

文章编号: 1001-0920(2007)11-1250-05

基于 SVM 与非参数 LDA 的雷达自动目标识别

刘 敬^{1a}, 张军英^{1a,1b}, 赵 峰^{1a,2}

(1. 西安电子科技大学 a. 计算机学院, b. 雷达信号处理国家重点
实验室, 西安 710071; 2. 济南大学 理学院, 济南 250012)

摘 要: 针对非参数线性判别分析(LDA)的类间散布矩阵,就如何有效描述类边界结构这一问题,提出一种 SVM 与 k 近邻(k NN)法相结合的非参数类间散布矩阵构造方法——SVM- k NN. 该方法消除了非类边界样本对类边界结构信息的扭曲. 将 SVM- k NN 非参数 LDA 方法用于外场实测高分辨距离像的特征提取,并将识别结果与加权 k NN 非参数 LDA 法和谱域原空间法比较,结果表明, SVM- k NN 非参数 LDA 方法能显著提高识别效率.

关键词: 雷达自动目标识别; 非参数线性判别分析; 支撑向量机; 特征提取; 高分辨距离像

中图分类号: TP391; TN957.52; TN911.72

文献标识码: A

Radar automatic target recognition based on SVM and nonparametric LDA

LIU Jing^{1a}, ZHANG Junying^{1a,1b}, ZHAO Feng^{1a,2}

(1a. School of Computer Science and Engineering, 1b. State Key Lab of Radar Signal Processing, Xidian University, Xi'an 710071, China; 2. School of Science, Jinan University, Ji'nan 250012, China. Correspondent: LIU Jing, E-mail: zyhalj1975@163.com)

Abstract: The between class scatter matrix of nonparametric linear discriminant analysis(LDA) faces the problem of how to efficiently specify the boundary structure of original data. A method of constructing nonparametric between class scatter matrix by combining SVM and k nearest neighbors (k NN) method, SVM- k NN method, is presented. The presented method avoids the distortion of boundary structure information caused by non-boundary samples. The presented SVM- k NN nonparametric LDA method is applied to the feature extraction of outfield real high resolution range profiles. Comparing with weighted k NN nonparametric LDA method and original spectrum domain method, the recognition results show that the presented SVM- k NN nonparametric LDA method can improve recognition efficiency significantly.

Key words: Radar automatic target recognition; Nonparametric linear discriminant analysis; Support vector machine; Feature extraction; High resolution range profile

1 引 言

高分辨距离像(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,目前已成为雷达自动目标识别(RATR)领域的研究热点^[1-4]. 高分辨 RATR 的典型方法有:最大相关系数匹配法、谱域原空间法及自适应高斯分类器方法^[3]等. 但这些方法均没有特征提取过程,识别过程的计算复杂度高且识别率较低. 特征提取过程提取关于分类的有效特征,可使原始高维数据映射到低维特征子空间后易于分类. HRRP 数据维数通常较

高,在设计分类器前对 HRRP 数据进行特征提取是非常必要的.

线性判别分析(LDA)是一种经典的特征提取方法,已广泛应用于人脸识别^[5]、文本分类^[6]以及基因微阵列数据分类^[7]等领域. LDA 旨在寻找一线性变换,使得原始数据经此线性变换映射到特征子空间后,类间散布与类内散布之比最大. LDA 的解为 $S_w^{-1}S_b$ 前 d 个最大特征值对应的特征向量^[8,9], S_w 与 S_b 分别为原始数据空间数据的类内散布矩阵与类间散布矩阵. 类间散布矩阵有参数 $S_{b(p)}$ 和非参数

收稿日期: 2006-08-12; 修回日期: 2007-01-04.

基金项目: 国家自然科学基金项目(60574039,60371044).

作者简介: 刘敬(1975—),女,安徽萧县人,博士生,从事雷达自动目标识别、智能信息处理的研究;张军英(1961—),女,江苏南通人,教授,博士生导师,从事生物信息学、雷达自动目标识别等研究.

$S_{b(n)}$ 两类,从而将 LDA 分为参数 LDA 与非参数 LDA,且参数 LDA 是非参数 LDA 的特殊形式^[8]. 目前,子空间分析方法有主分量分析法(PCA)^[8]和独立分量分析法(ICA)^[8]等.与这些方法相比,非参数 LDA 用于特征提取的优势为:1)与 PCA 相比,非参数 LDA 为非参数化方法,松弛了对数据分布的类高斯性要求.2)PCA 旨在寻找数据方差(或能量)损失最小的子空间;ICA 旨在寻找基向量相互独立的子空间;而非参数 LDA 旨在寻找数据可分性最大的子空间,即类内聚集和类间散布最大的子空间.

非参数类间散布矩阵 $S_{b(n)}$ 通过描述类边界结构表达类间散布信息.非类边界样本参与计算 $S_{b(n)}$ 会扭曲 $S_{b(n)}$ 对类边界结构的表达^[8].文献[8]介绍的加权 k 近邻(k NN)法,即是用权值降低非类边界样本的影响,但引入权值不能消除这种影响.针对 $S_{b(n)}$ 如何有效描述原始数据类边界结构这一问题,本文提出一种采用支撑向量机(SVM)与 k NN 方法相结合的特征提取方法——SVM- k NN 非参数 LDA 方法.本方法的新颖之处在于:支撑向量是两类边界上支撑结构风险最小化最优分类面的样本,支撑向量代表类边界处距离最近的那些数据.首先采用 SVM 获取每一类对的支撑向量;然后对这些支撑向量采用 k NN 方法计算类间散布矩阵 $S_{b(n)}$;最后运用所获散布矩阵采用 Direct LDA 方法^[10]实现特征维数压缩.将 SVM- k NN 非参数 LDA 法应用于高分辨 RA TR,并在特征子空间中设计了最短距离分类器和贝叶斯分类器,实测数据的识别结果与加权 k NN 非参数 LDA 法及谱域原空间法的比较表明,SVM- k NN 非参数 LDA 法能有效提取谱域 HRRP 数据的线性可分性特征,大大降低了数据维数,显著提高了识别率.

2 参数 LDA 与非参数 LDA

设 n 维数据空间中有 c 类数据,LDA 寻找线性变换矩阵 $R^{n \times d}$,使得采用 $y = R^T x$ 变换将原始空间的数据 x 映射到 d 维特征子空间中后判别准则 J 最大,即

$$J(\cdot) = \max[\text{tr}(S_w^{-1} S_b)], \quad (1)$$

其中

$$S_w = \sum_{j=1}^c p_j S_j. \quad (2)$$

式(1)中 S_w 和 S_b 为原始数据的类内散布矩阵和类间散布矩阵.式(2)中 S_j 为第 j 类协方差矩阵, p_j 为第 j 类先验概率.由文献[8,9]知,式(1)最优解为 $S_w^{-1} S_b$ 前 d 个最大特征值对应的特征向量.由类间散布矩阵有参数 $S_{b(p)}$ 和非参数 $S_{b(n)}$ 两类,将 LDA 分

为参数 LDA 和非参数 LDA.

1) 参数类间散布矩阵

$$S_{b(p)} = \sum_{j=1}^c p_j (m_j - m)(m_j - m)^T,$$

m_j 为第 j 类均值, m 为整体均值且 $m = \sum_{j=1}^c p_j m_j$.

2) 非参数类间散布矩阵 $S_{b(n)}$.

文献[8]给出两类情况下加权 k NN 法的计算公式,本文将推广到 c 类,即

$$S_{b(n)} = \frac{1}{N} \sum_{i=1}^{c-1} \sum_{j=i+1}^c \left\{ \left[\sum_{l=1}^{N_i} w_l^i (x_l^i - m_j(x_l^i))(x_l^i - m_j(x_l^i))^T \right] + \left[\sum_{l=1}^{N_j} w_l^j (x_l^j - m_i(x_l^j))(x_l^j - m_i(x_l^j))^T \right] \right\}. \quad (3)$$

其中

$$w_l^i = \frac{\min\{d(x_l^i, x_{kNN}^i), d(x_l^i, x_{kNN}^j)\}}{d(x_l^i, x_{kNN}^i) + d(x_l^i, x_{kNN}^j)}. \quad (4)$$

式(3)中: N 为样本总数, N_i 为第 i 类样本数, x_l^i 为第 i 类第 l 个样本, $m_j(x_l^i)$ 为 x_l^i 关于第 j 类 k 近邻的均值.式(4)中: $d(x_l^i, x_{kNN}^i)$ 为 x_l^i 到关于第 i 类 k 近邻的距离,可调参数 $k > 0$.

文献[8]中证明,在采用式(1)的准则情况下,参数 LDA 是非参数 LDA 的特殊情况.

3 SVM- k NN 非参数 LDA

3.1 非参数类间散布矩阵的原理与问题

如图 1 所示,“ $-$ ”与“ $+$ ”分别表示两类样本 ω_1 和 ω_2 ,设近邻个数 $k = 1$.非参数类间散布矩阵 $S_{b(n)}$ 应包含原始数据两类边界的结构信息,使得数据在 $S_{b(n)}$ 前 b 个最大特征值对应的特征向量所支撑的子空间中类间散布最大.




图 1 非参数类间散布矩阵原理

图 1 中类边界样本与其 1 近邻(1NN)的差向量(即 v_1, v_3, v_4, v_5)的散布矩阵描述了包含边界区域的子空间,若在此散布矩阵中引入非类边界样本与其 1NN 的差向量,如 v_2 ,则会扭曲边界结构信息^[8].即式(3)中 x_l^i 和 x_l^j 若有非类边界样本,则会影响 $S_{b(n)}$ 对类边界结构的描述,降低 $S_{b(n)}$ 对类间散布表

达的准确性. 加权 k NN 方法通过权值限制了非类边界样本的影响, 但仍无法彻底消除这种影响.

在计算非参数类间散布矩阵 $S_{b(n)}$ 时, 如何彻底消除非类边界样本的影响, 且 $S_{b(n)}$ 能够充分有效地表达数据的类间边界结构信息? 对此, 本文提出了 SVM- k NN 非参数类间散布矩阵计算方法.

3.2 SVM- k NN 非参数类间散布矩阵计算方法

SVM- k NN 非参数类间散布矩阵计算方法的思路是: 对每一类对, 训练 SVM 分类器得到相应的支撑向量, 仅使用这些支撑向量, 采用 k NN 法计算类间散布矩阵 $S_{b(n)}$.

SVM 是一种基于结构风险最小化的统计学习方法, 其目的是寻找两类之间的最优分类面. SVM 较之传统基于经验最小化准则的学习方法有很大的优势, 在小样本的情况下也能学习出推广能力强的最优分类面. 图 2(a), 图 2(b) 分别为两维数据空间线性可分与非线性可分情况下 SVM 的分类边界与支撑向量示意图. 最优分类线为 H , H_1 与 H_2 分别为过各类样本中离分类线最近点的线, H_1 与 H_2 上的训练样本为支撑向量, 它们支撑了最优分类线. 推广到高维数据空间, 最优分类线就成为最优分类面.




图 2 SVM 的分类边界与支撑向量

支撑向量代表两类边界上距离最近的那些样本, 这些样本与其近邻的差向量的散布矩阵可有效描述包含两类边界区域的子空间. SVM- k NN 非参数类间散布矩阵计算方法, 仅使用每一类对的支撑向量, 采用 k NN 方法计算非参数类间散布矩阵, 对于 c 类样本, 共有 $c(c-1)/2$ 个类对.

SVM- k NN 非参数类间散布矩阵计算公式为

$$S_{b(n)} = \frac{1}{N} \sum_{i=1}^{c-1} \sum_{j=i+1}^c \left\{ \frac{N_i}{N S_i} \left[\sum_{l=1}^{N_{s_i}} (s_i^l - m_j(s_i^l)) (s_i^l - m_j(s_i^l))^T \right] + \frac{N_j}{N S_j} \left[\sum_{l=1}^{N_{s_j}} (s_j^l - m_i(s_j^l)) (s_j^l - m_i(s_j^l))^T \right] \right\} \quad (5)$$

其中: N 为样本总数, N_i 为第 i 类样本数, N_{s_i} 为支撑第 i 类与第 j 类最优分类面的属于第 i 类的支撑向量个数, s_i^l 为其中第 l 个支撑向量, $m_j(s_i^l)$ 为 s_i^l 关于第 j 类 k 近邻的均值.

SVM- k NN 非参数类间散布矩阵计算方法具有

如下优点: 1) 无需计算权值; 2) 仅支撑向量参与计算 $S_{b(n)}$, 无需所有训练样本参与计算; 3) 彻底消除了非类边界样本对类边界结构信息的扭曲.

3.3 SVM- k NN 非参数 LDA 实现步骤

首先使用式 (2) 和式 (5) 分别计算类内散布矩阵 S_w 与类间散布矩阵 $S_{b(n)}$; 然后采用 Direct LDA 方法^[10] 求解 $S_w^{-1} S_{b(n)}$ 的前 d 个最大特征值对应的特征向量. SVM- k NN 非参数 LDA 具体步骤如下:

- 1) 给定近邻个数 k ;
- 2) 采用 SVM 获取每一类对的支撑向量;
- 3) 采用式 (5) 计算类间散布矩阵 $S_{b(n)}$;
- 4) 采用式 (2) 计算类内散布矩阵 S_w ;
- 5) 采用特征值分解对角化 $S_{b(n)}$, 令 U 为 $S_{b(n)}$ 的前 b 个非零特征值对应的特征向量, 即 $U^T S_{b(n)} U = D_b$, D_b 为对角矩阵;
- 6) 白化 $S_{b(n)}$, 令 $W_1 = U D_b^{-1/2}$, $W_1^T S_{b(n)} W_1 = I$;
- 7) 采用特征值分解对角化 $W_1^T S_w W_1$, 令 W_2 为 $W_1^T S_w W_1$ 前 d 个最小特征值对应的特征向量;
- 8) 线性变换矩阵 $W = W_1 W_2$, 原始 n 维数据空间样本 x 经

$$y = W^T x \quad (6)$$

映射到 d 维特征子空间.

上述步骤 5) ~ 8) 为利用 Direct LDA 方法求解 $S_w^{-1} S_{b(n)}$ 前 d 个最大特征值对应的特征向量.

4 基于 SVM- k NN 非参数 LDA 的 RATR

本文采用 SVM- k NN 非参数 LDA 对谱域 HRRP 数据进行特征提取, 并在特征子空间中设计了最短距离分类器和贝叶斯分类器进行分类识别.

4.1 HRRP 预处理

雷达的一次回波经距离门、离散化等处理得到 HRRP, HRRP 具有方位敏感性、平移敏感性和幅度敏感性^[11]. 本文按照在视角变化 R/L 的角域范围内 (R 是距离分辨单元的长度, L 是目标的最大横向尺寸) 划分观测区间来解决方位敏感性, 将观测区间内的 HRRP 序列定义为一帧距离像, 代表相应的一个角域; 对 HRRP 进行快速傅立叶变换 (FFT) 解决平移敏感性; 对 HRRP 的 FFT 后取模并在频域进行幅度归一化解决幅度敏感性. 综上所述, 本文中 HRRP 数据的预处理过程如下:

- 1) 训练数据: 划分观测区间, 建立各帧距离像; 对所获距离像均进行 FFT 取模, 并在频域进行幅度归一化. 设训练数据共有 s 个目标, 每个目标有 a 帧, 每帧有 h 个距离像. 经预处理后, 第 i 个目标的第 k 帧的第 l 个距离像为 $x_{ikl} = (x_{ikl}^{(1)}, x_{ikl}^{(2)}, \dots, x_{ikl}^{(n)})$; $i = 1, 2, \dots, s$; $k = 1, 2, \dots, a$; $l = 1, 2, \dots, h$. n 为经处理后距离像的维数.

2) 测试数据:对任意测试距离像,对其进行 FFT 取模,并在频域进行幅度归一化,经预处理后为 $x = (x^{(1)}, x^{(2)}, \dots, x^{(n)})$.

4.2 特征提取

以每一目标每一角域为一类,有 s 个目标,每个目标有 a 个角域(帧),共 as 类数据.采用 3.3 节中的 SVM- k NN 非参数 LDA 进行谱域多目标特征提取,得到线性变换矩阵.

4.3 建立模板库

将所有训练数据采用式(6)映射到特征子空间,存储各类数据的均值 $\{\mu_1, \mu_2, \dots, \mu_\alpha\}$ 和协方差矩阵 $\{\sigma_1, \sigma_2, \dots, \sigma_\alpha\}$ 作为模板.

4.4 分类识别

1) 对测试数据作线性变换.对任意测试数据 x ,采用式(6)将其映射到特征子空间后记为 y .

2) 分类器设计.设计了两种分类器,即:

最短距离分类器:判决 y 属于 $\arg \min_{i=1, \dots, \alpha} \|y - \mu_i\|^2$ 所决定的类.

贝叶斯分类器:计算

$$D_i = (y - \mu_i)^T i^{-1} (y - \mu_i) + \ln(\sigma_i), \quad i = 1, 2, \dots, \alpha, \quad (7)$$

判决 y 属于 $\arg \min_{i=1, \dots, \alpha} D_i$ 所决定的类.


5 基于外场实测数据的识别结果

采用某研究所的 ISAR 实验 C 波段雷达实测飞机数据进行识别仿真实验.信号带宽为 400 MHz.3 类飞机的飞行轨迹在地平面上的投影如图 3 所示,图中给出了雷达的相对位置,可以大致估计飞机的方位角.


为检验识别算法的推广能力,训练数据和测试数据在不同的数据段内选取.其中:雅克-42 的第 2, 5 段,安-26 的第 5, 6 段,奖状的第 6, 7 段数据作为训练数据,其他各段数据作为测试数据.训练数据段基本包含了测试数据段内各种方位角的情况,但俯仰角有所不同.根据以上所述,共有 3 类目标的训练数据,每类目标有 50 个角域,每一角域有 256 个距离像,每一距离像经 FFT 后的维数为 256,各目标的测试样本数均为 400.

按照第 4 节中的步骤进行实验,并将结果与加权 k NN 非参数 LDA 法及谱域原空间法进行比较.加权 k NN 非参数 LDA 法与谱域原空间法 HRRP 的预处理均与 SVM- k NN 非参数 LDA 法相同;加权 k NN 非参数 LDA 法的类间散布矩阵采用式(3)计算;谱域原空间法则没有特征提取过程,直接在 256 维原空间中分类识别.


表 1 ~ 表 3 分别为 SVM- k NN 非参数 LDA 法、



(a) 雅克-42



(b) 安-26



(c) 奖状

图 3 飞行轨迹

加权 k NN 非参数 LDA 法及谱域原空间法在采用最短距离分类器与贝叶斯分类器时的识别结果.在 SVM- k NN 非参数 LDA 法中, $k = 3$, SVM 采用 RBF

表 1 SVM- k NN 非参数 LDA 法实验结果

| 飞机类型 | 最短距离分类器 (4 维谱域子空间) | | | 贝叶斯分类器 (5 维谱域子空间) | | |
|-----------|-----------------------|-------|-------|----------------------|-------|-------|
| | 雅克-42 | 安-26 | 奖状 | 雅克-42 | 安-26 | 奖状 |
| 雅克-42 | 92.75 | 24.50 | 0 | 99.00 | 13.75 | 1.75 |
| 安-26 | 7.25 | 66.50 | 7.75 | 0.50 | 79.00 | 3.25 |
| 奖状 | 0 | 9.00 | 92.25 | 0.50 | 7.25 | 95.00 |
| 平均识别率 / % | 83.833 3 | | | 91 | | |

表 2 加权 k NN 非参数 LDA 法实验结果

| 飞机类型 | 最短距离分类器 (150 维谱域子空间) | | | 贝叶斯分类器 (33 维谱域子空间) | | |
|-----------|-------------------------|-------|-------|-----------------------|-------|-------|
| | 雅克-42 | 安-26 | 奖状 | 雅克-42 | 安-26 | 奖状 |
| 雅克-42 | 97.75 | 22.5 | 1.00 | 94.75 | 20.75 | 5.75 |
| 安-26 | 1.25 | 56.50 | 8.00 | 5.25 | 71.50 | 16.00 |
| 奖状 | 0.25 | 21.00 | 91.00 | 0 | 7.75 | 78.25 |
| 平均识别率 / % | 81.75 | | | 81.5 | | |

表3 谱域原空间法实验结果

| 飞机类型 | 最短距离分类器 (256 维谱域原空间) | | | 贝叶斯分类器 (256 维谱域原空间) | | |
|-----------|-------------------------|-------|-------|------------------------|-------|-------|
| | 雅克 -42 | 安 -26 | 奖状 | 雅克 -42 | 安 -26 | 奖状 |
| 雅克 -42 | 98.25 | 23.25 | 2.75 | 73.25 | 13.00 | 1.25 |
| 安 -26 | 1.75 | 61.25 | 16.75 | 25.25 | 75.50 | 50.25 |
| 奖状 | 0.00 | 15.50 | 80.50 | 1.50 | 11.50 | 48.50 |
| 平均识别率 / % | 80.00 | | | 65.75 | | |

核函数. 在加权 k NN 非参数 LDA 法中, $k = 3$, $\gamma = 2$.

在贝叶斯分类器情况下, SVM- k NN 非参数 LDA 法的特征子空间维数为 5 维, 加权 k NN 非参数 LDA 法的子空间维数为 33 维, 但前者识别率为 91%, 远高于后者的 81.5%. 在最短欧式距离分类器情况下, SVM- k NN 非参数 LDA 法识别率高于加权 k NN 非参数 LDA 法, 前者特征子空间维数仅为 4 维, 而后者子空间维数为 150 维. 无论采用最短距离分类器还是贝叶斯分类器, 特征子空间法均优于原空间法.

采用同样数据, 最大相关系数匹配法的平均识别率为 69.667%, 自适应高斯分类器法平均识别率为 83.1667%, 这两种方法的数据维数均为 256, 识别率均低于 SVM- k NN 非参数 LDA 法.

相比加权 k NN 非参数 LDA 法, SVM- k NN 非参数 LDA 法需要采用 SVM 获取每一类对的支撑向量, 但在计算类间散布矩阵时无需所有样本参与计算, 且不需计算权值. 对于 RATR, 特征提取属于离线训练, 相比原空间法, 虽然 SVM- k NN 非参数 LDA 法提高了离线训练的计算复杂度, 但由于大大降低了特征维数, 使得在线识别过程的计算复杂度有所降低, 提高了在线识别速度. 另外, SVM- k NN 非参数 LDA 法能有效提取数据的线性可分特征, 从而显著提高了在线识别率.

6 结 语

HRRP 数据具有方位敏感性、平移敏感性和幅度敏感性, 使得高分辨 RATR 比较棘手. 本文提出了 SVM- k NN 非参数 LDA 方法, 应用于谱域 HRRP 的特征提取. 实测数据识别结果表明, 该方法能有效提取谱域 HRRP 数据的线性可分特征, 显

著提高识别效率. 本文的工作表明, HRRP 数据在谱域原空间中的可分性表达存在较严重的冗余, 在设计分类器分类识别前有必要进行特征提取.

参考文献(References)

- [1] Webb A R. Gamma mixture models for target recognition[J]. Pattern Recognition, 2000, 33(12): 2045-2054.
- [2] Copsey K, Webb A R. Bayesian gamma mixture model approach to radar target recognition[J]. IEEE Trans on Aerospace and Electronic System, 2003, 39(4): 1201-1217.
- [3] Jacobs S P, O'sullivan J A. Automatic target recognition using high-resolution radar range profiles[D]. Washington: Washington University, 1999.
- [4] Van der Heiden R, Groen F C A. The box-cox metric for nearest neighbour classification improvement[J]. Pattern Recognition, 1997, 30(2): 273-279.
- [5] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs fisherfaces: Recognition using class specific linear projection[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720.
- [6] Chakrabarti S, Roy S, Soundalgekar M. Fast and accurate text classification via multiple linear discriminant projections[J]. Very Large Databases J, 2003, 12(2): 170-185.
- [7] Dudoit S, Fridlyand J, Speed T P. Comparison of discrimination methods for the classification of tumors using gene expression data[J]. J of American Statistical Association, 2002, 97(457): 77-87.
- [8] Fukunaga K. Introduction to statistical pattern recognition[M]. Boston: Academic Press, 1990.
- [9] Anil K Jain, Robert P W Duin, Mao Jianchang. Statistical pattern recognition: A review[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2000, 22(1): 4-37.
- [10] Yu Hua, Yang Jie. A direct LDA algorithm for high-dimensional data-with application to face recognition[J]. Pattern Recognition, 2001, 34(10): 2067-2070.
- [11] Xing Meng-dao, Bao Zheng. The properties of range profiles of aircraft[J]. Chinese J of Electronics, 2002, 11(1): 1-6.

(上接第 1249 页)

- [8] Tang G Y. Feedforward and feedback optimal control for linear systems with sinusoidal disturbances[J]. High Technology Letters, 2001, 7(4): 16-19.
- [9] Ma H, Tang G Y, Zhao Y D. Feedforward and feedback optimal control for offshore structures

subjected to irregular wave forces [J]. Ocean Engineering, 2006, 33(8/9): 1105-1117.

- [10] Tang G Y, Xie N. Sensitivity approach to optimal control for affine nonlinear discrete-time systems[J]. Asian J of Control, 2005, 7(4): 448-454.