

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

冯博 陈渤* 王鹏辉 刘宏伟

(西安电子科技大学雷达信号处理国家重点实验室 西安 710071)

摘要: 特征提取是雷达高分辨距离像(HRRP)目标识别的核心技术。传统的特征提取算法多采用浅层的模型结构,容易忽视样本的内在结构,不利于学习有效的分类特征。针对这一问题,该文利用多层非线性网络实现特征学习,构建了基于深层网络的雷达 HRRP 目标识别框架。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,提出了堆栈联合稳健自编码器。该网络由一系列联合稳健自编码器堆栈化实现,在匹配原始 HRRP 样本的同时,约束同帧样本趋近于平均像,并将网络的最终输出作为分类器的特征输入。基于实测 HRRP 数据的实验结果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; 深层网络; 堆栈联合稳健自编码器

中图分类号: TN957.51

文献标识码: A

文章编号: 1009-5896(2014)12-2949-07

DOI: 10.3724/SP.J.1146.2014.00808

Feature Extraction Method for Radar High Resolution Range Profile Targets Based on Robust Deep Networks

Feng Bo Chen Bo Wang Peng-hui Liu Hong-wei

(National Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China)

Abstract: Feature extraction is the key technique for Radar Automatic Target Recognition (RATR) based on High Resolution Range Profile (HRRP). Traditional feature extraction algorithms usually use shallow models. When applying such models, the inherent structure of the target is always ignored, which is disadvantageous for learning effective features. To address this issue, a deep framework for radar HRRP target recognition is proposed, which adopts multi-layered nonlinear networks for feature learning. Ground on the stable physical properties of the average profile in each HRRP frame without migration through resolution cell, Stacked Robust Auto-Encoders (SRAEs) are further developed, which are stacked by a series of RAEs. SRAEs can not only reconstruct the original HRRP samples, but also constrain the HRRPs in one frame close to the average profile. Then the top-level output of the networks is used as the input to the classifier. Experimental results on measured radar HRRP dataset validate the effectiveness of the proposed method.

Key words: Radar Automatic Target Recognition (RATR); High Resolution Range Profile (HRRP); Deep networks; Stacked Robust Auto-Encoders (SRAEs)

1 引言

雷达高分辨距离像(HRRP)是利用宽带雷达信号获取的目标散射点子回波在雷达视线方向上投影的矢量和。它包含了目标尺寸,散射点分布等许多重要的结构信息,且易于获取、存储和处理,如今已成为了雷达自动目标识别(RATR)领域的一个重要的研究方向^[1-7]。对于 RATR,特征提取技术是其算法核心。一个好的特征不仅可以消除回波中的噪声分量和冗余分量,而且能在降低数据维度的同

时尽可能地保留样本类别信息,从而提升识别效率与精度。但是,如何获得这样的特征却是长期以来困扰 RATR 领域的一个难题。

针对这一问题,不少学者对 HRRP 目标特征提取技术进行了广泛的研究^[3-7]。文献[3]提出了基于实 HRRP 双谱特征的识别算法以抑制噪声的影响;文献[4]分析比较了 HRRP 频谱幅度,功率谱及高阶谱等频域特征在识别性能上的差异。这些特征计算简单,但其设计通常是启发式的,依赖于研究人员对数据的认知以及长时间的经验积累,对数据的描述并不充分,因此在一些缺乏先验知识的特定应用中性能难以保证。文献[5]将超分辨算法引入识别框架,通过抽取 HRRP 显著散射点的位置信息作为分

2014-06-20收到, 2014-08-12改回

国家自然科学基金(61372132, 61201292), 新世纪优秀人才支持计划(NCET-13-0945)和中央高校基本科研业务费专项资金资助课题

*通信作者: 陈渤 bchen@mail.xidian.edu.cn

类器的特征输入。文献[6]利用冗余字典学习 HRRP 的稀疏表示特征, 获得了较好的泛化能力。文献[7]基于主成分分析(PCA)子空间投影特征, 构建最小重构误差准则实现 HRRP 目标识别。这些基于模型的特征具有明确的物理含义, 推广性能好, 但由于采用了浅层线性的模型结构, 不利于获得目标的深层分类信息, 因此识别性能受到了限制。近年来, 在无监督特征学习领域, 深层网络^[8-14]被广泛应用于机器学习任务, 获得了极其优异的性能表现, 其代表有深层置信网络(DBNs)^[9], 堆栈降噪自编码器(SDAEs)^[10]等。深层网络具有类似于人脑视觉皮层的层次化结构, 它与传统多层感知机(MLP)或者浅层模型的主要区别在于其大量的分层特征以及特有的无监督逐层贪婪学习思想。深层网络不过分依赖研究人员的经验, 而是尽量“让数据自己说话”, 其非线性层次化网络结构使得算法能够从数据中学习得到逐层抽象的特征, 从而有利于发现数据的内在结构, 并最终改善分类识别性能^[8]。

本文提出一种基于深层网络的 HRRP 特征提取算法。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的物理特性, 构建了堆栈联合稳健自编码器(SRAEs)。该深层网络由一系列联合稳健自编码器(RAE)堆栈化构成, 通过逐层贪婪思想训练每一层 RAE, 并将前一层的输出作为后一层的输入。SRAEs 利用平均像构建稳健约束, 结合 HRRP 自编码器得到一个联合网络, 在较好地匹配原始样本的同时, 约束同帧样本趋近于平均像, 从而获得稳健的层次化特征。基于实测数据的实验结果验证了本文算法的有效性。

2 深层学习网络

2.1 限制波尔兹曼机(RBM)

RBM 是二值的无向图模型, 具有双层结构: 第 1 层为可视层, 即输入数据层 $\mathbf{x} \in \{0, 1\}^D$; 第 2 层是隐层 $\mathbf{h} \in \{0, 1\}^K$, D 为输入信号维度, K 为隐层特征维度。其联合概率分布 $P(\mathbf{x}, \mathbf{h})$ 可表示为

$$P(\mathbf{x}, \mathbf{h}) = \frac{1}{Z} \exp(-E(\mathbf{x}, \mathbf{h})) \quad (1)$$

$$E(\mathbf{x}, \mathbf{h}) = -\mathbf{c}^T \mathbf{x} - \mathbf{b}^T \mathbf{h} - \mathbf{x}^T \mathbf{W} \mathbf{h} \quad (2)$$

其中 Z 是归一化常数, $E(\mathbf{x}, \mathbf{h})$ 称为能量函数, $\mathbf{W} \in \mathbb{R}^{D \times K}$ 是权值矩阵, $\mathbf{c} \in \mathbb{R}^D$, $\mathbf{b} \in \mathbb{R}^K$ 分别为可视层和隐层的偏置向量, 上标 T 表示转置操作。

传统 RBM 要求输入单元满足二值分布, 而通常认为 HRRP 数据为连续型随机变量^[2,7], 因此无法直接使用 RBM 对 HRRP 数据建模。为了解决这一问题, 可采用高斯伯努利限制波尔兹曼机 (GRBM)^[8,9]:

$$E(\mathbf{x}, \mathbf{h}) = \sum_{i=1}^D \frac{(x_i - c_i)^2}{2\sigma_i^2} - \sum_{j=1}^K b_j h_j - \sum_{i=1}^D \sum_{j=1}^K \frac{x_i}{\sigma_i} h_j W_{ij} \quad (3)$$

式(3)中 x_i 表示输入数据 \mathbf{x} 的第 i 个单元(维度), σ_i^2 为该单元的方差。相应的条件概率分布可表示为

$$P(x_i = x | \mathbf{h}) = \mathcal{N}\left(x | c_i + \sigma_i \sum_j h_j W_{ij}, \sigma_i^2\right) \quad (4)$$

$$P(h_i = 1 | \mathbf{x}) = \text{sigm}\left(b_j + \sum_i \frac{x_i}{\sigma_i} W_{ij}\right) \quad (5)$$

其中 $\mathcal{N}(\cdot | \mu, \sigma^2)$ 表示均值为 μ 方差为 σ^2 的高斯分布。 $\text{sigm}(x) = \frac{1}{1 + \exp(-x)}$ 是 logistic S 型激活函数。

给定观测样本集 $\mathbf{X} = \{\mathbf{x}_n\}_{n=1}^N$, GRBM 通过最大数据集的对数似然函数 $\sum_{n=1}^N \log p(\mathbf{x}_n)$ 来实现模型参数 $\theta_{\text{GRBM}} = \{\mathbf{W}, \mathbf{b}, \mathbf{c}, \boldsymbol{\sigma}\}$ 的估计。将学习得到的 GRBM 隐单元激活值作为下一层的输入用于学习第 2 层网络参数, 并以此类推, 这样学习得到的一组 GRBM 堆栈化后即可得到深层置信网络(DBNs)^[9]。

2.2 自编码器(AE)

自编码器由编码器和解码器两部分组成。编码器通过确知的映射函数将输入样本 \mathbf{x} 变换到隐层表示 \mathbf{h} , 通常为仿射映像后叠加非线性映射, 即 $\mathbf{h} = \text{sigm}(\mathbf{W}^T \mathbf{x} + \mathbf{b})$ 。解码器的作用是将编码所得的隐层表示 \mathbf{h} 重新投影回原始信号空间, 得到重构信号 $\hat{\mathbf{x}}$, 其典型形式为 $\hat{\mathbf{x}} = \mathbf{W} \mathbf{h} + \mathbf{c}$ 或者 $\hat{\mathbf{x}} = \text{sigm}(\mathbf{W} \mathbf{h} + \mathbf{c})$ 。

若对传统的自编码器不加任何约束, 则学习得到的权值矩阵可能是恒等映像, 这是无意义的^[8,10]。一般可以通过构建降噪自编码器(DAE)来避免该问题。DAE 是基于自编码器(AE)框架的一种简单变体, 通过从人为破坏的数据中恢复原始干净信号, 从而获得更加稳健的模型。在许多实际应用中, DAE 已经获得了与 RBM 相似甚至更优的性能^[13]。相比于传统 AE, DAE 的编码形式变为

$$\mathbf{h} = \text{sigm}(\mathbf{W}^T \mathbf{y} + \mathbf{b}) \quad (6)$$

其中 $\mathbf{y} = \mathbf{x} + \mathbf{n}$, \mathbf{n} 为人工添加的高斯白噪声或掩蔽噪声等。DAE 的解码形式与 AE 相同。

给定观测样本集 $\mathbf{X} = \{\mathbf{x}_n\}_{n=1}^N$, DAE 可以通过最小化重构误差实现参数优化:

$$L(\mathbf{X}, \theta_{\text{DAE}}) = \arg \min_{\theta_{\text{DAE}}} \sum_{n=1}^N \|\mathbf{x}_n - \hat{\mathbf{x}}_n\| \quad (7)$$

其中 $\theta_{\text{DAE}} = \{\mathbf{W}, \mathbf{b}, \mathbf{c}\}$ 。学习完第 1 层 DAE 后, 将其激活值作为下一层的输入。这样获得的一组网络进行堆栈化后就形成了堆栈降噪自编码器(SDAEs)。

3 基于联合稳健深层网络的 HRRP 目标识别

3.1 HRRP 敏感性预处理与平均像

由于 HRRP 存在幅度, 平移敏感性等问题, 所以需要在特征学习中考虑相应的敏感性预处理。HRRP 的幅度敏感性问题是指目标的 HRRP 幅度会受雷达发射功率、天线增益和目标距离等测量条件的影响。本文对 HRRP 进行 l_2 范数归一化, 以消除样本的幅度敏感性。HRRP 的平移敏感性是由于目标运动导致 HRRP 在距离波门中发生平移。本文采用质心对齐算法^[15]实现平移敏感性补偿。

文献[1-7]表明, 在散射点不发生越距离单元走动的方位角内(定义为一个方位帧), 一组 HRRP 样本的平均像不仅可以显著提高回波信噪比, 同时还能有效抑制幅度扰动、闪烁效应和奇异样本。文献[16]研究了平均像的物理机理, 进一步验证了平均像可以更好地描述帧内样本的散射特性。平均像的定义如下:

$$\begin{aligned} \mathbf{m} &\triangleq \left[\frac{1}{N} \sum_{n=1}^N |x_{n1}|, \frac{1}{N} \sum_{n=1}^N |x_{n2}|, \dots, \frac{1}{N} \sum_{n=1}^N |x_{nD}| \right]^T \\ &= \frac{1}{N} \sum_{n=1}^N |\mathbf{x}_n| \end{aligned} \quad (8)$$

其中 $\mathbf{X} = \{\mathbf{x}_n\}_{n=1}^N$ 表示一个方位帧内的 HRRP 样本, $\mathbf{x}_n = [x_{n1}, x_{n2}, \dots, x_{nD}]^T$ 。

3.2 基于 SRAEs 的 HRRP 目标识别

3.2.1 联合稳健自编码器(RAE) 对于 HRRP 目标识别而言, 一个好的特征不仅可以有效恢复原始观测, 而且能够同时保留 HRRP 样本的结构信息。为此, 本节提出一种联合稳健的自编码器(RAE)对 HRRP 进行特征提取。RAE 由两部分构成: 一部分对每个 HRRP 样本的细节信息单独建模, 令重构样本较好地匹配原始观测; 另一部分约束同帧中的重构 HRRP 样本趋于相同的稳健项——平均像, 从而保留帧内样本的结构相似性。这样的网络构架不仅具有较好的模型描述能力, 而且一定程度上使 HRRP 的帧内结构特性得到保持。相应的模型结构如图 1 所示。

将训练数据集 \mathbf{X} 等间隔划分为 P 个方位帧 $\{\mathbf{X}_p\}_{p=1}^P$, 其中 $\mathbf{X}_p = \{\mathbf{x}_{p,n}\}_{n=1}^N$ 为第 p 帧的样本集合。




图1 联合稳健自编码器框架

RAE 网络的数学描述为

$$\mathbf{h}_{p,n} = f(\mathbf{z}_2) = \text{sigm}(\mathbf{W}^T \mathbf{x}_{p,n} + \mathbf{b}) \quad (9)$$

$$\hat{\mathbf{x}}_{p,n} = g(\mathbf{z}_3) = \begin{cases} \mathbf{W} \mathbf{h}_{p,n} + \mathbf{c}, & \mathbf{x} \in \mathbb{R}^D \\ \text{sigm}(\mathbf{W} \mathbf{h}_{p,n} + \mathbf{c}), & \mathbf{x} \in \{0,1\}^D \end{cases} \quad (10)$$

其中 $\mathbf{z}_2 = \mathbf{W}^T \mathbf{x}_{p,n} + \mathbf{b}$, $\mathbf{z}_3 = \mathbf{W} \mathbf{h}_{p,n} + \mathbf{c}$ 。RAE 的目标函数可以定义为

$$\begin{aligned} L(\mathbf{X}, \theta) &= \frac{\lambda}{2T} \|\mathbf{X} - \hat{\mathbf{X}}\|_{\text{F}}^2 + \frac{1-\lambda}{2P} \sum_{p=1}^P \|\mathbf{M}_p - \hat{\mathbf{X}}_p\|_{\text{F}}^2 \\ &\quad + \alpha \text{KL}(\tilde{\rho} \parallel \rho) + \frac{\beta}{2} \|\mathbf{W}\|_{\text{F}}^2 \end{aligned} \quad (11)$$

其中

$$\begin{aligned} \text{KL}(\tilde{\rho} \parallel \rho) &= \sum_{j=1}^{|\rho|} \tilde{\rho} \log \frac{\tilde{\rho}}{\rho_j} + (1 - \tilde{\rho}) \log \frac{1 - \tilde{\rho}}{1 - \rho_j}, \\ \rho &\triangleq \frac{1}{N \cdot P} \sum_{p=1}^P \sum_{n=1}^N \mathbf{h}_{p,n} \end{aligned} \quad (12)$$

$\mathbf{M}_p = [\mathbf{m}_p, \mathbf{m}_p, \dots, \mathbf{m}_p]$, \mathbf{m}_p 为第 p 帧样本的平均像, $T = N \cdot P$ 为训练样本总数。式(11)中的第 1 项为自编码项, 该项使得重构样本尽可能保留样本自身的细节信息; 第 2 项为稳健项, 约束同帧重构 HRRP 趋于相同的平均像, 使得帧内样本具有结构相似性, 参数 λ 为调节两者权重的正则化参数。 $\text{KL}(\tilde{\rho} \parallel \rho)$ 是稀疏约束项, 它能在给定一激励(输入数据)时, 约束平均激活概率接近于一个取值很小的常数 $\tilde{\rho}$ (通常 $\tilde{\rho} \leq 0.1$), 从而使只有小部分的隐单元被激活。文献[8,9,11,13]表明, 稀疏约束的引入有助于发现输入样本的潜在数据结构。 $\|\mathbf{W}\|_{\text{F}}^2$ 为权值衰减项, 用于防止参数取值过大, 从而避免过学习现象^[8-10]。下面给出 RAE 参数的估计算法:

算法 1 RAE 参数估计算法

步骤 1 输入训练数据集 $\mathbf{X} = \{\mathbf{X}_p\}_{p=1}^P$, 并随机初始化参数 θ_{RAE} ;

步骤 2 利用式(9), 式(10)计算样本 $\mathbf{x}_{p,n}$ 的隐层特征 $\mathbf{h}_{p,n}$ 和相应的重构样本 $\hat{\mathbf{x}}_{p,n}$ 。令 $\Delta \mathbf{W} := \mathbf{0}$, $\Delta \mathbf{b} := \mathbf{0}$, $\Delta \mathbf{c} := \mathbf{0}$ (设置为全零矩阵或全零向量);

步骤 3 基于后向传播算法(BP)^[13], 依次对输入的各训练样本计算其相应的梯度, 并累加求和:

$$\Delta \mathbf{W} := \Delta \mathbf{W} + \mathbf{x}_{p,n} \cdot (\delta^2)^T + \delta^3 \cdot (\mathbf{h}_{p,n})^T \quad (13)$$

$$\Delta \mathbf{b} := \Delta \mathbf{b} + f'(\mathbf{z}_2) \odot (\mathbf{W}^T \cdot \delta^3 + \alpha \cdot \mathbf{t}) \quad (14)$$

$$\begin{aligned} \Delta \mathbf{c} &:= \Delta \mathbf{c} + \left[\lambda \cdot (g(\mathbf{z}_3) - \mathbf{x}_{p,n}) + (1 - \lambda) \right. \\ &\quad \left. \cdot (g(\mathbf{z}_3) - \mathbf{m}_p) \right] \odot g'(\mathbf{z}_3) \end{aligned} \quad (15)$$

其中

$$\delta^2 = \nabla_{\mathbf{z}_2} L = f'(\mathbf{z}_2) \odot (\mathbf{W}^T \cdot \delta^3 + \alpha \cdot \mathbf{t}) \quad (16)$$

$$\delta^3 = \nabla_{z_3} L = \left[\lambda \cdot (g(z_3) - x_{p,n}) + (1 - \lambda) \cdot (g(z_3) - m_p) \right] \odot g'(z_3) \quad (17)$$

向量 t 的第 j 个元素为 $t_j = -\frac{\tilde{\rho}}{\rho_j} + \frac{1 - \tilde{\rho}}{1 - \rho_j}$, \odot 表示

Hadamard 乘积。

步骤 4 更新所有参数, 其中 τ 为学习率

$$\left. \begin{aligned} \mathbf{W} &:= \mathbf{W} - \tau [\Delta \mathbf{W} / T + \beta \mathbf{W}] \\ \mathbf{b} &:= \mathbf{b} - \tau \cdot \Delta \mathbf{b} / T \\ \mathbf{c} &:= \mathbf{c} - \tau \cdot \Delta \mathbf{c} / T \end{aligned} \right\} \quad (18)$$

步骤 5 重复迭代步骤 2-步骤 4, 直到算法收敛。

3.2.2 堆栈联合稳健自编码器(SRAEs) 当学习完一层 RAE 后, 固定其权值不变, 将隐单元激活值作为下一层 RAE 的输入, 并以此类推, 直到得到 L 层的 RAE。将这些 RAE 堆栈化后就构成了堆栈联合稳健自编码器(SRAEs)。

算法 2 深层网络 SRAEs 的构造算法

步骤 1 建立第 1 层 RAE, 输入 HRRP 样本 $x_{p,n}$, 并通过权值矩阵 $\mathbf{W}^1 \in \mathbb{R}^{D \times K_1}$ 将其映射为第 1 层特征向量 $h_{p,n}^1 \in \mathbb{R}^{K_1 \times 1}$ 。 $h_{p,n}^1$ 可由式(19)计算得到:

$$h_{p,n}^1 = \text{sigm} \left((\mathbf{W}^1)^T x_{p,n} + \mathbf{b}^1 \right) \quad (19)$$

由于 $x_{p,n} \in \mathbb{R}^D$, 因此第 1 层 RAE 的重构样本 $\hat{x}_{p,n}$ 可以表示为

$$\hat{x}_{p,n} = \mathbf{W}^1 \cdot h_{p,n}^1 + \mathbf{c}^1 \quad (20)$$

步骤 2 建立第 2 层 RAE, 将 $h_{p,n}^1$ 和 $h^1(m_p)$ 作为第 2 层 RAE 的输入。特征向量 $h_{p,n}^2$ 和重构信号 $\hat{h}_{p,n}^1$ 分别为

$$h_{p,n}^2 = \text{sigm} \left((\mathbf{W}^2)^T h_{p,n}^1 + \mathbf{b}^2 \right) \quad (21)$$

$$\hat{h}_{p,n}^1 = \text{sigm} \left(\mathbf{W}^2 h_{p,n}^2 + \mathbf{c}^2 \right) \quad (22)$$

$h^1(m_p) = \text{sigm}((\mathbf{W}^1)^T m_p + \mathbf{b}^1)$ 表示的是平均像的层次特征。事实上, $h^1(m_p)$ 是基于平均像提取的, 由于平均像具有特定的物理机理, 这样的特征设计

有助于描述目标的结构信息。

步骤 3 重复步骤 2, 设计多层 RAE, 并将其堆栈化后得到 SRAEs。

SRAEs 的计算复杂度是各层 RAE 复杂度的线性叠加。RAE 通过算法 1 实现参数估计, 相应一次迭代的计算复杂度为 $O(KDT)$, 其中 K 为隐单元个数, D 为输入样本维度, T 为训练样本总数。因此, L 层 SRAEs 网络一次迭代的计算复杂度为 $O\left[T\left(K_1 D + \sum_{l=1}^{L-1} K_l K_{l+1}\right)\right]$, K_l 表示第 l 层的隐单元个数。测试阶段, 由于模型参数固定且不需迭代运算, 因此对于一个测试样本的计算复杂度为 $O\left(K_1 D + \sum_{l=1}^{L-1} K_l K_{l+1}\right)$ 。图 2 给出了基于 SRAEs 深层网络的 HRRP 目标识别框架。为了简化图示, 特征学习部分只显示了 3 个隐层。




图 2 基于深层网络的距离像目标识别框架

4 实验结果与分析

4.1 实验数据介绍

本文采用国内某所逆合成孔径雷达(ISAR)测量的飞机数据。实验飞机有 3 种, 其中“雅克-42”为中型喷气飞机, “奖状”为小型喷气飞机, “安-26”为中小型螺旋桨飞机。飞机航迹投影如图 3 所示。与文献[1,2,4,6,7,15]相同, 本文选择“雅克-42”的第 2, 5 段, “奖状”的第 6, 7 段, “安-26”的第 5, 6 段数据作为训练样本, 用于学习深层网络; 其余段数据作为测试样本用来验证算法性能。距离像维度 $D = 256$ 。




图 3 雅克-42、奖状和安-26 飞机的航迹图

4.2 实验结果分析

实验 1 识别性能对比分析 依文献[17]中的标准化参数设置，这里构建 3 层深层网络，相应的隐单元数为：1500, 500, 50。图 4 实验分别基于 4 种浅层模型：线性判别分析(LDA)^[18], K-SVD^[6], 主成分分析(PCA)^[7], 分形特征法，以及 3 种深层网络：DBNs, SDAEs 和 SRAEs 进行特征提取，并使用线性支撑向量机(LSVM)分类器进行识别。LDA 降维后信号维度为 C-1^[18]; K-SVD 的冗余特征维度与第 1 层隐单元数相同，稀疏度 $s=50$; 分形法不做特征降维; 其他算法的特征维度为 50。原始 HRRP 的 LSVM 分类结果仅作为性能基准，无特征降维操作。




图 4 不同算法的识别性能比较

图 4 中，PCA 在所有浅层特征提取算法中具有最优的识别性能，但与深度学习算法的识别率相比仍然相差 6-8%。因此，相比于浅层线性模型，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。在所有深层模型中，SRAEs 具有最优的识别性能，且随着层次的递增，特征的可分性增强，这表明 SRAEs 通过逐层特征变换，将原始空间样本变换到一个新的高度抽象的特征空间，从而使分类更加容易。图 4 中 MCC, AGC 法^[2]是常规的 HRRP 统计识别算法，两者均采用浅层模型结构，该识别结果进一步验证了 SRAEs 的有效性。需强调的是，LSVM 利用全部 256 维 HRRP 的识别率为 88.4%，而 SRAEs 在顶层特征维度为 50 的情况下识别率已达 91.51%，较 LSVM 提高了 3.1%，这充分验证了 SRAEs 有效的降维能力。

实验 2 SRAEs 稳健项性能分析 表 1 给出了

SRAEs 中稳健项对识别性能的影响。若 $\lambda = 1$ ，则不考虑稳健项，模型退化为堆栈自编码器(SAEs); 若 $\lambda = 0$ ，模型仅考虑稳健项; 若 $0 < \lambda < 1$ ，模型变为结合自编码器和稳健约束的联合模型。

表 1 结果显示，稳健项的引入可以改善深层网络的识别性能，而且联合 HRRP 自编码器与稳健约束的网络识别性能更优。利用平均像构建稳健约束的 SRAEs 保持了 HRRP 的帧内结构特性，有助于获得稳健的层次特征，减少噪声、幅度扰动、闪烁和奇异样本^[4,16]对特征学习的影响，但若仅考虑稳健项则又会丢失样本的一些细节信息，从而影响识别性能。

实验 3 SRAEs 可视化性能分析 图 5 分别给出了原始 HRRP 和 SRAEs 深层特征的 2 维 PCA 可视化投影，目的在于简单直观地分析 SRAEs 所提特征的可分性。为进一步验证算法的泛化性能，实验中增加了 400 个库外飞机距离像数据。

相比于原始 HRRP 的 2 维 PCA 投影，SRAEs 提取的特征具有更好的可分性能。需强调的是，SRAEs 的特征学习过程是完全无监督，没有利用任何类别信息，即网络的学习与最终的识别任务并无关联。由此可见，SRAEs 有助于从原始数据中直接提取有效的识别特征，具有学习数据本质特征的能力。

实验 4 SRAEs 重构泛化性能分析 实际应用中，HRRP 的训练样本数量是非常有限的，而待识别的库内样本和库外样本数量却很大。这种情况下训练得到的模型往往容易出现过学习现象，并导致对库外样本严重的失配问题，从而影响算法的推广性能^[1,2]。实验 4 分别对训练样本、测试样本和库外样本集进行了重构。图 6 结果显示，SRAEs 对 3 组 HRRP 样本均有较好的重构能力，保留了样本的主要细节信息，并未出现由于过学习现象带来的失配问题。因此，SRAEs 对 HRRP 数据具有较好的描述能力和泛化性能，利于算法的推广。

5 结论

传统特征提取算法的浅层线性结构不利于提取

表1 RAE中稳健项对识别性能的影响(%)

| 识别算法 | SAEs ($\lambda = 1$) | | | SRAEs ($\lambda = 0$) | | | SRAEs ($\lambda = 0.05$) | | |
|-------|------------------------|-------|-------|-------------------------|-------|-------|----------------------------|-------|-------|
| | 雅克-42 | 奖状 | 安-26 | 雅克-42 | 奖状 | 安-26 | 雅克-42 | 奖状 | 安-26 |
| 雅克-42 | 97.08 | 1.42 | 1.50 | 97.92 | 0.58 | 1.50 | 98.17 | 0.50 | 1.33 |
| 奖状 | 1.60 | 89.40 | 9.00 | 0.70 | 86.25 | 13.05 | 1.25 | 89.95 | 8.80 |
| 安-26 | 8.65 | 5.15 | 86.20 | 9.25 | 3.75 | 87.00 | 9.30 | 4.30 | 86.40 |
| 平均识别率 | 90.89 | | | 91.20 | | | 91.51 | | |

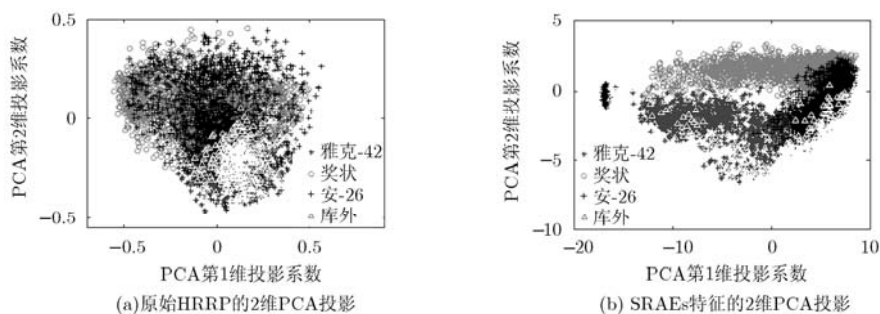


图5 可视化性能分析比较




图6 SRAEs 重构性能分析

有效的 HRRP 识别特征, 针对这一问题, 本文构建了基于深度网络的雷达目标识别框架, 利用多层非线性网络实现特征学习。结合平均像稳健的物理特性, 文章提出了 SRAEs 深度网络。SRAEs 是基于 HRRP 自编码和稳健约束的联合模型, 能够在保证较好地匹配原始 HRRP 样本的同时, 约束同帧样本趋近于平均像, 从而获得稳健有效的层次化识别特征。基于实测 HRRP 数据的实验结果表明, SRAEs 深度模型提高了识别性能, 而且具有较好的降维和泛化性能。

参考文献

- [1] 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 Signal Processing*, 2012, 60(7): 3546-3559.
- [2] 潘勉, 王鹏辉, 杜兰, 等. 基于TSB-HMM模型的雷达高分辨距离像目标识别算法[J]. *电子与信息学报*, 2013, 35(7): 1547-1554.
- [3] Pan Mian, Wang Peng-hui, Du Lan, *et al.* Radar HRRP target recognition based on truncated stick-breaking hidden Markov model[J]. *Journal of Electronics & Information Technology*, 2013, 35(7): 1547-1554.
- [4] Zhang X D, Shi Y, and 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.
- [5] Du L, Liu H W, Bao Z, *et al.* Radar HRRP target recognition based on higher-order spectra[J]. *IEEE Transactions on Signal Processing*, 2005, 53(7): 2359-2368.
- [6] Zhu F, Zhang X D, Hu Y F, *et al.* Nonstationary hidden Markov models for multiaspect discriminative feature extraction from radar targets[J]. *IEEE Transactions on Signal Processing*, 2007, 55(5): 2203-2213.
- [7] Feng B, Du L, Liu H W, *et al.* Radar HRRP target recognition based on K-SVD algorithm[C]. *IEEE CIE International Conference on Radar*, Chengdu, 2011: 642-645.
- [8] 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.
- [9] Bengio Y, Courville A, and Vincent P. Representation learning: a review and new perspectives[J]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 2013, 35(8): 1798-1828.
- [10] Hinton G and Salakhutdinov R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786): 504-507.
- [11] 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: 3371-3408.
- [12] Chen B, Polatkan G, Sapiro G, *et al.* Deep learning with hierarchical convolutional factor analysis[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(8): 1887-1901.
- [13] Bengio Y, Mesnil, *et al.* Better mixing via deep representations[C]. *Proceedings of the 30th International Conference on Machine Learning (ICML-13)*, Atlanta, USA, 2013: 552-560.
- [14] Bengio Y, Lamblin P, Popovici D, *et al.* Greedy layer-wise

- training of deep networks[C]. *Neural Information and Processing Systems (NIPS 2006)*, Vancouver, Canada, 2007: 153-160.
- [14] Goodfellow I, Mirza M, Courville A, *et al.* Multi-prediction deep Boltzmann machines[C]. *Proceedings of Neural Information Processing Systems (NIPS 2013)*, Vancouver, Canada, 2013: 548-556.
- [15] 陈渤, 刘宏伟, 保铮. 基于三种不同绝对对齐方法的分类器的分析与研究[J]. *现代雷达*, 2006, 28(3): 58-62.
Chen Bo, Liu Hong-wei, and Bao Zheng. Analysis of three kinds of classification based on different absolute alignment methods[J]. *Modern Radar*, 2006, 28(3): 58-62.
- [16] Xing M D, Bao Z, and Pei B. The properties of high-resolution range profiles[J]. *Optical Engineering*, 2002, 41(2): 493-504.
- [17] Bengio Y. Practical recommendations for gradient-based training of deep architectures[J]. *Neural Networks: Tricks of the Trade, Springer Berlin Heidelberg*, 2012, 7700: 437-478.
- [18] Yu H and Yang J. A direct LDA algorithm for high-dimensional data with application to face recognition[J]. *Pattern Recognition*, 2001, 34(10): 2067-2070.
- 冯 博: 男, 1988 年生, 博士生, 研究方向为雷达自动目标识别。
陈 渤: 男, 1979 年生, 博士, 教授, 博士生导师, 研究方向为雷达目标识别、统计信号处理、统计机器学习、深度学习网等。
王鹏辉: 男, 1984 年生, 博士, 讲师, 研究方向为雷达自动目标识别以及统计机器学习理论等。
刘宏伟: 男, 1971 年生, 博士, 教授, 博士生导师, 研究方向为雷达信号处理、雷达自动目标识别、认知雷达、协同探测等。

《雷达学报》“雷达目标识别技术”专题征文通知

雷达目标识别技术是针对目标和环境的雷达回波信号, 根据电磁散射机理, 提取目标特征, 实现目标类型和属性的自动判定。雷达目标识别是集传感器、目标、环境和信号处理为一体的复杂系统工程。随着大规模集成电路技术及高性能电子器件技术的发展, 高距离分辨率雷达技术、合成孔径雷达(SAR)技术和逆合成孔径雷达(ISAR)技术逐渐成熟, 通过获取更多的目标结构信息, 为雷达目标识别技术的发展提供了强有力的支持。该研究方向不仅有重大的理论和学术意义, 而且具有广阔的应用前景, 特别是巨大的军事应用价值, 美、俄等军事强国均把它作为发展未来智能化武器系统的重点和首先突破的关键技术。

为及时总结雷达目标识别研究与应用的最新进展, 《雷达学报》拟在 2015 年下半年出版“雷达目标识别技术”专题, 专题主编为西安电子科技大学雷达信号处理国家重点实验室杜兰教授。

现公开征集专题论文, 诚挚欢迎国内外专家、学者和科研人员积极投稿, 具体征文事项如下。

一. 征文方向(但不限于)

(一)基于宽、窄带一维信号的分类识别

1. 基于高分辨雷达目标回波的特征提取和识别方法
2. 目标微多普勒特性分析和分类方法
3. 基于多极化雷达回波的目标检测和分类方法
4. 辐射源电磁特征提取和分选识别方法

(二)二维雷达图像识别

1. SAR/ISAR/InSAR/PolinSAR 图像解译
2. 基于 SAR 图像的目标检测和分类方法

(三)机器学习新理论在雷达目标识别中的应用

(四)雷达目标识别系统设计

二. 征文要求

1. 来稿须进行脱密处理, 发表前应提交保密审查表(盖章)。
2. 观点明确, 论据充分, 引证准确; 尚未公开发表; 中英文皆可。
3. 题目、作者姓名及单位、摘要、关键词、图题、表题应给出中英文; 单位和物理量使用符合国家标准。
4. 稿件请采用 Office Word 97~2003 版本通栏排版。
5. 投稿请在《雷达学报》网站(<http://radars.ie.ac.cn>)“作者投/查稿”处注册、上传, 在作者留言中注明“雷达目标识别”专题论文。
6. 投稿截止日期: 2015 年 6 月 30 日。
7. 联系人: 贾守新、高华, 电话: 010-58887062, 邮箱: radars@mail.ie.ac.cn。