

应用最优小波包变换的特征提取方法

王首勇¹, 朱光喜¹, 唐远炎²

(1. 华中科技大学电子与信息工程系, 湖北武汉 430074; 2. 香港浸会大学计算机科学系, 香港)

摘 要: 在模式识别或分类中, 从原始模式中提取有效的分类特征是非常重要的. 但对于大量的非平稳或时变信号模式来说, 如语音、雷达、地震信号等, 用于分类的特征往往包含在局部的时-频信息中, 用一般的变换方法提取有效的特征比较困难. 近年来小波变换在信号处理和特征提取中得到了广泛应用, 但小波包变换的任意多尺度分解特性, 是分析非平稳信号更有效的方法, 这是由于小波库中包含了丰富的小波包基, 不同的小波包基具有不同的性质, 反映不同的信号特性, 能获取其他变换所不能获取的信号特征. 本文主要研究由给定的训练样本集, 如何选择最优小波包基, 从被识别或分类的信号中提取具有最大可分性的特征. 为此提出了应用三种可分性准则, 即距离准则、散度准则和熵准则选择最优基. 通过实验, 对应用各准则选择最优基提取特征与小波基提取特征的性能进行了比较.

关键词: 小波包; 特征提取; 小波变换; 模式识别; 分类

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2003) 07-1035-04

Feature Extraction Using Best Wavelet Packet Transform

WANG Shou-yong¹, ZHU Guang-xi¹, TANG Yuan-yan²

(1. Dept. of Electronic & Information Engineering, Huazhong Univ. of Sci. & Tech., Wuhan, Hubei 430074, China;

2. Dept. of Computer Science, Hong Kong Baptist University, Hong Kong, China)

Abstract: In pattern recognition or classification, extracting effective classification features from original pattern signals is very important. But, for a great number of non-stationary or time-varying signals, such as speech, radar, earthquake signals, etc., classification features are often localized both in time and frequency, so thus extracting effective features from them by general transformation methods is very difficult. Wavelet packet transform can provide an arbitrary time-frequency decomposition for the signals, because a wavelet packet library contains many wavelet packet bases, which can handle the different components of a signal. Therefore, by selecting a suitable basis, the effective features can be extracted. This paper is mainly concerned with extracting effective features from the recognized or classified signals by selecting wavelet packet basis via given training sample sets. Three separability criteria, i.e., distance criterion, divergence criterion and entropy criterion, are used for selecting the best basis. The performance of features extraction by wavelet packet transform is compared with that by wavelet transform through experiments.

Key words: wavelet packet; feature extraction; wavelet transform; pattern recognition; classification

1 引言

特征提取是模式识别或分类中的核心问题, 它直接影响到分类器的设计和性能. 如果不同类别的特征差别较大, 就比较容易设计出较好性能的分类器. 所以对识别或分类来说关键不在于完整地描述模式, 而是提取模式中有效的分类特征. 所谓有效分类特征就是不同模式类差别较大的特征. 但这些特征在原始特征域通常不易被观察或检测. 特征提取就是通过变换(通常是线性变换)的方法, 使这些重要的特征在变换域显示出来, 去掉对分类无意义的信息, 这样把原始的高维空间变为低维的特征空间. 一般被识别或分类的模式都是非平稳或时变信号模式, 如语音、雷达、地震信号等. 在这些信号

中, 通常都包含长时低频和短时高频不同尺度的信号. 用于分类的特征往往包含在局部的时-频信息中, 用一般的变换方法很难提取这些信号的重要特征. 傅里叶变换(DFT)是一种纯频率变换, 具有最优的频率分辨率, 而最差的时间分辨率, 不能提供任何局部时间段上的频率信息, 所以用于提取时变信号的特征通常效果不佳. 短时傅里叶变换(STFT)具有时-频分析能力, 但时-频单元(窗)是固定的, 海森堡测不准原理说明时-频窗的面积不小于 $1/4$, 这样很难找到一个“好的”窗适用于提取包含不同尺度信号的特征. 近年来小波变换(WT)在信号处理和特征提取中得到了广泛应用, WT是一种多尺度分解的时-频局域变换, 可分析包含不同尺度的信号, 但用于特征提取, 固定的时-频分解形式并不是最优的. 如在某些情况

收稿日期: 2001-11-28; 修回日期: 2003-03-02

下高频端频率分辨率低就是一个缺点. 而小波包变换 (WPT) 对信号具有任意的多尺度分解形式, 小波包库包含了丰富的小波包基 (其中包含了小波基和类似于 STFT 的子带基), 不同的小波包基具有不同的性质, 反映不同的信号特性, 能提供其他变换所不能提供的信号的重要特征. 因此根据类别可分性准则, 选择一个最优的小波包基, 提取有效的分类特征是可能的. 由 R. R. Coifman and M. V. Wickerhauser 根据熵准则提出的最优基选择方法主要用于信号压缩^[1], 在应用最优基特征提取方面, 文[2,3]根据文[1]的准则选择最优基提取特征, 文[4,5]提出了基于训练样本集的 Local Discriminate Bases (LDB) 准则选择最优基, 文[6]应用类似于不同的子带基提取特征. 在本文提出了应用距离准则、散度准则和熵准则选择小波包基. 由给定的训练样本集对信号进行小波包分解后, 按上述准则选择小波包基, 将该小波包基变换对应的具有最大可分性的部分小波包系数作为特征矢量.

小波包由 Coifman, Meyer, Quaker, Wickerhauser (CMQW) 提出. 为后面分析的需要, 这里简单介绍小波包基的概念. 如果 $\{h_g\}_k$ 和 $\{g_k\}_k$ 是一组共轭镜像滤波器 (QMF) 即

$$h_{n-2k}h_{n-2l} = \delta_{kl}, \quad h_n = \sqrt{2} \quad (1)$$

$$g_k = (-1)^k h_{1-k} \quad (2)$$

则可定义一系列函数 $\{u_n(t)\}$ ($n=0, 1, 2, \dots$) 满足如下方程

$$\begin{aligned} u_{2n}(t) &= \sqrt{2} \sum_k h_k u_n(2t-k) \\ u_{2n+1}(t) &= \sqrt{2} \sum_k g_k u_n(2t-k) \end{aligned} \quad (3)$$

当 $n=0$ 时, $u_0(t)$ 即为尺度函数 $\phi(t)$, $u_1(t)$ 即为小波函数 $\psi(t)$. 每一形如 $2^{-j/2} u_n(2^{-j}t-k)$, $j, k \in \mathbb{Z}$, $n \in \mathbb{Z}_+$ 的函数称作一个小波包函数, 其集合 $\{2^{-j/2} u_n(2^{-j}t-k), j, k \in \mathbb{Z}, n \in \mathbb{Z}_+\}$ 称为一个小波包库. 其中 j 是尺度参数, k 是平移参数, 而 n 是频率参数. 从小波包库中选择能构成 $L^2(\mathbb{R})$ 空间的一个基函数系称为 $L^2(\mathbb{R})$ 的一个小波包基. 对任一固定的 j 值, $\{2^{-j/2} u_n(2^{-j}t-k), k \in \mathbb{Z}, n \in \mathbb{Z}_+\}$ 均可构成 $L^2(\mathbb{R})$ 的一个正交基, 这个正交基与短时 Fourier 基类似, 称为子带基. 当 n 固定时, 例如 $n=1$ 时, $u_1(t) = \psi(t)$, $\{2^{-j/2} u_1(2^{-j}t-k), k, j \in \mathbb{Z}\}$ 即为 $L^2(\mathbb{R})$ 的标准正交小波基. 而 $n=0$, 则构成 $L^2(\mathbb{R})$ 的一个框架. 本文主要研究根据类别可分性准则, 从小波包库中选择一个对分类最优的小波包基, 从与该小波包基对应的小波包系数中, 选择一组具有最大可分性的系数作为模式的特征矢量.

2 基于距离准则的小波包基选择

2.1 距离准则

在特征空间中, 一个模式特征矢量视为该空间中的一个点, 模式中的样本集是该空间的一个点集, 通常样本平均类间距离越大, 平均类内距离越小, 类别的可分性越好. 因此样本之间的距离是研究样本分布和度量类别可分性最直观的准则. 设 c 个模式类 $\omega_1, \omega_2, \dots, \omega_c$ 的联合特征矢量集为 $\{x^{(i,k)}, i=1, 2, \dots, c, k=1, 2, \dots, N_i\}$, 其中 $x^{(i,k)} = (x_1^{(i,k)}, x_2^{(i,k)}, \dots, x_m^{(i,k)})^T$ 为 ω_i 中第 k 个 m 维特征矢量, N_i 为 ω_i 类中的特征矢量数目. 我们首先计算 ω_i 类中所有特征矢量间的平均距离 S_i , 则定义为

$$S_i = \frac{1}{2} \frac{1}{N_i} \sum_{j=1}^{N_i} \frac{1}{N_i-1} \sum_{k=1}^{N_i} \|x^{(i,j)} - x^{(i,k)}\|^2 \quad (4)$$

对 $S_i, i=1, 2, \dots, c$ 求平均后得到平均类内距离为

$$S_w = \frac{1}{c} \sum_{i=1}^c S_i \quad (5)$$

式(4)展开后, 经推导得到平均类内距离为^[7]

$$S_w = \frac{1}{c} \sum_{i=1}^c \frac{1}{m} \sum_{l=1}^m \frac{1}{N_i-1} \sum_{k=1}^{N_i} (x_l^{(i,k)} - \mu_l^{(i)})^2 \quad (6)$$

式中

$$\mu_l^{(i)} = \frac{1}{N_i} \sum_{k=1}^{N_i} x_l^{(i,k)}$$

$\mu_l^{(i)}$ 为 ω_i 类样本特征矢量第 l 个分量的均值. 此外, 通常可用类别的均值矢量代表该类别, 设 ω_i 类的样本均值矢量为 $\mu^{(i)}$, 样本总体均值矢量为 μ , 对 c 个类别平均类间距离定义为

$$S_b = \frac{1}{c} \sum_{i=1}^c \|\mu^{(i)} - \mu\|^2 = \frac{1}{c} \sum_{i=1}^c \frac{1}{m} \sum_{l=1}^m (\mu_l^{(i)} - \mu_l)^2 \quad (7)$$

式中

$$\mu_l = \frac{1}{c} \sum_{i=1}^c \frac{1}{N_i} \sum_{k=1}^{N_i} x_l^{(i,k)}$$

μ_l 为样本总体均值矢量第 l 个分量. 小的平均类内距离和大的平均类间距离才具有好的可分性, 因此距离准则定义为平均类间距离与平均类内距离之比, 即

$$J_A = \frac{S_b}{S_w} = \frac{\frac{1}{c} \sum_{i=1}^c \frac{1}{m} \sum_{l=1}^m (\mu_l^{(i)} - \mu_l)^2}{\frac{1}{c} \sum_{i=1}^c \frac{1}{m} \sum_{l=1}^m \frac{1}{N_i-1} \sum_{k=1}^{N_i} (x_l^{(i,k)} - \mu_l^{(i)})^2} \quad (8)$$

对于 1 维特征 ($m=1$), 则 $J_A = J_{A1}$

$$J_{A1} = \frac{\frac{1}{c} \sum_{i=1}^c (\mu_l^{(i)} - \mu_l)^2}{\frac{1}{c} \sum_{i=1}^c \frac{1}{N_i-1} \sum_{k=1}^{N_i} (x_l^{(i,k)} - \mu_l^{(i)})^2} \quad (9)$$

式(9)恰好为单个特征(分量)的类间均值的方差与类内方差的均值之比, 当类别数目 $c=2$ 时, 简化为 Fisher 可分性判据.

2.2 小波包基选择及特征提取

假定训练样本的小波包系数间是互不相关的 (小波变换具有较好的去相关性), 我们以式(9) J_{A1} 为准则选择小波包基. 具体算法为:

(1) 设 c 个模式类 $\omega_1, \omega_2, \dots, \omega_c$ 的训练样本集为 $\{x^{(i,k)}, i=1, 2, \dots, c, k=1, 2, \dots, N_i\}$, $x^{(i,k)} = (x_1^{(i,k)}, x_2^{(i,k)}, \dots, x_m^{(i,k)})^T$ 为 ω_i 中第 k 个 m 维样本矢量, N_i 为 ω_i 类的样本数. 对 $x^{(i,k)}$ 进行小波分解, 分解级数 $j=1, 2, \dots, L$. 第 j 级中第 n 个小波包空间为 U_j^n ($j=1, 2, \dots, L, n=0, 1, 2, \dots, 2^{j-1}$), U_j^n 中的小波包系数为 $\{x_p^{(i,k)}, p=1, 2, \dots, P_j\}$.

(2) 按式(9)计算 U_j^n 中第 p 个小波包系数 $x_p^{(i,k)}$ 对应的

J_{Ap} 、 J_{Ap} 越大,对应的该特征分量可分性越好. 如果 U_j^n 中所有 J_{Ap} ($p=1, 2, \dots, P_j$) 的平均值越大,则该子空间对分类越有利. U_j^n 中所有 J_{Ap} ($p=1, 2, \dots, P_j$) 的平均值为

$$J(j, n) = \frac{1}{P_j} \sum_{p=1}^{P_j} J_{Ap}$$

对每个子空间 U_j^n ,按上述方法可得到一个对应的 $J(j, n)$.

(3) 在小波包库中找出使 $J(j, n)$ 为最大值的小波包基,即最优基. 该小波包基中所有 m 个小波包系数对应的 J_{Al} 值为 $J_{A1}, J_{A2}, \dots, J_{Am}$. 对 $J_{A1}, J_{A2}, \dots, J_{Am}$ 排序后为 $J_{A1}^* \quad J_{A2}^* \quad \dots \quad J_{Am}^*$.

(4) 对待分类或识别的模式按所选择的最优基进行 WPT, 并选择与 $J_{A1}^* \sim J_{Ad}^*$ ($d < m$) 对应的一组 WP 系数作为特征矢量.

3 基于散度准则的小波包基选择

3.1 散度准则

通常根据分类错误概率寻找特征提取的准则或方法存在一定的困难. 而散度用来度量两类模式概率分布之间的一致性, 提供了模式类间可分性信息. 在模式为正态分布的情况下, 贝叶斯分类错误概率与散度有明确的关系表达式, 分类错误概率是散度的单调下降函数. 为此我们根据散度的大小选择小波包基提取特征. 两类模式 i 和 j 的概率分布之间的散度 J_{ij} 定义为^[7]

$$J_{ij} = - \int p(x|i) - p(x|j) \ln \frac{p(x|i)}{p(x|j)} dx \quad (10)$$

当 i 和 j 两类模式的概率分布为 m 维正态分布 $N(\mu_i, C_i)$ 和 $N(\mu_j, C_j)$ 时, 则

$$J_{ij} = \frac{1}{2} \text{tr}[(C_i^{-1} + C_j^{-1})(\mu_i - \mu_j)(\mu_i - \mu_j)^t + (C_i^{-1} - C_j^{-1})(C_i - C_j)] \quad (11)$$

如果模式特征矢量 $x = (x_1, x_2, \dots, x_m)^t$ 的各分量互不相关, 则 J_{ij} 为

$$J_{ij} = \frac{1}{2} \sum_{l=1}^m \left[\frac{(\mu_{il} - \mu_{jl})^2}{\sigma_{il}^2} + \frac{(\mu_{il} - \mu_{jl})^2}{\sigma_{jl}^2} + \frac{\sigma_{il}^2 - \sigma_{jl}^2}{\sigma_{il}^2 \sigma_{jl}^2} \right] \quad (12)$$

式中

$$\mu_{il} = E_i[x_l] \\ \sigma_{il}^2 = E_i[(x_l - \mu_{il})^2]$$

使 J_{ij} 最大的特征子集作为模式特征对分离 i 和 j 更有利. 对于多类模式 $1, 2, \dots, c$, 则定义散度为

$$J = \sum_{i=1}^c \sum_{j=i+1}^c J_{ij} \quad (13)$$

对于式(13), J 是由各 J_{ij} 相加而得, 如果其中有一个类别对的 J_{ij} 很大, 就使散度 J 显著偏离, 因而掩盖了对散度小的那些类别对的判别, 因此采用变换散度 J_{ij}^T 可以改善这一情况, J_{ij}^T 定义为

$$J_{ij}^T = 1 - \exp(-J_{ij}/J) \quad (14)$$

式中 J 为可调参数. 用于多类模式, 变换散度为

$$J_D = \sum_{i=1}^c \sum_{j=i+1}^c J_{ij}^T \quad (15)$$

J_D 比散度 J 有更可靠的多类可分性判别能力.

3.2 小波包基选择及特征提取

选择小波包基及提取特征矢量具体算法为:

(1) 同 2.2 节(1).

(2) 对于 i, j 类的 (i, k) 和 (j, k) , U_j^n 中的小波包系数分别为 $\{x_p^{(i, k)}, p=1, 2, \dots, P_j\}$ 和 $\{x_p^{(j, k)}, p=1, 2, \dots, P_j\}$, 根据式(12), 计算第 p 个小波包系数对应的 $J_{ij(p)}$. 对多类模式变换散度

$$J_{Dp} = \sum_{i=1}^c \sum_{j=i+1}^c J_{ij(p)}^T$$

计算各子空间 U_j^n 中小波包系数对应的 J_{Dp} 的平均值 $J(j, n)$

$$J(j, n) = \frac{1}{P_j} \sum_{p=1}^{P_j} J_{Dp}$$

(3) 在小波包库中找出使 $J(j, n)$ 为最大值的小波包基, 该小波包基中所有 m 个小波包系数对应的 J_{Dl} 值为 $J_{D1}, J_{D2}, \dots, J_{Dm}$. 对 $J_{D1}, J_{D2}, \dots, J_{Dm}$ 排序后为 $J_{D1}^* \quad J_{D2}^* \quad \dots \quad J_{Dm}^*$.

(4) 对待识别或待分类的模式, 按所选择的最优基进行 WPT, 并选择 $J_{D1}^* \sim J_{Dd}^*$ ($d < m$) 对应的一组 WP 系数作为特征矢量.

4 基于熵准则的小波包基选择

对于 c 个模式类 $1, 2, \dots, c$ 在某些情况下, 当每个类别具有同样的均值或均值非常接近时, $E[x|x \in i] \approx E[x|x \in j]$, 但方差提供了分类信息. 如果各类特征矢量某一分量的方差很接近, 则这一分量包含的分类信息就少, 某一分量的方差相差越大, 可分性就越好. 因此可用各类特征矢量的方差分散度来度量该分量对分类的重要性. 熵可用来作为分散度的度量^[8].

设 i 类特征矢量 $x^{(i)} = (x_1^{(i)}, x_2^{(i)}, \dots, x_m^{(i)})^t$ 的第 l 个分量的方差为 $\sigma_l^{(i)}$, 归一化后的方差为

$$V_l^{(i)} = \frac{\sigma_l^{(i)}}{\sigma_l^{(i)}} \quad (16)$$

因而

$$\sum_{i=1}^c V_l^{(i)} = 1$$

表征第 l 个分量可分性的熵准则为

$$J_E = - \sum_{i=1}^c V_l^{(i)} \ln V_l^{(i)} \quad (17)$$

由式(17)可以看出, 当第 l 分量的 $V_l^{(i)}$ ($i=1, 2, \dots, c$) 相等时, J_E 达到最大值, 可分性最差, 而当各 $V_l^{(i)}$ 相差越大, J_E 越小, 可分性越好. 根据 2.2 节的算法, 计算最优基中的 m 个小波包系数对应的 $J_{E1}, J_{E2}, \dots, J_{Em}$. 对 $J_{E1}, J_{E2}, \dots, J_{Em}$ 排序后为 $J_{E1}^* \quad J_{E2}^* \quad \dots \quad J_{Em}^*$. 取前 d ($d < m$) 个值所对应的小波包系数作为模式的特征矢量.

5 实验结果

为应用上述各准则提取特征与小波基提取特征的可分性进行比较. 这里使用了一组雷达多目标回波数据进行提取飞机数目特征的实验. 实验数据来自于在某引导雷达上现场采集的某型号歼击机(多架)视频回波数据, 信噪比(SNR)约为15dB. 包含飞机数目1~3的300个样本数据分别作为相应的3个模式类. 应用 Daubechies3 小波进行4级小波包分解. 图1(a)为应用距离准则得到的最优基与小波基对应 $J_{A1} \sim J_{Am}$ 的分布. 图1(b)为相应的 $J_{A1}^* \sim J_{Am}^*$. 从图1(b)可以看出, 最优基的 $J_{A1}^* \sim J_{Ad}^*$ (d 为30左右) 具有较大值, 并且大于小波基的 $J_{A1}^* \sim J_{Ad}^*$. 因此, 应把 $J_{A1}^* \sim J_{Ad}^*$ 对应的小波包系数作为模式的特征矢量, 这样可去除多余的不可分信息, 以降低特征维数. 图2(a)为应用散度准则得到的最优基与小波基对应的 $J_{D1} \sim J_{Dm}$ 分布. 图2(b)为相应的 $J_{D1}^* \sim J_{Dm}^*$. 从图2(b)看出, 最优基的 $J_{D1}^* \sim J_{Dd}^*$ (d 为30左右) 具有较大值, 并且大于小波基的 $J_{D1}^* \sim J_{Dd}^*$. 因此可取 $J_{D1}^* \sim J_{Dd}^*$ 对应的小波包系数作为模式的特征矢量. 在模式样本类均值相同的情况下, 可用熵准则提取特征, 为此我们把上述每个模式类零均值化后进行了实验, 实验结果对应于图3. 图3(a)为最优基与小波基对应的 $J_{E1} \sim J_{Em}$ 分布. 图3(b)为相应的 $J_{E1}^* \sim J_{Em}^*$, 从(b)看出, 最优基的




图1 应用距离准则测试结果. (a) 最优基与小波基对应的 $J_{A1} \sim J_{Am}$ 分布; (b) 最优基与小波基的 $J_{A1}^* \sim J_{Am}^*$




图2 应用散度准则测试结果. (a) 最优基与小波基对应的 $J_{D1} \sim J_{Dm}$ 分布; (b) 最优基与小波基的 $J_{D1}^* \sim J_{Dm}^*$




图3 应用熵准则测试结果. (a) 最优基与小波基对应的 $J_{E1} \sim J_{Em}$ 分布; (b) 最优基与小波基的 $J_{E1}^* \sim J_{Em}^*$

$J_{E1}^* \sim J_{Em}^*$ (d 为30左右) 具有较小的数值, 并且小于小波基的 $J_{E1}^* \sim J_{Em}^*$. 可取与 $J_{E1}^* \sim J_{Ed}^*$ 对应的小波包系数作为模式特征矢量. 从上述结果看出, 最优基变换比 WT 能提取更好的可分性特征. 由于实验中所使用的信号模式为低频信号模式, 所以可分性信息包含在低频段, 对于包含高频分量的信号模式, 最优基变换更能显示出其优越性.

6 结论

由于 WPT 对信号具有任意的多尺度时-频分解特性, 并且最优 WPT 是依赖于信号特性的变换, 因此比 WT 更适用于提取非平稳信号的局部时-频特征. 这些特征对于识别或分类来说往往是重要的特征. 本文提出了使用三种可分性准则选择最优基, 并对提取飞机数目特征进行了初步实验. 从实验结果看出, 应用这些准则提取特征优于 WT. 三种可分性准则比较而言, 距离准则简单直观, 散度准则更适用于正态分布模式, 当模式类别具有同样的均值时可使用熵准则, 并且使用这些准则只需根据训练样本集计算模式的两个重要统计量, 即均值和方差. 但为获得较稳定的特征, 需较大的训练样本集.

参考文献:

- [1] R R Coifman, M V W Hauser. Entropy based algorithms for best basis selection [J]. IEEE Trans, 1992, IT-38(3): 713 - 718.
- [2] G Antonini, A Orlandi. Wavelet packet-based EMI signal processing and source identification [J]. IEEE Trans, 2001, EC-43(2): 140 - 148.
- [3] H Liang, I Hartimo. A feature extraction algorithm based on wavelet packet decomposition for heart sound signals [A]. Proc of IEEE-SP Inter. Symp [C]. USA: IEEE, 1998. 93 - 96.
- [4] N Satio, R Coifman. On local orthonormal bases for classification and regression [A]. Proc of IEEE ICASSP [C]. USA: IEEE, 1995. 1529 - 1532.
- [5] N Satio, R Coifman. Local discriminant bases and their applications [J]. Mathematical Imaging and Vision, 1995, 5(4): 337 - 358.
- [6] R Sankaya, J H L Hansen. High resolution speech feature parameterization for monophone-based stressed speech recognition [J]. IEEE SP Letters. 2000, 7(7): 182 - 185.
- [7] 蔡元龙. 模式识别 [M]. 西安: 西北电讯工程学院出版社, 1986.
- [8] 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.

作者简介:



王首勇 男, 1956 年出生, 教授, 1989 年获武汉空军雷达学院工学硕士学位, 目前在华中科技大学电子与信息工程系攻读博士学位, 研究方向为现代信号处理、模式识别、目标识别等.