

基于堆栈滤波器和 Hopfield 神经网络的边界检测法

黎明 严超华 刘高航

(南昌航空工业学院应用工程系,南昌 330034)

摘要 提出了一种基于堆栈滤波器和 Hopfield 神经网络的边界检测法。采用较小滤波窗口的堆栈滤波器优化估计图象像素点之间的灰度梯度,再根据这些灰度梯度的优化估计值计算及确定 Hopfield 神经网络的权重矢量, Hopfield 神经网络收敛时输出图象的边界。相对于基于堆栈滤波器边界检测法,该方法对堆栈滤波器的优化训练速度大大提高,所需内存大为减少;而相对于基于 Hopfield 神经网络的边界检测法,该方法又具有较强的抗混合分布噪声的能力,边界检测的效果更好。

关键词 图象处理 边界检测 堆栈滤波器 Hopfield 神经网络

0 引言

堆栈滤波器是一般化的中值滤波器,它具有中值滤波器的所有优点,而且具有门限分解特性和堆栈特性, Yoo^[1,2]将数学形态学边界提取方式应用于堆栈滤波器,实现了直接的边界检测。这种方法较好地满足了保持图象结构和统计最优化的两个限制条件,所提取的图象边界对各种不同分布特征的噪声不敏感,保证了图象边界提取的准确性和精度。但是 Yoo 方法优化训练堆栈滤波器时需要大量的内存和计算,设堆栈滤波器的滤波窗口为 $N \times N$,则堆栈滤波器的优化训练共需要 2^{N^2+3} Bit 的内存,训练每个样本像素点需要 N^4 量级的交换计算和 N^2 的查找表操作运算^[1,2]。例如堆栈滤波器的滤波窗口为 5×5 ,以 10 幅 512×512 个像素点的图象为训练样本时,优化训练约需要 32MBit 的内存、 1.6×10^9 次交换计算和 6.5×10^7 次查找表操作运算,因此在微机上采用堆栈滤波器边界检测方法时滤波窗口一般不超过 5×5 。但是滤波窗口太小使得堆栈滤波器只能对较小的邻域内的信息进行最优化估计,不能有效地抑制那些在较大邻域内发生分布变化的噪声引起的干扰,因此滤波窗口太小的堆栈滤波器抗噪

声能力不强。试验表明采用 5×5 的滤波窗口抑制许多类型的噪声是不够的。

许多作者还尝试用人工神经网络作边界提取,通过大规模的神经元的相联和并行的运算方式,可以大幅度提高边界提取的速度。Chao^[3]和 Dhawan^[4]分别提出了 Hopfield 神经网络和自组织神经网络边界提取及边界增强方法。这 2 种方法将图象看作是一个动态系统,可以完全用能量函数来描绘。Chao 选择了合适的能量函数使得反馈网络收敛,边界提取的结果与 Sobel 算子相类似。Dhawan 提出的网络中图象作为神经系统,每个像素是一个神经元,任意 2 个神经元之间相互连接,神经元的初始输出等于相应的像素的灰度值,并通过一次或二次的对比连接函数迭代地调整各个神经元的输出,最后实现边界的增强。Hopfield 神经网络和自组织神经网络边界提取方法考虑了整幅图象的信息,因此抗噪声干扰能力比 Sobel 算子等边界提取方法强。但在具有各种不同分布特征的混合噪声的干扰下,因为缺少有监督的训练,它们的边界提取性能比堆栈滤波器的边界提取性能相差许多。

堆栈滤波器的边界提取方法边界提取性能很好,抗噪声能力强,但训练速度慢,需要巨大内存;而

Hopfield 神经网络和自组织神经网络边界提取方法可以采用并行的运算方式,计算速度快,但对混合分布噪声的抗噪声能力较强。本文提出一种新的基于堆栈滤波器和 Hopfield 神经网络的边界检测法,将堆栈滤波器的边界提取方法和 Hopfield 神经网络的边界提取方法结合在一起,融合了这 2 种方法的优点。

基于堆栈滤波器和 Hopfield 神经网络的边界检测法由以下 3 步组成:

(1) 有监督地训练样本图象,优化设计具有较小滤波窗口的堆栈滤波器,用来在较小的邻域内优化估计被测图象任意 2 象素点之间的灰度梯度。

(2) 将被测图象进行灰度归一化,并用堆栈滤波器优化估计图象任意 2 象素点之间的灰度梯度,根据这些灰度梯度的优化估计值计算及确定 Hopfield 神经网络的权重矢量。

(3) 将归一化的被测图象各象素点灰度作为 Hopfield 神经网络各神经元的初始输出,根据动态方程使 Hopfield 神经网络的能量函数值逐渐降低,直到 Hopfield 神经网络收敛。对收敛后的 Hopfield 神经网络各神经元的输出二值化,得到被测图象的边界。

1 堆栈滤波器优化估计任意 2 象素点之间的灰度梯度

设堆栈滤波器^[5,6]为 $S_f(\cdot)$,而 $S_f(\cdot)$ 为其每一层的布尔函数。 $S_f(\cdot)$ 用于优化估计被测图象任意 2 象素点之间的灰度梯度。设训练图象为:

$$f(x, y) = \bar{f}(x, y) + n(x, y) \quad (1)$$

式中 $\bar{f}(x, y)$ 为无噪声图象, $n(x, y)$ 为噪声,图象的尺寸为: $x \in [1, N_x], y \in [1, N_y]$ 。任取 2 象素点为 (x_1, y_1) 和 (x_2, y_2) ,从象素点 (x_1, y_1) 到象素点 (x_2, y_2) 的灰度梯度的期望值为:

$$\Delta \bar{f}(x_1, y_1, x_2, y_2) = |\bar{f}(x_1, y_1) - \bar{f}(x_2, y_2)| \quad (2)$$

为了训练堆栈滤波器,为象素点 (x_1, y_1) 和 (x_2, y_2) 分别选择尺寸为 $N \times N$ (其中 N 为奇自然数)的窗口邻域:

$$\left\{ \begin{aligned} f(x_1 + \Delta x, y_1 + \Delta y): \Delta x \in \left[-\frac{N-1}{2}, \frac{N-1}{2} \right], \\ \Delta y \in \left[-\frac{N-1}{2}, \frac{N-1}{2} \right] \end{aligned} \right\} \quad (3)$$

$$\left\{ \begin{aligned} f(x_2 + \Delta x, y_2 + \Delta y): \Delta x \in \left[-\frac{N-1}{2}, \frac{N-1}{2} \right], \\ \Delta y \in \left[-\frac{N-1}{2}, \frac{N-1}{2} \right] \end{aligned} \right\} \quad (4)$$

堆栈滤波器门限分解层数 $M-1$ 为图象最大灰度等级数。从象素点 (x_1, y_1) 到象素点 (x_2, y_2) 的灰度梯度在式(3)和式(4)相应的窗口邻域内 $N \times N$ 个样本为:

$$\begin{aligned} \Delta f_{N \times N}(x_1, y_1, x_2, y_2) = \\ \left\{ \begin{aligned} |f(x_1 + \Delta x, y_1 + \Delta y) - f(x_2 + \Delta x, y_2 + \Delta y)|: \\ \Delta x \in \left[-\frac{N-1}{2}, \frac{N-1}{2} \right] \\ \Delta y \in \left[-\frac{N-1}{2}, \frac{N-1}{2} \right] \end{aligned} \right\} \quad (5) \end{aligned}$$

对堆栈滤波器进行训练,使得堆栈滤波器的估计输出与期望输出之间的平均绝对误差最小^[6](MAE 准则):

$$\text{Minimize MAE}[FH] \quad (6)$$

$$\begin{aligned} \text{MAE} &= E \{ | \Delta \hat{f}(x_1, y_1, x_2, y_2) \\ &\quad - S_f(\Delta f(x_1, y_1, x_2, y_2)) | \} \\ &= E \left\{ \left| \sum_{m=0}^{M-1} T_m(\Delta \bar{f}(x_1, y_1, x_2, y_2)) \right. \right. \\ &\quad \left. \left. - S_f \left(\sum_{m=0}^{M-1} T_m(\Delta f(x_1, y_1, x_2, y_2)) \right) \right| \right\} \\ &= \sum_{m=0}^{M-1} E \{ | T_m(\Delta \bar{f}(x_1, y_1, x_2, y_2)) \\ &\quad - S_f(T_m(\Delta f(x_1, y_1, x_2, y_2))) | \} \quad (7) \end{aligned}$$

上式中的门限分解函数 $T_m(\cdot)$ 为:

$$T_m(x) = \begin{cases} 1, & \text{如果 } x \geq m (m \leq M-1) \\ 0, & \text{其它} \end{cases} \quad (8)$$

而 $E(\cdot)$ 表示对所有的 (x_1, y_1, x_2, y_2) 对应的估计输出与期望输出之间的误差求数学期望,例如只对一幅图象训练时, (x_1, y_1, x_2, y_2) 所有可能的取值为:

$$\begin{aligned} (x_1, y_1, x_2, y_2): \forall x_1 \in [1, N_x]; \forall x_2 \in [1, N_x]; \\ \forall y_1 \in [1, N_y]; \forall y_2 \in [1, N_y] \end{aligned} \quad (9)$$

式(6)和式(7)的求解参见文献[5,6]。

训练好的堆栈滤波器 $S_f(\cdot)$ 用于优化估计被测图象任意 2 象素点 (x_1, y_1) 和 (x_2, y_2) 之间的灰度梯度,从象素点 (x_1, y_1) 到象素点 (x_2, y_2) 的灰度梯度的优化估计值为:

$$\Delta \hat{f}(x_1, y_1, x_2, y_2) = S_f(\Delta f(x_1, y_1, x_2, y_2)) \quad (10)$$

本文的堆栈滤波器 $S_f(\cdot)$ 的滤波窗口选择得较

小(一般取3×3或5×5),用来在较小的邻域内优化估计被测图象任意2像素点之间的灰度梯度。下一节介绍的 Hopfield 神经网络将融合了整幅图象各像素点之间的灰度梯度的最优估计值,使得本文提出的边界检测法达到基于较大滤波窗口的堆栈滤波器边界检测法的边界检测效果。

2 基于堆栈滤波器和 Hopfield 神经网络的边界检测法

在基于堆栈滤波器和 Hopfield 神经网络的边界检测法中,计算堆栈滤波器 $S_f(\cdot)$ 输出的被测图象任意2像素点之间的灰度梯度优化估计值,用以确定 Hopfield 神经网络的权重矢量。本文的 Hopfield 神经网络的结构与 Chao^[3] 的 Hopfield 神经网络的结构相同,即将整幅被测图象看作为一个 Hopfield 神经网络,每一像素点是一神经元,每一神经元都与其他神经元相联但不与自身连接。Hopfield 神经网络由任意2像素点之间的灰度梯度优化估计值及对应的2像素之间距离所定义的能量函数所描述,每一神经元的初始状态由其对应的被测图象中像素点的归一化灰度决定,然后每一神经元的状态被迭代改变直到整个神经网络收敛。这种边界检测法将整个图象函数转化为一动态系统,动态方程将指导神经元的状态向 Hopfield 神经网络所定义的最低能量方向变化。

设被测的有噪声图象为 $f(x, y), x \in [1, N_x], y \in [1, N_y]$ 。设 t 为时间变量, $u(x, y, t)$ 和 $V(x, y, t)$ 分别为神经元 (x, y) 在 t 时刻的输入和输出, $\tau, R(x, y), I(x, y)$ 为能量函数参数^[3], $\bar{\omega}(x_1, y_1, x_2, y_2)$ 为神经元 (x_1, y_1) 到神经元 (x_2, y_2) 的权重系数。Hopfield 神经网络边界检测法由以下4个步骤组成:

(1) 归一化被测图象灰度到 0.0~1.0 之间,为表达方便仍然用 $f(x, y)$ 表示归一化的图象,并对应地归一化被测图象任意2像素点之间的灰度梯度优化估计值到 0.0~1.0 之间,同样仍然用 $\Delta\hat{f}(x_1, y_1, x_2, y_2)$ 表示从像素点 (x_1, y_1) 到像素点 (x_2, y_2) 的灰度梯度优化估计值。

(2) 计算 Hopfield 神经网络权重矢量 W 。

从神经元 (x_1, y_1) 到神经元 (x_2, y_2) 的连接权重系数被定义为:

$$\bar{\omega}(x_1, y_1, x_2, y_2) = \frac{1}{(\gamma + 1)!} \varphi(\Delta\hat{f}(x_1, y_1, x_2, y_2)) \quad (11)$$

$$\varphi(\beta) = \begin{cases} 1, & \text{如果 } \beta \leq \theta \\ -1, & \text{否则} \end{cases} \quad (12)$$

式中 θ 为预先定义的域值,反映2像素点之间距离信息的参数 γ 定义为:

$$\gamma = \max(|x_1 - x_2|, |y_1 - y_2|) \quad (13)$$

式(11)的阶乘将减弱相隔较远2神经元之间的连接强度。因此 Hopfield 反馈神经网络的连接权重系数矢量 W 为:

$$W = \{\bar{\omega}(x_1, y_1, x_2, y_2) : \forall x_1 \in [1, N_x], y_1 \in [1, N_y], x_2 \in [1, N_x], y_2 \in [1, N_y]\} \quad (14)$$

(3) 用图象每个像素点的归一化灰度初始化对应的神经元输出状态:

$$V(x, y, t = 0) = f(x, y) \quad (15)$$

(4) 随机选择一神经元 (x, y) , 用动态方程计算此神经元的输入状态 $u(x, y, t)$ 。这里采用的是标准的 Hopfield 神经网络动态方程:

$$\frac{du(x, y, t)}{dt} = -\frac{u(x, y, t)}{\tau} + \sum_{x'} \sum_{y'} \bar{\omega}(x, y, x', y') V(x', y', t) + I(x, y) \quad (16)$$

(5) 根据 Sigmoidal 变换更新此神经元的输出状态 $V(x, y, t)$:

$$V(x, y, t) = \Psi(u(x, y, t)) = \frac{1}{2} \left(1 + \tanh\left(\frac{u(x, y, t)}{u_0}\right) \right) \quad (17)$$

式中 u_0 为归一化基准值,当 $u_0 \rightarrow 0$ 时, $\Psi(\cdot)$ 成为硬限幅函数。

(6) 返回第(4)步,随机任选一其它神经元,重复第(4)步和第(5)步直到 Hopfield 神经网络的每个神经元的输出状态不变,即达到收敛状态。

(7) 二值化每个神经元的输出,获得图象边界。收敛后的 Hopfield 神经网络各神经元的输出将是近似的饱和值:接近 1.0 或接近 0.0。采用域值为 0.5 的简单二值化可以将神经元的输出转化为 0 或 1。如果像素点对应的神经元的输出为 0,则此像素点是边界点。

用于描述 Hopfield 神经网络的能量函数为:

$$E : S \subset R^{N_x \cdot N_y} \rightarrow R[FH] \quad (18)$$

$$E(t) = -\frac{1}{2} \sum_x \sum_y \sum_{x'} \sum_{y'} \bar{\omega}(x, y, x', y') V(x, y, t) V(x', y', t) + \sum_x \sum_y \frac{1}{R(x, y)} \int_0^{V(x, y, t)} \Psi^{-1}(\xi) d\xi - \sum_x \sum_y I(x, y) R(x, y) \quad (19)$$

式中 S 代表状态空间, R 为实数空间, $N_x \cdot N_y$ 是

Hopfield 神经网络的神经元总数。类似于文献[3]的分析,可以证明上述 Hopfield 神经网络的收敛性。

3 试验结果与结论

在本文中 Hopfield 神经网络由计算机模拟实现,我们将基于堆栈滤波器和 Hopfield 神经网络的

边界检测法和其他有关的边界检测对“Lena”图象进行了边界检测试验。图 1 显示的是标准的“Lena”图象,它不含干扰噪声,图象有 252×238 个像素点,象素灰度等级为 256。图 2 显示了噪声干扰下的“Lena”图象,其中包含 $SNR = 25$ 的 Gaussian 噪声和均匀分布的冲击噪声,冲击噪声密度为 15%。



图 1 无噪声的“Lena”原始图象



图 2 含 Gaussian 噪声和冲击噪声的“Lena”图象

由单纯的 Hopfield 神经网络检测到的图象边界如图 3 所示,检测到的图象边界受 Gaussian 噪声和冲击噪声的干扰较为严重,显然是由于 Hopfield 神经网络不能利用有监督训练所提供的信息造成的。

单纯基于堆栈滤波器的边界检测法^[1,2]对图 2 的噪声干扰下“Lena”图象的试验结果如图 4 所增

添。这种方法中使用的堆栈滤波器是根据图 1 和图 2 显示的无噪声和有噪声“Lena”图象进行训练得到的,堆栈滤波器采用的滤波窗口尺寸为 3×3 ,训练区域为图 1 和图 2 左上角 100×100 像素点的方形区域。由于堆栈滤波器滤波窗口较小,检测到的图象边界在一定的程度上仍然受到冲击噪声的影响。



图 3 基于 Hopfield 神经网络的边界检测结果



图 4 基于堆栈滤波器的边界检测结果(小窗口)

当采用较大的滤波窗口时,单纯基于堆栈滤波器的边界检测法对图 2 边界的检测结果如图 5 所

示,此时堆栈滤波器采用的滤波窗口尺寸为 7×7 ,训练区域同上。图 5 所示的图象边界基本上未受到

Gaussian 噪声和冲击噪声影响。

图6显示的是本文提出的基于堆栈滤波器和Hopfield神经网络边界检测对图2的边界检测结果。这种方法中使用的堆栈滤波器也是根据图1和图2训练得到的,堆栈滤波器采用的滤波窗口尺寸为3



图5 基于堆栈滤波器的边界检测结果(大窗口)

对比图6和图4的边界检测结果可以看出,采用同样的较小堆栈滤波器滤波窗口时,本文提出的边界检测法比单纯基于堆栈滤波器的边界检测法的抗噪声能力强得多;再对比图6和图5的边界检测结果可以看出,本文提出的边界检测法只需采用较小堆栈滤波器滤波窗口就可获得较大堆栈滤波器滤波窗口条件下单纯基于堆栈滤波器的边界检测法的边界检测效果。

上述试验是在主频为233MHz的Pentium II微机上进行的,本文提出的边界检测法采用较小的 3×3 的堆栈滤波器窗口,优化训练堆栈滤波器耗时12.7秒;单纯基于堆栈滤波器的边界检测采用较大的 7×7 的堆栈滤波器窗口时,优化训练堆栈滤波器耗时3小时11分钟。因此较大堆栈滤波器窗口条件下优化训练堆栈滤波器要耗费很多的计算时间。本文提出的边界检测法和Hopfield神经网络边界检测法同样可以容易地改为并行运算^[3]方式,因此也可以获得很快的边界检测速度。

本文提出了一种新的基于堆栈滤波器和Hopfield神经网络的边界检测法。实验表明,相对于基于堆栈滤波器边界检测法,本文提出的方法大大提高了对堆栈滤波器的优化训练速度,所需的内存大为减少。而相对于基于Hopfield神经网络的边界检测法,本文提出的方法又具有较强的抗混合分布

$\times 3$,训练区域也是图1和图2的左上角 100×100 像素点的方形区域。对比图6和图3,显然本文提出的边界检测法比单纯的Hopfield神经网络边界检测法的边界检测结果好的多。



图6 本文方法的边界检测结果

噪声的能力,可以获得较好的边界检测效果。

参考文献

- 1 Yoo J, Bouman C A, Delp E J, Coyle E J. Intensity edge detection with stack filter. SPIE Nonlinear Image Processing II, 1991, 1451: 58 ~ 69.
- 2 Yoo J, Bouman C A, Delp E J, Coyle E J. The nonlinear prefiltering and difference of estimates approaches to edge detection: Applications of stack filter. CVGIP: Graphical Models and Image Processing, 1993, 55: 140 ~ 159.
- 3 Chao C H, Dhawan A P. Edge detection using a Hopfield neural network. Optical Engineering, 1994, 33: 3739 ~ 3747.
- 4 Dhawan A P, Dufresne T. Low-level image processing and edge enhancement using a self-organizing neural network. In: Proceedings of IEEE Joint Conference on Neural Networks, 1990, 503 ~ 510.
- 5 Wendt P D, Coyle E J, Gallagher N C. Stack filters. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1986, 34: 898 ~ 911.
- 6 Lin J H, Selke T M, Coyle E J. Adaptive stack filtering under the mean absolute error criterion. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1990, 38: 938 ~ 954.
- 7 Hopfield J J, Tank D W. Neural computation of decisions in optimization problems. Biol Cybern, 1985, 52: 141 ~ 152.



黎明 1985年于上海交通大学电子工程系获学士学位,1990年和1997年于南京航空航天大学自动控制系及测试工程系分别获硕士和博士学位,副研究员,主要从事图象处理,模式识别,神经网络和遗传算法等方面的研究工作,已发表学术论文20余篇。



严超华 1982年于复旦大学数学系获学士学位,1984年于东南大学数理力学系获硕士学位,副教授,主要从事光测力学和图象处理等方面的研究工作。

刘高航 1969年于南京航空航天大学自动控制系获学士学位,教授,主要从事测试技术和模式识别等方面的研究工作。

Edge Detection Based on Stack Filter and Hopfield Neural Network

Li Ming, Yan Chaohua and Liu Gaohang

(Department of Applied Engineering, Nanchang Institute of Aeronautical Technology, Nanchang 330034)

Abstract A new kind of edge detection method based on stack filter and Hopfield neural network is proposed in this paper. First, the stack filter with smaller filtering window size is used to optimally estimate the gradient of gray scale for each pixels of the tested image. Then, weight vector of Hopfield neural network is determined by those optimal estimated values. Finally, converged Hopfield neural network outputs the image edges. Contrast to the stack filter based edge detection, the proposed method gains higher speed, uses less memory for optimal training of stack filter. Also contrast to the Hopfield neural network based edge detection, the proposed method has stronger abilities of reducing the effects of noise with different distributions, and can obtain much better edges.

Keywords Image processing, Edge detection, Stack filter, Hopfield neural network