

基于细胞神经网络的从阴影恢复形状的新方法

王怀颖, 于盛林, 冯 强

(南京航空航天大学自动化学院, 江苏南京 210016)

摘 要: 细胞神经网络(CNN)是一种实时处理信号的大规模非线性模拟电路, 它的连续时间特点以及局部互连特点使其可以进行并行计算, 并且非常适用于超大规模集成电路(VLSI)的实现. 本文针对从阴影恢复形状(SFS)问题, 提出了一种基于硬件退火 CNN 的能量函数优化方法, 并对该方法进行了详细分析, 给出了实例的仿真结果, 验证了该方法的有效性. 该方法为并行处理算法, 具有运算量小、易于大规模 VLSI 集成实现, 且能够克服局部极小等优点, 可以使 SFS 问题得到实时的处理.

关键词: 细胞神经网络(CNN); 从阴影恢复形状(SFS); 优化

中图分类号: TP751.1 **文献标识码:** A **文章编号:** 0372-2112 (2006) 11-2120-05

A New Approach for Shape from Shading Based on CNN

WANG Huai-ying, YU Sheng-lin, FENG Qiang

(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing, Jiangsu 210016, China)

Abstract: A cellular neural network (CNN) is a large-scale nonlinear analog circuit suitable for real-time signal and image processing. CNN can be used for high-speed parallel computation and is easy to be translated into a VLSI implementation. This paper presents one new approach for shape from shading (SFS) using paralleled hardware annealing CNN that performs optimization algorithm. Some practical results are presented and briefly discussed, which demonstrates the successful operation of the proposed algorithm. This new approach is very affordable to parallelism and analog VLSI implementation, which allowing the SFS solution to be performed in real-time.

Key words: cellular neural networks (CNN); shape from shading (SFS); optimization

1 引言

三维形状信息恢复是图像理解和计算机视觉研究领域的一项重要内容, 其研究目的就是使计算机能借助各种视觉传感器获取的 2-D 图像, 感知和恢复 3-D 环境中物体的几何形状、相互位置等信息. 三维形状信息恢复问题同视觉重构有关, 并且可以作为优化问题来处理. 近年来, 许多学者已经使用优化算法和神经网络模型来解决从阴影恢复形状(SFS)问题, 使计算的复杂度有了较大的下降^[1,2]. 但是这些方案都存在一个固有的缺陷, 由于它们是串行算法, 处理速度慢, 硬件的可实现性差, 很难满足图像实时处理的要求.

针对上述问题, 本文提出了一种采用细胞神经网络(CNN)的优化处理能力来解决 SFS 问题的新方法. CNN 对输入的 2-D 图像进行并行处理并以连续时间方式转换为输出图像, 同时, CNN 具有的最近邻细胞相互作用的特点, 使它比一般的神经网络更适用于超大规模集成电路(VLSI)的硬件实现, 可以快速实时地处理图像, 因此, 其在图像处理和计算机视觉领域具有很好的应用潜力.

本文将 SFS 问题作为一个优化问题来处理, 首先把 SFS 问题映射到 CNN 上, 基于 CNN 网络的能量函数, 结合硬件退火算法, 通过 CNN 对目标函数的搜索使网络能量达到全局最小值, 从而得到问题的最优解. 该方法为并行处理算法, 具有运算量小、易于大规模 VLSI 集成实现, 且能够克服局部极小等优点, 可以使 SFS 问题得到实时的处理.

2 细胞神经网络(cellular neural networks)

细胞神经网络^[3,4](CNN)是一种具有实时信号处理能力的大规模非线性模拟电路, 是基于生物神经学以及适合于集成电路的某些特点而提出的. CNN 来源于 Hopfield 神经网络^[5,6]和细胞自动机^[7,8], 其采用局域连接的网络拓扑结构的思想取自于细胞自动机, 而在 CNN 中引入网络能量函数的思想则继承于 Hopfield 神经网络, 所以它在兼顾了两者的优点的同时, 具有更强的实用性, 易于硬件实现是其最显著的特点之一.

CNN 是细胞局部连接的空间阵列, CNN 的每一个细胞就是一个基本电路单元, 每个细胞由 1 个线性电容、1 个非线性

压控电流源和几个线性电阻元件构成,并且每个细胞都是具有输入、输出及动力学特性相关的非线性系统.一个规模为 $M \times N$ 的细胞神经网络由 $M \times N$ 个细胞排列成 M 行, N 列.图 1 所示是一个 4×4 规模的二维 CNN,方块表示电路的单元,即细胞;细胞之间的连线表示所连接的细胞之间的相互作用.第 i 行,第 j 列的细胞用 C_{ij} 表示,每个细胞仅与它的邻域 $N_{ij}(r)$ 中的细胞相连,而不直接相连的细胞则通过连续动态的传播效应而相互影响.细胞 C_{ij} 的半径为 r 的邻域 $N_{ij}(r)$ 定义为:

图 1 4×4 规模的二维 CNN

$N_{ij}(r) = \{ C_{kl} \mid \max(|k-i|, |l-j|) \leq r, 1 \leq k \leq M, 1 \leq l \leq N \}$ (1)

式(1)中, r 表示邻域半径,是一个正整数,称 $r=1$ 的近邻系统为“ 3×3 近邻”.由式(1)所定义的近邻系统呈现对称性,即如果 $C_{ij} \in N_{kl}(r)$,那么同时也有 $C_{kl} \in N_{ij}(r)$.

一个标准的由 $M \times N$ 个细胞组成的 CNN 阵列中的每一个细胞 C_{ij} 都有一个状态变量 x_{ij} 、一个恒定的外界输入 u_{ij} 和一个输出 y_{ij} ,其中, $1 \leq i \leq M, 1 \leq j \leq N$.每一个细胞的动态过程可用下述一阶非线性微分方程描述.

状态方程:

$$C \frac{\partial x_{ij}(t)}{\partial t} = -\frac{1}{R_x} x_{ij}(t) + \sum_{C_{kl} \in N_{ij}(r)} A(i, j; k, l) y_{kl}(t) + \sum_{C_{kl} \in N_{ij}(r)} B(i, j; k, l) u_{kl} + I_{ij} \quad (2)$$

输出方程:

$$y_{ij} = f(x_{ij}) = \frac{1}{2} (|x_{ij} + 1| - |x_{ij} - 1|) \quad (3)$$

约束条件:

$$|u_{ij}| \leq 1, |x_{ij}(0)| \leq 1 \quad (4)$$

状态方程式(2)中, C 、 R_x 、 $I = (I_{ij})$ 分别是细胞等效电路中的线性电容、线性电阻及独立电流源,称 $\tau = R_x C$ 为时间常数,它反映了网络动态过程的快慢; $A(i, j; k, l)$ 表示细胞 C_{kl} 的输出 y_{kl} 与细胞 C_{ij} 之间的连接权; $B(i, j; k, l)$ 表示细胞 C_{kl} 的输入 u_{kl} 与细胞 C_{ij} 之间的连接权;称由元素 $A(i, j; k, l)$ 组成的矩阵 A 为反馈模板,称由元素 $B(i, j; k, l)$ 组成的矩阵 B 为控制模板, A 和 B 分别由 $(2r+1)^2$ 个元素组成,每个细胞与近邻细胞之间的连接权都由 A 和 B 中的元素所决定的. $y_{ij} = f(x_{ij})$ 表示输出与状态变量之间的关系,这里输出函数 $f(x_{ij})$ 是一个分段线性函数,如图 2 所示.偏置量 I 以及模板 A 和 B 可以根据处理问题的不同进行设计,它们的值决定了 CNN 的瞬态特性.

CNN 是连续时间网络模型,其能量函数定义为:

$$E_{\text{CNN}} = -\frac{1}{2} \sum_{(i,j) \in (k,l)} A(i, j; k, l) y_{ij}(t) y_{kl}(t) + \frac{1}{2R_x} \sum_{(i,j)} y_{ij}(t)^2 - \sum_{(i,j) \in (k,l)} B(i, j; k, l) y_{ij}(t) u_{kl}(t) - \sum_{(i,j)} I_{ij} y_{ij}(t) \quad (5)$$

在网络迭代过程中,能量函数随时间的变化为:

$$\frac{dE_{\text{CNN}}}{dt} = -C \left(-\frac{1}{R_x} x_{ij}(t) + \sum_{C_{kl} \in N_{ij}(r)} A(i, j; k, l) y_{kl}(t) + \sum_{C_{kl} \in N_{ij}(r)} B(i, j; k, l) u_{kl} + I_{ij} \right)^2 \quad (6)$$

由式(6)可知 $dE_{\text{CNN}}/dt \leq 0$,表明随时间的增加,网络总是朝着能量函数减小的方向运动,网络最终会达到稳定的平衡点,也就是 E_{CNN} 的一个极小值点.文献[3]也已证明 CNN 系统是稳定的,并且指出:如果参数满足 $A(i, j; i, j) > 1/R_x$,那么,每个细胞的状态经过暂态衰减至 0 之后,一定落在一个稳定平衡点上.

CNN 应用于图像处理时,首先将一个图像的信号空间映射到 CNN 的细胞排列空间阵列上, CNN 的规模与待处理图像的规模相同,即如果待处理的图像有 $M \times N$ 个像素,则 CNN 就包含 $M \times N$ 个细胞,图像中的每一个像素对应于 CNN 中相同位置上的一个细胞,偏置量 I 、初始输入 U 以及连接权矩阵 A 和 B 根据处理问题的不同而不同. CNN 是一种典型的具有局域连接结构和优化能力的非线性网络,与连接权对应的是网络的能量函数的局部极小值.处理时 CNN 的每一个细胞只与邻域 $N_{ij}(r)$ 内的细胞相连,并发生相互作用,每个细胞的状态按照其状态方程式(2)迭代改变,经过多次迭代,状态方程指导细胞的状态向 CNN 所定义的最低能量方向变化,直至整个网络收敛稳定,网络的能量函数达到局部极小值,此时网络的输出对应着所求问题的最优解.

3 基于硬件退火 CNN 的能量函数优化方法求解 SFS 问题

3.1 从阴影恢复形状^[9] (shape from shading)

从阴影恢复形状(SFS)是计算机视觉研究领域内的一项重要内容,其目的就是从唯一的一张单目 2-D 图像中恢复出相关物体的 3-D 几何形状.为了解决 SFS 问题,研究图像是如何形成的很重要.在从 3-D 场景获取 2-D 图像的过程中,原来场景中的一些有关物体形状的信息在成像时会转换成图像中对应原物体的不同形状的明暗度信息即阴影(常用灰度值表示).另外,物体表面各面元的法线的变化也可以导致图像灰度的变化.在图像的 lambertian 模型^[10]中:图像的一个像素点的灰度级取决于光源方向和物体表面形状.如果用表面梯度来描述物体的表面形状,则对于 SFS 问题,就是从给定灰度级的图像中恢复出光源方向和图像每一个像素点的表面梯度.

基于 lambertian 表面的反射特性函数模型定义为:对于一个光滑的 3-D 表面,图像的亮度约束方程为:

$$I(x, y) = R(p, q) = \frac{1 + pp_s + qq_s}{(1 + p^2 + q^2)^{1/2} (1 + p_s^2 + q_s^2)^{1/2}} \quad (7)$$

其中, $p = \partial Z / \partial x$, $q = \partial Z / \partial y$; 像素点 (x, y) 处的深度值为 $Z = Z(x, y)$; $I(x, y)$ 表示点 (x, y) 处的灰度值; $[p, q, -1]^T$ 为表面法线矢量,并称 (p, q) 为点 (x, y) 的表面梯度; $[p_s, q_s, -1]^T$ 为指向光源矢量.

图像亮度约束方程式(7)表明图像中像素点 (x, y) 处的

像素灰度值 $I(x, y)$ 取决于该像素由表面梯度 (p, q) 所表达的反射特性 $R(p, q)$. 由 p 和 q 所确定的表面梯度到由反射图 $R(p, q)$ 所确定的场景亮度或图像灰度是唯一对应的, 但一般情况下, 从图像灰




图2 CNN 的输出函数

度到表面梯度的对应并不是唯一的, 这是因为在每个空间位置上灰度值只有一个, 而表面梯度却有两个自由度, 即对每一个灰度值有两个梯度值要解, 所以, 即使在假设光源方向已知的条件下, 这仍旧是一个病态问题, 如果没有附加信息是不能仅由图像的亮度约束方程恢复表面梯度的, 考虑附加信息的一个简单方法是利用单目图像中的平滑约束。

一般情况下物体表面是比较光滑的, 在深度上是连续的, 进一步的偏微分也是连续的, 只是边缘不光滑, 以上信息提供了一个很强的约束, 称为平滑约束。平滑约束条件^[11]可以定义为:

$$(p_x^2 + p_y^2 + q_x^2 + q_y^2) = 0 \quad (8)$$

其中, $p_x = \partial p / \partial x$, $p_y = \partial p / \partial y$, $q_x = \partial q / \partial x$, $q_y = \partial q / \partial y$

由于图像亮度约束方程式(7)将像素的灰度与表面梯度联系起来, 所以, 可以考虑将图像亮度约束方程式(7)和平滑约束式(8)一起作为求解物体表面深度 $Z = Z(p, q)$ 的非线性偏微分方程。但是这种偏微分方程数值积分的方法对真实的图像处理来说并不实用, 这种方法的一个显著缺陷就是对噪声和边界条件太敏感。

求解 SFS 的另一种考虑是将 SFS 问题作为一个优化问题来处理, SFS 问题的能量函数^[2]构造为:

$$W(x, y) = \frac{1}{2} [I(x, y) - R(p, q)]^2 + \frac{1}{2} (p_x^2 + p_y^2 + q_x^2 + q_y^2) \quad (9)$$

式(9)中第一项为强度误差, 第二项为平滑约束, 是拉格朗日乘子。一般说来, 这种优化方法对所包含的附加约束条件更加灵活, 并且对图像噪声及模型误差的鲁棒性更强。

求解 SFS 能量函数式(9)的极值是一个标准的非线性规划问题, 可以对 p 和 q 分别进行多次迭代求解, 也有许多研究者使用了 Hopfield 网络模型^[7]的优化能力处理这样的优化问题, 但是这类方案的计算量大, 处理速度较慢, 硬件实现困难, 不能满足图像实时处理的需求。本文采用 CNN 处理 SFS 优化问题, 是基于 CNN 本身具有能量函数可以进行优化处理的特点, CNN 在兼顾了 Hopfield 神经网络优点的同时, 具有并行处理数据和易于硬件实现等优点, 有更强的实用性, 处理速度更快, 可以实时地处理图像。

3.2 基于硬件退火 CNN 的能量函数优化方法求解 SFS 问题

用 CNN 来求解 SFS 问题时, 关键是如何构造能量函数, 然后再由能量函数决定 CNN 的连接权矩阵 A 和 B , 当连接权矩阵确定下来以后, 用初始输入 U 和偏置量 I 给定网络的初

始状态, 然后, 网络便自动向最小能量状态变动, 当稳定后, 所得到的网络状态就是问题的解。

3.2.1 构造能量函数

对于 SFS 问题, 构造的能量函数应使其极小值对应于 SFS 的解, 即对应于深度 Z 的最优解。令图像中坐标点 (x, y) 对应于 2-D 图像矩阵中的第 i 行, 第 j 列, 然后将图像的信号空间映射到 CNN 的细胞排列空间阵列上, SFS 问题的能量函数^[12]重新构造为:

$$E_{\text{SFS}} = \frac{1}{2} \{ k_a [I(x, y) - R(i, j)]^2 + k_b G \} \quad (10)$$

其中,

$$G = (Z_{ij} - Z_{i+1, j})^2 + (Z_{ij} - Z_{i, j+1})^2 + (Z_{ij} - Z_{i-1, j})^2 + (Z_{ij} - Z_{i, j-1})^2 \quad (11)$$

$$p = \partial Z / \partial x = Z_{ij} - Z_{i+1, j}, \quad q = \partial Z / \partial y = Z_{ij} - Z_{i, j+1} \quad (12)$$

将式(12)代入图像的亮度约束方程式(7), 得:

$$R(i, j) = \frac{1 + (Z_{ij} - Z_{i+1, j}) p_x + (Z_{ij} - Z_{i, j+1}) q_x}{[1 + (Z_{ij} - Z_{i+1, j})^2 + (Z_{ij} - Z_{i, j+1})^2]^{1/2} (1 + p_x^2 + q_x^2)^{1/2}} \quad (13)$$

式(10)中第一项是强度误差, 第二项是用于解决病态问题的平滑约束条件; k_a 、 k_b 是时空影响因子; $I(i, j)$ 是像素点 (i, j) 的灰度值; $R(i, j)$ 是由反射特性决定的 (i, j) 点的亮度; 式(11)中 Z_{ij} 表示像素点 (i, j) 所对应的 3-D 表面深度值。

3.2.2 采用 CNN 求解 SFS 问题

为了利用 CNN 求解 SFS 优化问题, 令 SFS 的能量函数式(10)与连续时间型 CNN 的能量函数式(5)相等, 即 $E_{\text{SFS}} = E_{\text{CNN}}$, 通过比较, 可以确定网络细胞的连接权矩阵 A 、 B 、初始输入 U 和偏置量 I , 则 CNN 网络收敛的稳定平衡点就是 CNN 能量函数的极小值点, 也就是 SFS 能量函数的极小值点, 即 $\min E_{\text{SFS}} = \min E_{\text{CNN}}$, 此时 CNN 的稳定输出就对应着 SFS 问题的最优解。由于,

$$\frac{\partial E_{\text{SFS}}}{\partial Z_{ij}} = -k_a \frac{\partial R(i, j)}{\partial Z_{ij}} [I(i, j) - R(i, j)] + k_b (4 Z_{ij} - Z_{i+1, j} - Z_{i-1, j} - Z_{i, j+1} - Z_{i, j-1}) \quad (14)$$

考虑到 $E_{\text{SFS}} = E_{\text{CNN}}$, 及 $\min E_{\text{SFS}} = \min E_{\text{CNN}}$, 则式(14)与式(6)对应变量的参数项应相等, 这样就得到一组求解 SFS 问题的 CNN 连接权模板:

$$A = k_b \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}, \quad B = 0, \quad (15)$$

$$I = -k_a \frac{\partial R(i, j)}{\partial Z_{ij}} [I(i, j) - R(i, j)]$$

这样, CNN 的连接权模板设计基本完成, 但是对于普通的 CNN 来说, 在搜索能量函数最小值的过程中可能会陷入局部极小点, 其解决优化问题的实质仍然是一种局部搜索算法。为了寻找全局最优解可以引入模拟退火算法, 通过模拟退火算法可以使系统到达能量函数的全局最低点。但是模拟退火算法难以硬件实现, 因此本文选用经过简化处理的退火方法来实现 CNN 的硬件退火过程^[13, 14], 将 CNN 的输出函数式(3)改变为:

$$y_{ij}(t) = f(x_{ij}(t) \times g(t))$$

$$= \begin{cases} 1, & x_{ij}(t) \times g(t) = 1 \\ x_{ij}(t) \times g(t), & |x_{ij}(t) \times g(t)| < 1 \\ -1, & x_{ij}(t) \times g(t) = -1 \end{cases} \quad (16)$$

其中, $g(t)$ 是一个与时间有关的变量, 是一个有界线性函数:

$$g(t) = \begin{cases} g_{\min} + t/T_A, & t < T_A \\ 1, & t \geq T_A \end{cases} \quad (17)$$

这里, g_{\min} 是与网络稳定有关的常数, $0 < g_{\min} < 1$, 在 t T_A 后, 保持 $g = 1$ 的一段时间内使网络达到稳定状态。

将对应着解决 SFS 问题的连接权模板式 (15) 及对应硬件退火的输出函数式 (16) 用于 CNN 的状态方程式 (2), 用 z_{ij} 替代 x_{ij} , 就得到了 CNN 求解 SFS 问题的动力学方程。

4 CNN 求解 SFS 问题的仿真结果

为了验证和演示以上算法的正确性, 并且便于对本文的

方法与其他文献中的方法进行比较, 本文使用了 SFS 图像处理领域中的典型图像。如图 3 所示为半球体的 2-D 灰度图像, 其灰度值在 0~255 之间, 大小为 300×300 像素, SFS 要求从唯一的这张单目 2-D 图像中恢复出相关物体的 3-D 几何形状。




图 3 半球体的 2-D 灰度图

现设该半球体为 lambertian 表面, 其被一个点光源所照明, 且观察者也处于点光源位置, 此时有 $(p_s, q_s) = (0, 0)$; 取细胞连接的邻域半径 $r = 1$, 即为 3×3 近邻; 取时间常数 $= R_x C = 1$, ($R_x = 1, C = 1$); 取 CNN 的初始状态 $x_{ij}(0)$ 为图像的像素灰度值; 取 CNN 的外界输入 $u_{ij} = 0$; 网络中的每一个细胞都按照 CNN 求解 SFS 问题的动力学方程进行迭代, 经过几个电路的时间常数的时间以后, 网络便达到稳定状态。网络收敛后, 细胞输出产生一个稳定的矩阵, 即为相应像素点的深度值。通过本文提出的算法, 由 2-D 灰度图 (如图 3 所示) 获得的 3-D 物体形状如图 4 所示。从图上可以看出, 该算法达到了很好的效果。




图 4 由 2-D 灰度图恢复的 3-D 物体形状

5 结论

近年来, 许多学者在解决 SFS 问题时都使用了优化算法和神经网络^[15]模型, 这些方案使计算的复杂度有较大的下降, 性能也优于传统的二次变分法。但是 BP 神经网络训练时间较长, 参数选取依赖于经验; Hopfield 神经网络连接权数过多, 大规模集成困难很大, 且容易陷入能量函数的局部极小而无法收敛至全局最小点。

本文基于能量函数优化的方法, 将硬件退火算法嵌入到 CNN 中, 用该网络求解 SFS 问题, 克服了局部能量最小的陷阱, 确保了 CNN 向全局最小能量值方向收敛, 在获得较好的处理效果的同时也大大降低了算法实现的复杂度。CNN 的结构之所以非常适合于执行这样的优化处理过程, 在于其细胞的动态特性使问题演变成搜索能量函数的极小值。由于 CNN 的每一个细胞都是一个计算单元, 所以可以进行大规模的并行计算, 其计算量和计算时间远小于传统算法, 而且细胞之间的局部互连特性使网络的连接键大大的减少, 易于大规模 VLSI 集成实现, 可以使 SFS 问题得到实时的处理解决。

参考文献:

- [1] Lehky, Sejnowski. Network model of shape form shading: neural function arises from both receptive and projective fields [J]. Nature, 1988, 333: 452 - 454.
- [2] Wei G, Hirzinger G. Learning shape from shading by multilayer network [J]. IEEE Trans on Neural Networks, 1996, 7 (4): 985 - 995.
- [3] Chua L O, Yang L. Cellular neural networks: theory [J]. IEEE Trans on Circuits and Systems, 1988, 35: 1257 - 1272.
- [4] Chua L O, Yang L. Cellular neural networks: applications [J]. IEEE Trans on Circuits and Systems, 1988, 35: 1273 - 1290.
- [5] Hopfield J J. Neural network and physical systems with emergent collective computation abilities [A]. Proceedings National Academy of Science [C]. USA, 1982. 2554 - 2558.
- [6] Hopfield J J, Tank D W. Computing with neural circuits: a model [J]. Science, 1986, 233: 625 - 633.
- [7] Wolfram S. Theory and application of cellular automata [M]. Singapore: World Scientific Publishing Company, 1986.
- [8] Toffoli T. Cellular automata machines [M]. Cambridge, MA: The MIT Press, 1987.
- [9] Milan Sonka, Vaclav Hlavac, Roger Boyle. Image processing, analysis, and machine vision [M]. 北京: 人民邮电出版社, 2002. 494 - 501.
- [10] Tsai P S, Shah M. A fast linear shape from shading [A]. 1992 IEEE Computer Society Conference on Computer Vision and Pattern Recognition [C]. Proceedings CVPR 92, 1992. 734 - 736.
- [11] Zhang Ruo, Tsai P S, Cryer J E, Shah M. Shape - from -

- shading: a survey[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1999, 21(8): 690 - 706.
- [12] Lithon F, Dragomirescu D. A cellular analog network for MRF-based motion detection[J]. IEEE Trans on Circuits and Systems I, 1999, 46: 281 - 293.
- [13] Lee B W, Sheu B J. Paralleled hardware annealing for optimal solutions on electronic neural network[J]. IEEE Trans on NN, 1993, 4(4): 588 - 589.
- [14] Bang H, Sheu B J. Optimal solutions for cellular neural network by paralleled hardware annealing [J]. IEEE Trans on NN, 1996, 7(2): 440 - 453.
- [15] Ben-Arie J, Nandy D. A neural network approach for reconstructing surface shape from shading [A]. 1998 International Conference on Image Processing [C]. Proceedings ICIP 98, 1998. 972 - 976.

作者简介:



王怀颖 女, 1973 年出生于新疆伊宁. 南京航空航天大学自动化学院博士研究生. 研究方向为信号处理、计算机视觉等.

E-mail: whyliu @sohu. com

于盛林 男, 1941 年出生于江苏扬中. 南京航空航天大学自动化学院教授、博导. 研究方向为信号处理、测试计量技术及仪器.

冯 强 男, 1980 年出生于江苏江阴. 南京航空航天大学自动化学院博士研究生. 研究方向为神经网络、图像处理等.