

基于形态学变权神经网络的数据精炼

景晓军¹, 余 农²

(1. 北京邮电大学, 北京 100876; 2. 中国科学院上海技术物理研究所, 上海 200083)

摘 要: 本文研究了模式样本的选取操作要领和典型样本数据的精炼方法. 为改善神经网络普遍存在着误差精度与收敛速率对初始权值颇为敏感甚至过于依赖的缺陷, 采用感受野的 Gabor 函数模型来优化网络权值的初始量. 这不仅能为学习过程提供一个良好的开端, 重要的是将赋予网络模型以具备可塑性优化的基础和适应环境变化的潜力. 算法运用主成份数学分析法对结构元分量的贡献率进行了统计度量与计算, 以提取出对滤波运算最具影响力的主要分量, 从而可显著降低数据处理量, 使运行速度和学习效率更高.

关键词: 计算机视觉; 图像处理; 数学形态学; 数据精炼; 状态优化

中图分类号: TP317.4 **文献标识码:** A **文章编号:** 0372-2112(2005)03-0397-05

Data Abstraction Based on Morphological Adjusted-Weight Neural Network

JING Xiaojun¹, YU Nong²

(1. Beijing University of Posts and Telecommunications, Beijing 100876, China;

2. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, China)

Abstract: The selective operation of pattern sample and abstracting method of typical sample data are discussed in this paper. In order to improve obvious shortcoming existing in neural networks in which error precision and convergent rate will be sensitive to initial weight values, even more depending on them, the Gabor function model of visual perception field is applied to optimize initial weight value of neural networks. In this way a good start in learning process can be provided. It is more important to obtain plastic superiority adaptive to complicated alterable environment for the neural network model, and to implement optimal computing principle in which operation load of structuring element weights in morphological filter can be distributed according to their contributive rate.

Key words: computer vision; image processing; mathematical morphology; data abstraction; state optimization

1 引言

形态结构的多样性是图像景物的突出特征之一, 图像所反映的两类基本特性——形态结构和目标属性是互为依存的对应关系. 数学形态学对信号的处理具有直观上的简明性和数学上的严谨性, 在定量描述图像的形态特征上具有独特的优势. 为基于形状细节对图像进行准确分析提供了强有力的手段. 形态学主要通过腐蚀、膨胀、开、闭 4 种基本变换并选择相应的结构元来处理和分析图像, 一旦选定了所用的形态滤波算子(形态变换组合), 则结构元素便成为形态滤波运算的关键, 决定着算法变换的目的和性能. 如何自适应地优化确定结构元素, 长期以来已成为形态学领域中人们关注的研究热点和技术难点^[1~4]. 近年来国内外众多学者都在致力于这方面的研究与探索, 采用的主要方法有统计模型法^[5]、神经网络法^[4]、模拟退火法^[6]和遗传算法^[7]等. 这些方法都力求能有效地解决形态滤波器设计中的知识获取和精炼问题, 从而通过

自适应优化学习, 使结构元逐渐“掌握”图像目标的形态结构特征, 赋予其特定的知识, 使形态滤波过程融入特有的智能, 进而实现对复杂变化的图像环境具有良好的滤波性能和稳健的适应能力.

2 提取典型学习样本

特征提取算法在实际应用中, 模式样本的精炼加工至关重要. 模式样本并非一堆杂乱无章无规律可循的数据, 检测客体(目标)所固有的许多未知特征信息就蕴含其中. 实际样本数据的统计规律表明, 往往是若干个典型的样本数据就可反映出总体的分布.

2.1 模式样本选取操作

在论述选取操作以前, 先给出如下的基本定义.

模式特征 $P_j (j = 1, 2, \dots, M_w)$ 定义为模式样本集 $\{f_i | i = 1, 2, \dots, M_w\}$ 所具有的状态分布, 记为

$$P_j = [p_{j1}, p_{j2}, \dots, p_{jN}]^T \quad (1)$$

其中 M_W 为结构基元 $\text{Bas}(\Psi)$ 的滤波窗口 $W_{\text{窗}}$ (见图 1) 所决定的像点数目. $p_{jm} (1 \leq m \leq N)$ 表示某个模式样本的特征分量值. 这些特征分量分别对应着像点灰度、图像背景、亮度反差、形状因子和连通特性等.

样本数据 $\{e_k | k = 1, 2, \dots, N_e\}$ 定义为对应模式特征 P_j 的一组实现值 (也称短期记忆). k 为样本数据的排列序号 ($\{e_k\}$ 与 $\{f_i\}$ 的序结构相同), N_e 为样本的总体个数.




图 1 模式样本与结构元分量排列



图 2 选取模式样本特征数据

按照层次化目标检测网络模型 (自适应背景感知与对消处理、抑制背景的自动门限选取、形状分析与目标特征识别) 的方法选取模式样本时, 其操作过程十分简便, 只需针对实际图像中的目标景物通过光标“点击”来完成. 例如, 选取的目标景物为 A (如图 2 中的数字“5”). 操作时, 则只需在显示屏上目标处用光标 A “点击”一下, 或在触摸屏上对着目标用手“点触”一下即可. 于是, 程序将提供背景抑制后通过优化聚类与特征提取处理得到的拓扑连通分量 A 在灰度层上的视觉反差特征. 截取其中的一个自然片断, 并以此抽取反映模式样本全局共性特征的结构参数: ①计算片断域内的特征量均值 μ_A , 将域内特征值大于 μ_A 的像点集 S 及其邻域的图像数据选作学习样本, 而期望信号则为像点集 S 上的特征值本身. ②为消除强起伏的背景噪声 (“毛刺”), 可直接引用 μ_A 作为聚类分割的初始门限. ③基于像点集 S 的扩散域 (含特征值渐趋为零的像点集合) 将自动反映出一个适当的背景感知空间尺度, 有助于确定并行区域的感知范围. ④当模式样本的数据量趋于饱和时, 为满足高效便捷的运算要求, 将进一步选取和精




图 3 形态锥聚缩方式

炼其中反映总体模式分布特征的典型样本数据. 作为经验法则的运用, 可简要选取 S 域上的边界点并随机抽取 S 域内 30 ~ 60% 的像点及特征量值, 以组成待学习用的模式样本空间.

为解决背景感知的区域扩张问题, 提高样本数据的抽取速率, 对于静态的原有大目标或动态 (由远至近) 渐变形成的大目标, 可借助形态锥 (morphological pyramid) 渐近聚缩方法 (见图 3), 在保持结构元空间尺度恒常性 (整体视觉不变性) 的前提下对视场环境进行可靠的背景感知. 这就意味着: ①对样本目标区进行背景感知的结构元无需学习, 即样本目标的提取处理能够在全自动方式下完成; ②可使用一个较小的固定结构元对任意图像区背景 (即或是目标结构尺寸大于结构元) 进行可靠感知. 从而, 大大加快学习样本的数据提炼速度.

2.2 典型样本数据精炼

实际的模式样本与它们的邻域样本之间存在着较强的相关性, 因此重点选择那些具有典型意义的模式样本, 便可用它们来刻画样本空间的整体特征. 为实现这一目的, 通常采用的方法就是样本数据压缩法, 例如: 类内散度函数法、特征值分解法、正交迭代法和学习子空间法等, 它们都是着眼于如何从庞大的模式样本中选择典型样本来构造学习样本空间. 本文讨论其中具有代表性的学习子空间法 (Learning Subspace Method, LSM), 用以产生学习需要的主特征矢量.

Kohonen 率先提出了学习子空间的概念, 经过不断修正的模式子空间的主特征矢量能够反映变化的模式结构信息^[8].

LSM 算法的一般学习规则可描述为

$$\begin{cases} L_k^{(i)} = [I + \mu_x X_k^{(i)} (X_k^{(i)})^T] L_k^{(i-1)} - 1 \\ L_k^{(i)} = L[u_1^{(i)}, u_2^{(i)}, \dots, u_{p_i}^{(i)}] \end{cases} \quad (i = 1, 2, \dots, c) \quad (2)$$

式中 μ_x 为学习系数, $\mu_x > 0$ 表示正向学习, $\mu_x < 0$ 表示反向学习; $L_k^{(i)}$ 表示在学习迭代的第 k 个时刻, 由 p_i 个基矢量 $u_j^{(i)} (j = 1, 2, \dots, p_i)$ 所形成的第 i 类子空间; p_i 为第 i 类子空间的维数.

但是, 这种标准的 LSM 算法对模式样本的排列顺序却很敏感, 随机选取无任何方向性 (具有较大的盲从性), 其结果并不会带来性能的改善和提高. 由于子空间分类规则是基于模式样本在类别子空间内的投影长度来决定的, 利用模板样本模的大小来设计学习子空间最具直观性, 故一种最小模学习子空间方法 (Minimum Norm Learning Subspace Method, MNLSM)^[10]应运而生.

MNLSM 需要找到第 i 类模式的所有模板矢量 $x_j^{(i)} (j = 1, 2, \dots, N_i)$ 在该类别子空间的最小模矢量:

$$\begin{aligned} X_m^{(i)} &= \arg \min \{ \delta(X_j^{(i)}) \} \\ &= [(X_j^{(i)})^T P_k^{(i)} X_j^{(i)}]^{1/2} | j = 1, 2, \dots, N_i \end{aligned} \quad (3)$$

式中 $\delta(X_j^{(i)})$ 表示 $X_j^{(i)}$ 在 $L^{(i)}$ 中的投影, k 为迭代次数, $\arg \min \{ \otimes \}$ 表示求解最小模样本的运算符.

用获得的最小模矢量 $X_m^{(i)}$ 正向旋转所属子空间, 而反向旋转其他类别子空间. 具体的迭代公式为

$$L_k^{(i)} = L[I + \mu_m^{i,j} X_m^{(i)} (X_m^{(i)})^T] L_{k-1}^{(i)}, \quad i = 1, 2, \dots, c \quad (4)$$

$$L_k^{(i)} = L[I + \mu_m^{i,j} X_m^{(i)} (X_m^{(i)})^T] L_{k-1}^{(i)}, \quad i = 1, 2, \dots, c; j \neq i \quad (5)$$

式中 $\mu_m^{(i,j)}$ 为第 i 个类别的最小模样本旋转 (学习) 第 j

个子空间的学习系数, $\mu_m^{(i,j)}$ 为第 i 个类别的最小样本旋转(学习)第 j 个子空间的学习系数。

3 感受野型权值初始化

通过自然界长期的进化, 生物体内存在着许多十分优良和精细的功能结构, 它们可靠、致密、协同和高效。其中功能卓越的视觉系统则是通过遗传发育和可塑调节两个环节逐渐发展完善的。在出生前的孕育阶段, 由遗传因子所决定的视系统基本组构已经形成。在出生后正常的视觉环境中这些组构及功能不断地被塑造而变得越发精细(精密化)且更趋成熟。耐人寻味的是, 刚出生时视系统的这种结构模式(雏形)已经蕴含着对后天环境有适应性变化的潜力^[10]。广泛存在于各类生物神经系统的这种有序结构, 对于快捷处理信息, 提高识别学习能力, 起着至关重要的作用。为此, 将生物视觉系统中感受野空间分布特性^[11]用于优化模型的初始结构, 相当于把“固化”了的视功能结构——生物体经过亿万年进化而形成的优异功能特性引入其中。将有效改善神经网络中普遍存在的误差精度与收敛速率对初始权值颇为敏感甚至过于依赖的缺陷。考虑到目标检测时应具有边界突出、平移不变和旋转不变性, 初始的优化模型将选用圆对称型感受野结构。目前, 在感




图 4 Gabor 函数结构

受野数学模型中广为接受并普遍认同最合理的一种当数第一类广义 Gabor 函数^[12], 其结构如图 4 所示。这一同心圆结构模型的数学表达式为

$$EG_1(x, y) = A \exp(-r^2/\sigma^2) \cos(2\pi f_r r), \quad (6)$$

式中 (x, y) 为神经元坐标位置, A 是比例常数, 径向距离 $r = \sqrt{x^2 + y^2}$, f_r 为感受野的空间频率参数, σ 为与感受野空间分布大小有关的参数, 它们都具有一定的生理意义。

4 主成份分析算法

主成份分析是一种把原来多个函数变量化为少数几个互不相关的主要变量的一种统计方法, 可以达到简化运算、揭示变量之间的关系和进行统计解释的目的。为进一步分析函数变换的总体性质和运算规律提供一些重要信息。主成份分析的求解方法可描述如下。

设结构元(总体) $B_i = [b_1^{(i)}, b_2^{(i)}, \dots, b_M^{(i)}]^T$ 是 M 维随机变量, 协方差矩阵 $D(B_i) = V_i$, 注意到 $V_i > 0$ 。记 V_i 的特征根为 $\lambda_1^{(i)}, \lambda_2^{(i)}, \dots, \lambda_M^{(i)}$, 满足

$$\lambda_1^{(i)} \geq \lambda_2^{(i)} \geq \dots \geq \lambda_g^{(i)} > 0, \lambda_{g+1}^{(i)} = \dots = \lambda_M^{(i)} = 0 \quad (7)$$

其中 $g = \text{rg}(V_i)$, $\gamma_1^{(i)}, \gamma_2^{(i)}, \dots, \gamma_M^{(i)}$ 是 V_i 的特征根 $\lambda_1^{(i)}, \lambda_2^{(i)}, \dots, \lambda_M^{(i)}$ 对应的单位正交特征向量, 并有

$$(\Gamma)^T V_i \Gamma = \begin{bmatrix} \lambda_1^{(i)} & & & & 0 \\ & \ddots & & & \\ & & \lambda_g^{(i)} & & \\ & & & 0 & \\ 0 & & & & \ddots & \\ & & & & & 0 \end{bmatrix} \quad (8)$$

式中 $\Gamma_i = [\gamma_1^{(i)}, \gamma_2^{(i)}, \dots, \gamma_M^{(i)}]$ 。

根据结构元 B_i 的最简线性化准则, 即满足

$$z_j^{(i)} = A_j^T B_i = a_1^{(i)} b_1^{(i)} + \dots + a_M^{(i)} b_M^{(i)} \quad (j = 1, 2, \dots, g) \quad (9)$$

式中 $A_j = [a_1^{(i)}, a_2^{(i)}, \dots, a_M^{(i)}]^T$ 是待定的常数向量。

$z_j^{(i)}$ 将作为 B_i 的主成份, 就必须充分反映 B_i 的特征分布规律, 即要求 $D^L z_j^{(i)}$ 尽可能大。由数理统计学可知, $D^L z_j^{(i)} = A_j^T V_i A_j$ 。对常数向量 A 的自然约束条件通常为 $A_j^T A_j = 1$, 即令 A_j 为单位长度。于是, 求解问题就归结为首先寻找满足如下数学表达式的影响因子向量 A_1

$$\max_{A_j^T A_j = 1} A_j^T V_i A_j = A_1^T V_i A_1 \quad (10)$$

由数理统计学原理可知, 选取 $A_1 = \gamma_1$ 就可实现这一目的, 记

$$z_1^{(i)} = \gamma_1^T B_i \quad (11)$$

称 $z_1^{(i)}$ 为 B_i 的第一个主成份。

如果 $z_1^{(i)}$ 还不能充分反映 B_i , 则可继续求解 B_i 的第二个主成份 $z_2^{(i)}$, $z_2^{(i)}$ 除满足式(9)的要求外, 还需符合如下条件

$$\text{Cov}^L z_1^{(i)}, z_2^{(i)} = 0 \quad (12)$$

式中 Cov^L 是相关矩阵运算符, 其值为 0 是要求 $z_2^{(i)}$ 与 $z_1^{(i)}$ 之间互不相关, 或彼此尽可能不含重复信息。

可以推导 $\text{Cov}^L z_1^{(i)}, z_2^{(i)} = A_2^T V_i \gamma_1$, 而 γ_1 是 V_i 的特征根 λ_1 对应的特征向量, 故 $A_2^T V_i \gamma_1 = \lambda_1 A_2^T \gamma_1$, $\lambda_1 \neq 0$ 。于是式(12)便等价于 $A_2^T \gamma_1 = 0$ 。

因此, 与确定 $z_1^{(i)}$ 类似, 求解 $z_2^{(i)}$ 就归结为寻找满足如下数学表达式的影响因子向量 A_2

$$\max_{A_j^T A_j = 1, A_j^T \gamma_1 = 0} A_j^T V_i A_j = A_2^T V_i A_2 \quad (13)$$

同样, 由数理统计学有关定理可知, 取 $A_2 = \gamma_2$ 就可实现此目的, 记为

$$z_2^{(i)} = \gamma_2^T B_i \quad (14)$$

称 $z_2^{(i)}$ 为 B_i 的第二个主成份。

重复以上过程, 注意满足下列条件

$$\text{Cov}^L z_m^{(i)}, z_n^{(i)} = 0 \quad (m \neq n) \quad (15)$$

则可求得 $z_k^{(i)} = \gamma_k^T B_i$, 称 $z_k^{(i)}$ 为 B_i 的第 k 个主成份。

这样, 关于寻找总体 B_i 的综合指标——主成份的问题就化为求解 B_i 的协方差矩阵 V_i 的特征根和标准正交特征向量的问题。对此, 可按下列步骤进行:

(1) 求 B_i 的些方差矩阵 V_i 的特征根, 记为

$$\lambda_1^{(i)} \geq \lambda_2^{(i)} \geq \dots \geq \lambda_k^{(i)} > 0, \lambda_{k+1}^{(i)} = \dots = \lambda_M^{(i)} = 0.$$

(2) 求 λ_j 对应的单位特征向量 $\gamma_j, j = 1, 2, \dots, g$ 。

(3) 得到第 k 个主成份 $z_k^{(i)} = \forall_k^T B_i$, $k = 1, 2, \dots, g$.

此时, 如果 $V_i > 0$, 则可得到 B_i 的 M 个主成份. 另外, 当 λ_j 有重根时, 主成份不具有唯一性.

5 形态学变权神经网络模型

5.1 运动图像的时变特性

运动(序列)图像为人们提供了比单一(静态)图像更为丰富的信息. 但是, 运动图像的时变性和复杂性也增大了目标检测与跟踪的难度. 其样本选取表现为两点: 一是光标点击目标 A 后, 将得到有关 A 的一组训练样本集(特征数据片断). 从性能上讲, 训练后结构元的优化曲面应尽量准确地体现出这些特征数据所反映的形态特征. 但是, 这种准确是有代价的, 准确度越高, 总体误差越小, 而训练时间(迭代次数)则势必越长, 这会极大地影响系统的响应速度. 当处于联机在线操作方式时(在视景现场同时完成对景物的标定、滤波参数的优化学习以及对目标的检测、识别与跟踪等), 将难以保证对运动目标的持续可靠跟踪. 二是目标在运动过程中其航向、姿态及形体大小都在不断变化, 导致目标的形态结构也在变化. t_1 时刻的优化结构元 $\{B_i^1\}$ 对于时刻 t_2 而言就未必“优化”, 甚至有可能“恶化”. 因此, 任意时刻 t 的优化结构元素 $\{B_i^t\}$ 的分布特性不可能固定不变, 而是随着目标在运动过程中所表现出的不同形态也要相应的变化. 由此看来, 结构元素的优化训练不能只针对某一时刻进行“短期”的静态学习, 而应当是能自动适应其不断变化的一种“长期”的动态学习过程, 进而实现对模式样本时变结构特征的记忆与跟踪.

5.2 动态跟踪优化模型

为满足上述实际应用的需要, 本文设计了一种渐近收缩误差、递推辨识模型参数的优化结构——形态学变权神经网络模型(Morphological Adjusted Weight Neural Network, MANN), 如图5所示. 其主导思想是渐变调控误差指标 ε 的大小, 而非

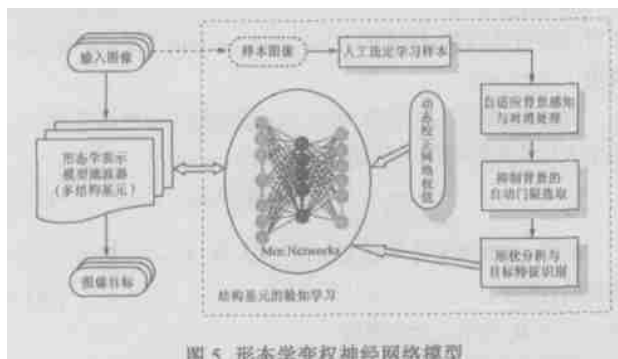


图5 形态学变权神经网络模型

一步到位, 即不指望由某一帧图像获得的一组训练样本集通过一轮学习(迭代 n 次), 就使训练效果甚佳(误差率 e 甚小). 具体操作时, 在 $t = t_0$ 初始训练的基础上将依据两种情况继续对前时刻的 $\{B_j^{(i-1)}, 1 \leq j \leq N_s\}$ ($t = t_1$ 时 $\{B_j^{(i-1)}\} = \{B_j^{(0)}\}$) 进行修正与完善: ①累计变化的图像帧数已超过预定值; ②对于现时刻 t_i 的图像数据由前时刻 t_{i-1} 的 $\{B_j^{(i-1)}\}$ 所引起的性能误差 f 超限. 设初始时刻 t_0 预置的误差指标为 ε_0 , 那么 ε_0 的取值大小则必须同时兼顾滤波性和时效性两方面

的要求: 一是在 $\varepsilon = \varepsilon_0$ 的误差水平下训练得到的结构元集 $\{B_j^{(0)}\}$ 要保证在后续若干帧的视景中仍能够持续稳定地检测出运动目标; 二是训练时间不能过长, 要保证联机在线操作方式下由现场优化训练获得 $\{B_j^{(0)}\}$ 后, 还应留有足够的时间来完成对运动目标的检测与跟踪. 为此, 算法运行时初始时刻 t_0 预置的 ε_0 可以稍大一些, 采用较粗的精度进行检测处理, 目的是便于早期的结构元 $\{B_j^{(0)}\}$ 在从无到有的缓慢生成过程中节省过量的训练时间, 以免后续环节丢失目标. 当 t_1 时刻($t_0 \sim t_1$ 期间的累计变化帧数超过预定值), 将利用此时跟踪获取的目标图像数据即一组新的训练样本集, 对 $\{B_j^{(0)}\}$ 进行“短暂”训练(限定迭代次数)而得到 $\{B_j^{(1)}\}$, 于是 $e_1 < e_0$, 系统误差逐渐减小. 当飞机目标进行转弯、横滚或机动飞行时, 只要 $\{B_j^{(i-1)}\}$ 对于现时刻的图像数据所引起的性能误差一旦超限, 便立刻转入对 $\{B_j^{(i-1)}\}$ 的“短暂”学习(限定 e 的改善程度). 总之, 误差率 e 是在对运动目标的自动持续跟踪过程中通过多轮不断的训练与调整, 才逐步衰退下来而渐近趋于一个幅值甚小的残差量. 至此, 检测处理的精度也随之变得越来越精细, 不仅保证了对运动目标持续可靠的检测与跟踪, 而且还为进一步的目标/景物解释(目标部位鉴别)和多源数据融合可提供完整、准确的目标特征信息.

6 结束语

近年来随着视觉研究的不断深入, 计算模型的概念受到了极大重视和广泛应用. 建模途径主要分为两种: 一是根据系统运动规律建立机理模型, 二是依据数理统计规律进行系统辨识. 由于客观条件的随机变化以及机理分析面临的复杂问题, 对目标识别算法人们普遍选用了通用性好并能以一定精度逼近系统响应函数的统计模型. 其实现方法将集中在确定系统结构(结构辨识)和估计模型参数(参数辨识)两个方面. 本文算法采用的人-机结合的系统集成思想, 将人的心智(宏观审视)和机器智能(微观探求)有机地统一起来, 强调人的主导作用和视觉经验的重要性, 突出在线交互方式下机器系统实施定量分析的数据挖掘功能. 算法建模中首先确立了描述图像结构具有独特优势的形态滤波感知“模型”, 并融入了人的“注视选择”能力, 待检测目标的模式样本由操作员直接选定, 样本数据的检测与挖掘等精确计算处理则由计算机自动完成, 滤波模型的“参数辨识”将通过学习算法优化获得. 这种智能体的检测模式较符合人类逐步求精的视觉感知过程, 人机交互技术通过“目视、选定、提示”的主动视觉引导对于模型参数的优化学习算法将恰到好处. 人工选定的学习样本(典型目标)数据中蕴涵的模式特征、属性关系和主特征矢量等潜在知识都有赖于计算机系统的学习机制——“数据发掘”与“知识发现”完成. 从而, 实现了学习内容的表达与传递, 以及内在知识的抽取、精炼和最终获取的智能塑造过程.

参考文献:

- [1] Serra J. Image Analysis and Mathematical Morphology [M]. London: Academic Press, 1988.

- [2] Dougherty E R, et al. Digital image processing methods[J]. Marcel Dekker, New York, 1994. 110– 138.
- [3] 龚炜, 石青云, 程民德. 数字空间中的数学形态学[M]. 北京: 科学出版社, 1997.
- [4] Won Y G, et al. Morphological shared weight networks with applications to automatic target recognition[J]. IEEE Trans Neural Networks, 1997, 8(5): 1195– 1203.
- [5] Loce R P, Corp X, Dougherty. Optimal restoration using the morphological hit or miss transform[J]. SPIE, 1992, 1769(1): 94– 105.
- [6] Davidson J L. Simulated annealing and morphology neural networks [J]. SPIE, 1992, 1769(1): 119– 127.
- [7] Ehrhardt R. Morphological filter design with genetic algorithms[J]. SPIE, 1994, 2300(1): 2– 12.
- [8] Kohonen T. Self organization and associative memory[M]. Springer Verlag, Third edition, 1989.
- [9] 黄德双. 神经网络模式识别系统理论[M]. 北京: 电子工业出版社, 1996.
- [10] 杨雄里. 视觉的神经机制[M]. 上海: 上海科学技术出版社, 1996.
- [11] 汪云九, 崔 , 齐翔林. BP 学习网络中权值的感受野型初始化研究[J]. 自然科学进展, 1996, 6(3): 346– 350.

- [12] 齐翔林, 汪云九, 朱舜山. 初级视觉信息的 Gabor 小波表达研究 [J]. 自然科学进展, 1996, 6(5): 608– 612.

作者简介:



景晓军 男, 北京市人, 北京邮电大学副教授, 2000 年至 2002 年在北京邮电大学从事博士后研究工作, 在国内外学术刊物和会议上发表学术论文 30 多篇, 合作出版著作二部, 负责在研项目 5 项, 主要研究方向为信息融合、模式识别、图像处理. E-mail: jing_xiao_jun@263.net.



余 农 男, 重庆市人, 副教授, 2000 年获信号与信息处理业博士学位, 现在中国科学院上海技术物理研究所从事博士后研究工作, 在国内外主要学术刊物和国际会议上发表论文 30 多篇, 主要研究领域: 模式识别、图像处理等.