

基于 RBF 神经网络和改进遗传算法的 货车车锁检测

严柏军 蔡宁涛 郑 链 王克勇

(北京理工大学机电工程学院, 北京 100081)

摘要 为实现货车自动检测记录系统, 需要根据货车图象检测进站货车的车锁是否存在. 为此, 提出了一种基于 RBF 神经网络和改进遗传算法的货车车锁检测方法. 该方法首先提取图象的投影特征、边缘图象的线性矩特征以及灰度直方图特征, 然后用 RBF 神经网络进行检测和定位. 同时引入遗传算法, 利用改进后的遗传算法的高并行性和鲁棒性, 可以较快地完成全局搜索, 而不会陷入局部最优. 实验表明, 该方法能有效克服车锁种类多, 变形大, 以及光照变化的影响, 具有较高的速度和检测成功率, 能满足于实际应用.

关键词 特征提取 RBF 神经网络 遗传算法

中图分类号: TP391.4 **文章标识码**: B **文章编号**: 1006-8961(2002)12-1307-07

The Lock Detection of Freight Train Based on RBF Neural Network and Genetic Algorithm

YAN Bo-jun, CAI Ning-tao, ZHENG Lian, WANG Ke-yong

(School of Mechatronic Engineering, Beijing Institute of Technology, Beijing 100081)

Abstract To realize automatically detecting and recording system of freight trains, it's necessary to detect whether the locks of freight trains exist by the image of freight trains when they are entering railway stations. An approach of fast lock detection is put forward, which is based on RBF neural network and improved genetic algorithm. In this method, firstly extract the projection features of images, linear moment features of edge images, and the features of gray histograms of images, and these features reflect different characters of targets from different points of view, and then they are normalized to the input vector of RBF neural network, and RBF neural network is used for detection and location. At the same time, improved genetic algorithm is used to search the whole image, and searching process is speeded up because the genetic algorithm is a parallel and robust algorithm. In addition, image preprocessing is not done alone, and gray variation of images is eliminated during the process of feature extraction. Experiment results show that the method can overcome the problems of many types, deformation, and the variation of environmental brightness, and have the fast speed and high success rate of detection, and can be put into practical application. Therefore, the method has significant engineering value.

Keywords Feature extraction, RBF neural network, Genetic algorithm

0 引言

目前, 铁路部门在对到站货车的货运情况, 如载货车厢数, 进站时载货车厢状态, 如是否存在正常状态下的闭合车锁等进行统计时, 主要采取人工观测

和手工记录的方法, 这样不但效率低, 而且容易产生错误. 因此, 为了使货运情况统计自动化, 就需要建立货车自动检测记录系统. 本文针对的问题是, 采集进站货车的图象, 检测货车是否存在正常状态下的闭合车锁(以下简称为车锁), 判别车厢状态, 从而自动记录货车运行情况.

要检测的货车车锁,由于以下原因而呈现出巨大的模式量:(1)种类多;(2)车锁由于长期使用,存在较大的变形,因而即使是同类车锁,也存在较大差异;(3)工作人员在上锁过程中造成锁呈不同形态(随机的);(4)车锁区域通常存在干扰,如涂抹、铅封等不确定因素;(5)光照变化的影响。另外,在下一列货车进站前,系统应完成图象的处理。这就要求系统有较快的处理速度。因此,如何根据货车图象检测是否存在正常状态下的闭合车锁就成为一个极具挑战性的问题。

在像场中,检测物体的基本方法之一是模板匹配法。此法是将所要检测物体的样本与像场中所有位置的物体进行比较,考察是否存在与模板匹配的物体。主要的模板匹配法有传统模板匹配方法^[1]、多模板匹配方法^[2]、可变形模板匹配方法^[3]、基于主元分析的匹配方法^[4]、基于小波变换的多分辨率模板匹配方法^[5]等。概括的说,可以分为基于灰度空间的直接匹配和基于特征空间的间接匹配。由于本文要检测目标的特点,上述方法在使用中,或者不能克服图象的畸变以及巨大的模式量,或者由于计算过于复杂,而难于实际应用。

本文提出了基于RBF神经网络和遗传算法的车锁检测算法。首先选择车锁模板图象并提取车锁的特征,包括一维灰度投影差分特征、边缘图象的线性矩特征,以及灰度直方图特征,这些特征分别从不同侧面反映了目标的特性,它们组合形成的特征向量,将目标映射成特征空间的一个点;然后,将这些特征向量送入RBF神经网络进行训练。采用车锁模板大小的窗口在货车图象中滑动来扫描整幅图象,对每一采样的图象块提取特征,送入训练好的神经网络进行检测。为了提高检测速度,引入遗传算法并进行改进,使匹配由逐点移动变为随机取点,从而极大地提高了匹配速度。由于摄像头一旦固定,所采集的图象大小也就固定,而且车锁大小相差不多,因此本文使用的是固定大小的模板,只要能容纳下最大的车锁即可。

1 车锁特征提取

通常,图象识别过程如图1所示。




图1 图象识别流程图

其中,特征量的选择至关重要。当然,最终的效果还有赖于模式分类器的性能。由于RBF神经网络的特点是通过训练自动形成分类准则,所以只要特征向量具有良好的可分性,经过训练,RBF神经网络就一定会有良好的识别效果。作为待检测目标的车锁,由于种类多,变形大,并且受光照条件变化影响,很难找出具有明显物理意义的特征;另外,由于检测速度要求,也不可能进行过于复杂的变换来提取变换域上的特征。本文从统计观点出发,定义如下4个统计变量

$$\text{平均值 } m = \frac{1}{N} \sum_{k=1}^N f(k) \quad (1)$$

$$\text{能量 } e = \frac{1}{N} \sum_{k=1}^N f^2(k) \quad (2)$$

$$\text{标准方差 } s = \frac{1}{N} \sum_{k=1}^N [f(k) - m]^2 \quad (3)$$

$$\text{平均残差 } a = \frac{1}{N} \sum_{k=1}^N |f(k) - m| \quad (4)$$

然后,从不同侧面——图象的投影差分曲线、边缘图象的线性矩曲线和灰度直方图,提取图象的这4个统计特征,它们分别反映了目标的不同特性,将它们组成特征向量。另外,本文没有单独进行图象预处理,而是将其与特征提取结合在一起,在特征提取的过程中消除图象灰度变化的影响,进一步减少了检测所需时间。


1.1 投影特征

假设车锁模板区域大小为 $M \times N$, $f(m, n)$ 为其中任意一点, $m < M, n < N$, 以向 x 轴投影为例。以左下角为原点,向 x 轴做叠加投影,投影后的一维


图象为 $f_x(m) = \sum_{n=1}^N f(m, n)$, 图2为向 x 轴的投影

和投影后 $f_x()$ 与 x 轴的关系。同理,向 y 轴投影后的一维图象为 $f_y(n) = \sum_{m=1}^M f(m, n)$ 。

为克服光照变化带来的影响,考虑到相邻像素灰度值之间的相对大小关系并不随着图象灰度的线性变化而变化,因此对一维投影进行差分处理^[6],即在相邻的两个数据中用后面的投影减去前面的投影,并取绝对值 $DifD[i] = |D[i] - D[i-1]|$, Dif 表示求差分。这样一个长度为 M 的一维数据,可以得到长度为 $M-1$ 的一维差值字符串。计算一维投影差分后曲线的平均值、标准方差、能量、平均残差,并将它们作为投影差分曲线的特征参数。



(a) 向 x 轴投影



(b) 投影数据与 x 轴的关系

图 2 投影示意图

1.2 边缘图象的线性矩特征

图象边缘是图象中相对稳定的信息,它受外界条件的影响相对较小,通过提取图象边缘,可以有效地去除光照变化的影响.采用基于侧抑制竞争原理提取图象边缘的方法^[7],不仅能有效提取图象边缘,而且提取的边缘不移位,克服了一些常用方法提取图象边缘特征中存在的不足,并且算法简单,便于实时提取边缘.首先建立图象网络结构,使每个像素与它周围 8 个像素相互联系,再计算该像素的侧抑制竞争系数,抑制竞争系数反映了该点的边缘特性,像素抑制竞争系数为

$$R_0(m,n) = I_0(m,n) - \alpha \times \left| \sum_{i=-1}^1 \sum_{j=-1}^1 I_0(m+i,n+j) - I_0(m,n) \right| \quad (5)$$

式中, $I_0(m,n)$ 是 (m,n) 点的灰度值, $R_0(m,n)$ 是 (m,n) 点的抑制竞争系数, α 是侧抑制系数,通常取 α 值为 $0.125 < \alpha < 0.150$,根据式(5),选定 $\alpha = 0.133$,将 α 值带入下式

$$I(m,n) = \begin{cases} 1 & R_0(m,n) > 0 \\ 0 & R_0(m,n) \leq 0 \end{cases} \quad (6)$$

式中, $I(m,n)$ 是竞争后 (m,n) 点灰度值,“1”表示边缘,“0”表示非边缘.竞争中胜利时, $R_0(m,n)$ 大于等于 0,失败时, $R_0(m,n)$ 小于 0.

提取图象边缘,得到二值边缘图象后,计算图象的线性矩特征^[8],二值图象的线性矩描述如下:一幅含有物体的二值图象可以表述为

$$f(m,n) = \begin{cases} 0 & (m,n) \in \text{物体} \\ 1 & (m,n) \in \text{物体} \end{cases} \quad (7)$$

在图象上的初始参考点 $C_0 = (m_0, n_0)$ 定义如下

$$\begin{cases} m_0 = \min(m; \exists n, \text{使得 } f(m,n) = 1, n = 0, 1, \dots, N-1; \\ \quad \quad \quad m = 0, 1, \dots, M-1) \\ n_0 = \min(n; \exists m, \text{使得 } f(m,n) = 1, m = 0, 1, \dots, M-1; \\ \quad \quad \quad n = 0, 1, \dots, N-1) \end{cases} \quad (8)$$

在图象上,定义行、列上的矩向量 M_{row} 和 M_{col} ,以 M_{row} 为例说明.设 M_{row} 矩向量的元素个数为 $Count_{row}$,第 k 个元素记为 $M_{row}[k]$ ($Count_{row} \leq N$,第 k 个矩元素的行扫描线是图象的第 $\lceil \frac{N}{Count_{row}} k + 0.5 \rceil$ 行, $\lceil \cdot \rceil$ 表示取整)在扫描线上,有黑线段 $B_{k,i}$ 和白线段 $W_{k,i}$,其中, $B_{k,i}$ 表示物体的一个分段, $W_{k,i}$ 表示背景的一个分段,记 $1 \leq i \leq Count_{row_k}$, $Count_{row_k}$ 为第 k 个元素的扫描线上黑线段的数目.同时记 $L_{k,i}$ 为 $B_{k,i}$ 的长度, $C_{k,i}$ 为 $B_{k,i}$ 的中心点.有

$$M_{row}[k] = \sum_{i=1}^{Count_{row_k}} (C_{k,i} - C_0) \cdot L_{k,i} \quad (9)$$

可以看到,矩向量的大小与黑线段的数目、长度、位置间隔成正比关系.定义线性矩为

$$lm_{row}[k] = \frac{M_{row}[k]}{\sum_{k=1}^{Count_{row}} M_{row}[k]} \quad (10)$$

可以推导证明,线性矩是平移、伸缩不变的.证明如下:

记行向伸缩因子为 S ,平移后的中心点为 $\tilde{C}_{k,i}$,图象中物体的初始点为 \tilde{C}_0 ,则

$$\tilde{C}_{k,i} - \tilde{C}_0 = S \cdot (C_{k,i} - C_0), \tilde{L}_{k,i} = S \cdot L_{k,i}$$

从而

$$\begin{aligned} \tilde{M}_{row}[k] &= \sum_{i=1}^{Count_{row_k}} (\tilde{C}_{k,i} - \tilde{C}_0) \cdot \tilde{L}_{k,i} \\ &= S^2 \cdot \sum_{i=1}^{Count_{row_k}} (C_{k,i} - C_0) \cdot L_{k,i} \\ &= S^2 \cdot M_{row}[k] \end{aligned}$$

所以有

$$\begin{aligned} \tilde{lm}_{row}[k] &= \frac{\tilde{M}_{row}[k]}{\sum_{k=1}^{Count_{row}} \tilde{M}_{row}[k]} = \frac{S^2 \cdot M_{row}[k]}{\sum_{k=1}^{Count_{row}} S^2 \cdot M_{row}[k]} \\ &= lm_{row}[k] \end{aligned} \quad (11)$$

即 $lm_{row}[k]$ 是平移、伸缩不变的.计算线性矩的平均值、标准方差、能量和平均残差,并将其作为线性矩曲线的特征参数.

1.3 直方图特征

直方图反映了图象在灰度空间的统计特征,为

了消除光照带来的灰度变化影响,在计算直方图前先对图象进行如下变换

$$f'(m,n) = \frac{(f(m,n) - \bar{F}(m,n) + 255) \times 255}{\max(f(i,j) - \bar{F}(i,j) + 255)} \quad (12)$$

式中, $i=1, \dots, M, j=1, \dots, N, f'(m,n)$ 为变换后像素灰度值, $f(m,n)$ 为变换前像素灰度值, $\bar{F}(m,n)$ 代表整幅图象, $\bar{F}(m,n)$ 为该图象灰度平均值。

上述变换相当于减去图象灰度的平均值,并进行灰度变换,将图象重新变为 $0 \sim 255$ 级灰度之间,从而消除灰度变化的影响。计算灰度变换后图象直方图的平均值、标准方差、能量和平均残差,并将其作为直方图的特征参数。

1.4 特征向量的形成

组合上述特征参数形成特征向量,并进行统计标准化后作为神经网络的输入向量。统计标准化的方法如下:设特征向量为 $\{x_i, i=1, 2, \dots, N\}$, 则

$$\begin{aligned} \bar{x} &= \frac{1}{N} \sum_{i=1}^N x_i \\ V_{ar} &= \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \\ x_i^{norm} &= \frac{(x_i - \bar{x})}{\sqrt{V_{ar}}} \end{aligned} \quad (13)$$

其中, x_i^{norm} 为统计标准化后的特征。

2 神经网络和遗传算法

2.1 RBF神经网络的构造和训练

在提取了目标图象的特征后,需要将其送入分类器进行相似性判别。由于要检测目标的图象有畸变,且模式量巨大等,难以采用传统的相似性度量方法,为此采用人工神经网络(ANN)作为相似性度量。人工神经网络由于具有极强的容错性、鲁棒性以及广泛的学习能力,因此能够有效地克服传统相似性度量算法的缺点。尽管训练过程需要一定的时间花费,但是一经训练完毕,神经网络就可以快速地处理数据。

近年来在图象识别领域研究较多的径向基函数(RBF)神经网络,与基于BP算法的多层感知器(MLP)相比,具有更强的局部聚类能力,具有不会陷入局部最小、训练周期更短等优点。

RBF神经网络是融合了参数化的高斯统计密度分布模型和非参数化的单层感知器映射模型的一种前向神经网络模型,一般由输入层、RBF层和输出层3层组成,相邻两层之间采用全连接的方式。

RBF层的神经元一般采用高斯函数作为激励函数,通过输入层到维数足够高的RBF层的非线性映射,结合RBF层到输出层的线性映射,完成从输入模式到输出类别的模式分类。

RBF网络输入层的单元数就是上述特征参数的个数12。输出层的单元数为1。根据多次实验结果,在检测时,设阈值 $T_{out} = 0.8$,若对某一输入产生的输出 O_{RBF} 大于 T_{out} ,则认为找到正常状态下的闭合车锁,说明当前车厢状态正常。

RBF层神经元个数和聚类算法是影响RBF神经网络性能的重要因素。一般是在预先确定结点数后,采用硬聚类算法来进行,但如能自适应地确定合适的神经元数,便可以更准确地获取训练样本的分布信息。基于以上要求,这里对RBF层采用APC(Automatic Pattern Clustering)算法^[9]。APC算法只需对训练集中的所有样本进行一次计算即可完成对所有样本的聚类。又因为APC算法能够基于训练样本的分布确定聚类的半径,所以它能产生合适的聚类数。

确定了RBF层神经元聚类中心和参数后,网络的训练任务就是学习得到合适的输出层权值。不同于RBF层,采用的是非线性优化策略,输出层对线性权值进行调整。对于输出层的训练可以有多种算法,本文使用正交最小二乘算法(Orthogonal Least Square—OLS)。

这里需要注意的是训练样本的选取。由于神经网络的输出只有两种状态,因此相应的样本分为正样本和反样本两类。正样本容易确定,即正常状态下的闭合车锁模板所产生的特征向量,其对应的网络理想输出为1,而反样本需要在训练过程中确定(如非闭合状态车锁的特征以及其他干扰图象块的特征)。首先选择含有一定正样本数的样本集,用APC算法进行聚类,得到聚类中心和高斯函数的宽度,再用OLS算法对输出层进行训练,训练完成后,使用该神经网络在货车图象中搜索,若对图象进行了正确的检测(即如果存在闭合车锁,系统正确找到了;如果不存在闭合车锁,系统没有误判),则换下一幅图象,直到其发生错误。此时,发生错误的图象块就是反样本,其对应的网络理想输出为0,提取特征后,与上述正样本组成样本集重新聚类和训练,如此反复这个过程。在聚类和训练时,正样本与反样本要交叉地组织输入神经网络,这样可以防止同类样本对权值修正过大产生震荡,直至训练误差小于设定值,此时的RBF网络就为最终的神经网络。在实际使用

中,当出现新的闭合车锁没有被正确检测出来,或者错误地将其他区域误认为闭合车锁,都可以将它们加入样本集中,然后对包含新样本的样本集重新聚类和训练,得到新的 RBF 网络用于检测。可以看出,由于采用了神经网络,系统可根据情况进行自适应调整,从而具有极大的灵活性。

2.2 遗传算法在图象匹配中的应用

通常用模板匹配进行识别,是在全图进行搜索,匹配位置多,计算量大,且浪费时间,为解决这一问题,缩短匹配时间,在匹配过程中引入了遗传算法(GA)^[10],使逐个像素全图象搜索变为随机取点搜索,通过 GA 的进化功能,由适当的适应度函数指导其搜索过程向最优点进化,大大减少了运算量。

将 GA 与 RBF 神经网络联系起来进行图象匹配,要解决如下两个问题:(1)构造适当的适应度函数;(2)将问题的解编码到基因串中,定义物体匹配的适应度函数为

$$f(x, y) = O_{RBF}(x, y) \quad (14)$$

式中, x, y 为模板在图象中移动的位置坐标; O_{RBF} 为 RBF 神经网络在 (x, y) 点处的输出, (x, y) 构成了解空间的两个 2 个待寻参数。

解参数编码的基因串为

$$S = \{x, y\} \quad (15)$$

在具体算法实现时,每个参数采用 8bit 的二进制编码,则每个基因串由 8×2 bit 的二进制串组成,并形成了一个大小为 2^{16} 的搜索空间。相应的 GA 参数为:种群个体数 $N_g = 80$,最大进化代数 90,变异率 P_m 和交叉率 P_c 。

为使 GA 算法能更有效地搜索到全局最优解,对 GA 进行以下几点改进:

(1)均匀交叉互换算子 从父母染色体中以一定概率(0.5)随机选取等位基因而构成两个子代染色体,它可以改善单点和双点交叉的局限性,提高遗传搜索效率。

(2)自适应选择交叉率和变异率(Adaptive GA) 交叉概率 P_c 和变异概率 P_m 按下式随适应度自动改变^[11]

$$P_c = \begin{cases} \frac{k_1 \times (f_{\max} - f')}{f_{\max} - \bar{f}} & f' \geq \bar{f} \\ k_3 & f' < \bar{f} \end{cases} \quad (16)$$

$$P_m = \begin{cases} \frac{k_2 \times (f_{\max} - f')}{f_{\max} - \bar{f}} & f' \geq \bar{f} \\ k_4 & f' < \bar{f} \end{cases} \quad (17)$$

式中, f_{\max} 为当前种群最大适应度, \bar{f} 为该代种群的平均适应度, f' 为待交叉父母个体中适应度较大者, f 为变异个体的适应度。其中, $k_1 = k_3 = 1, k_2 = k_4 = 0.5$ 。

这样当种群各个个体适应度趋于一致或局部最优时, P_c 和 P_m 增加,而当种群适应度比较分散时 P_c 和 P_m 减小。

(3)稳态复制技术 稳态复制是指不是简单地以子代代替父代的个体,而是采用父代、子代按适应度排序,固定种群大小,保留适应度最高的部分个体组成新的子代,从而使整个种群表现出不断变化的趋势,使有限的人口空间发挥更大的作用。

(4)适应度的模拟退火拉伸 借鉴模拟退火思想,采用式(18)进行适应度拉伸,可以避免在 GA 早期,个别好的后代充斥整个种群,造成早熟,在 GA 后期,适应度趋向一致,优秀的个体在产生后代时,优势不明显,从而使整个种群进化停滞不前等问题。

$$f_i = \frac{f_i}{N_g} \frac{e^{\frac{f_i}{T}}}{\sum_{i=1}^{N_g} e^{\frac{f_i}{T}}}, T = T_0(0.99^{g-1}) \quad (18)$$

式中, f_i 为第 i 个个体适应度, N_g 为种群个体总数, g 为遗传代数, T 为温度, T_0 为初始温度。

3 算法的实现

图 3 给出了车锁检测系统检测流程图。图 4 给出了遗传算法的流程图。

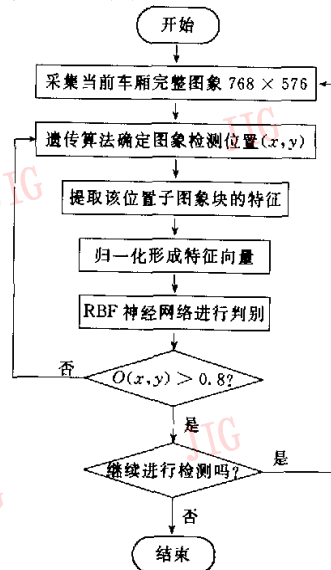


图 3 车锁检测系统检测流程图

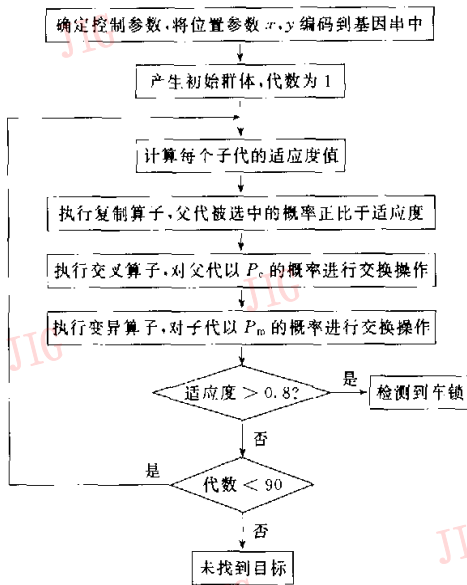


图4 遗传算法流程图

4 实验结果

基于本算法的货车自动检测记录系统,目前正在南京货运站进行测试和运行,取得了较好的效果。系统由 Visual C++ 实现,计算机 CPU 为 P III-800,内存 256MB,操作系统为 WinNT4.0。每过一节车厢采集一幅图象,采集的图象大小为 768×576 pixels,平均每幅图象检测时间为 3s。图 5 为不同情况下的匹配检测结果(由于完整图象过大,因此仅截取了部分图象),其中白色方框为程序运行结果,表示找到了正常状态下的闭合车锁以及车锁的位置。




图5 检测结果

选取晴天,阴天,上午,下午,黄昏以及夜间等各种不同光照条件下的厢式货车图象进行实验,实验结果见表 1。其中,正确判别的含义是正确找到了闭合车锁,由表 1 可以看出,算法具有较高的鲁棒性和准确率。

表 1 实验结果

照明条件	数量 (个)	正确判别 (个)	准确率 (%)	总准确率 (%)
货车图象	上午	150	142	94.7
	下午	150	141	94.0
	黄昏	100	93	93.0
	夜晚	150	143	95.3

5 结论

处于实际应用环境的货车闭合车锁检测,由于车锁种类多、变形大、以及受光照条件变化的影响,并且受检测时间的限制,是一个比较困难的问题。本文通过提取图象的不同特征,如投影特征、边缘图象线性矩特征以及灰度直方图特征,使用 RBF 神经网络进行相似性度量,并结合改进的遗传算法加快检测速度,取得了较好的效果,具有重要的工程实用价值,也为其他类似检测问题开辟了新的途径。

参考文献

- 1 沈庭芝,方子文. 数字图象处理及模式识别[M]. 北京:北京理工大学出版社,1998.
- 2 袁超,张长水. 基于多模板匹配的自动人脸检测[J]. 电子学报,2000,28(3):95~98.
- 3 Yuille A, Cohen D, Hallinan P. Feature extraction from faces using deformable templates[A]. In: Proceedings of the IEEE Computer Society Conference on CVPR[C], San Diego, 1989: 104~109.
- 4 Turk M A, Pentland A P. Face recognition using eigenfaces[A]. In: Proceedings of the International Conference on Pattern Recognition[C], Maui, 1991:586~591.
- 5 蒋晓瑜,黄应清. 基于小波变换的多分辨率模板匹配[J]. 中国图象图形学报,2000,5A(4):304~308.
- 6 孙远,周刚,赵立. 灰度图象匹配的快速算法[J]. 上海交通大学学报,2000,34(8):702~704.
- 7 何世春. 抑制竞争原理的理论与应用研究[D]. 西安:西北工业大学,1994.
- 8 沈会良,李志能. 基于矩和小波变换的数字、字母字符识别研究[J]. 中国图象图形学报,2000,5A(3):249~252.
- 9 高城. 径向基函数神经网络及其在目标图象识别中的应用[D]. 北京:北京理工大学,2001.
- 10 Rudolph G. Convergence analysis of canonical genetic algorithms[J]. IEEE Trans. On Neural Networks, 1994, 5(1):96~101.
- 11 Srinivas M, Patnaik L M. Adaptive probabilities of crossover and mutation in genetic algorithms[J]. IEEE Trans. Syst. Man and Cybernetics, 1994, 24(4):656~667.



严柏军 1973 年生,北京理工大学博士研究生,主要研究方向为计算机视觉、模式识别以及人工智能,已发表论文 6 篇。



郑链 1942 年生,北京理工大学教授、博士生导师,主要从事引信技术、智能信息处理与图象识别技术研究。



蔡宁涛 1977 年生,北京理工大学硕士研究生,主要研究方向为图象处理与模式识别。



王克勇 1972 年生,北京理工大学讲师、在职博士研究生,主要从事智能信息处理与图象识别技术研究。

戴尔推出三款新型工作站 Precision 系列全线升级

日前,戴尔计算机公司推出了戴尔 Precision™650 和 450 两款新型工作站,拥有全新英特尔® 7505 芯片组和英特尔®至强™双处理器技术,随之,还推出了支持英特尔®奔腾®4 单处理器的 Precision350 工作站。

戴尔 Precision650 和 450 拥有速度高达 2.8GHz 的单或双英特尔®至强™处理器、533MHz 前端总线以及超线程技术支持;高达 4GB 的双通道 PC2100 DDR 内存,可选 ECC 功能,支持 4.2GB/秒内存带宽;AGP 8x Pro 以及高性能 PCIx 总线;集成英特尔®Pro64 位千兆以太网网卡和 USB2.0;带有内置 RAID-0 的集成 U320 SCSI 控制卡(在 650 工作站上为标准配置,在 450 工作站上为选装配置)等技术特性。

戴尔 Precision650 为需求最佳的 I/O 设备扩展功能,以及图形与存储性能的工作站用户提供了卓越的性能与可扩展性。戴尔 Precision 450 不仅拥有 650 相近的架构优势,而且其机箱设计更适合于需求双处理器性能而空间有限的环境,如金融贸易桌面系统或群集应用。Precision350 为客户提供了卓越的单处理器性能,其技术特性包括:速度高达 3.06GHz 的英特尔®奔腾®4 处理器、533MHz 前端总线以及超线程技术支持;双通道 PC1066 RDRAM 内存,支持 4.2GB/秒内存带宽;集成千兆以太网卡和 USB2.0。

戴尔 Precision 工作站的客户可尽享三款全新 OpenGL 图形加速卡所带来的优越性能;针对 3D 环境而优化的 ATI FireGL®E1,带有 64MB 显存;面向大规模装配与复杂 3D 环境的 ATI FireGL X1 高性能图形适配器,带有 128MB 显存;配置丰富的 3Dlabs Wildcat®7110 高端图形适配器,带有 256MB 显存。

所有戴尔 Precision 工作站产品都是专为要求独立软件开发商工作站硬件认证的客户端身定制,适用于计算机辅助设计、工程计算、数字内容创作、地理信息系统、电脑动画制作、软件开发以及财务分析等应用。