{x}_{p,n} \sim N(\mu_{\hat{x}_{p,n}}, \sigma_{\hat{x}_{p,n}}^2)$ 。

平均像生成过程:

$$h_{p,n}^3 = \text{Relu}(\mathcal{Z}_{p,n} W^{31} + b^{31}) \quad (7)$$

$$\begin{cases} \mu_{\hat{m}_p} = h_{p,n}^3 W^{32} + b^{32} \\ \log \sigma_{\hat{m}_p} = h_{p,n}^3 W^{33} + b^{33} \end{cases} \quad (8)$$

其中, $h_{p,n}^3$ 表示第 p 帧中第 n 个样本在 H^3 层中的隐层表示, $\hat{m}_p \sim N(\mu_{\hat{m}_p}, \sigma_{\hat{m}_p}^2)$ 。

RVAE 模型的目标函数表示为:

$$\begin{aligned} L(X, M; \theta) = & E_{q(Z|X)} [\log p(X|Z)] \\ & + E_{q(Z|X)} [\log p(M|Z)] \\ & - \text{KL}(q(Z|X) \| p(Z)) \end{aligned} \quad (9)$$

其中

$$\text{KL}(q(Z|X) \| p(Z)) = E_{q(Z|X)} \left[\log \frac{q(Z|X)}{p(Z)} \right] \quad (10)$$

$p(Z) \sim N(0, 1)$, M 表示训练样本集对应的平均像集, 元素个数与训练样本个数保持一致, Z 为模型的隐变量. 式(9)中的第一项希望隐变量 Z 尽可能地匹配原始观测的分布特性, 使提取到的特征能够保留样本的细节信息; 第二项希望隐变量 Z 可以拟合各帧平均像的数据分布, 使得特征具有 HRRP 数据的帧内结构信息; 第三项是 $q(Z|X)$ 和 $p(Z)$ 的 KL 距离, 约束两个概率分布的差异尽可能小。

基于上述过程, RVAE 模型的实现步骤总结如下。

步骤 1: 输入训练数据集 $X = \{X_p\}_{p=1}^P$ 和平均像集 $M = \{M_p\}_{p=1}^P$, 并随机初始化参数 θ_{RVAE} ;

步骤 2: 按照式(2) ~ (9) 基于 Python 平台的 Lasagne 库构建网络模型;

步骤 3: 利用反向传播算法和随机梯度算法实现模型参数的更新;

步骤 4: 重复步骤 3, 直到算法收敛;

RVAE 模型所提取的特征可用于分类、识别等后续任务中. 图 4 是基于 RVAE 模型的雷达 HRRP 目标识别框架。




图4 基于RVAE模型的雷达HRRP目标识别框架

4 实验结果与分析

4.1 实验数据介绍

本文采用的实验数据取自西安电子科技大学数据库中的实测飞机数据。数据包含三类飞机目标:“雅克(Yark)-42”,“奖状(Cessna)”和“安(An)-26”。雷达和飞机的具体参数详见表1。三类目标飞机航迹的地面投




图5 三类目标飞机航迹在地面上的投影

4.2 实验结果分析

实验1 RVAE 识别性能分析

首先对模型参数进行初始化:权值矩阵初始化服从标准高斯分布,偏置向量为全零向量,mini-batch 大小为200。RVAE模型各隐层单元个数均为400,隐变量维度为20(模型参数基于实验结果设定)。本实验将RVAE分别与三种浅层模型:线性判别分析(Linear Discriminant Analysis, LDA)^[11], K-SVD^[4]和主成分分析(PCA)^[3],以及三种深层网络:深度置信网络(DBN)^[7],堆栈降噪自编码模型(SDAE)^[8]和堆栈联合稳健自编码模型(Stacked Robust Auto-Encoders, SRAE)^[5]进行识别性能比较,结果如表2所示。深层网络DBN,SDAE和SRAE的隐层结构均为:1500-500-50。其它模型的特征维度均为50。为了验证不同特征的可分性能,本实验选择线性支持向量机(Linear Support Vector Machine, LSVM)作为分类器对所提取的特征进行识别。原始HRRP的LSVM分类中不涉及特征降维操作,故此处将其作为性能基准。

表2中,PCA较于其他浅层非统计模型具有最优的识别性能,且以单个HRRP样本作为输入数据时可获得83.81%的平均识别率,但其与深层网络结果相比仍相差6%~8%。由此可见,深层网络的非线性层次化结构更有利于学习数据的有效识别特征。在深层网络中,DBN和

影如图5所示。与文献[3~5,10]相同,本文选择“雅克-42”的第2、5段,“奖状”的第6、7段以及“安-26”的第5、6段数据作为训练样本,用于模型学习,其余数据作为测试样本验证算法性能。训练样本共2800帧,每一帧由50个相邻的HRRP数据构成,通过对各帧HRRP数据进行平均处理获得相应平均像。测试样本共5200个,原始一维距离像维度 $D=256$ 。

表1 ISAR 实验飞机和雷达参数

雷达参数	中心频率	5520MHz	
	带宽	400MHz	
飞机类型	机长(m)	机宽(m)	机高(m)
雅克-42	36.38	34.88	9.83
奖状	14.40	15.90	4.57
安-26	23.80	29.20	9.83

SDAE模型以平均像作为输入数据所获得的平均识别率,均略高于基于单个HRRP样本所得,这说明平均像的稳健性能够在一定程度上提高模型性能。虽然SRAE也在模型中引入平均像以学习帧内样本的结构信息,但由于其本质是一种基于最小化重构误差的优化模型,变量依据映射函数的不同表现为对应确定的节点,无法对随机变量进行描述,导致模型对数据的表达能力受到限制,模型性能略低于RVAE。RVAE在上述网络模型中具有最优的识别性能,这说明RVAE具有获取稳健有效识别特征的能力。需强调的是,RVAE当前的识别率是在所提特征维度仅为20的情况下基于LSVM分类器获得的,这充分证明了RVAE有效的降维能力。

表2 不同算法的识别性能比较

输入	单个HRRP样本	平均像
LDA	81.3%	73%
K-SVD	74.7%	70.83%
PCA	83.81%	83.66%
LSVM	86.7%	88.28%
DBN	90.29%	90.64%
SDAE	90.42%	91.20%
SRAE	91.51%	
RVAE	92.12%	

进一步为了分析训练样本数量对 RVAE 模型识别性能的影响,分别随机抽取全部训练数据的 20%、40%、60%、80% 和 100% 作为样本数据对模型进行训练,结果如表 3 所示.通过比较,发现不同数量训练样本下的模型识别率差异甚微,最高识别率与最低识别率仅相差 0.89%,且在训练数据量仅为 20% 的情况下,依然能够取得 91.23% 的平均识别率,这一结果说明 RVAE 模型的识别性能不依赖于大量、完备训练样本的支持,模型具有稳健性.

表 3 基于不同训练样本数 RVAE 的识别性能比较

训练样本数量	平均识别率
20%	91.23%
40%	91.55%
60%	91.74%
80%	92.01%
100%	92.12%

实验 2 RVAE 可视化性能分析

图 6 分别给出了原始 HRRP 数据和 RVAE 所提特征的 2 维 PCA 可视化投影.由图可知,RVAE 所提取的特征相较于原始 HRRP 数据具有更好的可分性能.此外,RVAE 的特征学习过程没有利用数据的任何类别信息,属于无监督学习,模型学习与识别任务是互相独立的.由此可见,RVAE 能够从原始数据中直接获取有效识别特征,具有较好的特征提取能力.




图6 RVAE可视化性能分析

实验 3 RVAE 重构性能分析

实际应用中,HRRP 的训练样本数量是有限的,而待识别的测试样本数量却十分巨大.这种情况下训练得到的模型往往容易出现“过学习”现象,具体表现为过分拟合训练数据而失配于测试数据,从而影响算法的泛化能力^[5].本实验分别对三类飞机目标训练样本的原始数据、平均像和测试样本的原始数据进行重构,并通过重构性能对该模型的泛化能力进行评估.结果如图 7~10、表 4 所示,其中图 7(a)、图 7(b)是“安-26”训练样本的重构,图 8(a)、图 8(b)是“奖状”训练样本的重构,图 9(a)、图 9(b)是“雅克-42”训练样本的重构,图 10 是测试样本原始数据重构.





图7 “安-26”训练样本


表 4 RVAE 重构性能定量分析

实验数据	重构对象		平均相似度
训练样本	安-26	原始数据	96.47%
		平均像	99.97%
	奖状	原始数据	97.36%
		平均像	99.91%
	雅克-42	原始数据	92.90%
		平均像	99.95%
	原始数据		95.58%
	平均像		99.94%
测试样本	原始数据		67.45%

从图表中可以看出,RVAE 针对上述三种情况均有




(a) 训练样本原始数据重构




(b) 训练样本平均像重构

图8 “奖状”训练样本



(a) 训练样本原始数据重构



(b) 训练样本平均像重构

图9 雅克-42训练样本

较好的重构性能,既包含了样本的细节信息,又保留了样本的帧内结构特性.虽然模型对于测试样本的重构效果没有训练样本的理想,但仍然学习到了信号的主要结构信息.由此可见,RVAE对HRRP样本具有较好的描述能力和泛化性能.




图10 测试样本原始数据重构

5 总结与展望

本文针对雷达高分辨距离像目标识别任务,结合HRRP数据特性提出了一种非线性稳健的特征提取方法—稳健变分自编码模型.该模型利用平均像的逼近约束,学习单个HRRP样本的稳健隐表示,使其不仅可以表示自身样本内容,同时可有效反映其对应平均像的稳健特点,从而获取稳健有效的识别特征.基于实测HRRP数据的实验结果表明,相比于其他方法,RVAE具有较好的识别性能,以及降维和泛化能力.

本文中RVAE模型的隐变量个数为1,可以将其看作是一个浅层非线性网络,为了进一步提高模型性能,得到层次化的识别特征,我们将在已有方法的基础上发展深层网络.目前基于深层网络的工作仍处于研究阶段.

参考文献

- [1] Bo Feng, Bo Chen, Hongwei Liu. Radar HRRP target recognition with deep networks [J]. Pattern Recognition, 2017, 61 (2017): 379–393.
- [2] Zhang X D, Shi Y, Bao Z. A new feature vector using selected bispectra for signal classification with application in radar target recognition [J]. IEEE Transactions on Signal Processing, 2001, 49(9): 1875–1885.
- [3] Du L, Liu H W, Bao Z, et al. Radar automatic target recognition using complex high-resolution range profiles [J]. IET Radar, Sonar, Navigation, 2007, 1(1): 18–26.
- [4] Feng B, Du L, Liu H W, et al. Radar HRRP target recognition based on K-SVD algorithm [A]. IEEE CIE International Conference on Radar [C]. Chengdu: IEEE, 2011. 642–645.
- [5] 冯博, 陈渤, 王鹏辉, 刘宏伟. 基于稳健深层网络的雷达高分辨距离像目标特征提取算法 [J]. 电子与信息学报, 2014, 36 (12): 2949–2955.

- Feng Bo, Chen Bo, Wang Peng-Hui, Liu Hong-Wei. Feature extraction method for radar high resolution range profile targets based on robust deep networks[J]. Journal of Electronics & Information Technology, 2014, 36(12): 2949 – 2955. (in Chinese)
- [6] 杜兰, 刘宏伟, 保铮, 等. 一种利用目标雷达高分辨距离像幅度起伏特性的特征提取新方法[J]. 电子学报, 2005, 33(3): 411 – 415.
Du Lan, Liu Hong-wei, Bao Zheng, et al. A new feature extraction method using the amplitude fluctuation property of target HRRPs for radar automatic target recognition[J]. Acta Electronica Sinica, 2005, 33(3): 411 – 415. (in Chinese)
- [7] Hinton G, Salakhutdinov R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504 – 507.
- [8] Vincent P, Larochelle H, Lajoie I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. The Journal of Machine Learning Research, 2010, 11(12): 3371 – 3408.
- [9] Kingma Diederik P, Welling Max. Auto-encoding variational Bayes[A]. In Proceedings of the International Conference on Learning Representations (ICLR) [C]. Banff: ICLR, 2014.
- [10] Xing M, Bao Z, Pei B. The properties of high-resolution range profiles[J]. Optical Engineering, 2002, 41(2): 493 – 504.
- [11] Yu H, Yang J. A direct LDA algorithm for highdimensional data with application to face recognition[J]. Pattern Recognition, 2001, 34(10): 2067 – 2070.

作者简介



翟 颖 女, 1992 年生于陕西西安, 分别于 2015 和 2018 年获西安电子科技大学学士、硕士学位. 现为西安导航技术研究所助理工程师. 主要研究方向为信号与信息处理、雷达目标识别、模式识别和深度学习.

E-mail: yingzhai_rainie@163.com



陈 渤(通信作者) 男, 博士、教授、博士生导师. 1979 年生于河南郑州, 分别于 2003、2006 和 2008 年获西安电子科技大学学士、硕士和博士学位. 2008 年至 2013 年在美国杜克大学电子计算机工程系做研究员(research scientist), 2013 年被西安电子科技大学引进, 现为西安电子科技大学教授、博士生导师. 主要研究方向为统计信号处理、雷达信号处理、机器学习、深度学习网络及在雷达目标检测识别方面的应用.

E-mail: bchen@mail.xidian.edu.cn