

文章编号: 1003-501X(2011)01-0015-08

推扫式实时图像目标识别处理系统的设计

郭志军, 何 昕, 魏仲慧

(1. 中国科学院 长春光学精密机械与物理研究所, 长春 130033;

2. 中国科学院研究生院, 北京 100039)

摘要: 针对目前反辐射技术及反辐射导弹技术的迅速发展, 对空有源预警系统易被发现和攻击。设计了一种基于推扫式实时图像处理的无源预警系统, 通过光学成像方法实现区域范围内的对空预警目标。提出了一种新的图像并行处理架构实现了空中目标的实时识别预警。同时提出了一种新的基于粗糙集和支持向量机迭代的识别算法, 通过对训练样本基于类隶属度进行分块和排序, 加速对支持向量的选取和最优分界面的构建, 使样本集的训练时间大大减少, 并且提高了识别函数的识别率, 泛化性能和可实现性。实验结果显示该系统的目标识别反应时间约为 15.1 ms, 识别率高达 93%, 达到了对空实时预警的要求。

关键词: 线阵 CCD; 光电预警系统; DSP; 粗糙集; 目标识别

中图分类号: TP18; TP391

文献标志码: A

doi: 10.3969/j.issn.1003-501X.2011.01.004

Design of Recognition System Based on the Real-time Scan-image Processing

GUO Zhi-jun, HE Xin, WEI Zhong-hui

(1. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences,

Changchun 130033, China; 2. Graduate University of Chinese Academy of Sciences, Beijing 100039, China)

Abstract: When the current anti-radiation technology and anti-radiation missile technology developed rapidly, active antiaircraft warning system can be easily found and attacked. Passive warning system is designed based on real-time scan-image processing by the optical imaging method to achieve region-wide early warning. A new parallel image processing structure is proposed to achieve real-time recognition of early warning air targets. At the same time, a new iterative identification algorithm is proposed based on Rough Sets (RS) and Support Vector Machine (SVM). The training data sets are separated into some blocks and their samples in sort-subjection are arranged to speed up the selection for support vector and the construction of the optimal interface. Therefore, training time of the sample set was greatly reduced and the recognition rate, generalization, realization performance of its recognition function was increased. Experimental results show that the system reached real-time early warning of air requirements while target recognition reaction time was about 15.1 ms and recognition rate was as high as 93%.

Key words: linear CCD; photoelectric warning system; DSP; rough set; target recognition

0 引 言

当前形势下战争中信息的准确, 实时获取成为战争胜利的关键。光电预警系统通过光学成像, 实时处理图像实现区域范围内的对空预警目标。而实时图像处理需要高速处理大量图像数据。用高性能的数字信

收稿日期: 2010-08-19; 收到修改稿日期: 2010-09-10

基金项目: 国家 863 高技术研究发展计划资助项目(NO.2007AA12Z113)

作者简介: 郭志军(1982-), 男(汉族), 湖南耒阳人。博士, 主要研究工作是数据传输, 存储, 图像处理, 模式识别。

E-mail: guozhijun968@126.com。

号处理器(DSP)和 FPGA 构成的系统能满足此要求^[1-2]。对于更大容量数据图像更高速实时处理,一些学者用多片 DSP 和 FPGA 并行处理构成的系统来实现^[3-4]。而针对不同图像处理算法和不同应用场所,需要设计与之相适应的专用硬件实现平台。

预警系统中图像处理的核心是模式识别。目前主流分类方法有神经网络和支持向量机。神经网络需要大量的先验知识,且训练算法极易陷入局部极小^[5-6]。网络结构非常复杂,还容易出现过拟合,导致算法的推广性能差。支持向量机 SVM^[7]不需要很多的先验知识,而且泛化性还很强。但在样本数较大时候,尤其是支持向量数较大时候,支持向量机的训练算法会面临维数灾,内存空间不够,运算速度慢等严重问题。设计一种能满足大容量图像数据实时处理的硬件系统和开发一种其判别函数泛化性能高,硬件实现容易的算法成为本文研究的重点。

1 双 DSP+FPGA 实时数字图像处理系统硬件的构成

选取美国 Armel 公司的线阵 CCD 相机 AViVA SM2 作为系统图像数据输入,采用美国 TI 公司的高速数字信号处理器 TMS320DM642 为处理核心,辅助以现场可编程门阵列 FPGA Virtex-II 系列芯片 VC2V2000 为预处理以及数字图像存储器单口 RAM 和双口 RAM 等器件构成了实时高速数字图像处理系统。串口通讯用于设置 FPGA 内图像分辨率和边缘检测阈值等参数。为了提高系统的可扩展性我们还对 FPGA 引出了大量的 IO 资源以满足其他格式的图像输入。主 DSP 外接了大存储容量的 SDRAM 以便可以适应图像帧相关等算法的实现。图 1 为系统实物图。系统原理框图如图 2。



图 1 系统硬件 PCB 实物图

Fig.1 System PCB hardware board




图 2 系统原理框图

Fig.2 System working principle

其工作原理是,线阵 CCD 相机采集后的原始图像数据输入到 FPGA 内部三个子模块。一方面原始图像数据由 FPGA 乒乓缓存到 FPGA 外接图像存储器组 SRAM1, SRAM2 中以供主 DSP 通过 FPGA 从乒乓取出,由 PCI 接口来完成原始视频数据实时传输;另一方面,原始图像数据由 FPGA 输入到双口 RAM1 中以便主,从 DSP 取出进行处理。再者原始图像数据输入到 FPGA 内部的边缘检测模块, FPGA 对其进行实时边缘检测,选出大于阈值的边缘像素点。主 DSP 接收这些边缘像素点信息,对其进行连通性分析,并对不同连通区域块进行标识。主 DSP 把满足要求的连通区域块(将其定义为可疑目标)的最大外接矩形坐标通过双口 RAM2 传输给从 DSP。主、从 DSP 根据连通区域块坐标的范围从双口 RAM1 取出相应的原始数据进行处理,然后计算特征值并识别目标。最后主 DSP 将识别结果,以及原始视频数据经由 PCI 通道传送给 PC 机。系统数据流程框图如图 3。




图 3 系统数据流程框图

Fig.3 System data flow

2 关键技术研究

2.1 图像处理架构的设计

目前对可见光图像处理一般都基于灰度特征和几何特征, 需要分别处理其灰度图像和二值化图像。TMS320DM642 为 32 位定点处理器, 主频高达 600 MHz, 处理速度为 4 800 MIPS。其外设接口 EMIFA 口采用 133 MHz 时钟从外部高速搬移数据进入内存中进行处理。在无 CPU 干预情况下还可以实现 EDMA 数据搬移。从而保证 DSP 有足够的时间进行数据处理。图 4 为本文提出的处理架构简图。系统以输入图像数 20 列为一节拍(本文称为帧节拍), 采用流水线方式进行处理。当 FPGA 进行一帧节拍边缘检测的同时, 主 DSP 接收 FPGA 上一帧节拍传过来的所有边缘像素点做连通性分析, 确定目标的矩形坐标范围, 立即将结果通过双口 RAM2 通知从 DSP。主 DSP 做连通性分析的同时从 DSP 根据主 DSP 的上一帧节拍内连通性分析的结果从双口 RAM1 中读取原始灰度图像数据进行高通滤波, 背景抑制, 图像二值化等操作。




图 4 目标识别处理架构图

Fig.4 Target recognition processing architecture

从 DSP 读取双口 RAM1 中数据的时候, 主 DSP 打开数据缓冲器用 EDMA 方式搬移数据到其内部二级缓存区。待连通分析完后主 DSP 从其二级缓存区内读取此数据计算目标的灰度特征。从 DSP 二值化图像后计算目标特征, 每算完一个特征就立即送入双口 RAM2, 然后从 DSP 继续计算下一特征。直到算完目标所有特征。

线阵 CCD 相机 AViiVA SM2 图像输出速率每列 0.185 ms。每列 2 048 像素点。像素位宽 12 bit, 存储采用 2 字节。选择无云和多云条件下空中三种不同飞机的照片各 50 张, 共 600 张, 由图像发生器模拟线阵 CCD 图像数据格式输入进行测试。典型的目标大小不超过 20×20 像素点, 其矩形框大小取为 40×40 。采用标准 C 语言进行编程后利用 CCS 转换程汇编语言, 并对执行的汇编语言指令进行计数。表 1, 表 2 为对多云和无云背景下目标图像检测消耗的指令数及软件实际运行时间的测试结果。

由 camlink 输入图像数据的速率可知一个帧节拍时间为 3.7 ms。每一个帧节拍数据处理横跨 4 个帧节拍, 在 FPGA 内部用 1 个帧节拍时间进行边缘检测, 主 DSP 和从 DSP 在 3 个帧节拍时间内并行处理。由表 1, 表 2 知, 处理一帧节拍数据需要最多的时间量为主 DSP 总共消耗时间, 为 2.99 ms, 小于帧节拍时间 3.7 ms, 满足处理实时性需求。定义目标识别反应时间为图像目标完全输入本系统时刻到 PC 机接收完此目标的识别结果并给出目标质心时刻之间的时间。对上述 600 张图片进行识别测试, 最大的目标识别反应时间为 15.1 ms。

表 1 主 DSP 任务安排及时间消耗(多云/无云)

Table 1 Task arrangements and time consuming of master DSP(cloudy / no cloud)

Master DSP	Connectivity analysis	Original features calculation	Original features recognition	Binary feature recognition	PCI data transmission
Instruction (Million)	8.783 /6.768	2.928 /2.688	0.624 /0.624	2.016 /1.968	1.565 /1.565
Time/ms	1.83 /1.41	0.61 /0.56	0.13 /0.13	0.42 /0.41	0.326 /0.326

表 2 从 DSP 任务安排及时间消耗(多云/无云)

Table 2 Task arrangements and time consuming of slave DSP(cloudy / no cloud)

Slave DSP	High-pass filter	Binary	Binary feature calculation
Instruction (Million)	5.75 /5.27	1.152 /1.104	1.824 /1.824
Time /ms	1.2 /1.1	0.24 /0.23	0.38 /0.38

2.2 识别算法的推导及实现

预警系统中图像处理的核心是模式识别。难点是识别的实时性必须得高。本系统识别算法采用离线训练,训练完后将训练结果写入主 DSP,从 DSP 内部一级缓存中以便系统调用对目标进行运算,识别。

2.2.1 概述

粗糙集理论^[8-9]是一种刻画具有不精确、不确定全新数学工具,为研究不精确不确定知识的表达,学习,归纳方法提供了一个有力的工具。支持向量机训练是基于结构风险最小化原理,判别函数的构造只与少数的支持向量有关^[10-11]。造成支持向量机的训练算法面临维数灾,内存空间不够,运算速度慢等严重问题根本原因是训练集样本数和属性维数过大。一些学者通过粗糙集属性约简和规则简化来减少训练样本^[12-13]。此方法效果有限。另一些学者提出了用样本类的最小包含超球选择训练子集^[14-15]。这些方法计算复杂,而且也不直观。

提出了一种新的基于粗糙集 RST(Rough Set Theory)和支持向量机相结合的迭代算法。该算法首先通过粗糙集方法对原始样本进行属性约简,降低属性维数,提取知识,并按照类隶属度定义对约简后的对象进行初步分块,排序,为支持向量机选择有效训练样本集提供指引方向,从而大大加速了最优分界面的构建,并且得到的识别判断函数简洁,工程实现容易,识别率高。

2.2.2 样本的分块

粗糙集定义及相关推论参考文献[8]。由于篇幅限制,本文只给出了自己独有的定义及推导公式。由粗糙集的上近似,下近似定义可知

$$BN_{T_i}(X) = T_i^*(X) - T_{i*}(X) \quad (1)$$

$BN_{T_i}(X)$ 表示 X 在关系 T_i 下 X 的 T_i 属性边界集。 $BN_{T_i}(X)$ 既不属于 X 也不属于 $\bar{X}$ 。类 X 在一个属性关系 T_i 下只有一个 T_i 属性边界集。下面定义类下边界集,类上边界集,类边界负域。

$T = \{T_1, T_2, \dots, T_n\}$ 类下边界集为各个属性边界集的交集:

$$BN_T(X_j) = BN_{T_1}(X_j) \cap \dots \cap BN_{T_n}(X_j) \quad (2)$$

类上边界集为各个属性边界集的并集:

$$BN^T(X_j) = BN_{T_1}(X_j) \cup \dots \cup BN_{T_n}(X_j) \quad (3)$$

类边界负域:

$$\overline{BN^T(X_j)} = U - BN^T(X_j) \quad (4)$$

类下边界集表示的是其每个属性都有不同粗糙度的所有对象的集合。换句话说就是,在这个对象的每一个属性条件下,该对象都可以隶属于不同的决策集合。类上边界集表示的是有属性为不同粗糙度的所有对象的集合。类边界负域为类上边界集的补集。将论域 U 分为三个数据块, L_1, L_2, L_3 :

$$L_1 = BN_T(X_j), \quad L_2 = BN^T(X_j) - BN_T(X_j), \quad L_3 = U - L_1 - L_2 \quad (5)$$

L_1 为属于类 X_j 的每一个属性边界集的所有对象的集合。 L_2 只属于类 X_j 的某些属性边界集的所有对象的集合。 L_3 为不属于类 X_j 的每一个属性边界集的所有对象的集合。 L_1 中对象属于类 X_j 的模糊性最大,类边界也最集中。 L_2, L_3 依次减弱。

2.2.3 样本隶属度的确定

定义了集合粗糙度: $X \neq \phi$, 从 U 中划分的一个子集合 X 的不确定程度定义为集合粗糙度:

$$u_T(x, X) = \frac{\{[x]_T \cap X\}}{\{[x]_T\}} \quad (6)$$

$u_T(x, X)$ 表示在 T 关系下, 对象 x 属于集合 X 的集合粗糙度, 表达了对象 x 属于集合 X 不确定性程度。

由于决策集合是由其决策属性决定的。因此类隶属度也必然由其集合粗糙度所决定。决策集合的决策属性 $D = T_1 \cup T_2 \cup \dots \cup T_n$, 对象 $x_k (k=1, 2, \dots, m)$ 在决策属性 D 条件下属于集合 $X_j (j=1, 2, \dots, t)$ 粗糙类隶属度:

$$\tilde{P}_k = \prod_{i=1}^{i=n} (u_{T_i}(x_k, X_j)) \quad (7)$$

由于粗糙集理论适用于处理离散数据, 所以对连续性属性需要进行离散化。为得到样本更精确的类隶属度, 提出了模糊离散化方法。

$$v_{kT_i}(x_{ki}) = \max_{t \in \{1, 2, \dots, m_t\}} \{v_{kT_{i,t}}(x_{ki})\} \quad (8)$$

其中: x_{ki} 为对象 x_k 在 T_i 关系下的属性值, m_t 为在 T_i 关系下所有不可分辨子集的个数, $v_{kT_{i,t}}(x_{ki})$ 为 x_k 在 T_i 关系下, 属于 m_t 的模糊隶属度。可以得到对象的准确类隶属度:

$$\overline{P}_k = \prod_{i=1}^{i=n} (u_{T_i}(x_k, X_j) v_{kT_i}(x_{ki})) \quad (9)$$

其中 $u_{T_i}(x_k, X_j)$ 为在属性 $T_i (i=1, 2, \dots, n)$ 下, 对象 x_k 隶属于子集合 X_j 的粗糙度。准确类隶属度越小, 对象的类归属争议性就越大, 对象就越接近类边界, 越可能成为支持向量。根据准确类隶属度的大小, 可以将所有对象进行排序。

2.2.4 改进的支持向量机判别函数

支持向量机原始判别函数:

$$y(x) = \text{sign}[\sum_{x_k \in \text{SV}} a_k y_k K(x_k, x) + b] \quad (10)$$

其中: $b = \frac{1}{N_{\text{NSV}}} \sum_{x_k \in \text{NSV}} (y_k - \sum_{x_j \in \text{SV}} a_j y_j K(x_j, x_k))$ 。

SV 为支持向量集, 满足 $0 < a_k < H$ 。NSV 为标准支持向量集, 满足 $0 < a_k < H$ 。 N_{NSV} 为标准支持向量的个数。

改进后的判别函数为

$$y(x) = \text{sign}[\sum_{t=0}^{t=i} \sum_{x_k \in \text{SV}} a_k y_k \Psi_t(x) \Psi(x_k) + b] \quad (11)$$

其中: $\Psi_t(x)$ 为待识别样本 x 的第 t 个特征属性不变, 而其余所有其他特征属性置为 0 所形成的向量, i 表示样本的特征维数, $\Psi(x_k)$ 为训练样本 x_k 的特征向量。由式(10)可以看出, 目标最终的判别结果可以由各个特征属性代入公式 $\sum_{x_k \in \text{SV}} a_k y_k \Psi_t(x) \Psi(x_k)$ 运算, 最后将中间结果叠加。这为系统硬件流水性工作方式及双 DSP 并行实时处理提供了方便。

2.2.5 粗糙集与支持向量机结合的迭代识别算法(RSSVM)及实现

因为决定 SVM 最优分类面的支持向量主要分布在边界区域^[15-16], 用边界集来作为 SVM 的训练子集,




图 5 样本训练流程

Fig.5 Samples training flow

可以大幅度减少训练样本数。算法如图 5, 若数据具有稀疏性, 则 L_1 为小集合, 设 L_1 为初始训练集, L_2 , L_3 为补充训练集。补充训练集用来对判别函数进行初步识别测试, 若满足识别要求则停止迭代, 否则从 L_2 , L_3 按排序结果依次选取数据小块加到 L_1 中, 更新 L_1 , L_2 , L_3 。重新进行训练, 直到满足停止迭代要求为止。若数据不满足稀疏性条件, 则 L_1 根据样本排序结果, 选取 L_1 中数据小块作为初始训练集, L_1 剩余部分, L_2 , L_3 作为补充训练集。同样, 训练, 补充集合实时更新, 直到满足停止迭代条件为止。停止迭代条件为: 支持向量机 SMO 算法停止条件, 预定识别率或循环次数。

3 实验结果

选取两类图像, 一种为军用战斗机 F-16, 其图像分布具有稀疏性。另一类为地空导弹图像, 分布具有稠密性。每类图像各有 1 000 训练样本, 500 测试样本。测试样本用于对最终判别函数进行识别测试。所有样本中有一些为负样本, 有一些为正样本进行了旋转, 倾斜, 尺度缩放等一些变化。由于篇幅限制, 本文只给出了军用战斗机 F-16 详细的识别过程。识别特征属性选用目标一, 二, 三阶矩不变量, 目标面积, 长宽比, 复杂度(周长与面积比), 紧凑度(目标面积与外接矩形的面积比), 周长与突起周长比, 目标灰度均值, 目标对比度(目标最小灰度与最大灰度之比), 目标灰度方差, 目标与背景灰度对比度。分别记为 $TZ_1 \dots TZ_{12}$ 。其中 TZ_9 , TZ_{10} , TZ_{11} , TZ_{12} 在原始图像中计算, 其余在二值化图像中计算。得到属性表如表 3。FL 表示分类。1 代表正样本, 0 代表负样本。

表 3 属性分类表

Table 3 Property classification

U	TZ_1 ($\times 10^3$)	TZ_2 ($\times 10^3$)	TZ_3 ($\times 10^4$)	TZ_4	TZ_5	TZ_6	TZ_7	TZ_8	TZ_9	TZ_{10}	TZ_{11}	TZ_{12}	FL
1	2.53	5.06	1.93	51	0.42	0.32	0.72	0.77	88	0.66	0.32	6	1
2	2.02	4.10	6.9	61	1.48	0.59	0.76	0.89	89	0.41	0.19	4.1	1
3	2.33	4.97	4.7	73	4.20	0.51	0.74	0.83	129	0.47	0.50	4.9	1
4	2.41	6.72	5.2	75	3.50	0.49	0.63	0.98	113	0.44	0.49	5.3	1
5	2.59	6.93	5.9	48	0.45	0.45	0.67	0.93	131	0.49	0.47	4.9	1
...	...	...	...	...	...	...	...	...	...	...	...	...	...
763	2.62	7.17	4.0	69	1.43	0.39	0.88	0.97	95	0.61	0.59	6.2	1
764	2.21	2.92	6.1	73	0.76	0.37	0.81	0.97	93	0.79	0.72	6.9	0
765	2.07	3.61	8.0	75	1.31	0.40	0.83	0.89	101	0.61	0.41	3.8	0
766	2.03	5.84	9.3	75	1.32	0.53	0.72	0.91	110	0.51	0.50	4.8	0
...	...	...	...	...	...	...	...	...	...	...	...	...	...
998	2.20	6.01	3.29	37	0.42	0.71	0.61	0.95	61	0.42	0.51	4.9	0
999	2.05	3.30	3.31	42	0.61	0.60	0.71	0.80	73	0.31	0.11	3.3	0
10^3	2.48	3.15	3.61	68	0.81	0.61	0.89	0.73	76	0.39	0.08	3.1	0

首先对属性模糊离散化, 用公式(8)计算样本的各属性模糊离散度。然后用式(2), 式(3), 式(4)对计算样本的类边界上边界, 下边界和类边界负域。最后用式(5)对所有样本进行分块。表 4 为属性离散化, 约简, 样本分块后的结果。

表 4 属性离散化, 类分块表

Table 4 Property discretization, class block

U	TZ_1	TZ_2	TZ_3	TZ_5	TZ_6	TZ_7	TZ_8	TZ_9	TZ_{10}	TZ_{11}	FL	FK
1	5	3	1	1	1	2	1	2	6	6	1	L_1
2	1	2	6	2	2	2	3	2	4	3	1	L_1
3	3	3	3	3	2	2	3	5	3	5	1	L_3
4	4	4	4	3	2	1	5	4	4	5	1	L_2
5	5	4	5	1	2	1	5	5	4	5	1	L_2
...	...	...	...	...	...	...	...	...	...	...	...	...
687	5	4	3	2	1	3	5	3	6	6	1	L_3
688	2	1	6	2	1	3	5	3	7	7	0	L_3
689	1	1	7	2	1	3	3	4	5	4	0	L_1
700	1	3	7	2	2	2	3	4	4	5	0	L_2
...	...	...	...	...	...	...	...	...	...	...	...	...
980	2	3	3	1	3	1	4	1	4	5	0	L_1
981	1	1	3	1	3	2	1	2	1	1	0	L_3
982	5	1	3	2	3	3	1	2	1	1	0	L_3

经过分块后得到 L_1 , L_2 , L_3 分别包含样本数 343, 464, 175。用式(9)分别计算其样本的准确类隶属度。按隶属度大小在 L_1 , L_2 , L_3 块中分别进行从小到大排序。然后用图 5 所示 IRSSVM 算法进行训练。与传统的 SVM 训练方法进行比较, 其结果如表 5 所示。

其中复杂度表示的是训练后得到的判别函数进行识别计算时候需要进行的乘加次数。从表 5 中可以看出 IRSSVM 训练方法比传统的 SVM 方法需要的训练样本更少, 需要支持向量也更少, 训练时间更短, 识别率也更高。同时, 获得的判别函数复杂度也更低, 硬件更容易实现。从表 5 中, 还可以看出, IRSSVM 算法更适合用于具有稀疏性的样本训练。

使用了神经网络^[16]和 RMLN^[17]两种分类器同样对上述样本进行训练识别。其比较结果如表 6 所示。

表 5 训练结果比较(飞机/导弹)

Table 5 Comparison of training results (aircraft / missile)	Traditional SVM	IRSSVM
Samples number after pretreatment	982/976	982/976
Training samples number	982/976	292/586
Supported vector number	59/62	31/50
Training time/ms	795/921	411/703
Recognition rate/%	91/89	93.2/93
Complexity	5 901/7 503	3 101/6 051

表 6 3 种分类器测试比较(飞机/导弹)

Table 6 Comparison of 3 classifiers (aircraft / missile)	Neural network	RMLN	IRSSVM
Training time/ms	1 031/1 023	913/920	411/703
Recognition rate/(%)	88.4/88.5	90/91	93.2/93

表 6 表明 IRSSVM 算法需要训练时间更短, 识别率更高, 具有更高的效率。

训练完成后得到判别公式(11)的各参数值, 并将其下载到相应的主 DSP 和从 DSP 中。系统通过实时扫描 100 组空中飞机图像对上述的识别算法进行验证。识别率高达 93%。

4 结 论

由两片高性能数字信号处理器 TMSDM642 和 FPGA XC2V2000 组成的实时图像处理系统, 实现了数据采集, 目标识别以及结果 PCI 输出。采用流水线工作方式, FPGA, 双 DSP 并行处理, 大大增强了系统的处理能力, 提高了系统的处理速度, 保证了系统目标识别的实时性。基于粗糙集和支持向量机的迭代识别算法通过对大容量样本进行训练后得到的识别公式简洁, 系统容易实现, 且泛化性能好, 识别率高。实验结果表明, 该系统的目标识别率高达 93%, 识别反应时间最大为 15.1 ms, 满足对空实时预警的要求。

参考文献:

- [1] ZHOU Hang-xing, LAI Run, LIU Shan-qiao. A New Real Time Processing System for Imaging Signal Based on DSP&FPGA [J]. *Infrared Physics & technology*(S1350-4495), 2005, 46(4): 277-281.
- [2] DUAN Jing-hong, DENG Ya-ling, LIANG Kun. Development of Image Processing System Based on DSP and FPGA [C]//*The Eighth International Conference on Electronic Measure and Instruments*, Xi'an, china, July 16-18, 2007, 2: 791-794.
- [3] Mariatos V, Adaos K D, Alexiou G P. A Novel System-on-chip Architecture for Efficient Image Processing [C]//*The 19th IEEE/IFIP International Symposium on Rapid SystemPrototyping*, Monterey, CA, June 2-5, 2008: 165-171.
- [4] Franz Rinnerthaler, Wilfried Kubinger, Josef Langer, *et al.* Boosting the Performance of Embedded Vision Systems Using a DSP/FPGA Co-processor System [C]//*The Eighth International Conference on Electronic Measure and Instruments*, Montreal, Que, Oct 7-10, 2007: 1141-1146.
- [5] 张赢, 李琛. 基于粗糙集理论的神经网络研究及应用 [J]. *控制与决策*, 2007, 22(4): 462-464.
ZHANG Ying, LI Chen. Research on neural networks based on rough set theory [J]. *Control and Decision*, 2007, 22(4): 462-464.
- [6] LI Meng-xin, WU Cheng-dong, JIN Feng. A Vision-Based Inspection System using Fuzzy Rough Neural Network Method [C]//*Proceedings of the Fifth International Conference on Machine Learning and Cybernetics*, Dalian, China, Aug 13-16,

- 2006: 3228-3232.
- [7] 邓乃扬, 田英杰. 数据挖掘中的新方法—支持向量机 [M]. 北京: 科学出版社, 2006.
DENG Nai-yang, TIAN Ying-jie. **The new method of data mining-SVM** [M]. Beijing: Science Press, 2006.
- [8] 张文修, 吴伟志, 梁吉业. 粗糙集理论与方法 [M]. 北京: 科学出版社, 2001.
ZHANG Wen-xiu, WU Wei-zhi, LIANG Ji-ye. **Theory and method of Rough Set** [M]. Beijing: Science Press, 2001.
- [9] Pawlak Z. **Rough sets: Theoretical aspects of reasoning about data** [M]. Boston: Kluwer Academic Publishers, 1991.
- [10] Benett R, Bredensteiner E J. Geometry learning [J]. **International Journal of Computer Vision** (S0920-5691), 1996, **36**(2): 63-70.
- [11] Murphey Y L, Zhihang Chen Putrus M, Feldkamp L. SVM learning from large training data set [J]. **Proceedings of the International Joint Conference on Neural Networks**(S1098-7576), 2003, **4**: 2860-2865.
- [12] TIAN Jin-yu, LIN Yan. Short-term Electricity price Forecas Ting Based on Rough sets and improved SVM [C]// **Second International workshop**, Moscow, Jan 23-25, 2009: 68-71.
- [13] ZHANG Guo-jun. An Improved Hypertension prediction model Based on RS and SVM in the Three Gorges Area [C]// **International conference on Computer Science and Software Engineering**, Wuhan, China, December 12-14, 2008, **1**: 810-814.
- [14] 万群, 王伟, 黄际彦, 等. 模糊支持向量机的非直达波抑制算法 [J]. 电子科技大学学报, 2008, **37**(6): 803-806.
WAN Quan, WANG Wei, HUANG Ji-yan, *et al.* Method for NLOS Mitigation Based on Fuzzy Support Vector Machines [J]. **Journal of University of Electronic Science and Technology of China**, 2008, **37**(6): 803-806.
- [15] 吴青, 刘三阳, 杜桔. 基于边界向量提取的模糊支持向量机方法 [J]. 模式识别与人工智能, 2008, **21**(3): 332-337.
WU Qing, LIU San-yang, DU Jie. Fuzzy Support Vector Machine Method Based on Border Vector Extraction [J]. **PR&AI**, 2008, **21**(3): 332-337.
- [16] 罗健旭, 邵惠鹤. 一种基于粗集的模糊神经网络 [J]. 上海交通大学学报, 2003, **37**(11): 1702-1704.
LUO Jian-xu, SHAO Hui-he. A Neurofuzzy System Based on Rough Set Theory [J]. **Journal of Shanghai Jiaotong University**, 2003, **37**(11): 1702-1704.