

一种融合多极化特征的雷达目标识别方法

张玉玺^{1,2} 王晓丹¹ 姚旭¹ 雷蕾¹

(空军工程大学导弹学院计算机工程系 三原 713800)¹ (93424 部队 北京 102101)²

摘要 针对高分辨率一维距离像(HRRP)多极化特征信息融合目标识别带来的数据量剧增问题,提出一种基于低维平移不变特征向量和多分类器动态组合的识别方法。该方法首先提取单极化 HRRP 序列的 3 种一维特征组成平移不变的特征向量,然后通过动态组合的方法生成总分类器组合进行分类,最后采用加权投票算法融合 4 种单极化 HRRP 的分类结果。实验结果显示,该方法在缩减数据规模的同时,有效利用极化信息,得到了较高的分类正确率。

关键词 高分辨率距离像,多极化,动态组合,融合

中图分类号 TP391 **文献标识码** A

Approach of Radar Target Recognition Based on Multiple Polarization Features Fusion

ZHANG Yu-xi^{1,2} WANG Xiao-dan¹ YAO Xu¹ LEI Lei¹

(Missile Institute Air Force Engineering University, Sanyuan 713800, China)¹

(Air Force 93424, Beijing 102101, China)²

Abstract Aiming at the problem of a dramatic increase in data of multi-polarized high resolution range profile (HRRP) target recognition, a recognition algorithm based on low-dimension time-shift invariant feature vectors and dynamic combination of multiple classifiers was proposed. In this algorithm, firstly three one-dimension features of single-polarized HRRP sequence are extracted to form the time-shift invariant feature vectors, and then a general classifier combination by dynamic ensemble of multiple classifiers is achieved, which is used to classify. Finally, the classification results of four single-polarized HRRPs are assembled by weighted voting method. The result of experiment indicates that the algorithm not only reduces the size of the data, but also uses polarization information effectively to acquire higher correct recognition rate.

Keywords High range resolution profile, Multiple polarizations, Dynamic ensemble, Fusion

1 引言

雷达目标一维高分辨距离像(High Range Resolution Profile, 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向量和的幅度波形,具有容易获取、实时性强、能够反映目标的精细结构和材料质地等特点^[1,2],提取 HRRP 的不同特征相互补充,从不同方面描述目标属性,通过融合生成特征向量,可以更全面地表征目标。极化信息反映了电磁波的矢量特性,是电磁波除时域、频域和空域信息以外的又一可以利用的重要信息,可获取目标表面粗糙度、对称性和取向等其它参数难以表征的信息,是完整刻画目标特性不可或缺的重要参数^[3]。因此 HRRP 多极化多特征信息融合,是提高雷达目标识别能力的有效途径。但是,由于 HRRP 的表征向量维数较高,多特征多极化信息融合也带来了数据量剧增和计算复杂度高的问题,导致正确识别目标的难度增大,这不符合雷达系统对目标实时处理的要求。

多极化或多特征信息融合的方法在多篇研究 HRRP 目标识别的文献中被应用。文献[4]提取 3 种一维数字特征,采

用最小距离准则设计分类器,分别对 4 类目标进行了识别,然后再根据 3 种特征的分类信息进行决策级融合。文献[5]提取 4 种一维数字特征,在特征级融合生成特征向量,然后分别用最近邻分类器和朴素贝叶斯分类器对 3 类目标进行分类。文献[4,5]都是提取 HRRP 序列一维数字特征,有效降低了样本维数,并得到了较好的识别效果,但是没有利用目标的极化信息。文献[6]在不同极化方式下提取 6 种平移不变特征,对 3 类目标进行分类,在决策级根据 D-S 理论融合不同特征、不同极化方式的分类信息,其分类性能较单极化单特征提高了 17 个百分点,但是文献[6]提取的平移不变特征维数远高于文献[4,5]。本文给出一种基于低维平移不变特征向量和多分类器动态组合的识别方法,有效降低了样本维数,并充分利用了目标的极化信息,实现了多极化多特征信息融合,提高了雷达目标的识别能力,较好地解决了数据量剧增和计算复杂度高的问题。

2 目标全极化 HRRP

在宽带多极化体制下,对目标进行一维距离成像,可以获

到稿日期:2011-11-23 返修日期:2012-02-17

张玉玺 博士生,工程师,主要研究方向为智能信息处理、机器学习, E-mail: zhyuxibj@163.com; 王晓丹 博士生,教授,主要研究方向为智能信息处理、机器学习; 姚旭 博士生,主要研究方向为智能信息处理、机器学习; 雷蕾 硕士生,主要研究方向为智能信息处理、机器学习。

得4种极化组合状态(HH, HV, VH, VV)的HRRP, H, V分别表示水平、垂直极化。假设 $P \in \{H, V\}$ 表示发射极化, $Q \in \{H, V\}$ 表示接收极化, 那么目标不同极化组合状态的HRRP为^[7]:

$$X_{PQ}(i) = \{x_{PQ}(i, j), j=1, 2, \dots, n\} \quad (1)$$

式中, n 是距离像的长度, i 表示目标的第 i 次一维距离成像。

图1是某目标4种极化方式下的一次极化HRRP。由图1可以看出, 不同极化组合状态的HRRP波形有较大的差别, 特别是同极化HRRP(HH, VV)与交叉极化HRRP(HV, VH)分量之间。虽然各种极化组合状态HRRP的主要散射点的位置分布基本一致, 但相同散射点在不同极化HRRP中的幅度仍然存在明显差异, 这说明将多极化HRRP融合起来可以改善雷达系统对目标的识别性能。




图1 4种极化组合状态的一次极化HRRP

单极化HRRP具有姿态敏感性(对飞机类目标主要考虑方位敏感性^[8])、平移敏感性和幅度敏感性。多极化HRRP同样具有这3种敏感性, 所以在使用之前也要进行相应的处理。本文在不发生散射点越距离单元徙动(MTRC)的角域 $\delta\varphi \leq \Delta R/L$ 内(ΔR 是距离分辨率的长度, L 是目标的横向尺寸)^[1, 8], 对HRRP进行强度归一化处理, 松弛了方位敏感性和幅度敏感性, 在此基础上, 提取在HRRP的3种平移不变特征组成特征向量, 解决了HRRP目标识别时的平移敏感性问题。

3 平移不变特征向量

特征提取是模式识别过程的关键步骤之一, 其方法的优劣极大地影响着分类器的设计和性能。宽带雷达的高分辨率使HRRP包含了目标丰富的结构信息, 但也带来HRRP的表征向量维数较高的问题, 常用的谱域特征、功率谱以及双谱特征等均具有良好的平移不变性, 但都没有压缩样本维数, 有的甚至加剧了维数的增长, 如双谱特征。如果采用高维特征进行多特征多极化信息融合, 势必会大大增加数据量和计算复杂度。因此, 选择提取融合HRRP序列的偏度、变异系数、能量聚集区长度3种平移不变一维数字特征组成特征向量。

3.1 特征提取

给出HRRP序列 $X_{PQ}(i)$ 的常用统计量均值 $\bar{x}_{PQ}(i)$ 和标准差 $\sigma_{PQ}(i)$ 定义如下:

$$\bar{x}_{PQ}(i) = \frac{1}{n} \sum_{j=1}^n x_{PQ}(i, j) \quad (2)$$

$$\sigma_{PQ}(i) = \sqrt{\frac{1}{n-1} \sum_{j=1}^n (x_{PQ}(i, j) - \bar{x}_{PQ}(i))^2} \quad (3)$$

1. HRRP序列的偏度

由统计学理论知道, 偏度是衡量样本形态偏斜程度的统计量^[9], 这里定义HRRP序列的偏度为:

$$SK_{PQ}(i) = \frac{n \sum_{j=1}^n (x_{PQ}(i, j) - \bar{x}_{PQ}(i))^3}{(n-1)(n-2)\sigma_{PQ}(i)^3} \quad (4)$$

当 $SK_{PQ}(i) < 0$ 时, 说明中位点大于均值, 样本形态呈左偏; 否则中位点小于均值, 样本形态呈右偏。 $SK_{PQ}(i)$ 绝对值大小说明了偏斜的程度。

2. HRRP序列的变异系数

标准差和变异系数都是衡量样本变异程度的统计量, 标准差反映样本相对于均值的绝对平均离散趋势, 而变异系数则反映样本相对于均值的相对平均离散趋势, 更能真正地反映出不同水平样本的离散程度, 便于对多个变量进行比较^[9]。定义HRRP序列的变异系数为:

$$CV_{PQ}(i) = \frac{\sigma_{PQ}(i)}{\bar{x}_{PQ}(i)} \quad (5)$$

3. HRRP序列的能量聚集区长度^[4]

能量聚集区长度能反映目标的径向长度, 故可将其作为目标的一个特征进行提取。HRRP序列能量聚集区长度的具体提取方法如下:

(1) 求取HRRP序列 $X_{PQ}(i)$ 的均值 $\bar{x}_{PQ}(i)$ 。

(2) 设置一阈值 Th , 使得

$$Th = \eta * \bar{x}_{PQ}(i) \quad (6)$$

式中, η 为置信系数, 可在0.8~2之间取值, 它取决于HRRP的信噪比, 当信噪比较大时, η 取较小值, 反之 η 则取较大值。

(3) 对 $X_{PQ}(i)$ 各点的值从两端向中间搜索, 当左右两端分别出现第一个大于阈值的点时, 就停止搜索, 并记下它们的位置, 分别为 $m_{PQ}(i)$ 、 $n_{PQ}(i)$, 则能量聚集区长度为

$$L_{PQ}(i) = n_{PQ}(i) - m_{PQ}(i) \quad (7)$$

3.2 特征融合

特征级融合精度介于数据级融合和决策级融合之间, 但可以实现可观的数据压缩, 降低对系统的要求, 有利于实时处理。上述3种平移不变特征都是一维统计量, 有效地缩减了数据规模, 而且分别从样本序列的变异程度、能量聚集区长度及样本序列形态的偏离程度3个方面反映了样本和目标的属性, 互为补充, 将其融合生成特征向量, 可比单一特征更全面地表征目标信息, 有益于提升雷达目标识别性能。本文对4种极化方式分别进行特征融合, 生成特征向量 $(SK, CV, L)_{PQ}$, 其中 PQ 分别代表HH, HV, VH, VV4种极化方式。

4 一种融合多极化特征的目标识别方法

多分类器融合的方法在目标识别领域被广泛研究和应用, 关于多分类器系统研究的大量理论和实验结果表明, 通过多分类器融合不但可以提高分类的正确率, 而且能够提高模式识别系统的效率和鲁棒性^[10, 11]。本文在提取平移不变特征向量 $(SK_{PQ}, CV_{PQ}, L_{PQ})$ 的基础上, 基于多分类器动态组合提出一种融合多极化特征的目标识别方法。该方法首先对原始数据集进行特征提取, 然后采用多分类器动态组合方法求取总分类器组合并对目标分类, 最后在决策级融合单极化HRRP的分类信息, 得到总体识别正确率。图2给出融合多极化特征的目标识别方法的结构图, 虚线框内的4个分类器是由多分类器动态组合结果给出的分类器组合。

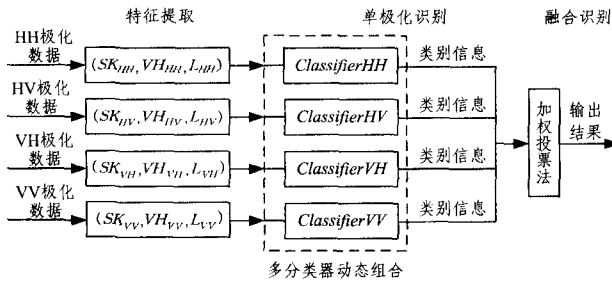


图2 融合多极化特征的目标识别方法结构图

表1给出了融合多极化特征的目标识别方法的具体过程。

表1 融合多极化特征的目标识别方法

输入:	确定分类器组合的k种基分类器类型(Classifier ₁ , ..., Classifier _k), 本文选择不同核函数的4种支持向量机, k=4; 确定融合策略: 加权投票融合算法; 设置计算能量聚集区长度的置信系数; 全极化 HRRP 数据集。
Step1	对全极化 HRRP 数据集分别提取不同极化方式平移不变特征, 组成4种极化方式的平移不变特征向量, 得到新的样本空间。
Step2	把新样本空间划分为训练集 Train_set、验证集 Vali_set 和测试集 Test_set。
Step3	分别用 Train_set 的每种极化方式的数据集训练不同类型基分类器, 得到四个分类器组合(Classifier _{1PQ} , ..., Classifier _{kPQ}), 其中 PQ 分别代表 HH, HV, VH, VV 4种极化方式。
Step4	用每种极化方式分类器组合中的基分类器分别对 Vali_set 相应极化方式数据集分类, 统计分类正确率为(CorrectRate _{1PQ} , ..., CorrectRate _{kPQ})。
Step5	选择 Vali_set 每种极化方式分类正确率最高的基分类器为 Test_set 对应极化方式的基分类器, 组成用于 Test_set 分类的总分分类器组合(Classifier _{iHH} , Classifier _{jHV} , Classifier _{mVH} , Classifier _{nVV}), i, j, m, n=1, ..., k。对应的 Vali_set 4种极化方式最佳分类正确率组合为 CR=(CorrectRate _{iHH} , CorrectRate _{jHV} , CorrectRate _{mVH} , CorrectRate _{nVV})。
Step6	对 CR 归一化处理, 作为加权投票融合算法的权系数。
Step7	用 Step5 中选择的总分分类器组合对 Test_set 进行分类。
Step8	融合不同极化方式的分类信息。
输出:	总体识别正确率。

5 实验

本节将采用两种飞机目标的实测数据验证上述方法的有效性。

5.1 实验数据

实验数据为两种典型飞机缩比模型的宽带极化散射矩阵扫频测量数据, 每组数据包含 181 个角度下的极化散射矩阵扫频测量数据; 每个角度的扫频数据均有 201 个频率采样点, 每个采样点由幅度/相位数据组成。频率范围: 12.5~17.5GHz (采样间隔 25MHz); 极化方式: HH、HV、VH、VV; 方位角范围: 0~180°(采样间隔 1°); 俯仰角: 0°; 横滚角: 0°。数据经过反傅立叶变换得到各目标 0~180°角范围内、角度间隔为 1°的 201 维 HRRP 数据。

实验取各目标 0~10°、20~30°、50~60°、80~90°、110~120°、140~150°和 160~170°角范围内的数据。由于原始数据较少, 数据对应的姿态角间隔较大, 因此采用线性数据插值方法补充在不同角度附近的测量数据, 插值数取值为 9, 方位角间隔为 0.1°, 每个样本集规模为 202。

5.2 实验设计

1. 实验数据处理

通过逆 Fourier 变换, 把频域全极化 HRRP 数据 $S(f_n)$

变换到时域全极化 HRRP 数据 $S(n)$; 根据十重交叉验证的抽样方法, 确定 80% 的样本为训练集 Train_set, 10% 的样本为验证集 Vali_set, 10% 的样本为测试集 Test_set; 最后对 3 个数据集进行极差归一化处理。

在估计分类正确率时采用十重交叉验证进行, 并利用双边估计 t 检验法来计算置信水平为 0.95 的分类正确率置信, 且将其区间作为最终结果, 计算公式如下:

$$\frac{|\bar{x} - u|}{\sigma/\sqrt{n}} \geq t_{0.025}(n-1) \quad (8)$$

式中, u, σ 分别表示十重交叉验证的均值和标准差, $t_{0.025}(9) = 2.2622$ 。

2. 初始化设置

(1) 置信系数

考虑使用的是两种典型飞机缩比模型的扫频测量数据, 信噪比较大, 设定计算能量聚集区长度的置信系数为: $Th=1$ 。

(2) 基分类器

采用核函数分别为线性核函数(linear)、二次核函数(quadratic)、多项式核函数(polynomial)和高斯径向基核函数(rbf)的4种支持向量机(Support Vector Machine, SVM)为基分类器, 参数设置为缺省值。

(3) 融合策略

分类器的融合策略采用加权投票融合算法, 每个分类器的权系数是由验证集 Vali_set 不同极化方式的最佳分类正确率组合 $CR = (CorrectRate_{iHH}, CorrectRate_{jHV}, CorrectRate_{mVH}, CorrectRate_{nVV})$ 归一化处理所得, 权系数向量为 $\alpha = (\alpha_{HH}, \alpha_{HV}, \alpha_{VH}, \alpha_{VV})$, 其中

$$\alpha_{HH} = CR(1) / \sum_{i=1}^4 CR(i), \alpha_{HV} = CR(2) / \sum_{i=1}^4 CR(i)$$

$$\alpha_{VH} = CR(3) / \sum_{i=1}^4 CR(i), \alpha_{VV} = CR(4) / \sum_{i=1}^4 CR(i)$$

3. 实验环境

实验中所用分类器均来自 Bioinformatics Tools 工具箱, 实验机器配置为 1G 内存, 2.30G CPU, 算法基于 Matlab7.7 (R2008b) 实现。

5.3 实验结果与分析

1. 计算单极化多特征向量与多极化多特征向量融合的识别正确率, 验证平移不变特征向量的有效性和多极化融合提高目标识别能力的可行性; 比较同一种基分类器的多分类器组合与多分类器动态组合的识别效果, 验证多分类器动态组合能够改善系统的目标识别性能。表2记录了4种基分类器组合和多分类器动态组合在每个极化方式多特征融合和多极化多特征融合的分类正确率。

表2 同一基分类器组合和多分类器动态组合的分类正确率(%)

	HH	HV	VH	VV	多极化融合
SVM (linear)	90.90 ±1.04	83.55 ±3.43	83.08 ±1.01	91.53 ±1.15	94.86 ±1.01
SVM (quadratic)	91.19 ±1.41	83.62 ±3.18	84.80 ±1.07	91.92 ±1.35	94.96 ±4.52
SVM (polynomial)	92.66 ±1.05	93.47 ±2.97	87.95 ±2.36	90.20 ±2.03	97.91 ±0.89
SVM (rbf)	91.39 ±1.61	86.35 ±4.67	84.80 ±1.07	90.10 ±2.02	95.25 ±1.15
多分类器动态组合	94.99 ±0.30	96.06 ±1.13	92.59 ±0.63	93.99 ±1.29	99.37 ±0.55

(下转第 234 页)

[13] Tenenbaum J, Silva V, Langford J. A Global Geometric Framework for Nonlinear Dimensionality Reduction[J]. Science, 2000, 290(5500):2319-2323

[14] Weinberger K, Saul L. Unsupervised Learning of Image Manifolds by Semidefinite Programming[J]. International Journal of Computer Vision, 2006, 70(1):77-90

[15] Roweis S, Saul L. Nonlinear Dimensionality Reduction by Locally Linear Embedding[J]. Science, 2000, 290(5500):2323-2326

[16] Renyi A. On Measures of Entropy and Information[J]. Selected Papers of Alfred Renyi, 1976, 2:565-580

[17] Parzen E. On the Estimation of a Probability Density Function and the Mode[J]. The Annals of Math. Statistics, 1962, 32: 1065-1076

[18] Deng Zhao-hong, Chung Fu-lai, Wang Shi-tong. FRSD: Fast reduced set density estimator using minimal enclosing ball approximation[J]. Pattern Recognition, 2008, 41: 1363-1372

[19] Kollios G, Gunopulos D. Efficient biased sampling for approximate clustering and outlier detection in large datasets[J]. IEEE Trans. Knowledge and Date Engineering, 2003, 15(5): 1170-1187

(上接第 210 页)

由表 2 数据可以看出,每个极化方式的识别正确率都在 80%以上,说明提取的特征向量可从不同方面表征目标属性,保留较多的目标信息,有利于解决文中研究的分类问题。通过多极化融合的分类结果可知,在单极化特征向量表征目标属性的基础上,多极化融合又加入了目标的极化属性,更全面地保留了目标信息,所以目标识别正确率比单极化目标识别提高了 4%~11%。多分类器动态组合在每个极化方式的识别结果都等于或优于其它同一基分类器组合,对 4 个极化方式分类结果进行融合后,目标识别正确率提高了 2%~5%,验证了文中给出的多分类器动态组合方法的有效性。

2. 对不同方位角范围的多极化数据集进行分类,验证所提取特征向量和本文给出的 HRRP 目标识别方法对不同姿态角目标的分类性能。选择不同方位数据集进行分类,分类结果统计于表 3。

表 3 不同方位数据集的分类正确率(%)

	HH	HV	VH	VV	多极化融合
0~10°	95.32 ±1.25	99.17 ±0.56	93.95 ±1.65	98.68 ±0.39	99.81 ±0.08
20~30°	95.68 ±0.86	98.98 ±0.69	94.85 ±1.38	98.47 ±0.64	99.84 ±0.09
50~60°	97.91 ±2.26	100.00	99.21 ±0.13	100.00	100.00
80~90°	98.92 ±0.67	98.84 ±0.58	99.47 ±0.13	99.02 ±0.32	99.97 ±0.05
110~120°	96.32 ±0.50	100.00	100.00	98.55 ±0.60	100.00
140~150°	93.65 ±0.78	97.76 ±0.51	96.85 ±1.17	97.87 ±0.62	99.35 ±0.23
160~170°	94.32 ±1.25	99.37 ±0.31	94.96 ±1.28	97.35 ±0.54	99.72 ±0.11

由表 3 中的数据可知,不同方位角的分类正确率变化较小,分类效果稳定,验证了 $(SK_{PQ}, CV_{PQ}, L_{PQ})$ 特征向量和本文给出的 HRRP 目标识别方法良好的分类性能。

表 4 不同特征向量的分类正确率(%)

	HH	HV	VH	VV	多极化融合
文献[4]提取特征向量	69.93 ±2.91	84.23 ±3.06	72.64 ±5.27	69.80 ±3.10	88.82 ±3.15
文献[5]提取特征向量	75.29 ±1.92	91.18 ±2.85	91.38 ±1.78	75.12 ±1.83	94.61 ±3.54
本文提取特征向量	93.03 ±0.62	94.50 ±2.38	88.04 ±2.32	90.37 ±2.20	99.07 ±0.69

3. 用文献[4]提出的目标强散射中心维数、能量聚集区长度、目标散射中心分布熵 3 种平移不变特征以及文献[5]提出的能量聚集区长度、强散射中心数目、HRRP 序列方差和一

维像的“信源熵”4 种平移不变特征分别组成的特征向量进行分类,并与本文给出的特征向量的分类结果进行比较。表 4 记录了不同特征向量的分类结果,可以看出,本文提取的 $(SK_{PQ}, CV_{PQ}, L_{PQ})$ 特征向量分类正确率较高。

结束语 多极化多特征融合是提高雷达系统目标识别能力的有效途径,本文给出的基于低维平移不变特征向量和多分类器动态组合的多特征多极化融合方法,有效地降低了样本维数和计算复杂度,并通过实验验证了该方法的有效性和可行性。但是由于其提取的平移不变特征是一维的数字特征,只能表征部分目标属性,虽然多特征多极化融合能在一定程度上弥补目标信息的损失,但仍然会造成部分目标信息丢失,不利于对目标的正确识别。因此,提取更有效的目标极化特征向量,提出更合理的多极化多特征融合方法是下一步研究的方向。

参 考 文 献

[1] 吴顺君,梅晓春. 雷达信号处理和数据处理技术[M]. 北京:电子工业出版社,2008

[2] Jacobs S P. Automatic target recognition using high-resolution radar range profiles[D]. Dissertation, Washington University, 1999

[3] 代大海. 极化雷达成像及目标特征提取研究[D]. 长沙:国防科学技术大学,2008

[4] 许人灿,姜卫东,陈曾平. 目标一维距离像特征提取方法研究[J]. 系统工程与电子技术,2005,27(7):1173-1174,1191

[5] 徐庆,王秀春,李青. 基于高分辨一维像的目标特征提取方法[J]. 现代雷达,2009,31(6):60-63

[6] 曹向海,刘宏伟,吴顺君. 多极化多特征融合的雷达目标识别研究[J]. 系统工程与电子技术,2008,30(2):261-264

[7] 李丽亚,刘宏伟,纠博,等. 基于核函数的多极化 HRRP 识别[J]. 西安电子科技大学学报:自然科学版,2010,37(1):49-55

[8] 杜兰. 雷达高分辨率距离像目标识别方法研究[D]. 西安:西安电子科技大学,2007

[9] 胡可云,田凤占,黄宽厚. 数据挖掘理论与应用[M]. 北京:清华大学出版社,北京交通大学出版社,2008

[10] 陈冰,张化祥. 集成学习的多分类器动态组合方法[J]. 计算机工程,2008,34(24):218-220

[11] Sun J, Li H. Listed companies' financial distress prediction based on weighted majority voting combination of multiple classifiers[J]. Expert Systems with Applications, 2008, 35(3): 818-827

[12] 边肇祺,张学工,等. 模式识别(第二版)[M]. 北京:清华大学出版社,2000