

文章编号: 1007- 2985(2004) 02- 0066- 05

基于 FART 网络与数据融合的图像增强和恢复

傅 明, 肖如良, 唐贤瑛

(长沙交通学院计算机工程系, 湖南 长沙 410076)

摘 要: 为了有效地进行图像的增强和恢复处理, 提出了 1 种基于 Fuzzy ART(FART) 网络与数据融合的方法. 利用灰度直方图门限化方法, 不仅可以自动确定分类数目以进行聚类分析, 而且可对来自同一景物的多幅带有不同噪声的图像进行处理. 仿真实验表明, 在数据融合时, FART 网络能较好地实现图像的增强和恢复.

关键词: Fuzzy ART 网络; 数据融合; 图像增强和恢复; 聚类分析

中图分类号: TP391

文献标识码: A

1 FART 简介

图像的融合是图像的增强和恢复等综合处理过程, 对来自同一景物的多幅图像从多维信号中提取信息, 减少信号的不确定性, 并对信号源进行更精确的表达. 由于待处理的各幅图像中有效信息之间是相关的, 而各幅图像中的干扰信息却不具有这种相关性, 故这些技术大多是靠多幅静止的或运动的图像之间的相关性, 进行一系列的运算和现代算法来实现. 最显著的是应用于卫星云图的处理. 张兆礼等^[1]利用自组织神经网络(Kohonen 网络)算法结合模糊处理方法对图像数据的融合提出了一种可行的方法. 张定会^[2]、吴秀清^[3]提出了一种基于 BP 神经网络的数据融合的方法. 范凯等^[4]分析了传统神经网络的数据融合算法的缺点并提出了改进的算法. 袁曾任^[5]介绍了有关 ART 的基础理论. 莫玉龙等^[6]提供了一种可参考的模糊 ART 的应用方法. 笔者分析了基于模糊 ART 理论(Fuzzy Adaptive Resonance Theory, 简称 FART) 网络模型进行数据融合的特点, 利用灰度直方图法进行聚类分析, 给出了一种基于 FART 网络与数据融合的图像增强和恢复方法, 最后在 Matlab 里实现仿真.

FART 是美国 BOSTON 大学的 S. Grossberg 于 1991 年在自振动网络理论模型 ART1 的基础上, 将模糊理论和自振动理论相结合而引入的一种理论. 该理论的出现引发了系列实时无导师聚类学习和神经网络模型的发展, 这些模型可以对输入序列进行稳定的快速或慢速的学习. 此后, Carpenter G 与 Grosberg S 合作推出了基于 ART 理论的 2 种基本模型, 即 ART2 和 ART3. 近年来, ART 技术在此基础上得到了迅速发展. Fuzzy ART 是由 ART1 结构演化而来的, 二者的结构基本相同, 前者将模糊集合的性质及运算特性引入 ART1, 这一点从其名称也可看出, 从而克服了 ART1 只能处理二进输入的不足, 实现对模拟量进行运算, 为工程实用拓宽了视野.

2 基于 FART 网络与数据融合的图像增强和恢复技术

为了对多幅带有不同噪声的同一景物的图像进行处理, 得到一幅更清晰、能反映主要内容的图像, 首先, 对每一张图像进行预处理, 即对图像的噪声进行滤波, 去掉部分干扰因素, 得到更加接近原图像的结果; 其次, 采用本文中构造的基于 Fuzzy ART 网络的聚类分析方法, 对每一幅图像的像素灰度进行聚类分析; 最后, 对上面的结果根据一定的规则进行数据融合, 得到融合图像, 实现图像的增强和恢复.

收稿日期: 2002- 10- 25

作者简介: 傅 明 (1961-), 男, 湖南省汨罗市人, 长沙交通学院计算机工程系教授, 主要从事计算机网络技术、人工智能等研究.

2.1 图像的预处理

对降质、失真退化的图像直接进行融合, 必然导致图像噪声融入融合结果, 这是图像数据融合结果不能实现理想的增强和恢复的主要原因. 所以在做进一步处理前, 必须对降质的原始图像进行预处理, 即进行图像滤波. 图像滤波的方法很多, 如何选择合适的滤波器一直让人们困惑. 显然, 图像的性质和处理要求决定着图像滤波的方法. 例如, 对于高斯噪声图像, 滑动均值滤波是一种有效的滤波方法; 对于脉冲噪声图像, 由于中值滤波在滤除多种噪声的同时, 能一定程度上较好地保留信号的边缘细节信息, 故中值滤波是理想的滤波器; 对于乘性噪声图像, 因为它满足平稳随机过程模型且其实质是一近似线性系统, 宜选用自适应维纳滤波. 每幅图像, 根据各自的噪声特点, 按照上述各滤波算法在消除了部分噪声后, 可得到一组改善的待处理图像, 在此基础上进行的数据融合效果无疑更接近原图像.

2.2 FART 网络的结构与学习原理

FART 是将模糊集合理论引入 ART1 而构成的一种神经网络, 把输入模式推广到模拟量, 继承了所有 ART 系统的基本特征, 主要是在矢量运算时, 由于矢量元素的模糊化(在 $[0, 1]$ 内分布), 采用了模糊集合的运算规则. 它的输入和输出结构与 ART1 相同, 但增加了对输入矢量的归一化处理, 图 1 是其结构简图.




图 1 Fuzzy ART 基本结构

首先要确定 FART 的输入矢量. 它是一个模糊量(或模糊集), 应反映图像的模糊特征. 由于图像的灰度统计信息具有数据量小的特点, 因此以图像灰度的模糊特征作为 FART 的输入, 通过对图像灰度的分类来实现对图像的融合.

(1) FART 输入的预处理. 设待测样本矢量为 $a = (a_1, a_2, \dots, a_M)$. 其中: $a_i \in [0, 1]; i = 1, 2, \dots, M$. 在 FART 中, F_0 层将输入矢量作预处理, 得到 $I = (a, a^c) = (a_1, a_2, \dots, a_M, a^{c1}, a^{c2}, \dots, a^{cM})$. 其中: $a^{ci} = 1 - a_i; 1 \leq i \leq M$.

这种处理方式称为补码编码, 在 FART 运行中这种变换是必要的, 尤其是在输入矢量 I 为模拟量时, 因为对每个输入 $I = (a, a^c)$, 恒有

$$|I| = |(a, a^c)| = |a| + |a^c| = M. \tag{1}$$

可见, 输入的预处理相当于对输入作了归一化. 如图 1 中的 F_0 层, (1) 式中的 $|*|$ 表示对矢量各元素的求和计算, 称为矢量的大小. F_2 层为类别表示层, 它的每个节点用来表示输入模式所属的类别编号.

(2) FART 网络的学习原理. 设 F_1 层有 $2M$ 个节点, F_2 层有 N 个节点, 下标 i 表示 F_1 层的节点, j 表示 F_2 层的节点. 由底向上的权与由顶向下的权取相同值, 所以只需定义 $F_2 \rightarrow F_1$ 的权. 设 $W_j = (w_{j1}, \dots, w_{j(2M)})$ 表示 F_2 层 j 节点由顶向下的权矢量, 所有节点由顶向下的权矢量的初始值为 1. 当输入模式 I 进入 F_1 层时, F_1 层对 F_2 层每节点各产生 1 个输入, 其中对第 j 个节点的输入为

$$T_j(I) = \frac{|I \cdot W_j|}{|I| + |W_j|}, \tag{2}$$

这里: $T_j(I)$ 简化记作 T_j , 称 T_j 为选择函数; $|*|$ 为正实数, 称为选择参数; 算子 \cdot 为模糊集合的求小运算. $I \cdot W_j$ 就是 $2M$ 维的矢量, 其中的第 i 个元素对应 I 和 W_j 中第 i 个元素的最小值. 类似地, $|*|$ 为模糊并运算,

它的计算结果则是由 2 个矢量对应最大元素构成的矢量.

F_2 层中, 接收到最大 T_j 值的节点就表示输入模式 I 可能所属的类型. 设该点为第 J 个节点, 如果对节点 J 存在

$$\frac{|I - W_j|}{|I|} \quad (3)$$

则认为把模式 I 归入第 J 类是合适的, 此处 称为警戒参数, 取值在区间 $[0, 1]$ 内. 若节点 J 不能满足(3)式, 则发生重置, 并在 F_2 层中搜索下一个最大 T_j 值的节点, 将输入模式与之作匹配测试; 若所有具有最大 T_j 值的节点均不能满足(3)式, 则在 F_2 层开辟新节点. 重置由 FART 中的注意子系统完成. 节点 J 满足(3)式, 学习开始, 系统更新由顶向下的权矢量为 $W_j = (1 - \alpha)W_j + \alpha(I - W_j)$. 其中: α 为 FART 的参数, 称为学习速率, 在 $[0, 1]$ 中取值. $\alpha = 1$ 的学习称为快速学习; $\alpha < 1$ 的学习称为慢速学习. 当节点是新开辟的时, $\alpha = 1$, 进行快速学习. 设 j 为新开辟的节点, 经快速学习后的权矢量为 $W_j^{new} = I = (a, a^c)$, 否则做慢速学习. F_2 层中每个节点对应的由顶向下的权矢量称为一个模板, 若该节点已被占用, 则称此模板为已占用模板, 对应的节点称已占用节点. 相应地, 有未占用模板和未占用节点的概念.

2.3 基于 FART 的聚类分析与图像融合

根据 FART 网络模型的运行原理及其特点可知, 该网络既可处理模糊信息, 自动将注意集中到已学习过的样本, 实时自学习, 又能自动确定样本类别数等.

2.3.1 模糊化 为了能把 FART 网络模型应用到图像处理中, 首先确定 FART 的输入矢量 a , 它是一个模糊量(或模糊集), 反映图像的模糊特征. 图像的灰度统计信息正好具有这些特点, 因此以图像灰度的模糊特征作为整个网络的输入, 实现对图像灰度的分类. 假设待分类的图像为 $g(m, n)$. 其中: $m = 0, 1, \dots, M-1$; $n = 0, 1, \dots, N-1$. 定义 2 个模糊集 A 和 B , 其隶属度函数分别为 $A(i) = i/L$, $B(i) = H(i) / \sum_{j=1}^L H(j)$.

其中: $i = 1, 2, \dots, L$; $L = \max_{m=0}^{M-1} \max_{n=0}^{N-1} g(m, n)$, 是图像的最大灰度数; $H(i) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} (i - g(m, n))$, 是图像灰度直方图, 当 $x = 0$ 时, $H(x) = 1$, 当 $x > 0$ 时, $H(x) = 0$. 这样, 模糊集 A 表示了图像灰度等级 i 的亮度, 模糊集 B 表示灰度级 i 属于图像的程度. 于是, 灰度级 i 的模糊特征可以表示为 $a(i) = (A(i), B(i))$.

2.3.2 网络的训练 有了图像的模糊特征以后, 就可以对 FART 进行训练了. 具体的训练算法如下: (1) 在 F_0 层对输入矢量 a , 进行补码编码, 即令 $I(i) = (a_i, a^c) = (A(i), 1 - A(i), B(i), 1 - B(i))$, 于是有输入节点数 $M = 4$. (2) 令 F_2 节点数 $N = 1$, 选定类别选择参数 $\alpha (> 0)$ 、学习率参数 $\alpha \in [0, 1]$ 和警戒线参数 $\beta \in [0, 1]$. (3) 令 $t = 0, w_{11}(0) = w_{12}(0) = w_{13}(0) = w_{14}(0) = 1$. (4) 令 $i = 1, 2, \dots, L$, 对每个 $I^{(i)}$ 执行下文过程() 至().

() 计算每个 F_2 节点 j 的选择函数 $T_j(I^{(i)}) = \frac{|I^{(i)} - W_j|}{|I^{(i)}| + |W_j|}$, 其中 \oplus 表示模糊与运算, 定义为

取小操作的运算, 范数 $\| \cdot \|$ 定义为 $\| P \| = \sum_{k=1}^4 P_k$.

() 若 t 时刻至多只有 1 个 F_2 节点兴奋, 则称系统进行了 1 次类选择, 记被选中的类为 J , 即 $T_J = \max\{T_j; j = 1, 2, \dots, N\}$. 若有超过 1 个的 T_j 取得最大, 则下标最小的被选中. 当第 J 类被选中时, $Y_j = 1$ 且对于 $j \neq J$ 有 $Y_j = 0$. 笔者在仿真时, 此处作了简化.

() 计算 F_1 兴奋矢量

$$x = \begin{cases} I^{(i)} & F_2 \text{ 不兴奋,} \\ W_J & F_2 \text{ 兴奋.} \end{cases}$$

若 $\|x\| = |I^{(i)} - W_J| + |I^{(i)}|$, 则称系统发生共振. 此时对每个权值都进行修正调整, 令 $W_{J(t+1)} = (I^{(i)} - W_{J(t)}) + (1 - \alpha)W_{J(t)}$ 和 $t = t + 1$, 然后对新的输入进行学习. 否则对 F_2 进行重置, 即令 $T_J =$

0并返回()重新进行选择.

()如果所有 F_2 的 J 节点(即具有最大选择函数值的最小下标值节点)都试过之后,系统仍不能发生共振,则在 F_2 加入新的节点,并令新节点的权值等于 F_0 中的矢量,即令 $N = N + 1$, $W_{N+1} = I^{(i)}$,并继续对新输入进行学习.当训练结束以后, F_2 节点数目就是分类的类别数.

图像中的每个像素点经过上面的聚类分析和模糊化后,所有的像素点都有一个所谓的补编码矢量,其中第一分量是像素点的亮度,第三分量是该像素点灰度值隶属图像的程度.图像在经过 FART 网络的训练后,像素点的像素值改为像素点的像素值与模式类神经元的权值数组中第三分量之积的 255 倍.

3 仿真实验

3.1 数据来源

对 256×256 的 8 位灰度图分别加入 2 种不同噪声得到 2 幅图像.图 2 是原始的 Lena 图像,图 3,4 分别为加入高斯噪声、椒盐噪声后的 Lena 图像.为更能说明问题,这时仿真不进行滤波处理.

3.2 网络训练

网络训练时, $\eta = 0.9$, $\alpha = 20$, $\beta = 0.9$,即采取较快速学习的方法.因为在 1 幅 256×256 的 8 位灰度图像里有 65 536 个像素点,而像素值只有 256 个,故取训练次数为 10 次已足够.其训练过程如下:(1) 输入被处理的 256×256 的 8 位灰度图;(2) 对图像进行预处理;(3) 将图像的每个像素点编码后输入该网络,在适当的参数下进行聚类,对每类像素都得到一个相应的神经元权值.

3.3 聚类分析

图像在训练结束以后进入聚类分析过程:(1) 将该图像的各像素输入该网络,进入 F_0 层编码以后送入 F_1 层;(2) 在该网络中找出每一个像素对应神经元的共振神经元;(3) 根据该神经元对应的权值及亮度值调整该图像的每一个像素值.分别对 3 幅图像进行上述类似处理后,可自动对灰度等级和其隶属度分类为 12, 23 类.

3.4 融合方法

将图 3,4 取加权平均值后即合成为所需结果.为便于分析,将最后融合的结果再次经过该网络分类.结果如图 5 所示.



图 2 原始清晰的 Lena 图像



图 3 被高斯噪声污染的 Lena 图



图 4 被椒盐噪声污染的 Lena 图像



图 5 最后融合结果

3.5 仿真结果分析

对原始噪声图像、分类后的图像、融合后的图像,分别计算其峰值信噪比(PSNR)、均方误差(MSE)、平均绝对误差(MAE):

$$\text{PSNR} = 10 \log_{10} 255^4 / \sum_{m=1}^s \sum_{n=1}^t [p(m, n) - \hat{p}(m, n)]^2,$$

$$\text{MSE} = \frac{1}{s \times t} \sum_{m=1}^s \sum_{n=1}^t [p(m, n) - \hat{p}(m, n)]^2 / 255^2,$$

$$\text{MAE} = \frac{1}{s \times t} \sum_{m=1}^s \sum_{n=1}^t |p(m, n) - \hat{p}(m, n)| / 255^2,$$

其中 $p(m, n)$, $\hat{p}(m, n)$ 分别是原始图像和处理后图像中点 (m, n) 的灰度值, s 和 t 分别是以像素点数表征图像的长和宽,都取 256. 图像性质比较见表 1. 从表 1 可以看出,融合以后的图像在噪声特性上有了很大改善.

表 1 图像各指标对比

指标	高斯噪声图像	椒盐噪声图像	高斯噪声图分类后	椒盐噪声图分类后	融合图像	融合图像分类后
PSNR	59.598 0	63.439 7	60.570 1	56.565 8	64.226 6	66.719 9
MSE	0.071 3	0.029 5	0.057 0	0.143 4	0.024 6	0.013 8
MAE	0.217 0	0.216 8	0.216 6	0.216 5	0.021 65	0.216 5

参考文献:

- [1] 张兆礼,孙圣和.基于二维自组织神经网络的图像数据融合算法研究[J].电子学报,2000,(9):74-77.
- [2] 张定会,戴曙光.神经网络数据融合和目标识别[J].仪器仪表学报,2000,8(4):285-286.
- [3] 吴秀清.面向 MATLAB 神经网络工具箱的图像数据融合算法及实现[J].计算机工程,2000,(4):16-17.
- [4] 范凯,陶然.基于神经网络数据融合的目标跟踪简化算法[J].系统工程与电子技术,2000,(8):82-84.
- [5] 袁曾任.人工神经网络及其应用[M].北京:清华大学出版社,2000.305-319.
- [6] 莫玉龙,唐卫平.用模糊 ART 神经网络设计自适应调色板[J].上海大学学报,1997,(6):237-242.

Image Enhancement and Restoration Based on FART Network and Data Fusion

FU Ming, XIAO Ru-liang, TANG Xian-ying

(Department of Computer Engineering, Changsha Jiaotong University, Changsha 410076, China)

Abstract: This paper presents a new kind of image enhancement and restoration based on Fuzzy ART network and data fusion in order to process the images effectually. This approach which uses grayscale histogram threshold can not only automatically determine the number of classes of an image to analyze clusters, but also process the image which comes from the same scene with noises. Simulation experiment demonstrates that FART network can realize the image enhancement and restoration very well.

Key words: Fuzzy ART network; data fusion; image enhancement and restoration; cluster analysis