

基于前向神经网络和 Hopfield 反馈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 提出了一种新的基于前向神经网络和 Hopfield 反馈神经网络的边界检测法,它分别探测每个象素点是否为边界点,便于实现边界检测的并行运算。首先设计了两层前向神经网络来增强和编码被检测象素点邻域的信息,然后利用增强和编码后的邻域图象作为 Hopfield 反馈神经网络的输入, Hopfield 神经网络收敛时得到图象边界点。这种新的神经网络边界检测法所需的计算量比传统的 Hopfield 网络边界检测法少得多,并增强了网络的抗噪声能力。整个神经网络是非监督学习的,为神经网络的训练提供了方便。

关键词 图象处理 边界检测 前向神经网络 Hopfield 反馈神经网络

0 引言

许多类型的人工神经网络已被尝试用于图象边界检测^[1-4],例如 Spreeuwiers^[1]的两层前向神经网络边界检测法、Dhawan^[2]的自组织神经网络边界检测法和 Xue^[3]的 Hopfield 神经网络边界检测法。Xue 将边界检测看作一种优化问题,这种方法与传统的 Sobel、Laplacian 等微分算子概念完全不同,它检测二维 Gaussian 函数的二次导数过零点,并用之初始化多层 Hopfield 神经网络的神经元,这种多层 Hopfield 类型神经网络的神经元之间只有局部的互联,是一种简化的 Hopfield 神经网络。Chao^[4]提出了另一种 Hopfield 神经网络边界检测法,将整幅图象看作为一个 Hopfield 神经网络,每个象素点是一个神经元,每个神经元都与其他神经元相联但不与自身连接,神经网络由象素灰度及象素之间距离所定义的能量函数所描述。Hopfield 神经网络收敛时得到图象边界。这是一种自组织的神经网络,不需要训练样本和训练过程,使得此方法的基层处理很容易进行。Chao^[4]的试验表明这种边界检测法与 Sobel 等算子的效果基本相当。但是这种 Hopfield

神经网络边界检测法所需的计算量比一般的边界检测法大得多,要花较长的时间才能使网络迭代收敛。这种方法的另一缺点是抗噪声能力不强,检测出的边界较弱,后续的二值化阈值选择较困难。要为它的能量函数设定噪声平滑的限制条件是非常困难的。

本文为克服上述的 Hopfield 神经网络边界检测法的两个缺点提出了一种新的基于前向神经网络和 Hopfield 反馈神经网络的边界检测方法,如图 1 所示。这种新方法分别探测每个象素点是否边界点,为每个象素点 (x, y) 选择一个 $M \times M$ 邻域,形成邻域图象 P_{xy} ,设计一个两层前向神经网络来增强和编码邻域内的信息,然后将利用增强和编码后的 $N \times N$ 邻域图象 Q_{xy} 作为 Hopfield 反馈神经网络的输入,检测此象素点是否边界。由于 Hopfield 反馈神经网络的神经元数目大为减少,而且可以同时在一象素点并行运算,这种新方法可以获得很快的边界检测速度。通过前向神经网络对邻域内的信息增强,这种新方法相对 Chao^[4]提出的方法可以获得更强的边界,抗噪声能力也得到改善。我们在训练前向神经网络采用的是 Hebb^[5]学习规则,因此整个神经网络仍然是非监督学习的。




图 1 基于前向神经网络和 Hopfield 反馈神经网络的边界检测法框

1 用于增强图象边界的前向神经网络

用于增强图象边界的两层前向神经网络结构如图2所示,在神经网络的训练过程中输出层有相互的侧向负反馈,而在增强图象边界的工作过程中去除这种侧向负反馈。对象素 (x,y) ,选择一以 (x,y) 为中心的 $M \times M$ 邻域,其中 M 为正奇整数, $M \times M$ 邻域内每个像素灰度值一一对应地输入到 $M \times M$ 个神经元的输入层。输出层有 $N \times N$ 个神经元,其中 N 为小于或等于 M 的正奇整数。假设输入矢量和输出矢量分别为: $P_{xy} = [p_0 p_1 \dots p_{M^2-1}]^T$ 和 $Q_{xy} = [q_0 q_1 \dots q_{N^2-1}]^T$,输入层到输出层的权重系数矢量为: $W = [w_0 w_1 \dots w_{N^2-1}]^T$,其中 W_i 代表输出层第 i 个神经元与输入层各个神经元之间的连接权重矢量,因此 $Q_{xy} = W^T P_{xy}$ 。训练前向神经网络的目的是为了使得由连接权重矢量 W 产生的输出矢量 Q_{xy} 能反映以象素 (x,y) 为中心的邻域内最大的边界信息。 Q_{xy} 中的每一个分量都期望能显示输入矢量中的最大变化并与 Q_{xy} 中的其他分量保持最小关联。输入矢量中的最大变化对应最大信息内涵,输出矢量之间最小关联意味着最少信息重叠。训练过程中的输入邻域样本尽可能包括各种不同强度、不同方向、不同曲率、不同位置的边界。




图2 两层前向神经网络的结构图

在详细描述这种前向神经网络的训练算法之前,先总体介绍一训练过程。训练过程包括九个步骤:

- (1) 训练开始时,用随机值初始化神经网络的连接权重系数,然后规一化连接权重系数,使得连接权重矢量 W 的幅值为1;
- (2) 随机选择一象素点 (x,y) ,并产生以此象素点为中心的 $M \times M$ 邻域;

(3) 初始化输入层神经元的输出:将邻域内 $M \times M$ 个象素的灰度值规一化到 $[0,1]$ 范围,并作为输入层 $M \times M$ 个神经元的初始输出;

(4) 竞争过程:计算输出层 $N \times N$ 个神经元的输出,这些神经元相互之间的侧向负反馈决定那一个神经元能竞争获胜;

(5) 假设输出层的第 i 个神经元竞争获胜,采用Hebb规则调整此神经元的权重矢量 W_i ;

(6) 衰减竞争获胜的神经元的学习系数 η ,防止经常竞争获胜的神经元过度学习;

(7) 判断此竞争获胜的神经元是否已是成熟的神经元,如果不是,则回到(2)进行另一次的学习过程;否则进入下面步骤;

(8) 产生反馈矢量:如果此竞争获胜的神经元是已成熟的神经元,为了防止它抑制其它神经元对这次输入矢量的学习,产生一反馈矢量的输入层,再回到(3)重复本次训练过程,由于经负反馈改变后的输入矢量与此已成熟的神经元的权重矢量相互正交,在重复的竞争过程中此已成熟的神经元将不会获胜;

(9) 如果所有输出层神经元都成为成熟的神经元,结束训练过程。

为了使得输出矢量各分量之间变化最大,采用Hebb规则调整竞争获胜的神经元权重矢量 W_i ,对于第 τ 次训练过程,神经元权重矢量被调整为:

$$W_i^{\tau+1} = W_i^{\tau} + \eta_i q_i P_{xy}^{\tau} \tag{1}$$

其中对应于输出层第 i 个神经元的学习速率 η_i 将随着训练次数的增加而逐渐衰减,当学习速率 η_i 衰减到小于一定值时,对权重矢量 W_i 的调整将可以忽略不计,此时我们将神经元称为成熟的神经元。

为了使得输出层的输出矢量各分量之间的信息重叠最小,在保持输出矢量各分量之间变化最大的前提下,尽量使得输出层各神经元对应的权重矢量之间距离最大。这是由神经网络的竞争学习机制来实现的。在每一次训练过程中,如果某一输出层的神经元对应的权重矢量与输入矢量最相似,则此神经元将竞争获胜,而在此次训练过程中只有竞争获胜的神经元权重矢量根据Hebb规则得到调整,其他的神经元权重矢量保持原值。而且,如果某一输入矢量使得竞争获胜的神经元权重矢量向着靠近其他输出层神经元权重矢量的方向调整,则这种调整将受到抑制,如果此输入矢量使得竞争获胜的神经元权重矢量向着远离其他输出层神经元权重矢量的方向调整,则这种调整将得到加强。这是通过训练过程中

的输出层各神经元之间的充分侧向负反馈来实现的。这种充分侧向负反馈是将神经元的输出经过加权后作为抑制信号输入到所有其他的神经元。假设所有神经元的侧向负反馈的权重系数都相同,其值为 v ,则在第 τ 次训练过程中,输入到第 i 个输出层神经元的侧向负反馈抑制信号为: $h_i^- = \sum_{n \neq i} vq_n^+$ 。本文称与侧向负反馈抑制信号 h_i^- 对应的第 i 个输出层神经元的输出为此神经元的激励状态。

在每一个训练过程中,输出层的竞争是由多次迭代完成的。在这些迭代过程中,输出层神经元的激励状态和其侧向负反馈抑制信号同时发生动态变化。对第 τ 次训练过程中的第 k 次迭代,假设第 i 个输出层神经元的激励状态为 $a_i^+(k)$,则此神经元的输出为:

$$q_i^+(k) = \begin{cases} a_i^+(k) & \text{If } a_i^+(k) \geq \varphi \\ 0 & \text{Otherwise} \end{cases} \quad (2)$$

(2)式中 φ 是一个小的正实数域值。在第 τ 次训练过程的初始,第 i 个输出层神经元的激励状态等于输入矢量与其权重矢量之积,即由下式决定:

$$a_i^+(0) = (W_i^+)^T P_{xy} \quad (3)$$

在第 k 次迭代时,此神经元的激励状态为:

$$a_i^+(k) = \frac{a_i^+(k-1)}{1 + \sum_{n \neq i} [vq_n^+(k-1)]} \quad (4)$$

因此输出层神经元的激励状态将会不断地被抑制。与之对应,输出层各神经元的输出被这种相互的侧向负反馈所减弱,直到只有竞争获胜的神经元有非零输出。在这种平衡状态下,竞争获胜的神经元权重矢量由式(1)学习调整。

如果竞争获胜的神经元权重矢量与输入矢量的靠近程度只比其他神经元权重矢量与输入矢量的靠近程度高少许,则此竞争获胜的神经元的输出将被较大的抑制,与之相应的权重矢量调整将较小,否则的话,竞争获胜的神经元权重矢量与其他输出层的神经元权重矢量有很大的区别,其他输出层的神经元权重矢量对竞争获胜的神经元的最后输出影响较小,而与之相应的权重矢量调整将较大,从而使得输出层的各神经元权重矢量尽量被分开,也就是使得输出层的输出矢量各分量之间的信息重叠最小。

每个神经元的初始学习速率(学习系数)被设置为相同的值,一般为 0.999,随着训练过程中竞争获胜的次数增加,学习速率逐渐被衰减。在每次训练结束时只有竞争获胜的神经元的学习速率被衰减,假设第 τ 次训练过程的第 i 个神经元竞争获胜,则其学

习速率被衰减为:

$$\eta_i^{\tau+1} = \eta_i^{\tau} \alpha (1 - \beta q_i^+) \quad (5)$$

其中 α, β 为控制学习速率衰减过程的参数。如果某一神经元经常竞争获胜,其学习速率迅速衰减,从而使得此神经元的权重矢量较快地达到稳定值。如果某一神经元很少竞争获胜,其学习速率变化较为呆滞,此神经元的权重矢量还有较大的调整余地。这样的学习速率变化规则大大加强了神经网络的自适应性。如果某一神经元的学习速率被衰减到小于一定的域值(通常此域值选为 0.01),则此神经元为成熟的神经元。

通常一个神经元会探测到大量输入矢量之间的显著特征而快速成熟,此神经元经常竞争获胜会阻止其他神经元的训练学习,为了避免这种情况的发生,假设在第 τ 次训练过程,当一个成熟的神经元竞争获胜时,此成熟的神经元产生一负反馈矢量到输入矢量。假设此成熟的神经元是输出层的第 i 个神经元,则经负反馈的输入矢量改变为:

$$P_{xy}^{\tau+1} = P_{xy}^{\tau} - W_i^-(W_i^+)^T P_{xy}^{\tau} \quad (6)$$

然后此改变过的输入矢量被重新利用,并重复整个第 τ 次训练过程。经负反馈改变过的输入矢量与上述的成熟神经元的权重矢量正交,此成熟的神经元将在重复的第 τ 次训练过程中被抑制。也就是说,此成熟的神经元通过产生反馈矢量将它探测到的特征从输入矢量中去除,因此允许其他神经元对输入矢量进行学习。

当所有的输出层神经元都被训练成熟,我们称此两层前向神经网络被充分训练,然后将输出层的侧向负反馈去除,输出层的神经元不再竞争,连接到输入层的负反馈矢量也被去除。

2 用于图象边界检测的 Hopfield 反馈神经网络

Hopfield 神经网络检测图象边界的方法^[4]是将图象看作一个动态系统,而此动态系统是由能量函数完整描述的,象素点与神经元是一一对应的。神经元除了不与自身连接外,与其他神经元充分连接,任意两神经元之间连接权重系数由对应两象素点的灰度变化和它们之间距离定义。

先将 $N \times N$ 图象邻域内象素灰度规一化到 0.0—1.0 之间,然后将每个神经元的初始输出设置为其对应象素点的规一化灰度。在 Hopfield 神经网络收敛过程中,神经元的输出状态将会不断地迭代

改变,直到网络收敛。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 $N \times N$ 图象邻域中心像素点对应的神经元的输出为 0,则此像素点是边界点。

因此 Hopfield 神经网络检测 $N \times N$ 图象邻域中心像素点是否边界点的方法如下:

- (1) 用对应像素点的归一化灰度初始化各神经元的输出状态;
- (2) 随机选择一个神经元;
- (3) 用动态方程计算此神经元的输入状态;
- (4) 根据 Sigmoidal 变换更新此神经元的输出状态;
- (5) 返回(2),直到 Hopfield 神经网络收敛;
- (6) 如果 $N \times N$ 图象邻域中心像素点对应的神经元的输出为 0,则此像素点是边界点。

此 Hopfield 神经网络的能量函数与收敛性证明参见文献^[4]。

3 试验结果和结论

我们用计算机模拟上述的两层前向神经网络和 Hopfield 反馈神经网络,对图象进行了边界检测试验。图 3 显示了基于前向神经网络和 Hopfield 反馈神经网络的边界检测法与传统 Sobel 边界检测法对 'Lena' 图象边界检测的试验对比结果。图 3(a)是含 Gaussian 噪声(SNR=20)的原始 'Lena' 图象,图象尺寸为 252×238 ,有 256 灰度等级;图 3(b)是对传统 Sobel 算子输出二值化(域值为 140)后探测到的边界;图 3(c)是基于前向神经网络和 Hopfield 反馈神经网络的边界检测法探测到的边界,这种方法的参数选择为: $M=11, N=9$ 。从图 3(b)和(c)的边界对比可以看出基于前向神经网络和 Hopfield 反馈神经网络的边界检测法检测出的边界较强,由于此方法选择的邻域可以比 Sobel 算子覆盖的邻域大得多,因此抗噪声能力得到加强。



(a) 原始 'Lena' 图象(含 Gaussian 噪声)

(b) Sobel 原始算子探测到的边界

(c) 本文方法探测到的边界

图 3 基于前向神经网络和 Hopfield 反馈神经网络的边界检测法对 'Lena' 图象试验结果

图 4 显示了基于前向神经网络和 Hopfield 反馈神经网络的边界检测法与单纯 Hopfield 反馈神经网络边界检测对掌纹图象边界检测的试验对比结果。图 4(a)是含 Gaussian 噪声(SNR=15)的原始手掌中心掌纹图象,图象尺寸为 204×220 ,有 256 灰度等级;图 4(b)是单纯 Hopfield 反馈神经网络边界检测法检测到的掌纹边界;图 4(c)是基于前向神经网络和 Hopfield 反馈神经网络的边界检测法探测到的掌纹边界,这种方法的参数选择为: $M=11, N=7$ 。显然图 4(c)的边界信号与噪声的信噪比图 4(b)的边界信号与噪声的信噪比高得多。


在前向神经网络的训练过程中,由于采用的是 Hebb 学习规则,对于每一个 $M \times M$ 图象邻域的训

练是非常快的,但整个前向神经网络的收敛速度与被测图象本身边界特征和噪声分布规律有关,在检测图 3 图象边界时,被训练图象像素占整幅图象的约 28%时前向神经网络的学习到达收敛,而检测图 4 图象边界时,被训练图象像素只占整幅图象的约 20%时前向神经网络的学习就到达收敛。前向神经网络的收敛权重值随被测图象边界特征和噪声分布规律而变化,因此检测不同类型图象边界时,其对应的前向神经网络需要再训练。

由于 Hopfield 反馈神经网络的神经元数目大为减少,而且可以同时在一像素点并行运算,基于前向神经网络和 Hopfield 反馈神经网络的边界检测法可以获得很快的边界检测速度。通过前向神

神经网络对邻域内的信息增强,这种方法可以获得更强的边界信息,而且具有较强的抗噪声能力。整个

神经网络是非监督学习的,为神经网络的训练提供了方便。



(a) 原始掌纹图象(含 Gaussian 噪声)

(b) Hopfield 网络探测到的边界

(c) 本文方法探测到的边界

图 4 基于前向神经网络和 Hopfield 反馈神经网络的边界检测法对掌纹图象试验结果

参 考 文 献

- 1 Spreeuwens L J. Neural network edge detector. In: Proc SPIE, 1991, 1451:204~215.
- 2 Dhawan A P, Dufresne T. Low-level image processing and edge enhancement using a self-organizing neural network. In: Proc IEEE J Conf on Neural Networks, 1990, 503~510.
- 3 Xue K, Breznik C W. A neural-net computing algorithm for detecting edges in a gray scale image. In: Proc 29th EIII Conf on Decision and Control, 1990, 4:2368~2373.
- 4 Chao C-H, Dhawan A P. Edge detection using a Hopfield neural network. Optical Engineering, 1994, 33: 3739~3747.

- 5 Lippmann R P. An introduction to computing with neural nets. IEEE Acoustics, Speech and Signal Processing Magazine, 1987, 4~22.

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 Feed Forward Neural Network and Hopfield Neural Network

Li Ming, Yan Chaohua and Liu Gaohang

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

Abstract An edge detection method based on feed forward neural network and Hopfield neural network are proposed, the feed forward neural network is used to enhance and encode the information in the region of tested pixel, and its result is the input of Hopfield neural network which does iterative working till the network converges. The new neural network saves the computational cost and can generate edge map clearer than traditional Hopfield neural network. The whole system works under unsupervised learning, so it is easy to train the neural networks

Keywords Image processing, Edge detection, Feed forward, Hopfield