

基于神经网络的纹理图象生成

吴小培 周荷琴 冯焕清

(中国科学技术大学电子科学与技术系, 合肥 230026)

摘要 提出了一种利用多层前馈神经网络生成纹理图象的新方法. 利用该方法可方便地生成图案丰富的纹理图象集, 并且该纹理图象集中的任何一幅图象均唯一地对应一组神经网络的权值和阈值, 因此不仅便于图象保存, 还大大地节省了图象存储空间.

关键词 多层前馈神经网络 纹理图象 BP 算法

中图法分类号: TP319.9 TP183 文献标识码: A 文章编号: 1006-8961(2000)06-0484-05

The Texture Image Generation Based on Neural Network

WU Xiao-pei, ZHOU He-qin, FONG Huan-qing

(Department of Electronic Science and Technology, USTC, Hefei 230026)

Abstract In this paper, a new method to generate the texture image by use of Multi-layer feed-forward neural network is presented. This method can be used conveniently to generate different kinds of texture image sets. Each image in texture image sets corresponds to a group of definite weights and thresholds of neural network. This characteristic of the method is very useful for image's saving and then a lot of storage space can be saved.

Keywords Multilayer feed-forward neural network, Texture image, BP algorithm

0 引言

纹理特征是图象的一个重要特征, 因此纹理分析在图象分析与处理中占有非常重要的地位, 而纹理综合则是对自然纹理的模拟, 具有很高的应用价值. 但是无论采用以纹理模型或者是几何模型为基础的纹理综合, 都是一个比较复杂的过程. 本文利用多层前馈神经网络进行纹理综合, 是纹理图象综合方法的一种新的尝试, 利用该方法可方便地生成特征各异的纹理图象, 而且生成方法非常简单, 只需提供给多层前馈神经网络一个“种子”(学习样本), 网络就可以在学习过程中自动生成纹理图象. 由于我们有意识地对网络结构、节点函数、学习样本进行了选择, 从而使得网络始终处于学习调整状态, 而无法收敛, 因此网络的学习过程可无限制地进行, 也就是说, 可生成无穷多幅纹理图象, 而且每一幅纹理图象唯一地对应一组网络的权值和阈值, 因而非常便于

图象的保存.

本文讨论的纹理图象的生成过程如图 1 所示:



图 1 纹理图象生成过程

1 纹理综合神经网络

1.1 网络结构^[1]

图 2 是用于纹理综合的多层前馈神经网络.




图 2 纹理综合神经网络模型

从图 2 可见, 该网络有二个输入节点(x_1, x_2), 用来表示象素点的二维坐标; 一个输出节点 Z , 表示该象素点的灰度值. 该网络可包含有多个隐层和隐节点. 设节点函数为 $g(\cdot)$, 网络的权值集合为 $W(t)$, 则图 2 所示网络的输入输出关系为

$$Z = F_t(x_1, x_2) \quad t = 1, 2, 3, \dots \quad (1)$$

函数 $F(\cdot)$ 的形式由节点函数 $g(\cdot)$ 和权系数 $W(t)$ 决定, t 为网络学习的次数. 在网络的学习过程中, 如果 $g(\cdot)$ 保持不变, 则 $F(\cdot)$ 随 $W(t)$ 在学习过程中的不断调整而调整. 每次调整的结果将产生一组新的模型参数, 即网络的权系数, 不同的权系数则对应不同的二维图象. 实验表明, 通过选择合适的节点函数和学习样本, 网络可产生多种具有纹理特性的纹理图象.

1.2 BP 算法与节点函数的选择^[2]

我们采用 BP 算法作为纹理模型的参数调整算法. BP 算法是用于多层前馈神经网络学习的最常用算法. 这种算法是由正向传播与反向传播过程组成. 其学习样本的输入模式经隐单元逐层处理, 并传向输出层. 如果在输出层得不到期望的输出, 则转入反向传播过程, 并根据输出误差逐层调整每一连接权值和节点函数的阈值, 再进入正向传播过程, 如此往复, 直至收敛. 其中误差函数定义为

$$E = \frac{1}{2} \sum_{l=1}^N (\tilde{z}_l - z_l)^2 = \sum_{l=1}^N E_l \quad (2)$$

而

$$E_l = \frac{1}{2} (\tilde{z}_l - z_l)^2 \quad (3)$$

式中, N 为学习样本的个数, z_l 为第 l 个学习样本的理想输出, \tilde{z}_l 是学习过程中的实际输出. 学习过程中权值的调整是按下式进行的.

$$W_{ij}^s(t+1) = W_{ij}^s(t) - \Delta W_{ij}^s(t) \quad (4)$$

其中

$$\Delta W_{ij}^s(t) = \eta \frac{\partial E}{\partial W_{ij}^s} = \eta \sum_{l=1}^N \frac{\partial E_l}{\partial W_{ij}^s} \quad (5)$$

式中, t 为学习次数, η 为一小正数.

在多层前馈神经网络的一般应用中, 通常选择节点函数为 Sigmoid 函数, 其目的是为了使得网络在经过一定次数的学习后, 能稳定地收敛到全局极小点. 但是, 基于 BP 算法的多层前馈网络在应用中存在一些必须解决而又难以解决的问题, 例如, 如何提高网络学习速度、如何避开局部极小点等. 虽然用其它类型的节点函数取代 Sigmoid 函数以及采用一些

对 BP 算法的改进措施, 在一定程度上能改善网络的学习性能, 但效果并不理想.

值得一提的是, 就纹理图象合成而言, 其目的是在学习过程中随机地产生包含纹理特征的图象, 至于网络能否收敛则并不重要, 因而也就避开了多层前馈神经网络在一般应用中所遇到的难题. 相反, 我们却希望网络始终处在不收敛的状态下, 以便使网络的权值能不断得到调整, 而生成更多的纹理图象.

对于纹理图象, 至今一直没有一个统一的定义. 一般而言, 纹理图象可描述为^[3]

$$F(x_1, x_2) = T(x_1, x_2) * \sum_{k_1, k_2 \in z} \delta(x_1 - k_1 \Delta x_1, x_2 - k_2 \Delta x_2) \quad (6)$$

其中, $T(x_1, x_2)$ 是一局域性函数, 它决定着纹理图象最基本的纹理特征. 这一局域模式在图象中反复出现, 即形成了具有一定周期性(或准周期)的纹理图象. $\Delta x_1, \Delta x_2$ 表示水平方向和垂直方向的纹理周期, 它们可以是常数或是缓变化数. 由于纹理特征具有明显的周期性(准周期), 同时考虑到 BP 算法对节点函数的要求, 因此必须选择具有周期性的连续可微函数作为纹理综合多层前馈神经网络的节点函数. 显然, 正余弦类函数以及调幅调频函数满足该要求.

由于 $T(x_1, x_2)$ 与网络结构以及权系数 $W(t)$ 直接相关, 且随着对“种子”样本学习次数 t 的增加, $W(t)$ 不断得以调整, 因而 $T(x_1, x_2)$ 也随之不断调整. 纹理周期 $\Delta x_1, \Delta x_2$ 则直接受控于所选择的周期性节点函数的周期 T_p , 以及由网络结构所确定的二维函数的形式. 在给定了网络结构和节点函数的情况下, 纹理图象的基本形式是很容易得到的. 图 3 是图 2 纹理综合神经网络模型的一种较简单的形式: 它是只含有一个隐层、二个隐节点的神经网络, 其所描述的纹理图象的数学模型可表达为

$$Z = F(x_1, x_2) = g(g(x_1 w_1 + x_2 w_3 - \theta_1) w_4 + g(x_1 w_2 + x_2 w_5 - \theta_2) w_6 - \theta_3) \quad (7)$$

式(7)中, 参数(权值、阈值)在 BP 算法的控制下进行调整, 每次调整的结果则对应于一新的纹理数学模型. 图 3 只是一简单的网络模型. 实际应用中, 网络的结构要复杂得多, 如对一个含有 M 个隐层的网




图 3 网络模型

络,其权值数 W 和阈值数目 R 分别为

$$W = 2 \times L_1 + L_1 \times L_2 + \dots + L_{M-1} \times L_M + L_M \quad (8)$$

$$R = L_1 + L_2 + \dots + L_M + 1 \quad (9)$$

其中, $L_i (i = 1, 2, \dots, M)$ 为每一隐层的节点数, 由于众多的参数共同调整, 使纹理模型变得非常复杂. 也正因如此, 才能获得千变万化的纹理图象.

1.3 “种子”样本的选择

通常, 确定了网络的基本结构与节点函数, 也就给定了纹理图象的神经网络模型. 在同一种神经网络模型下, 而对应于不同的“种子”样本, 则可生成不同的“纹理图象集”. 而对应于同一“种子”样本, 如改变网络的隐层数和隐节点数, 同样也可生成不同的“纹理图象集”.

设 S 为“种子”样本, $P = \{P_1, P_2, \dots, P_t, \dots\}$ 表示由“种子”样本 S 生成的纹理图象集. 由图 2 可知, S 由有限个二维点集组成

$$S = \left\{ \begin{array}{l} x_{1i} \\ x_{2i} \end{array}, y_i; i = 1, 2, \dots, N \right\} \quad (10)$$

式中, x_{1i}, x_{2i} 表示“种子”样本的输入模式, y_i 表示输出模式.

由于网络是无法收敛的, 因此理论上 P 中应包含无穷多幅纹理图象, 但实际上随着学习次数增加到一定的次数 t_m 后, 网络所生成的纹理图象之间的差异会越来越小, 这表明 $t > t_m$ 后, 网络虽然仍在继续学习, 但权值的调整量 $\Delta W_{ij}(t)$ 已经很小, 我们称此时的 t_m 为纹理图象的生成周期. 对于不同的样本集, t_m 显然也是不相同的. 通常在选定网络结构和学习样本 S 后, 希望纹理图象的生成周期较长, 即 t_m

较大, 以便生成较多的纹理图象, 以供选择. 但样本 S 的分布与 t_m 的关系难以精确描述, 一般而言, 样本分布越复杂, t_m 越大, 所生成的纹理图案也越丰富, 而且网络的结构 (隐层数与隐节点数) 的复杂度与所生成的纹理图象也存在类似的关系.

2 实验结果与讨论

由式 (10) 所示的样本形式, 选择一“种子”样本, 样本个数 $N = 124$, 样本分布如图 4 所示, 当 x_{1i}, x_{2i} 取图中实线边框上的点时, $y_i = 1$; 当 x_{1i}, x_{2i} 取图中虚线边框上的点时, $y_i = -1$.




图 4 “种子”样本的分布

实验中, 选取节点函数 $g(x) = \sin(0.5x)$, 在图 2 所示的网络中, 取一个隐层, 隐节点数为 5. 在此模型下, 网络在学习过程中产生的部分纹理图象如图 5 所示. 若隐节点数增加为 7, 其网络生成的部分纹理图象如图 6 所示. 若增加一隐层, 且第一隐层和第二隐层的节点数分别为 5 和 4, 其网络生成的部分纹理图象如图 7 所示.




图 5 纹理图象 (1 个隐层, 5 个隐节点)




图 6 纹理图象(1个隐层, 7个隐节点)




图 7 纹理图象(2个隐层, 隐节点数为 5, 4)

由图 5、图 6 和图 7 可以看出, 同一“种子”样本, 在不同的网络结构下, 可生成不同的纹理图象集, 不难想象不同的“种子”样本, 在同一网络结构下也可生成不同的纹理图象集. 另外, 网络初始权值、节点函数的不同, 都会对所生成的纹理图象产生不同的影响. 因此, 在实际应用中, 可多方面地对纹理综合过程进行控制, 以便生成图案丰富的纹理图象供选择. 同时也可以看出, 由于每一幅纹理图象唯一地对应一组神经网络权值和阈值, 例如图 5 中与任意一幅图象对应的权值和阈值为 $2 \times 5 + 5 \times 1 + 6 = 21$, 因此只要保存这 21 数值, 以及节点函数和网络结构参数, 即可保存一幅图象. 这将可大大地节省储存空间. 图象尺寸的大小完全由 x_{1i}, x_{2i} 的取值范

围决定, 可根据需要任意选择.

最后, 我们给出纹理图象生成、存储及恢复的详细步骤:

- (1) 根据图 2 所示的网络结构, 选择网络的隐层数、隐节点数以及具有周期特性的节点函数.
- (2) 按式(10)的形式, 选择一组“种子”样本.
- (3) 选择观测图象的尺寸 $N_1 \times N_2$ (例如图 5 中的每一幅图象的尺寸为 100×100).
- (4) 用 BP 算法进行网络学习. 在学习过程中, 根据网络结构所确定的数学模型(如式(7)), 并代入每次学习后(或间隔若干次学习后)的权值、阈值, 取 $x_1 = 0, 1, 2, \dots, N_1; x_2 = 0, 1, 2, \dots, N_2$, 计算出图象在 (x_1, x_2) 坐标点的灰度值 $F(x_1, x_2)$, 并显示图象.

(5) 选择感兴趣的纹理图象, 保存相应的权值和阈值。(注: 也可按常规方法保存整幅图象)。

(6) 保存网络结构参数(隐层数和隐节点数)。

(7) 如要恢复图象, 则可读取所存储的参数, 按步骤(4)显示图象的方法即可。

3 结束语

本文提出了利用多层前馈神经网络进行纹理图象综合的新方法, 实验表明, 利用该方法可生成丰富的纹理图案. 所生成的纹理图案可用于广告设计、动画片背景设计、纺织图案设计等诸多商业和工业领域, 具有很好的应用前景. 同时本方法也可为纹理分析领域的科研人员提供大量的纹理图象以供选择. 应该说明的是: 在网络结构参数和“种子”样本的选择上, 我们还没有得出可靠的理论依据, 在应用中, 一般以尝试法为主. 我们认为这是一个非常有意义的研究课题.

参考文献

- 1 Lippmann R P. An introduction to computing with neural nets. IEEE ASSP Magazine, 1987, 4(1): 4~ 22.

- 2 吴小培, 柴晓冬, 张德龙. 多层前馈网络在图象分割中的应用. 电子科学学刊, 1995, 17(3): 225~ 231.
- 3 贾天旭, 郑南宁, 张元亮. Shannon 小波包分解自适应 Gabor 滤波器设计及其在纹量分割中的应用. 电子学报, 1998, 26(10): 75~ 80.



吴小培 1966年生, 1988年获电子科技大学(成都)硕士学位, 现为安徽大学副教授, 硕士生导师, 中国科技大学博士生(在职), 中国电子学会会员, 中国图象图形学会会员. 主要研究领域为信号处理理论及应用.

周荷琴 中国科技大学自动化系教授、博士生导师. 主要研究方向为医学影像图象处理、生物医学信息处理、智能医疗仪器、计算机辅助教育等.

冯焕清 中国科技大学电子科学与技术系教授、博士生导师. 主要研究方向为生物医学信息处理、医学影像图象处理、生物系统建模与仿真、智能医疗仪器等.

通告

为适应我国信息化建设需要, 扩大作者学术交流渠道, 本刊已加入《中国学术期刊(光盘版)》和“中国期刊网”. 作者著作权使用费与本刊稿酬一次性付给. 如作者不同意将文章编入该数据库, 请在来稿时声明, 本刊将做适当处理.