

基于神经网络的图象序列特征点匹配

汪亚明

(浙江工程学院信息电子学院, 杭州 310033)

摘要 利用神经网络优化技术解决图象序列的特征点匹配问题, 将特征点匹配归结为一个带约束的优化问题, 并用 2D Hopfield 网络实现. 在 Hopfield 网络的能量函数的设计中, 综合考虑了特征点的预测结果、特征点的遮挡等情况, 从而克服了现有的多数方法所存在的误匹配现象. 对于特征点的跟踪, 头 3 帧图象的正确匹配是十分关键的. 本文提出了一种 3D Hopfield 网络用以解决头 3 帧图象的特征点匹配, 并提出了一个运动平滑性的代价函数用以构造 3D Hopfield 网络的能量函数. 实际图象序列的实验结果证明了本方法的有效性.

关键词 图象序列 特征点匹配 特征点跟踪 Hopfield 网络 3D Hopfield 网络

中图法分类号: TP391.41 TP183 文献标识码: A 文章编号: 1006-8961(2002)04-0313-06

Feature Point Correspondence of Image Sequence Based on Neural Networks

WANG Ya-ming

(School of Informatics and Electronics, Zhejiang Institute of Science and Technology, Hangzhou 310033)

Abstract This paper proposes an approach to feature point correspondence of image sequence based on neural networks. We formulate the correspondence problem as a constrained optimization problem and propose a 2D Hopfield neural network to solve it. The design of energy function of neural network has ranged over the results of visual tracking and the condition of occlusion. Therefore, it can solve the problem of error correspondence resulting from current existing methods. The correct correspondence of the first three frames is very important for the point tracking. This paper develops a 3D Hopfield network to handle the correspondence of the first three frames and proposes a cost function of motion smoothness to formulate the energy function of 3D Hopfield network. Experiment on a real image sequence demonstrates the feasibility of the approach.

Keywords Image sequence, Feature point correspondence, Feature point tracking, Hopfield neural network, 3D Hopfield neural network

0 引言

特征点匹配是动态图象序列分析中的一项重要工作, 它的准确度将直接关系到图象序列分析的成败. 对于这一问题, 研究者们作了大量的工作, 他们常常利用一些先验信息或根据图象序列的特点加入某些约束来加以解决, 但现有的方法仍普遍存在着计算较复杂及误配率高的现象. 例如, Sethi 和 Jain

提出了路径连贯(Path Coherence)的概念, 并在此基础上提出了两种不同的迭代算法^[1]. Salari 和 Sethi 以及 Rangarajan 和 Shah 也在类似的约束基础上提出了特征点匹配算法^[2,3]. 这两种匹配方法都需要大量的执行时间, 而且遮挡点(Occluded Point)的定位也存在较大的误差. Jeong 和 Moon 从特征点的空间坐标、特征点运动轨迹的方向及幅度等方面提出了更为详细的约束^[4], 但这种方法仍需要大量的计算时间, 而且遮挡点的定位问题也没有得到

解决. Sanchiz 和 Pla 也仅仅利用了图象帧间特征点的相似性和特征点轨迹的平滑性来进行特征点匹配^[5]. 在特征点的轨迹较复杂时, 这种方法会出现特征点的误配现象, 而且遮挡点的定位问题依旧存在. Mehrotra 的方法采用了特征点在图象帧间的一致性约束, 并且允许特征点轨迹起始于或终止于图象序列中间的某帧图象^[6], 但仍未较好地解决遮挡点的定位问题.

本文采用神经网络优化的方法解决图象序列的特征点匹配问题, 并将匹配的建立问题表述为一个带约束的优化问题. 首先, 用特征点预测的方法预测本帧图象的特征点在下一帧图象中的位置, 然后以点匹配的唯一性及预测点和下一帧图象的特征点之间的最小距离建立 Hopfield 网络的能量函数. 通过 Hopfield 网络的计算, 使预测位置和下一帧图象中的对应特征点建立一一匹配, 从而使下一帧图象中的每一特征点逐一归入本帧图象之前已形成的各运动轨迹之中. 由于在头 3 帧图象中采用特征点预测跟踪将可能会产生较大的误差, 所以在头三帧图象的特征点匹配中, 采用了一种新型的 3D Hopfield 网络优化的方法进行特征点的匹配. 此外, 本文提出了特征点运动的平滑性代价方程, 并在 3D Hopfield 网络能量函数的设计中采用了此代价方程, 使头 3 帧图象的特征点匹配在平滑性的约束下得以完成.

1 特征点的跟踪及运动平滑性代价方程

假设一图象序列含有 n 帧图象, $S = \{I_1, I_2, \dots, I_n\}$, 且每帧图象中的特征点位置已事先获得. 对应于图象 I_i , 特征点的位置为 $P_i^1, P_i^2, \dots, P_i^m$. 其中 P_i^j 是二维位置向量, 它代表第 j 个特征点在第 i 帧图象中的位置坐标, m 代表了第 i 帧图象特征点的总数.

在此可以建立特征运动的常加速度模型, 并用 Kalman 滤波的方法得到特征点在下一帧图象中的预测位置. 由于状态方程和观测方程都是线性的, 所以可以用两个标准的卡尔曼滤波器^[7]分别对两个坐标进行预测跟踪. 具体内容请参阅文献[8], 这里不再赘述.

对于相邻的 3 帧图象 I_{t-1}, I_t 和 I_{t+1} 中的某 3 点 P_{t-1}^i, P_t^i 和 P_{t+1}^k 所组成的轨迹段, 用下式来度量它的平滑性^[8]:

$$T(P_{t-1}^i, P_t^i, P_{t+1}^k) = w_1 V(P_{t-1}^i, P_t^i, P_{t+1}^k) + w_2 D(P_{t-1}^i, P_t^i, P_{t+1}^k) \quad (1)$$

其中, w_1 和 w_2 为权系数, 它们的大小通过实验的方法确定. $V(P_{t-1}^i, P_t^i, P_{t+1}^k)$ 用来度量运动速度的平滑性, 且有

$$V(P_{t-1}^i, P_t^i, P_{t+1}^k) = \frac{\| \overrightarrow{P_{t-1}^i P_t^i} - \overrightarrow{P_t^i P_{t+1}^k} \|}{\max_{m,n,r} \| \overrightarrow{P_{t-1}^m P_t^n} - \overrightarrow{P_t^n P_{t+1}^r} \|} \quad (2)$$

其中, $1 \leq m \leq |I_{t-1}|$, $1 \leq n \leq |I_t|$ 以及 $1 \leq r \leq |I_{t+1}|$. $|I_i|$ 代表第 i 帧图象中特征点的总数. 当速度变化越平滑时, $V(P_{t-1}^i, P_t^i, P_{t+1}^k)$ 的值越小, 且有 $0 \leq V(P_{t-1}^i, P_t^i, P_{t+1}^k) \leq 1$. $D(P_{t-1}^i, P_t^i, P_{t+1}^k)$ 用来度量轨迹方向变化的平滑性, 且有

$$D(P_{t-1}^i, P_t^i, P_{t+1}^k) = 1 - \frac{\| \overrightarrow{P_{t-1}^i P_t^i} \cdot \overrightarrow{P_t^i P_{t+1}^k} \|}{\| \overrightarrow{P_{t-1}^i P_t^i} \| \cdot \| \overrightarrow{P_t^i P_{t+1}^k} \|} \quad (3)$$

当轨迹方向变化越平滑时, $D(P_{t-1}^i, P_t^i, P_{t+1}^k)$ 的值越小, 且有 $0 \leq D(P_{t-1}^i, P_t^i, P_{t+1}^k) \leq 1$. 所以式(1)从整体上描述了轨迹运动的平滑性.

2 用神经优化法确立特征点的匹配

在目标跟踪中, 必须在收到观测数据和运动轨迹计算之前, 先确定观测数据与目标的对应关系. 这是目标跟踪中非常重要的一环, 因为只有走完这一步, 才可以根据状态方程和观测方程, 进行滤波和预测^[9]. 对应于图象序列的特征点匹配问题而言, 就是在假设第 K 帧图象之前的特征点运动轨迹已确立的前提下, 根据第 K 帧图象的特征点在第 $K+1$ 帧图象中的预测位置, 使第 $K+1$ 帧图象中的特征点与已确立的运动轨迹得到正确的关联. 轨迹的正确关联是序列图象特征点匹配的关键, 当某帧图象中的轨迹关联发生错误时, 将有可能使后续的运动轨迹也发生错误, 从而使后续的特征点匹配变得毫无意义.

根据特征点运动的平滑性, 第 K 帧图象中的特征点在第 $K+1$ 帧图象中的预测位置与第 $K+1$ 帧图象中相匹配的实际特征点位置之间的距离应较小, 且第 K 帧图象的特征点与第 $K+1$ 帧图象的特征点完成匹配后, 第 $K-1$ 帧、第 K 帧及第 $K+1$ 帧图象的特征点所形成的运动轨迹应呈现一定的平滑性. 下面用 Hopfield 网络^[10]进行优化处理, 使第 K 帧图象的特征点和第 $K+1$ 帧的特征点得到一一匹配.

用于特征点匹配的 Hopfield 网络由一个 2D 的神经元阵列组成(如图 1 所示), 阵列的行与列分别对应于第 K 帧图象的特征点以及第 $K+1$ 帧图象中的实际特征点. 每个神经元的输出和输入满足下式

$$v_{ix} = 0.5 \times \left| 1 + \tanh \left| \frac{u_{ix}}{u_0} \right| \right| \quad (4)$$

其中, u_0 为网络的增益参数, 输出 v_{ix} 反映了预测点 i 和实际特征点 j 之间的匹配程度, 0 与 1 之间的任何值反映了点间匹配的置信度. 当 v_{ix} 为 0 时, 表示完全不匹配, 当 v_{ix} 为 1 时, 表示完全匹配.

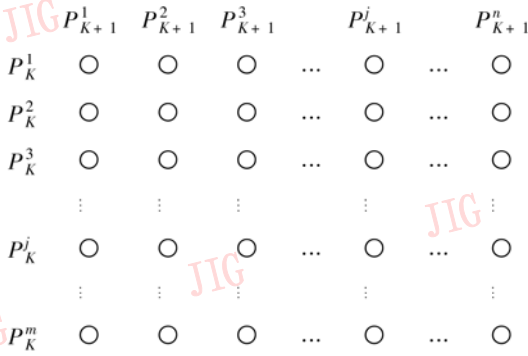


图 1 用于两帧图象间特征点匹配的 Hopfield 网络

网络的能量函数定义如下

$$E = \frac{A}{2} \sum_{i=1}^m \sum_{x=1}^n \sum_{y=1, y \neq x}^n v_{ix} v_{iy} + \frac{B}{2} \sum_{x=1}^n \sum_{i=1}^m \sum_{j=1, j \neq i}^m v_{ix} v_{jx} + \frac{C}{2} \left| \sum_{i=1}^m \sum_{x=1}^n v_{ix} - n \right|^2 + \frac{D}{2} \sum_{i=1}^m \sum_{x=1}^n v_{ix} d_{ix} + \frac{E}{2} \sum_{i=1}^m \sum_{x=1}^n \sum_{j=1, j \neq i; y=1, y \neq x}^m \sum_{y=1}^n M_{ixjy} v_{ix} v_{jy} \quad (5)$$

其中, A, B, C, D 和 F 为常数; m, n 分别为第 K 帧和第 $K+1$ 帧图象的特征点的总数. d_{ix} 代表第 K 帧图象的特征点 i 在第 $K+1$ 帧图象中的预测点与第 $K+1$ 帧图象中的实际特征点 x 之间的欧氏距离. M_{ixjy} 反映了神经元 v_{ix} 和 v_{jy} 之间的相容性 (Compatibility).

式(5)的第 1 项和第 2 项保证了网络在稳态时, 每行和每列至多有一个神经元的输出为非 0, 而其他神经元的输出为 0; 第 3 项保证了阵列中只有 n 个神经元的输出为 1, 即, 图象帧间有 n 对特征点取得匹配, 从而在网络稳态时每行每列只有一个神经元的输出为 1, 当 $n < m$ 时, 表明第 $K+1$ 帧图象的特征点存在遮挡现象; 第 4 项执行最小距离映射, 它使得网络稳定时, 所有预测点和对应的实际特征点的距离和为最小; 第 5 项为相容性约束, 针对特征点匹配问题而言, 就是运动平滑的相似性约束. M_{ixjy} 可用下式定义

$$M_{ixjy} = \alpha_1 f_a(P_K^i, P_{K+1}^x) + \alpha_2 f_a(P_K^j, P_{K+1}^y) + \alpha_3 f_b(P_K^i, P_{K+1}^x) + \alpha_4 f_b(P_K^j, P_{K+1}^y) \quad (6)$$

其中,

$$f_a(P_K^i, P_{K+1}^x) = \begin{cases} 1 & \text{if } V(P_{K-1}^i, P_K^i, P_{K+1}^x) < \epsilon_1 \\ -1 & \text{otherwise} \end{cases} \quad (7)$$

$$f_b(P_K^j, P_{K+1}^x) = \begin{cases} 1 & \text{if } D(P_{K-1}^j, P_K^j, P_{K+1}^x) < \epsilon_2 \\ -1 & \text{otherwise} \end{cases} \quad (8)$$

这里, 需要说明的是, 从第 2 帧图象起, 当某帧图象的特征点已与前一帧图象的特征点完成了匹配时, 该图象中特征点的次序应重新排列, 每一特征点的编号为从第 1 帧图象起穿过该点的轨迹号. 例如, 当第 K 帧图象与第 $K+1$ 帧完成特征点对应后, 从第 1 帧图象起的第 j 条轨迹穿过第 $K+1$ 帧图象中的某特征点, 则应将该点重新记为 P_{K+1}^j .

标准的 2D Hopfield 神经网络的能量函数为

$$E = -\frac{1}{2} \sum_i \sum_j \sum_x \sum_y W_{ixjy} v_{ix} v_{jy} - \sum_i \sum_x i_{ix} v_{ix} \quad (9)$$

将式(9)与式(5)相比, 可以得出神经元 (i, x) 与神经元 (j, y) 之间的连接权 W_{ixjy} 和神经元的偏置 i_{ix} 分别为

$$W_{ixjy} = -A \delta_{ij} (1 - \delta_{xy}) - B \delta_{xy} (1 - \delta_{ij}) - C - F M_{ixjy} (1 - \delta_{ij}) (1 - \delta_{xy}) \quad (10)$$

$$i_{ix} = Cn - \frac{D}{2} d_{ix} \quad (11)$$

式中, δ_{ij} 的定义为

$$\delta_{ij} = \begin{cases} 1 & (i = j) \\ 0 & (i \neq j) \end{cases} \quad (12)$$

神经元 (i, x) 处的动态方程为

$$\frac{du_{ix}}{dt} = \sum_i \sum_x W_{ixjy} v_{jy} - \frac{u_{ix}}{\tau} + i_{ix} \quad (13)$$

其中, τ 为时间常数. u_{ix} 可按下式进行差分近似

$$u_{ix}(t+1) = u_{ix}(t) + \left| \sum_i \sum_x W_{ixjy} v_{jy} - \frac{u_{ix}}{\tau} + i_{ix} \right| \Delta t \quad (14)$$

这样, 将式(10)及式(11)代入式(14)就可以进行网络的迭代运算.

在发生遮挡现象时, 遮挡特征点的位置可由未得到匹配的特征点的预测位置代替. 例如, 在计算第 K 帧图象与第 $K+1$ 帧图象的特征点匹配时, 第 $K+1$ 帧图象中有一个特征点被遮挡了, 并假设第 K 帧图象中有一特征点 P_K^i 尚未得到匹配处理, 那么就将这一特征点在第 $K+1$ 帧图象中的预测位置 P_K^i 作为被遮挡点的位置.

3 用 3D Hopfield 网络完成头三帧图象的特征点匹配

在头 3 帧图象的特征点匹配中, 由于特征点预测跟踪的误差较大, 所以将不采用特征点的预测跟踪方法, 而是直接从特征点运动的平滑性出发, 用 3D Hopfield 网络进行特征点匹配. 在此, 假设头 3 帧图象中没有遮挡现象发生, 即, 每帧图象均含有 m 个特征点.

用于头 3 帧图象点匹配的 3D Hopfield 网络如图 2 所示, 三维神经元阵列分别对应于第 1 帧、第 2 帧和第 3 帧图象的特征点. 网络中的各神经元呈对称连接, 且各神经元无自连接. 当网络趋于稳态时, 各神经元的输出代表了 3 帧图象中特征点的匹配情况. 例如: 图 2 中的某一神经元的输出 v_{ixp} 代表了第 1 帧图象的第 i 个特征点、第 2 帧图象的第 x 个特征点和第 3 帧图象的第 p 个特征点的匹配情况, 当 $v_{ixp} = 1$ 时, 表明这 3 个特征点是相互匹配的, 当 $v_{ixp} = 0$ 时, 表明这 3 个特征点相互不匹配. 图中 W_{jyqip} 代表了 v_{ixp} 到 v_{jyq} 的连接权.




图 2 用于头 3 帧图象特征点匹配的 3D Hopfield 网络

网络中神经元的输出 v_{ixp} 和输入满足

$$v_{ixp} = 0.5 \times \left| 1 + \tanh \left| \frac{u_{ixp}}{u_0} \right| \right| \quad (15)$$

网络的能量函数定义如下

$$E_{3D} = \frac{A_{3D}}{2} \left| \sum_{i=1}^m \left| \sum_{x=1}^m \sum_{p=1}^m v_{ixp} - 1 \right|^2 + \sum_{x=1}^m \left| \sum_{i=1}^m \sum_{p=1}^m v_{ixp} - 1 \right|^2 + \sum_{p=1}^m \left| \sum_{i=1}^m \sum_{x=1}^m v_{ixp} - 1 \right|^2 \right|$$

$$\frac{B_{3D}}{2} \sum_i^m \sum_x^m \sum_p^m v_{ixp} T(P_1^i, P_2^x, P_3^p) \quad (16)$$

其中, A_{3D} 和 B_{3D} 为常数; $T(P_1^i, P_2^x, P_3^p)$ 为式(1)所定义的平滑代价函数. 式中的第 1 项保证了网络在稳态时, 垂直于各坐标轴的每一神经元平面阵列中只有一个神经元的输出为 1, 同时也保证了整个三维神经元阵列只有 m 个神经元的输出为 1, 这就确保了前 3 帧图象中的特征点得到一一匹配. 式中的第 2 项执行最小平滑映射, 它使得网络稳定时, 特征点匹配结果的平滑代价之和为最小.

根据文献[11], 3D Hopfield 网络的能量函数可表述为下式的形式

$$E_{3D} = - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \sum_{x=1}^m \sum_{y=1}^m \sum_{p=1}^m \sum_{q=1}^m W_{ixpjyq} v_{ixp} v_{jyq} - \sum_{i=1}^m \sum_{x=1}^m \sum_{p=1}^m v_{ixp} i_{ixp} \quad (17)$$

比较式(16)与式(17), 可以得到神经元 (i, x, p) 和神经元 (j, y, q) 之间的连接权 W_{ixpjyq} 和神经元的偏置 i_{ixp} 分别为

$$W_{ixpjyq} = - A_{3D} (\delta_{ij} + \delta_{xy} + \delta_{pq}) \quad (18)$$

$$i_{ixp} = 3A_{3D} - \frac{B_{3D}}{2} T(P_1^i, P_2^x, P_3^p) \quad (19)$$

神经元 (i, x, p) 处的动态方程为

$$\frac{du_{ixp}}{dt} = \sum_{i=1}^m \sum_{x=1}^m \sum_{p=1}^m W_{ixpjyq} v_{jyq} - \frac{u_{ixp}}{\tau_{3D}} + i_{ixp} \quad (20)$$

其中, τ_{3D} 为时间常数, u_{ixp} 可按式求得数值解

$$u_{ixp}(t+1) = u_{ixp}(t) + \left| \sum_{i=1}^m \sum_{x=1}^m \sum_{p=1}^m W_{ixpjyq} v_{jyq} - \frac{u_{ixp}}{\tau_{3D}} + i_{ixp} \right| \Delta t_{3D} \quad (21)$$

这样, 将式(18)和式(19)代入式(21)即可进行 3D Hopfield 网络的迭代运算.

将特征点匹配实现步骤总结如下:

(1) 将头 3 帧图象的特征点用 3D Hopfield 网络进行匹配. Kalman 滤波从第 1 帧图象开始. 根据特征点的匹配结果更新 Kalman 滤波器的参数. 第 3 帧以后的图象的特征点匹配从步骤 2 开始进行.

(2) 用两个卡尔曼滤波器预测各轨迹在下一帧图象中的位置.

(3) 根据所得到的预测点的位置, 将本帧图象与下一帧图象用 2D Hopfield 神经优化法进行一一匹配, 对应结果将下一帧图象中的特征点分别归入不同的运动轨迹. 当下一帧图象发生遮挡现象时, 用本图象中未经匹配的特征点的预测位置代替被遮挡

瞪点的位置.


(4) 以下一帧图象中的对应特征点位置作为测量值, 并以此更新卡尔曼滤波器的参数.

(5) 当所有图象都经过处理后, 则结束运算. 否则, 转至步骤 2.


4 实验分析

用一跛行者行走的图象序列验证本文算法, 该图象序列共有 23 帧 256×256 点阵图象. 图 3(a) 列出了序列的第 1、第 8、第 15 和第 23 帧图象. 图象中各关节位置都用亮斑标出. 取特征点的位置为亮斑的中心位置, 图象序列的所有特征点位置如图 3(b) 所示. 本图象序列的第 1、第 2 和第 3 帧图象中没有


遮挡现象. 用本文的方法对特征点进行对应, 2D Hopfield 网络的各参数取为: $A = 20, B = 20, C = 12, D = 20, F = 30, \tau = 1, \Delta t = 0.0001$. 3D Hopfield 网络的各参数取为: $A_{3D} = 50, B_{3D} = 40, \tau_{3D} = 1, \Delta t_{3D} = 0.0001$; 平滑代价方程中 w_1 取 0.8, w_2 取 0.2; 式(5)中的 μ_0 取 0.02; 式(6)中的 α_i 和 α_e 各取 0.2, α_s 和 α_t 均取 0.3; 式(7)中的 ϵ_1 和 ϵ_2 均取 0.8. 在这里, 3D Hopfield 网络迭代 212 次收敛, 帧间的 2D Hopfield 网络迭代不超过 20 次便可收敛. 特征点匹配的结果如图 3(c) 所示. 本序列中的有些帧图象存在遮挡现象, 图 3(c) 中的“o”代表了这些被遮挡点的位置. 实验证明, 本文的方法对图象序列的特征点匹配有着良好的效果.



(a) 原始图象序列



(b) 图象序列各帧的特征点位置



(c) 特征点匹配结果, “o”代表被遮挡点的位置

图 3 一人体行走图象序列的特征点匹配

5 结 论

本文根据特征点预测跟踪的结果将两帧图象之间特征点的匹配归结为一个带约束的优化问题, 并

用 2D Hopfield 神经网络加以实现. 在头 3 帧的图象匹配中, 本文提出了特征点运动的平滑代价方程, 并用 3D Hopfield 实现平滑代价最小化以实现头 3 帧图象特征点的正确匹配. 本文的方法能解决除头 3 帧以外各图象中的特征点遮挡问题.

参考文献

- 1 Sethi I K, Jain R. Finding trajectories of feature point in a monocular image sequence[J], IEEE Trans. PAMI, 1987, 9(1): 56~ 72.
- 2 Salari V, Sethi I K. Feather point correspondence in the presence of occlusion[J], IEEE Trans. PAMI, 1990, 12(1): 87~ 91.
- 3 Rangarajan K, Shah M. Establishing motion correspondence [A], In: Proc. IEEE Conf. CVPR[C]. Maui, Hawaii, 1991: 103~ 108.
- 4 Jeong J M, Moon Y S. A feature tracking algorithm using adaptive weight adjustment [J]. Journal of the Institute of Electronics Engineers of Korea S, 1999, 36(11): 68~ 78.
- 5 Sanchez J M, Pla F. Feature correspondence and motion recovery in vehicle planar navigation [J]. Pattern Recognition, 1999, 32(12): 1961~ 1977.
- 6 Mehrotra R. Establishing motion-based feature point correspondence[J]. Pattern Recognition, 1998, 31(1): 23~ 301.
- 7 Brown R G. Introduction to random signal analysis and Kalman filtering[M]. New York: Wiley, 1983.
- 8 汪亚明, 楼正国等. 一种非刚体图象序列的特征点对应. 中国图象图形学报, 2000, 5A(3): 232~ 236.
- 9 Zhang Z. Token Tracking in a cluttered scene[J]. Image and Vision Computing, 1994, 12(2): 110~ 120.
- 10 胡上序, 程翼宇. 人工神经网络计算导论[M]. 北京: 科学出版社, 1994.
- 11 Huang C L, Huang W Y. Sign language recognition using model-based tracking and a 3D hopfield neural network [J]. Machine Vision and Applications, 1998, 10(5~ 6): 292~ 307.



汪亚明 1972年生, 博士, 浙江工程学院信息电子学院副教授. 主要研究方向为计算机视觉、机电控制及自动化.

IBM 推出 IntelliStation M Pro 图形工作站

IBM IntelliStation 图形工作站家族最近又将有新品上市, IBM 近日在美国宣布推出了采用功能强劲的 2.2GHz 英特尔 4 处理器的新款 IntelliStation M Pro 工作站. 新型 IntelliStation M PRO 采用了先进的技术, 它以其卓越的性能、强劲的 2D 和 3D 表现能力和超强的稳定性以及出色的应用程序兼容性和系统可靠性显示出了非凡的实力.

新款 IntelliStation M Pro 采用主频高达 2.2GHz 的英特尔 4 奔腾处理器, 具有 400MHz(4× 100) 前端总线, 256KB 高速 L2 缓冲存储器, 具有 4 个 RDRAM RIMM 插槽, 最高可支持 4GB 的 ECC Rambus 高速内存. 硬盘为转速为 10000 转/分的 18.2GB ULTRA 160 S. M. A. R. T. SCSI 硬盘或转速为 7200 转/分的 40GB ATA-100 EIDE 硬盘. 系统配置了最高可达 48 倍速的 CD-ROM 驱动器, 并预装了微软的 Windows 2000 操作系统(用户也可以选择恢复为 Windows NT 4.0)

IBM 为有不同需求的用户提供了不同的图形解决方案: 具有高性能 2D 表现力的 Matrox Millennium G450 适配器, 16MB 显存; 具有先进的 2D/3D 功能的 NVIDIA Quadro2 PRO 适配器, 64MB 显存; 对于追求极品 3D 效果的用户, IBM 提供了具有 128MB 显存的 Fire GL4 图形适配器.

IntelliStation M Pro 采用了灵活的微塔式设计, 内置 6 个插槽(5 个 PCI 插槽和一个 AGP 插槽)、7 个扩展坞和三个风扇, 有两个 9 针串行接口, 一个 25 针并行接口和两个 USB 接口, 具有极强的可扩展性. 这套系统同样具有集成的以太网接口.

IBM IntelliStation 同时还提供了大量的应用程序和多种先进的系统管理, 为用户的使用和对系统的管理和维护提供了极大的方便.