

## 基于 PGBN 模型的 SAR 图像目标识别方法

郭丹丹 陈渤\* 丛玉来 文伟

(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:** 特征提取是合成孔径雷达图像目标识别的关键步骤,也是难点之一。该文提出一种基于 PGBN(Poisson Gamma Belief Network)模型的 SAR 图像目标识别方法。PGBN 模型作为一种深层贝叶斯生成网络,利用伽马分布具有的高度非线性,从复杂的 SAR 图像数据中获得了更具结构化的多层特征表示,这种多层特征表示有效提高了 SAR 图像目标识别性能。为了获得更高的训练效率和识别率,该文进一步采用朴素贝叶斯准则提出了一种对 PGBN 模型进行分类的方法。实验采用 MSTAR 的 3 类目标数据进行了验证,结果表明通过该方法提取的特征有更好的结构信息,对 SAR 图像目标识别具有较好的性能。

**关键词:** SAR 图像; 特征提取; PGBN(Poisson Gamma Belief Network)模型

中图分类号: TN957.51

文献标识码: A

文章编号: 1009-5896(2016)12-2996-08

DOI: 10.11999/JEIT161068

## SAR Image Recognition Method with Poisson Gamma Belief Network Model

GUO Dandan CHEN Bo CONG Yulai WEN Wei

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

**Abstract:** Feature extraction is a key step and difficult point in SAR image target recognition. This paper presents a novel method based on Poisson Gamma Belief Network (PGBN) for SAR image target recognition. As a deep Bayesian generative network, the PGBN model obtains a more structured multi-layer feature representation from the complex SAR image data using the high nonlinearity of the Gamma distribution, and the multi-layer feature representation effectively improves SAR image target recognition performance. In order to obtain a higher recognition rate and efficiency of training, this paper further proposes a method for classifying PGBN model based on the Naive Bayes rule. The experimental results about MSTAR dataset show that the feature extracted by this new method has better structure information, and it has better performance for SAR image target recognition.

**Key words:** SAR image; Feature extraction; Poisson Gamma Belief Network (PGBN) model

### 1 引言

SAR 图像目标识别具有重要的商业价值和军事价值,一直是国内外研究的热点<sup>[1-2]</sup>。虽然近几年目标识别领域已经得到了极大的发展,但是准确快速地完成 SAR 图像目标识别仍然是一项充满挑战的任务。对于 SAR 图像目标识别来说,特征提取是其中十分关键的一步,特征提取的好坏直接影响 SAR

图像目标的识别性能,因此有必要对 SAR 图像进行有意义的特征提取,提高 SAR 图像目标识别性能。现在已经有了许多针对 SAR 图像的特征提取方法。例如:文献[3]采用 PCA(Principal Component Analysis)对图像作特征提取,该方法属于线性特征提取方法,并不能得到数据的非线性特征;文献[4]采用 KPCA(Kernel Principal Component Analysis)方法得到数据的非线性特征,对数据有更好的表征能力;文献[5]采用 ICA(Independent Component Analysis)算法在假设各信号分量独立的基础上对信号进行分解,得到了生成信号的独立分量。上述提取 SAR 图像特征的方法很大程度上改善了 SAR 图像目标识别性能,但这些方法存在一个共同特点:当输入的数据具有非负性时,得到的字典与隐变量仍然存在负值,但是 SAR 图像数据中不可能有负的像素点,因此在物理意义上并不能得到很好的解释。

收稿日期: 2016-10-12; 改回日期: 2016-12-02; 网络出版: 2016-12-14

\*通信作者: 陈渤 bchen@mail.xidian.edu.cn

基金项目: 国家自然科学基金(61372132, 61271291), 新世纪优秀人才支持计划(NCET13-0945), 杰出青年科学基金(61525105), 青年千人计划

Foundation Items: The National Natural Science Foundation of China (61372132, 61271291), The Program for New Century Excellent Talents (NCET13-0945), The National Science Fund for Distinguished Young Scholars (61525105), The Program for Young Thousand Talent by Chinese Central Government

为了获得物理可解释的分解方法, 文献[6]提出了非负矩阵分解 (Non-negative Matrix Factorization, NMF) 方法, 文献[7]对该方法求解方式做了改进, 提高了算法效率。NMF 的主要思想是将输入矩阵近似分解为字典与隐变量的非负加权组合形式, 获得了数据的基本结构信息, 龙泓琳等人在文献[8]中采用 NMF 算法对 SAR 图像做了特征提取, 相比于其他特征提取方法, 该方法提取到了 SAR 图像内部结构信息, 增加了目标识别性能。NMF 采用优化方式进行求解, 为了平衡各惩罚项需要通过交叉验证的方法对参数进行选择, 具有较高运算复杂度。Zhou 等人在文献[9]中提出了基于贝叶斯框架的非负矩阵分解模型 (Poisson Factor Analysis, PFA) 模型, 有效避免了模型参数的选择问题。该模型将数据通过泊松分布表示为字典与隐变量加权组合的形式, 并对隐变量采用伽马分布进行建模, 应用 PFA 模型对数据建模获得数据结构信息, 且先验的存在可以减少过拟合, 对于数据及参数设置更具鲁棒性。

事实上, 从 SAR 图像相干斑生成的角度看, 每一个像素点可以看成由若干个散射点回波共同叠加的结果, 在统计学上可以将散射点数量描述为一个服从泊松分布的随机过程<sup>[10]</sup>, 而 PFA 模型采用泊松分布对数据进行建模, 是一个计数过程, 这里可以将散射点数目看作服从泊松分布的变量, 因此采用 PFA 模型对 SAR 图像数据进行建模在理论上是可行的。

虽然 PFA 模型可以对 SAR 图像进行特征提取, 但是其作为单层模型, 挖掘的信息属于较为简单的结构, 为了提取更为丰富的数据结构特征, 在深度学习的启发下, Zhou 等人在文献[11]中提出了 PGBN (Poisson Gamma Belief Network) 模型。PGBN 模型在 PFA 模型的基础上, 构建了一个深层贝叶斯生成网络, 在第 1 层通过泊松分布将数据表示为字典与隐变量非负加权组合的形式, 然后将底层隐变量经伽马分布分解为高层隐变量与高层字典的乘积, 使得其高层字典具有更为丰富的结构信息。与传统深层网络如深度置信网络 (Deep Belief Network, DBN)<sup>[12]</sup>相比: 在建模方式上, DBN 模型对隐变量采用二值数据建模, 而 PGBN 模型对隐变量采用伽马分布建模, 伽马分布的存在增强了网络的非线性; 在参数的训练方法上, DBN 模型采用贪婪逐层堆叠策略训练网络参数, 而 PGBN 模型利用吉布斯采样的方式对各层参数联合训练。

PGBN 模型属于无监督模型, 为了利用 SAR 图像的监督信息获得更好的目标识别结果, 本文进一步提出了一种基于朴素贝叶斯分类准则对 PGBN 模型进行分类的方法 (Naive Bayes Poisson Gamma Belief Network, NBPGBN)。NBPGBN 模型除了在训练过程中引进类别信息, 仍然采用原来的建模方式和求解方法。简单来说, NBPGBN 模型采用 PGBN 模型分别训练各类数据, 得到各类样本的字典, 测试时采用朴素贝叶斯准则得到识别结果。

本文贡献主要有: (1) 提出了一种基于 PGBN 模型提取 SAR 图像特征的方法, 通过 PGBN 模型对 SAR 图像进行多层特征提取, 获得了具有多层结构信息的 SAR 图像字典表示。(2) 提出了一种基于朴素贝叶斯分类准则对 PGBN 模型进行分类的方法 (NBPGBN), 获得了具有区分能力的数据的多层特征表示。

## 2 基于 PGBN 模型的特征提取方法

### 2.1 PFA 模型

PFA 模型属于单层 PGBN 模型, 为了便于理解, 这里首先对 PFA 模型做简单介绍。PFA 模型是贝叶斯生成模型, 即在贝叶斯的框架下对数据进行非负分解, 且由于 SAR 图像的相干斑特性, 用泊松分布对数据进行分解是有意义的。

模型将数据  $\mathbf{x}_j$  通过泊松分布分解为字典  $\Phi$  与隐变量  $\theta_j$  的乘积,  $\theta_j$  服从伽马分布。生成模型表示为

$$\mathbf{x}_j \sim \text{Poiss}(\Phi\theta_j), \quad \theta_j \sim \text{Gam}(\mathbf{r}, p_j/(1-p_j)) \quad (1)$$

其中,  $j = 1 \sim N$  代表样本数,  $k = 1 \sim K$  代表隐变量维度, 为了推导方便 (不失一般性), 字典每一列  $\phi_k$  需要满足一范数约束, 使得字典每一列  $\phi_k$  服从 Dirichlet 分布, 隐变量  $\theta_j$  共享伽马形状参数  $\mathbf{r} = (r_1, r_2, \dots, r_K)$ ,  $r_k$  服从伽马分布;  $p_j$  是概率参数, 服从贝塔分布。  $a_0, b_0, c_0, \eta, \gamma_0$  为模型超参数,  $\phi_k, r_k$  和  $p_j$  的表示为

$$\begin{aligned} \phi_k &\sim \text{Dir}(\eta, \sim, \eta), \quad r_k \sim \text{Gam}(\gamma_0 / K, 1/c_0), \\ p_j &\sim \text{Beta}(a_0, b_0) \end{aligned} \quad (2)$$

### 2.2 PGBN 模型

PGBN 模型是基于 PFA 模型的深层网络模型。该模型首先把数据  $\mathbf{x}_j^{(1)}$  通过泊松分布分解成字典  $\Phi^{(1)}$  和隐变量  $\theta_j^{(1)}$  的乘积, 然后将隐变量  $\theta_j^{(1)}$  通过伽马分布的形状参数分解得到下一层的字典  $\Phi^{(t+1)}$  和隐变量  $\theta_j^{(t+1)}$  的乘积, 顶层隐变量  $\theta_j^{(T)}$  共享伽马形状参数  $\mathbf{r} = (r_1, r_2, \dots, r_{K_T})$ ,  $T$  层 PGBN 生成模型表示为

$$\left. \begin{aligned} \boldsymbol{\theta}_j^{(T)} &\sim \text{Gam}(\mathbf{r}, 1/c_j^{(T+1)}) \\ \boldsymbol{\theta}_j^{(t)} &\sim \text{Gam}(\boldsymbol{\Phi}^{(t+1)}\boldsymbol{\theta}_j^{(t+1)}, 1/c_j^{(T+1)}) \\ \boldsymbol{\theta}_j^{(1)} &\sim \text{Gam}(\boldsymbol{\Phi}^{(2)}\boldsymbol{\theta}_j^{(2)}, p_j^{(2)}/(1-p_j^{(2)})) \\ \mathbf{x}_j^{(1)} &\sim \text{Poiss}(\boldsymbol{\Phi}^{(1)}\boldsymbol{\theta}_j^{(1)}) \end{aligned} \right\} \quad (3)$$

同样对字典的每一列  $\phi_k^{(t)}$  加上  $L_1$  范数约束, 即  $\phi_k^{(t)}$  服从 Dirichlet 分布,  $\mathbf{r}$  服从伽马分布:

$$\phi_k^{(t)} \sim \text{Dir}(\eta^{(t)}, \dots, \eta^{(t)}), \quad r_k \sim \text{Gam}(\gamma_0/K_T, 1/c_0) \quad (4)$$

给定  $p_j^{(2)}$  为贝塔分布, 且满足  $c_j^{(2)} := (1-p_j^{(2)})/p_j^{(2)}$ ,  $\{1/c_j^{(t)}\}_{3,T+1}$  服从伽马分布,  $a_0, b_0, c_0, \eta, \gamma_0, e_0, f_0$  为模型超参数:

$$p_j^{(2)} \sim \text{Beta}(a_0, b_0), \quad c_j^{(t)} \sim \text{Gam}(e_0, 1/f_0) \quad (5)$$

根据式(3)~式(5)可以写出 PGBN 模型参数的联合分布(为了保持公式的简洁, 这里只列出字典和隐变量):

$$\begin{aligned} p(\mathbf{X}^{(1)}, \{\boldsymbol{\Phi}^{(t)}\}_{t=1:T}, \{\boldsymbol{\theta}^{(t)}\}_{t=1:T}) \\ = \prod_{j=1}^N p(\mathbf{x}_j^{(1)} | \boldsymbol{\Phi}^{(1)}, \boldsymbol{\theta}_j^{(1)}) \\ \cdot \prod_{t=1}^{T-1} p(\boldsymbol{\theta}_j^{(t)} | \boldsymbol{\Phi}^{(t+1)}, \boldsymbol{\theta}_j^{(t+1)}) p(\boldsymbol{\theta}_j^{(T)}) \\ \cdot \left[ \prod_{t=1}^T \prod_{k=1}^{K_t} p(\phi_k^{(t)} | \eta) \right] \end{aligned} \quad (6)$$

### 2.3 PGBN 模型推理

该模型采用马尔科夫链蒙特卡洛(MCMC)方法对参数进行估计, 基于 Gibbs 采样的算法具有可行性, 这里采用 Gibbs 采样技术进行参数估计<sup>[13]</sup>。在 Gibbs 采样的每次迭代中, 参数是从其条件后验分布的采样中获取的。根据 PGBN 模型参数的联合分布和贝叶斯公式推导出 PGBN 模型各个参数的条件后验分布。为了保证文章连贯性只给出几个主要变量的采样, 采样过程中需要增广两个变量, 在第  $t$  层通过多项式分布采样增广变量  $x_{vkj}^{(t)}$ , 在第  $t+1$  层通过 CRT(Chinese Restaurant Table)分布采样增广变量  $x_{kj}^{(t+1)}$ , 具体如下:

(1) 从多项式分布中采样增广变量  $x_{vkj}^{(t)}$ :

$$\begin{aligned} p(\{x_{vkj}^t\}_k | x_{vj}^{(t)}, \phi_v^{(t)}, \boldsymbol{\theta}_{:j}^{(t)}) \\ = \frac{p(\{x_{vkj}^t\}_k, x_{vj}^{(t)} | \phi_v^{(t)}, \boldsymbol{\theta}_{:j}^{(t)})}{p(x_{vj}^{(t)} | \phi_v^{(t)}, \boldsymbol{\theta}_{:j}^{(t)})} \\ \left[ (x_{vkj}^t)_k | \cdot \right] \sim \text{Mult} \left( x_{vj}^{(t)}, \frac{(\phi_{vk}^{(t)} \boldsymbol{\theta}_{kj}^{(t)})_k}{\sum_k \phi_{vk}^{(t)} \boldsymbol{\theta}_{kj}^{(t)}} \right) \end{aligned} \quad (7)$$

分别对  $x_{vkj}^{(t)}$  的  $J$  维和  $V$  维加和得到:  $\sum_j x_{vkj}^{(t)} = x_{vk}^{(t)}$ ,  $\sum_v x_{vkj}^{(t)} = x_{kj}^{(t)}$ ,  $m_{kj}^{(t+1)} := x_{kj}^{(t)}$ 。

(2) 在层数  $t > 1$  时, 从 CRT 分布中采样下一层数据  $x_{kj}^{(t+1)}$ :

$$x_{kj}^{(t+1)} \sim \text{CRT}(m_{kj}^{(t+1)}, \phi_k^{(t)} \boldsymbol{\theta}_{:j}^{(t+1)}) \quad (8)$$

(3) 从 Dirichlet 分布中采样  $\phi_k^{(t)}$ :

$$(\phi_k^{(t)} | \cdot) \sim \text{Dir}(\eta^{(t)} + x_{1k}^{(t)}, \dots, \eta^{(t)} + x_{V_k}^{(t)}) \quad (9)$$

(4) 从伽马分布中采样  $\boldsymbol{\theta}_j^{(t)}$ :

$$\begin{aligned} (\boldsymbol{\theta}_j^{(t)} | \cdot) \sim \text{Gam}(\boldsymbol{\Phi}^{(t+1)}\boldsymbol{\theta}_j^{(t+1)} + \mathbf{m}_j^{(t+1)}, \\ 1/(c_j^{(t+1)} - \ln(1-p_j^{(t)}))) \end{aligned} \quad (10)$$

其中,  $t = T$  时,  $\boldsymbol{\Phi}^{(T+1)}\boldsymbol{\theta}_j^{(T+1)} := \mathbf{r}$ 。

这里需要说明的是, 该模型在给定网络层数时, 采用联合学习方式训练模型, 即上下吉布斯采样的方式。每次迭代时, 先从  $t = 1, 2, \dots, T$  向上采样得到  $x_{vkj}^{(t)}, x_{kj}^{(t+1)}, \phi_k^{(t)}$ , 然后采样得到  $p_j^{(2)}, \mathbf{r}, \{1/c_j^{(t)}\}_{3,T+1}$ , 计算得到  $c_j^{(2)}$ , 最后从  $t = T, T-1, \dots, 1$  向下采样得到  $\boldsymbol{\theta}_j^{(t)}$ 。

### 3 基于 PGBN 模型的分类

上述 PGBN 模型属于无监督生成模型, 训练过程中并没有用到类别信息, 然而充分利用类别信息有利于识别性能的提高。鉴于此, 本文提出了一种基于朴素贝叶斯准则<sup>[14]</sup>对 PGBN 模型进行分类的方法(NBPGBN)。NBPGBN 模型首先对训练样本分类训练, 得到各类样本字典, 然后提取测试样本对应于各类字典的特征。每类字典分别对应每类样本的结构信息, 即各类字典对所属类别的样本有最好的描述能力, 因此当测试样本选择属于该类的字典时会得到最大后验概率。朴素贝叶斯准则将最高后验概率对应的类别作为测试样本的类别:

$$\begin{aligned} \arg \max_c p(c | \mathbf{x}_j^{(1)}) &= \arg \max_c \frac{p(\mathbf{x}_j^{(1)} | c) p(c)}{p(\mathbf{x}_j^{(1)})} \\ &= \arg \max_c p(\mathbf{x}_j^{(1)} | c) \end{aligned} \quad (11)$$

其中,  $c = 1 \sim C$  代表类别, 等式最左边求类别  $c$  的后验概率, 根据式(11)所示贝叶斯公式后验概率  $p(c | \mathbf{x}_j)$  可以由联合概率  $p(\mathbf{x}_j, c)$  和边缘概率  $p(\mathbf{x}_j)$  来求解。由于分类时只关心相对概率而不关心具体概率, 因此数据样本给定时可以不考虑边缘概率,  $p(c)$  是类别先验概率, 一般对于所有类别将会给定同样的先验概率, 所以求解最大类别后验概率通过贝叶斯公式可以转化为求解最大似然。第  $j$  个测试样本对应第  $c$  类字典的似然表示为

$$\begin{aligned}
 p(\mathbf{x}_j^{(1)}|c) &= p(\mathbf{x}_j^{(1)}, \boldsymbol{\theta}_{jc}^{(1:T)} | \Phi_c^{(1:T)}) \\
 &= p(\mathbf{x}_j^{(1)} | \Phi_c^{(1)}, \boldsymbol{\theta}_{jc}^{(1)}) \\
 &\quad \cdot \prod_{t=1}^{T-1} p(\boldsymbol{\theta}_{jc}^{(t)} | \Phi_c^{(t+1)}, \boldsymbol{\theta}_{jc}^{(t+1)}) \Big] p(\boldsymbol{\theta}_{jc}^{(T)}) \quad (12)
 \end{aligned}$$

根据式(11)算出第  $j$  个样本对应各类字典的似然值，然后将最大似然值所对应的类别选为样本类别。

由于原本图像大小为  $128 \times 128$ ，为了减少计算量，首先对所有图像从中心区域进行切割，得到  $64 \times 64$  的目标图像，然后将 SAR 图像数据离散化变为非负整数型数据，最后将每个图像样本进行列向量化，每一个样本变为  $4096 \times 1$  的列向量。将训练数据在 PGBN 模型分类进行训练，得到各类样本的字典之后，用测试数据进行测试，对得到的隐变量经过朴素贝叶斯准则分类，得到识别结果。为了便于直观理解算法流程，图 1 给出基于 PGBN 模型进行分类的流程图。

## 4 实验结果与分析

### 4.1 实验数据

为了验证该方法的有效性，本文采用MSTAR公共数据集进行验证，该数据是由X波段聚束式SAR得到。图像大小为  $128 \times 128$ ，分辨率为  $0.3 \text{ m} \times 0.3 \text{ m}$ 。该数据集包含了俯仰角为  $15^\circ$  和  $17^\circ$  的3类目标共7种型号。其中训练样本采用俯仰角为  $15^\circ$  的目标图像，测试样本采用俯仰角为  $17^\circ$  的目标图像，用于训练和测试的具体样本如表1所示，测试数据中存在与训练数据类型相同但型号不同的数据，该测试场景主要验证识别算法对于不同型号的同目标的识别能力。将所有的训练数据经过上述预处理得到输入矩阵，然后分别在PGBN模型和监督PGBN模型上进行训练。

### 4.2 实验设置

该实验主要分为两大部分：第1部分是基于单层PGBN模型对SAR图像进行特征提取及分析，第2部分是基于多层PGBN模型和多层NBPGBN模型分别对SAR图像进行特征提取和分析。第1部分，首先将不同维度的单层PGBN模型分别与NMF, PCA和ICA进行比较，隐层维度  $K$  分别设置为500, 400, 300, 200, 100；第2部分，由于MSTAR的3类目标数据训练样本较少，所以该网络深度  $T$  只需要设置为3，各层隐变量维度分别为  $K = 1000, 500, 200$ ；实验结果将与多层RBM, DBN, SDBN, JSRC作比较。为了比较的公正性，NBPGBN模型采用朴素贝叶斯准则进行分类，DBN模型用Softmax分类器进行分类，其它模型分类结果均采用SVM分类器得到，其中SVM 分类实验采用 LIBSVM 算法包进行求解<sup>[15]</sup>。所有实验均在3.2 GHz加4 G内存的普通计算机上完成。训练NBPGBN 的时间大约为1 h，而每幅图像的测试时间大约在1 s。

### 4.3 实验结果

本文实验将从多方面验证该算法的可行性。首先给出采用上述实验数据得到的字典，通过分析字典来更深入地了解目标的局部信息，以及其对目标识别的意义；然后将基于本文方法得到的识别率分别与其他方法等进行比较。

**4.3.1 数据字典的结果及分析** 图2表示PGBN模型的3层字典。在给定3层网络的前提下，本文获得了每一层字典表示，为了保证字典的清晰性，图中只选了每层字典使用频率最高的前30列进行展示。第1层字典呈现出数据的基础结构信息，属于像素级别简单通用；从第2层字典中可以看出，该模型已经学到了部分目标结构信息，以及背景杂波和阴影信息；而模型第3层字典得到了数据的高层结构信




图 1 基于 PGBN 模型进行分类的流程图

表 1 MSTAR 3 类目标数据训练数据和测试数据

数据类型	BMP2			BTR70		T72	
	SNC21	SN9563	SN95666	C71	SN132	SN812	SNS7
训练数据	233	0	0	233	232	0	0
测试数据	196	195	196	196	196	195	191

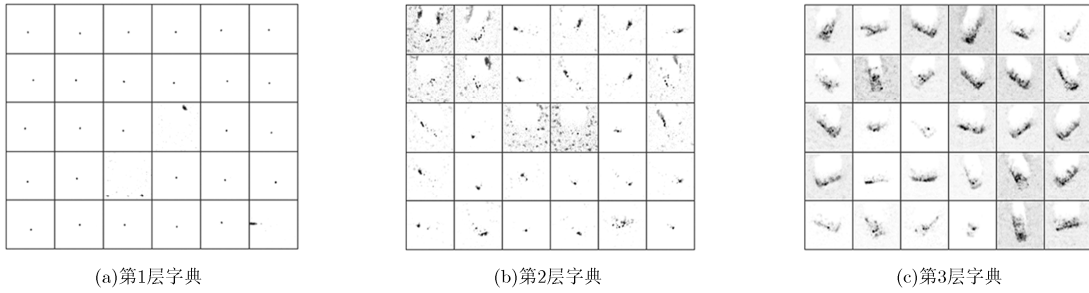


图 2 PGBN 模型关于 MSTAR 图像字典展示

息，完全可以将目标，背景杂波，阴影的结构分别表示出来。上述实验结果表明基于 PGBN 模型进行特征提取可以学到有物理意义的 SAR 图像多层结构信息。

图 3 所示为 MSTAR 图像字典使用情况对比，从结果可以看出，随着层数的增高字典变得更为稀疏，产生这种现象的主要原因有两个：字典随着层数增加变得更加结构化，通常一个样本只需由几个不同的高层字典构成，所以相较于底层字典，高层字典系数往往很稀疏；该模型有能力学到稀疏的字典系数，而稀疏性正是字典学习方法的理想特性。

图 4 所示为样本与各层字典之间的关系树图，根节点为训练样本图像。在给定样本图像的基础上，选取构成该样本的主要字典，即从  $\Phi^{(3)}$  中选取其中 3 维，这 3 个字典已经分别包含了样本图像的大部分结构，而且 3 个字典之间存在着明显区别；其次从  $\Phi^{(2)}$  中找出构成  $\Phi^{(3)}$  的主要字典，选出的字典同样具备上层字典的结构信息，但是 6 个字典之间的差异性已经降低；最后从  $\Phi^{(1)}$  中找出构成  $\Phi^{(2)}$  的主要字典，第 1 层字典存在着很少的结构信息，大部分属于像素级别信息，这些字典之间差异性再次降低，说明底层信息简单通用。从上到下观看图像字典树图时，字典信息变得越来越简单，阐述了各层字典之间的关系；从下到上的字典树图直观地表示了给定字典时样本的生成过程。

图 5 表示 NBPGBN 模型的字典，由于第 1 层字典代表比较基础的信息(如图2(a)所示)，因此这里只画出了各类样本在第 2 层，第 3 层的字典。同样选取每一类字典使用频率最高的前 30 列进行对比。从图中可以看出每一类样本的高层字典变得更加结构化，且随着层数的增加各类样本字典之间区别逐渐明显，反映了各类样本字典具有不同的结构信息。采用 NBPGBN 模型提取 SAR 图像特征，可以得到各类样本的字典，通过比较各类字典之间的异同，有利于后期对于 SAR 图像的目标识别及分析。

**4.3.2 识别率比较** 表 2 所示为单层 PGBN 模型与其他方法识别率的比较。NMF 方法是将输入矩阵分解为字典与隐变量的非负加权组合形式，模型求解采用迭代的方式依次对字典和隐变量进行更新，其缺点是需要通过交叉验证对参数进行选择，当隐变量维度逐渐增加时，由于样本数量过少和参数选择的问题，NMF 方法的识别率先增加后减少，发生了过拟合。PCA 方法直接求得数据协方差矩阵的特征向量，然后向选取的特征向量方向进行投影，但是对于 SAR 图像目标识别来说，该方法提取得到的特征向量含有负值，而负值在物理上是不可解释的。ICA 方法在假设各信号分量是独立的基础上对数据进行分解，得到独立的基向量，当隐变量维度为 100 维和 200 维时，ICA 方法获得了与单层 PGBN 模型




图 3 MSTAR 图像各层字典使用频率

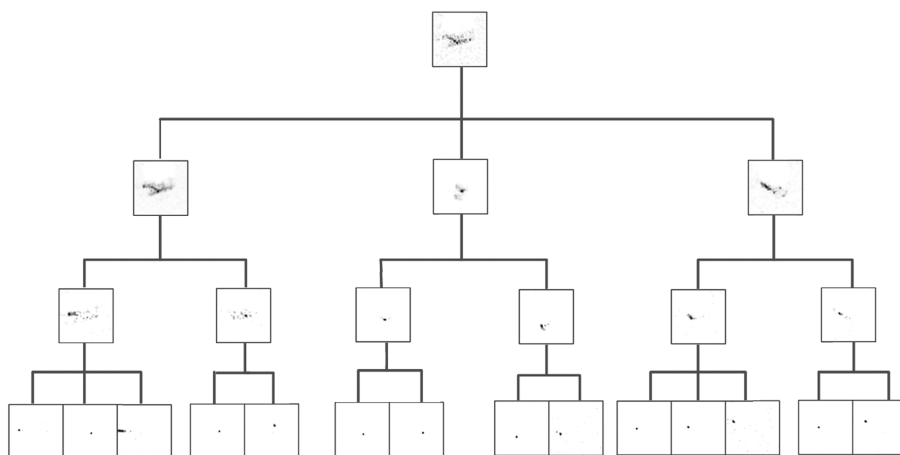


图 4 MSTAR 图像字典树图

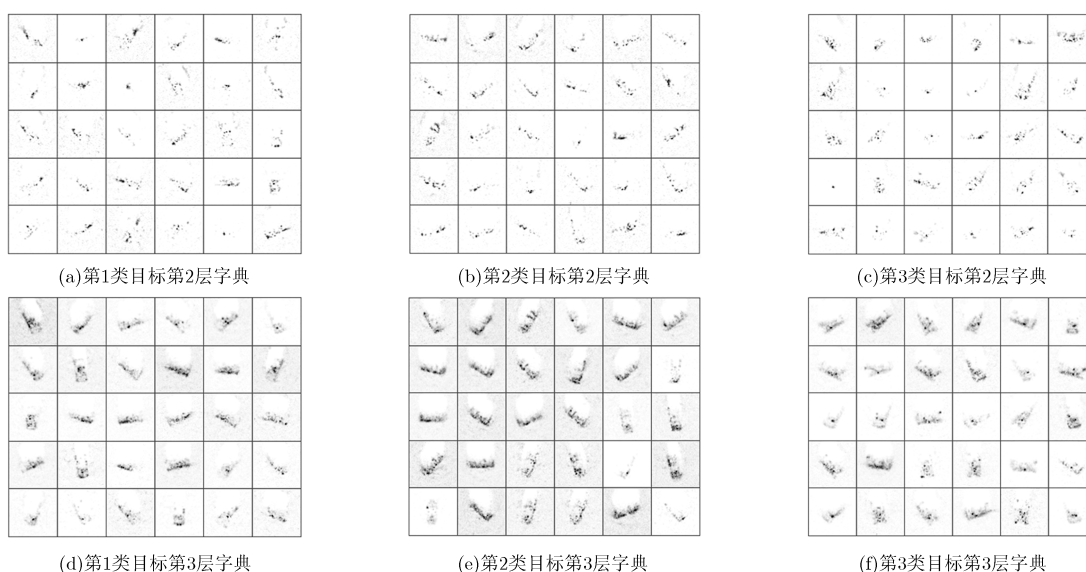


图 5 NBPGBN 模型关于 MSTAR 图像的字典

表 2 单层 PGBN 模型与其他方法识别率的比较(%)

模型	识别率				
	K=100	K=200	K=300	K=400	K=500
单层 PGBN	<b>84.54</b>	<b>86.80</b>	<b>87.77</b>	<b>87.62</b>	<b>87.47</b>
NMF	81.83	86.45	87.47	86.45	85.86
PCA	83.81	84.61	85.57	85.78	85.93
ICA	84.32	86.61	85.86	85.13	84.40

很近似的识别率，但是随着维度的增加，该算法发生过拟合，导致其识别率逐渐降低。总结来讲，单层 PGBN 模型属于非负矩阵分解范畴，能够对非负数据提取物理意义的特征；单层 PGBN 模型基于贝叶斯框架，先验的存在可以有效减少过拟合现象，即模型随着隐变量维度增加变得更加复杂时识别率不会受到很大影响。因此相比于其他特征提取方法，

单层 PGBN 模型可以获得更好的特征识别效果。

表 3 所示为多层 PGBN 和多层 NBPGBN 分别与其它方法识别率的比较。多层 PGBN 模型训练时并未用到监督信息，因此首先将多层 RBM (Restricted Boltzmann Machine)模型<sup>[16]</sup>和多层 PGBN 模型做比较，在第 1 层时 PGBN 模型所得识别率已经超过多层 RBM 模型将近一个百分点，第 2

表3 多层 PGBN 模型识别率比较

模型	识别率		
	T=1	T=2	T=3
PGBN	88.28	88.50	89.16
RBM	87.36	86.99	87.84
NBPGBN	<b>92.67</b>	<b>93.19</b>	<b>93.85</b>
SDBN	92.18	92.54	91.90
DBN		88.94	
SVM		86.73	
K SVM		90.20	
JSRC		93.61	

层多层 RBM 模型的识别率降低, 而 PGBN 模型识别率却稳定增加, 第 3 层时 PGBN 模型识别率持续增加到 89.16%, 优于多层 RBM 识别率。相比于 PGBN 模型, NBPGBN 模型有两大优势: NBPGBN 模型在训练时引进了监督信息, 其识别率得到了提高; NBPGBN 模型对样本分类训练, 训练过程中采用并行方式, 训练效率得到提升。SVM 方法直接求得样本之间间隔最大的分离超平面, 属于线性分类方法, K SVM 方法利用核函数将 SVM 推广到非线性空间, 属于非线性分类方法, 这两种方法都属于 MSTAR 目标识别的常用方法。因此将 SVM 和 K SVM 对 MSTAR 3 类目标的识别率作为基准。为了比较公正性, 这里将单层 NBPGBN 模型得到的结果分别与 SVM 和 K SVM 方法进行比较。直接用 SVM 进行分类, 可以得到识别率为 86.73%, 采用 K SVM 方法可以得到 90.2% 的识别率, 然而单层 NBPGBN 模型可以得到 92.67% 的识别率, 因此采用 NBPGBN 模型提取特征有利于提高目标识别性能。DBN 模型是由多层 RBM 堆叠而成, 首先训练各层 RBM, 然后采用神经网络对参数进行微调, 相比于多层 RBM 模型虽然其引进了监督信息来微调参数但其识别性能并未获得很大提高, 相似性约束的深度置信网络 (Similarity Deep Belief Network, SDBN)<sup>[17]</sup> 在 DBN 模型增加了相似性约束, 属于有监督的特征提取方法, 但是其仍然采用贪婪逐层堆叠策略训练参数。如表 3 所示, SDBN 模型相对于 DBN 模型识别率得到了提高, 但其在第 3 层的识别率降低, 表明网络性能不够稳定, 两者与 NBPGBN 的整体对比结果表明: NBPGBN 得到的目标识别结果更好, 各层识别性能更加稳定。基于独立字典联合稀疏表示的分类方法 (Joint Sparse Representation with independent dictionary based Classification, JSRC)<sup>[18]</sup> 需要分割目标与阴影(该模

型对分割阈值较为敏感), 并对目标与阴影进行随机降维, 再分别学习目标与阴影的字典, 而 NBPGBN 模型无需上述复杂的预处理, 具有较好的推广性和易实现性。结果对比表明, 当采用简单的朴素贝叶斯准则对 PGBN 模型进行分类时, NBPGBN 获得的识别效果优于上述其他方法, 且 NBPGBN 模型是从非负矩阵分解的角度出发, 相比于其他方法, 可以获得有物理意义的 SAR 图像特征, 如炮管等结构。由此可以反映出 PGBN 模型建模方式, 联合训练策略和伽马分布的高度非线性使其得到的特征有较好的表征能力, 而这种多层化的表示有利于提高目标识别性能。

## 5 总结

文中提出了一种基于 PGBN 模型的 SAR 图像目标识别方法, 为了提高识别率和分类效率, 进一步提出了一种基于朴素贝叶斯准则对 PGBN 模型进行分类的方法 NBPGBN。采用上述方法对 MSTAR 数据库中的 3 类目标图像数据进行验证和分析。对目标图像字典的多角度分析表明本文的 NBPGBN 方法能够提取出目标的多层结构信息; 实验结果与其他特征提取方法识别率的比较, 表明该模型有更好的稳定性和更高的识别率。

## 参考文献

- [1] 张红, 王超, 张波. 高分辨率 SAR 图像目标识别[M]. 北京: 科学出版社, 2009: 5.2 节.  
ZHANG Hong, WANG Chao, and ZHANG Bo. High Resolution SAR Images Target Recognition[M]. Beijing: Science Press, 2009: 5.2 Section.
- [2] 保铮, 邢孟道, 王彤. 雷达成像技术[M]. 北京: 电子工业出版社, 2004: 1.1 节.  
BAO Zheng, XING Mengdao, and WANG Tong. Radar Imaging Technology[M]. Beijing: Publishing House of Electronics Industry, 2004: 1.1 Section.
- [3] HE Zhiguo, LU Jun, and YAO Kuanggang. A fast SAR target recognition approach using PCA features[C]. International Conference on Image and Graphics, Chengdu, China, 2007: 580-585.
- [4] LIN C, PENG F, WANG B H, et al. Research on PCA and KPCA self-fusion based MSTAR SAR automatic target recognition algorithm[J]. *Journal of Electronic Science and Technology*, 2012, 10(4): 352-357.
- [5] 宦若虹, 杨汝良. 基于 ICA 和 SVM 的 SAR 图像特征提取与目标识别[J]. *计算机工程*, 2008, 34(13): 24-25.  
HUAN Ruohong and YANG Ruliang. SAR images feature extraction and target recognition based on ICA and SVM[J]. *Computer Engineering*, 2008, 34(13): 24-25.

- [6] LEE D D and SEUNG H S. Learning the parts of objects by non-negative matrix factorization[J]. *Nature*, 1999, 401(6755): 788–791.
- [7] LEE D D and SEUNG H S. Algorithms for non-negative matrix factorization[C]. *Neural Information Processing Systems*, Denver, CO, USA, 2000: 556–562.
- [8] 龙泓琳, 皮亦鸣, 曹宗杰. 基于非负矩阵分解的 SAR 图像目标识别[J]. *电子学报*, 2010, 38(6): 1425–1429.  
LONH Honglin, PI Yiming, and CAO Zongjie . Non-negative matrix factorization for target recognition[J]. *Acta Electronica Sinica*, 2010, 38(6): 1425–1429.
- [9] ZHOU Mingyuan and CARIN Lawrence. Beta-negative binomial process and Poisson factor analysis[C]. *Artificial Intelligence and Statistics*. La Palma, Canary Islads, Spain, 2012: 1462–1471.
- [10] 孙洪. 高分辨率 SAR 图像目标识别[M]. 北京: 电子工业出版社, 2013: 5.1 节.  
SUN Hong. *Processing of Synthetic Aperture Radar Images* [M]. Beijing: Publishing House of Electronics Industry, 2013: 5.1 Section.
- [11] ZHOU Mingyuan, CONG Yulai, and CHEN Bo. The Poisson Gamma belief network[C]. *Neural Information Processing Systems*, Montreal, Canda, 2015: 562–570.
- [12] CHEN Y, ZHAO X, and JIA X. Spectral-Spatial classification of hyperspectral data based on deep belief network[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 1–12. doi: 10.1109/JSTAR.2015.2388577.
- [13] 张学峰. 雷达高分辨距离像目标识别与拒判方法研究[D]. [博士论文], 西安电子科技大学, 2016: 71–73.  
ZHANG Xuefeng. *Study of radar target recognition and outlier rejection based on high range resolution profiles*[D]. [Ph.D. dissertation], Xi dian University, 2016: 71–73.
- [14] LIU X, LIU R, MA J, *et al.* Privacy-preserving patent-centric clinical decision support system on Naïve Bayes classification [J]. *IEEE Journal of Biomedical & Health Informatics*, 2016, 20(2): 655–668. doi: 10.1109/JBHI.2015.2407157.
- [15] CHAN Chihchung and LIN Chinjen. LIBSVM: A library for support vector machines[J]. *ACM Transactions on Intelligent Systems and Technology*, 2011, 2(3): 1–27. doi: 10.1145/1961189.1961199.
- [16] GE Hinton. A practical guide training restricted boltzmann machines[J]. *Momentum*, 2010, 9(1): 599–619. doi: 10.007/978-3-642-35289-8\_32.
- [17] 丁军, 刘宏伟, 陈渤. 相似性约束的深度置信网络在 SAR 图像目标识别中的应用[J]. *电子与信息学报*, 2016, 38(1): 91–103. doi: 10.11999/JEIT150366.  
DING Jun, LIU Hongwei, and CHEN Bo. Application of similar constraints deep belief networks in SAR image target recognition[J]. *Journal of Electronics & Information Technology*, 2016, 38(1): 91–103. doi: 10.11999/JEIT150366.
- [18] 丁军, 刘宏伟, 王英华, 等. 一种联合阴影和目标区域图像的 SAR 目标识别方法[J]. *电子与信息学报*, 2015, 37(3): 594–600. doi: 10.11999/JEIT140713.  
DING Jun, LIU Hongwei, WANG Yinghua, *et al.* The method of SAR target recognition with joint shadow region and target region image[J]. *Journal of Electronics & Information Technology*, 2015, 37(3): 594–600. doi: 10.11999/JEIT140713.
- 郭丹丹: 女, 1993 年生, 博士生, 研究方向为统计机器学习、雷达自动目标识别.
- 陈渤: 男, 1979 年生, 教授, 研究方向为雷达目标识别、统计机器学习, 深度学习网络等.
- 丛玉来: 男, 1988 年生, 博士生, 研究方向为统计机器学习、雷达自动目标识别.
- 文伟: 男, 1987 年生, 博士生, 研究方向为统计机器学习、SAR 图像检测与识别.