

文章编号: 1001- 2486(2008) 03- 0136- 05

基于 PCA 特征的快速 SAR 图像目标识别方法*

王世 , 贺志国

(国防科技大学 电子科学与工程学院, 湖南 长沙 410073)

摘要: 目标识别是 SAR 图像解译的重要一环, 受到广泛的关注, 而实时性又是评估目标识别系统性能的主要指标之一。从实时的角度出发, 提出了一种快速的 SAR 目标识别方法。该方法采用基于 Hebb 学习规则的主分量分析(PCA) 进行特征提取, 使用多层感知器神经网络(MLP NN) 进行目标分类。实验结果表明, 在维持较好识别性能的前提下, 该方法具有内存需求少、运行速度快的特点, 能用于实时处理。

关键词: 目标识别; 特征提取; PCA; 合成孔径雷达; 神经网络

中图分类号: TN957 文献标识码: A

The Fast Target Recognition Approach Based on PCA Features for SAR Images

WANG Shi-xi, HE Zhi-guo

(College of Electronic Science and Engineering, National Univ. of Defense Technology, Changsha 410073, China)

Abstract: The extensively focused target recognition is one of the important problems for SAR imagery interpretation. With the aim to real-time processing, a fast SAR target recognition system is built, which utilizes the principal component analysis (PCA) for feature extraction and a multi-layer neural network (MLP NN) as the classifier. The experimental results show that it consumes little memory and runs very fast, thus can be used in the real-time situation.

Key words: target recognition; feature extraction; PCA; SAR; neural network

近年来, 随着 SAR 数据获取手段的发展, 人们对 SAR 自动目标识别 (Automatic Target Recognition, ATR) 技术的发展需求也日益紧迫。目前, 国内外对 SAR ATR 展开了广泛深入的研究。比较著名的如由林肯实验室开发的基于模板的 ATR 系统^[1], 以及由 DARPA 和 AFRL 共同资助的基于模型的 MSTAR ATR 系统^[2] 等, 这些 ATR 系统通常分为检测、鉴别以及分类等几个阶段^[3]。本文着重研究目标分类过程, 可以分为三个处理步骤: 预处理、特征提取和分类。

虽然 SAR ATR 经历了多年的发展, 然而对于实际目标, 由于其在实际场景中配置条件的千变万化^[4], 以现有的技术水平无法达到完美目标分类的要求。因而, 从实用系统的角度考虑, 如何在保证一定识别性能的基础上, 实时地完成目标分类成为当前一个研究热点。本文以实时性为主要指标, 提出了一种快速的 SAR 目标识别方案, 该方法依次采用主分量分析(PCA) 和多层感知器神经网络(MLP NN) 进行特征提取和目标分类。

1 设计方案

整个方案分为训练和测试两个阶段, 如图 1 所示。训练阶段, 首先对切片图像进行预处理, 再进行 PCA 特征提取, 将得到的特征向量输入 MLP NN 训练网络, 得到分类结果, 再将结果反馈给特征提取模块, 调整 PCA 提取特征的个数, 直到在正确分类率与提取特征个数二者之间达到一个平衡为止。

测试阶段比较简单, 将预处理后的图像进行 PCA 特征提取之后, 将其输入已训练好的 MLP NN, 得出分类结果, 并进行性能评估。

* 收稿日期: 2008- 04- 23

作者简介: 王世 (1963-), 男, 副教授, 在职博士生。

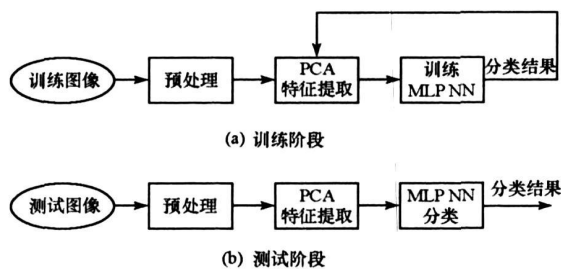


图1 设计方案
Fig.1 The designing scheme




图2 一个仅有单层计算结点的自组织前馈网络
Fig.2 CSOFN with single level computing node

1.1 预处理

特征提取和分类算法对目标位置偏移、旋转和强度等敏感。减少对这些几何和电磁变化的敏感性可增强 ATR 系统的准确性。因此,在进行特征提取之前,需要对切片图像做一些预处理。预处理包括地距转换、目标方向旋转、目标切片大小裁减以及图像归一化处理等。为节省篇幅,本文对预处理不介绍,有兴趣的读者可以参看文后所列的文献。

1.2 特征提取

特征提取广义上指的是一种变换,将高维空间的样本数据通过映射转换到低维空间,达到降低维数的目的。其最大优势在于可以显著地减少解译一幅图像所需的信息量。就目标识别任务而言,特征提取算法从每个目标切片中提取出独特的信息或者说是特征。

主分量分析(Principal Component Analysis, PCA),也称离散 K-L 变换,是一种基于目标统计特性的最佳正交变换。称其为最佳变换是由于它具有重要的优良性质:使变换后产生的新分量正交或不相关;以部分新分量表示原矢量均方误差最小;使变换矢量更趋稳定、能量更趋集中等,这使得它在特征提取方面有着极为重要的应用^[5]。而且,由于它本身的计算量小,能很好地用于实时处理。因此,采用 PCA 进行特征提取是降维处理的一种良好方案。

传统的 PCA 特征提取方法需要计算输入数据的协方差矩阵,并运用一个对角化步骤来提取特征值及对应的特征向量^[5]。对于大型数据集,协方差矩阵的维数会显著增大,从而使得计算量巨大,同时受截断和舍入误差的影响,计算结果也不会十分准确。本文的切片图像尺寸为 64×64 ,协方差矩阵的维数将达 4096×4096 ,直接对这样一个高维矩阵进行操作是不合适的。此外,在数据变换过程中,即使仅需要最显著特征值所对应的特征向量,也必须计算所有的特征值及对应的特征向量,因而存在极大的计算资源浪费。这几个缺陷使得传统 PCA 方法不能用于实时处理场合。为了有效地执行 PCA 特征提取,需要一种不利用协方差矩阵就能计算出最显著向量的方法,这可通过基于 Hebb 学习规则的自组织神经网络来实现。该算法顺序地更新线性神经元的权值,直到权值收敛到期望的特征向量,输出逼近输入数据的主分量为止。由于不需要直接计算协方差矩阵,因而该方案适于处理大块数据。下面简要介绍利用该方法提取 SAR 切片图像主分量的主要步骤,关于该方法的具体原理请参阅文献。

将训练集内每幅切片图像的像素顺序排列,形成一个 m 维列向量,记为 $x(n)$,其中, n 表示训练样本的序号。用于计算主分量的仅有单层计算结点的自组织前馈网络结构,如图 2 所示。该网络输出层的每个神经元是线性的;网络具有 m 个输入和 l 个输出,网络输出少于输入(即 $l < m$);网络接受训练的仅有突触权值集 $\{w_{ji}\}$,它们将输入层的源结点 i 和输出层的计算结点 j 连接起来,其中, $i = 1, 2, \dots, m, j = 1, 2, \dots, l$ 。训练步骤如下:

- (1) 在时刻 $n = 1$ 时,将网络突触权值 w_{ji} 初始化为一个小的随机数,学习率参数赋予一个小的正数。
- (2) 对于 $n = 1, j = 1, 2, \dots, l$ 和 $i = 1, 2, \dots, m$,计算

$$y_j(n) = \sum_{i=1}^m w_{ji}(n) x_i(n) \tag{1}$$

$$\Delta w_{ji}(n) = \eta \left[y_j(n) x_i(n) - y_j(n) \sum_{k=1}^j w_{ki}(n) y_k(n) \right] \quad (2)$$

其中, $x_i(n)$ 是 $m \times 1$ 维输入向量 $x(n)$ 的第 i 个分量, l 是期望的主分量个数。

(3) 将 n 增加 1 ($n = n + 1$), 转到第(2)步, 并继续执行直到 w_{ji} 达到稳态值。当 n 较大时, 神经元 j 的突触权值 w_{ji} 收敛于输入向量 $x(n)$ 的协方差矩阵中第 j 个特征值对应特征向量的第 i 个分量。

1.3 分类器

目前常用的分类器包括: 贝叶斯分类器^[6], 神经网络和支持向量机等。由于神经网络分类器仅依赖于训练数据本身的鉴别能力, 而与待分类数据的分布无关。因此, 与贝叶斯分类器相比, 神经网络分类器更加通用。同时, 支持向量机虽然具有良好的分类性能, 但其处理速度劣于神经网络分类器。本文选用的多层感知器神经网络(MLP NN)是一种非线性回归模型^[5], 它能用于非线性函数的学习。典型的 MLP NN 由一个输入层、一个输出层以及至少一个隐含层构成。本文使用一个四层 MLP NN, 包括一个输入层、两个隐含层及一个输出层, 如图 3 所示。输入层结点数目依赖于选用特征的个数, 初始值设置为 43 个, 该数值对应于通过 PCA 特征提取包含 98% 的




图 3 一个四层 MLP 神经网络
Fig. 3 A NN with four level MLP

的方差时所获得的特征数目。随着训练的迭代调整, 该值可能会发生变化。因为网络要对 T-72、BTR-70 和 BMP-2 三类地面军事车辆分类, 所以输出层需要 3 个结点。结点 1 分派给 T-72, 结点 2 分派给 BTR-70, 结点 3 分派给 BMP-2。隐含层的数目和各隐含层内的结点个数设置一般无理论支持, 需依据经验和实验决定, 本文给出的值并非最优。传输函数采用对数 S 形函数(Log-sigmoid), 之所以采用该函数, 是因为它的输出范围(0~1)正好适合在学习后输出布尔值。

网络以批量模式训练, 所有训练向量输入到神经网络, 用于计算为得到网络输出与期望输出间的最小均方误差、权值和偏置向量应当改变的方向。网络训练分为两个阶段。在第一阶段, 使用共轭梯度(CG)算法, 用大约 10 个周期训练网络。之后, 转入 Levenberg-Marquardt(LM)算法, 用大约 50 个周期训练网络。CG 算法的收敛速度较快, 但单独使用时, 不一定能将代价函数最小化到期望水平上; LM 算法在邻近极小值点处具有快速收敛性, 但单独使用时算法速度又太慢。联合使用二者, 则可使训练加快到实用水平(在 Pentium 4 CPU 1.8GHz, RAM 512MB 的计算机上使用 Matlab 实现, 训练 698 幅切片图像, 大约为 123s)。

2 实验分析

2.1 数据集

本文使用 MSTAR 公共数据集, 它是聚束模式下分辨率为 30cm 的 SAR 图像。本文用到的训练集分三类: T-72、BMP-2 和 BTR-70。所有训练图像均在 1° 俯视角和全方位覆盖情形下得到。用于训练的目标类别和样本数目如表 1 所示, 用于评估识别率的数据集(测试集 1)如表 2 所示。所有用于测试的车辆目标均属于已定义类别中的一种, 但具有不同的序列号, 而且所有的测试图像均在 15° 俯视角下得到。为生成 ROC 曲线, 也需要一些未用于训练的车辆作为虚警。

表 1 训练集

Tab. 1 The training data

目标类别和序列号	样本数目	备注
T- 72(132)	232	所有目标数据均在 17° 俯视角和全方位覆盖情形下采集, 具有 30cm 的分辨率
BTR- 70(c72)	233	
BMP- 2(9563)	233	
合计	698	

表 2 测试集 1——用于生成混淆矩阵的样本

Tab. 2 Testing data for creating confusion matrix

目标类别和序列号	样本数目	备注
T- 72(812)	195	所有目标数据均在 15° 俯视角和全方位覆盖情形下采集, 具有 30cm 的分辨率
T- 72(s7)	191	
T- 72(132)	196	
BTR- 70(c72)	196	
BMP- 2(9563)	195	
BMP- 2(9566)	196	
BMP- 2(c21)	196	
合计	1365	

2.2 结果分析

将 2.1 节中描述的测试集 1 和输入到训练好的 NN。为生成接收机工作特性(ROC) 曲线, 门限值从 0 到 1 以 0.05 的步长不断变化。在每次步长增加中, 计算出检测率(P_d , 即为正确分类率) 和虚警率(P_{fa} , 即为错误分类率), 再绘制出曲线图。该曲线图如图 4 所示。




图 4 MLP NN 分类器的 ROC 曲线

Fig. 4 The ROC curve of MLP NN




图 5 两种方法得到的目标分类 ROC 曲线

Fig. 5 The ROC of the two methods above mentioned

由图 4 可见, 对于相同的检测率 P_d , BMP- 2 的虚警率 P_{fa} 最高, 且 BTR- 70 的性能优于其他两类目标。这是因为, BTR 的测试集与训练集均来自同一种目标型号, 测试性能自然会更优一些; 而 BMP- 2 的配置变化较大, 因而产生了较大的虚警(错误)。从图 4 中可以看出, 通过在 ROC 曲线上找到最接近 (0, 1) 的点, 也就是左上角的点, 可得出一个最优的门限值, 从而获得分类器的最优性能。在本实验中, 该门限对 T- 72 为 0.05, BTR- 70 为 0.15, BMP- 2 为 0.10。使用这些门限, 对测试集 1 计算出正确的分类率, 如表 3 所示。星号表示同时出现在训练集和测试集的特定目标。如我们所料, 在这些目标上获得的正确分类率要高于同类其他目标获得的正确分类率。

2.3 与其他算法的比较

基于条件高斯模型的贝叶斯分类器(CGBC) 是 SAR ATR 中较为成功的方法之一。同时, 贝叶斯算法是一种理论上最优的分类算法, 在给定的训练数据充分大且数据集的真实概率密度函数已知的情形

下,可以获得最优结果。将对文中所提算法与 CGBC 算法进行比较。

表3 MLP 混淆矩阵(高 P_d , 低 P_{fa})

Tab. 3 The confusion matrix of MLP

	T- 72	BTR- 70	BMP- 2	拒绝	$P_{ccl.d}(\%)$
T- 72(812)	131	10	14	40	84.5
T- 72(S7)	117	13	28	33	74.1
T- 72(132) *	171	0	7	18	96.1
BTR- 70(C72) *	4	179	0	13	97.8
BMP- 2(9563) *	3	2	168	22	97.1
BMP- 2(9566)	27	10	129	30	77.7
BMP- 2(C21)	17	3	154	22	88.5
总 $P_{ccl.d}(\%)$			88.0		

在 CGBC 算法中,图像像素假定服从条件高斯分布,取决于目标类别和方位:

$$r = s(\Theta, a) + w \quad (3)$$

式中, r 为像素强度向量, w 为加性高斯噪声, s 为信号, 受目标方位角 Θ 和目标类别 a 的控制。给定 $\{\Theta, a\}$ 的情形下, r 的对数似然函数正比于下式:

$$- \sum_{i=1}^N \left[\log(\Sigma_i) + \left(\frac{r_i - M_i}{\Sigma_i} \right)^2 \right] \quad (4)$$

其中, r_i 是测试图像的第 i 个像素强度值, Σ_i, M_i 分别为像素的标准差和均值的第 i 个分量(由训练数据估计得到), N 为测试图像的像素个数。而目标分类则通过如下方法实现:

假定 $f_{i1}, f_{i2}, \dots, f_{in}$ 是从 n 幅属于 C_i 类($i = 1, 2, 3$, 分别表示 BMP- 2、BTR- 70 和 T- 72) 的训练图像中提取出的特征向量, 则均值特征向量和协方差矩阵由下式计算:

$$\mu_i = \frac{1}{n} \sum_{j=1}^n f_{ij}, \quad \Sigma_i = \frac{1}{n} \sum_{j=1}^n (f_{ij} - \mu_i)(f_{ij} - \mu_i)^T, \quad i = 1, 2, 3, 4, 5 \quad (5)$$

测试中, 对于从一幅测试图像中获取的特征向量, 计算出距离 $d_i = (f - \mu_i)^T \Sigma_i^{-1} (f - \mu_i)$, 测试图像中的目标指定为最小距离对应的类。这里, 假定每个类的先验概率相等。

两种方法的目标分类 ROC 曲线如图 5 所示。由图可见, 本文方法的识别性能稍优于 CGBC 方法。另外, 就计算效率而言, 本文方法所消耗的内存和时间均比 CGBC 方法要少几个数量级, 在 Pentium 4 CPU 1.8GHz, RAM 512MB 的计算机上使用 Matlab 编程, 测试文中训练数据集中每幅图像时, 本文方法占有 20.7KB 内存, 处理时间为 24.43ms, 而 CGBC 方法需要 1483.4KB 内存, 耗时 1345.38ms。因而, 文中的方法优于 CGBC 方法。

3 结论

本文采用 PCA 提取特征向量, 以一个四层 MLP NN 作为分类器, 实现了一个快速的 SAR 目标识别系统, 用于 MSTAR 数据库中的三类地面车辆目标分类。使用 ROC 曲线和混淆矩阵, 对识别性能进行评估, 并与 CGBC 分类器得到的结果进行比较。实验结果表明, 在维持较好识别性能的前提下, 该系统具有内存需求少、运行速度快的特点, 能用于实时处理。如何进一步提高系统的识别性能, 是下一步需要研究的课题。

参考文献:

- [1] Dudgeon D E, Lacoss R T. An Overview of Automatic Target Recognition[J]. The Lincoln Laboratory Journal, 1993, 6(1): 3- 10.
- [2] Ross T D, et al. SAR ATR: So What's the Problem? An MSTAR Perspective[C]//Proc. SPIE, 1999, 3721: 662- 672.
- [3] Kreithen D E, Halversen S D, Owirka G J. Discriminating Targets from Clutter[J]. The Lincoln Laboratory Journal, 1993, 6(1): 25- 51.
- [4] Blanu B, Dudgeon D E, Zelnio E G, et al. Introduction to the Special Issue on Automatic Target Detection and Recognition[J]. IEEE Transactions on Image Processing, 1997, 6(1): 1- 6.
- [5] 孙即祥, 等. 现代模式识别[M]. 长沙: 国防科技大学出版社, 2002.
- [6] DeVore M D, Ó Sullivan J A. Performance Complexity Study of Several Approaches to ATR from SAR Images[J]. IEEE Transactions on Aerospace and Electronic Systems, 2002, 38(2): 632- 648.