

# 一种用于图象恢复的数据融合算法研究

张兆礼<sup>1)</sup> 孙圣和<sup>1)</sup> 赵春晖<sup>2)</sup>

<sup>1)</sup>(哈尔滨工业大学自动化测试与控制系, 哈尔滨 150001)

<sup>2)</sup>(哈尔滨工程大学电子工程系, 哈尔滨 150001)

**摘要** 近年来多传感器数据融合技术在图象处理领域得到广泛的重视和应用. 鉴于来自同一景物的多幅变形图象, 其来源不同, 每幅图象都带有不同的噪声, 针对这种图象的恢复提出了一种基于自组织特征映射神经网络的图象融合算法. 该算法可分为 3 步, 第 1 步是图象的预处理阶段, 即对图象进行加权中值滤波, 去除部分噪声; 第 2 步利用自组织神经网络对每幅图象的象素进行聚类分析; 第 3 步, 对第 2 步得到的结果按照一定规则进行融合. 仿真结果表明, 该算法能明显提高图象质量.

**关键词** 中值滤波 自组织特征映射神经网络 图象数据融合

中图分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2001)01-0061-04

## An Image Data Fusion Method for Image Restoration

ZHANG Zhao-li<sup>1)</sup>, SUN Sheng-he<sup>1)</sup>, ZHAO Chun-hui<sup>2)</sup>

<sup>1)</sup>(Department of Automatic Test, Measurement and Control, Harbin Institute of Technology, Harbin 150001)

<sup>2)</sup>(Department of Electronic Engineering Harbin Engineering University, Harbin 150001)

**Abstract** Multisensor data fusion has played an important role in image processing recently. For some images from the same scene, each of them has different noise because of their different sources. This paper presents a new kind of image data fusion algorithm based on the self-organizing feature map neural network. This algorithm can be performed with three steps. In the first step, the pretreatment of the images is performed by the weighted-median filter in order to remove some noise. In the second stage we use self-organizing feature map neural network to cluster the pixels of each image and then extend hard partition into fuzzy partition. In the third stage, we fuse the data from the last step in conformity to a certain rule. The simulation results illustrate that this new algorithm can improve the quality of the image distinctly and the pretreatment of the images can improve the fusion result efficiently.

**Keywords** Median filter, Self-organizing feature map neural network, Image data fusion

## 0 引言

多传感器数据融合是一门正在快速发展的信息处理技术, 它已在各个领域得到广泛的应用. 由于该技术能从多源信息中融合信息<sup>[1]</sup>, 以减少信号的不确定度, 并能再现出一个全面的信源, 因此多传感器数据融合技术业已应用在图象处理领域. 大家知道, 对于来自同一景物的多幅图象, 由于成像传感器的不同、景物本身的问题以及各种干扰的存在, 使得摄取的图象存在某些失真与程度不同的变质, 因而这就产生了如何从多幅失真图象中来恢复出原始真实

图象的问题, 而多传感器数据融合技术在解决这一问题中得到了广泛地应用<sup>[2,3]</sup>.

利用多传感器数据融合技术来恢复图象已引起越来越多人的研究兴趣, 如 Deepa 给出了一种基于盲目反卷积的盲图象融合法<sup>[4]</sup>, 但由于盲目反卷积本身的应用范围有限, 所以这种盲图象融合法的应用范围较窄; Pongsak 也给出了一种复杂的图象融合系统, 但也只能用于红外和可视两种图象的融合<sup>[5]</sup>; Desachy 虽给出了一种混合的图象融合算法<sup>[6]</sup>, 但其实质上还是一种基于假设检验的融合方法, 因而实时处理能力差.

本文给出了一种基于自组织神经网络的数据融

合方法,包括图象的预处理、聚类分析以及聚类结果的融合等 3 个步骤. 其原理框图如图 1 所示.

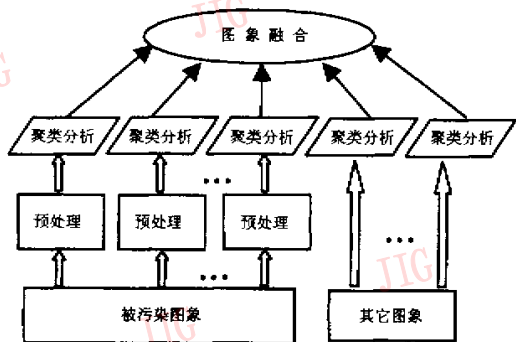


图 1 图象融合原理框图

## 1 图象的预处理

若对于失真退化的图象直接进行融合,必然导致图象噪声融入融合结果,这是图象数据融合结果不够理想的主要原因,所以在进行进一步处理前,必须对原始图象进行图象的预处理,即首先进行图象滤波.

由于在各种非线性滤波方法中<sup>[7,8]</sup>,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,所以本文选择中值滤波进行预处理. 中值滤波的过程是:首先设置一窗口,再将其移遍图象上的点,然后用窗内各原始值的中值来代替窗口中心点的值,但在这种简单的中值滤波器中,由于窗口内所有的原始值对所产生的输出都有相同的影响. 而我们则希望窗口中心点有较大的影响,因此本文选用了加权中值滤波. 这种加权中值滤波是先根据加权系数,对滤波窗内各元素进行复制,然后再对所有元素进行排序,并取中值的一种非线性滤波.

对于二维图象信号,设  $G(m, n)$  是一大小为  $M \times N$ , 灰度级在  $L$  范围内的数字图象,  $P(m, n)$  为图象内  $(m, n)$  点象素的灰度值  $(0 \leq P(m, n) \leq L-1)$ . 设滤波窗内有  $k$  个元素,若  $w_1, w_2, \dots, w_k$  分别表示  $x_1, x_2, \dots, x_k$  的加权中值滤波加权系数,且  $B_{wk}(x_1, x_2, \dots, x_k)$  表示窗口内元素的中值滤波函数,则有

$$B_{wk}(x_1, x_2, \dots, x_k) = \text{Med}(\underbrace{x_1, \dots, x_1}_{w_1}, \underbrace{x_2, \dots, x_2}_{w_2}, \dots, \underbrace{x_k, \dots, x_k}_{w_k}) \quad (1)$$

式中  $\text{Med}$  表示  $\underbrace{x_1, \dots, x_1}_{w_1}, \underbrace{x_2, \dots, x_2}_{w_2}, \dots, \underbrace{x_k, \dots, x_k}_{w_k}$  按大小排序后取中值. 即

$$\text{Med}(X) = \begin{cases} x_{(\sum_{i=1}^k w_i + 1) / 2} & \text{当 } \sum_{i=1}^k w_i \text{ 为奇数时} \\ \frac{x_{(\sum_{i=1}^k w_i) / 2} + x_{(\sum_{i=1}^k w_i + 2) / 2}}{2} & \text{当 } \sum_{i=1}^k w_i \text{ 为偶数时} \end{cases} \quad (2)$$


其中,  $X$  为  $\underbrace{x_1, \dots, x_1}_{w_1}, \underbrace{x_2, \dots, x_2}_{w_2}, \dots, \underbrace{x_k, \dots, x_k}_{w_k}$  按大小排序后的集合.

按照上述加权中值滤波算法,首先对二维图象  $G(m, n)$  进行周边扩展,然后滑动取中值,则将象素灰度值  $P(m, n)$  变为  $P'(m, n)$ . 图象  $G(m, n)$  经过中值滤波后变为  $G'(m, n)$ ,它在一定程度上消除了噪声. 这样若对多幅带有噪声的污染图象分别进行加权中值滤波,则可得到一组改善的图象.


## 2 图象融合

### 2.1 图象的聚类分析


对于经过滤波得到改善的来自同一景物的多幅照片,由于获得方式的不同也会造成图象间的差异,例如背景灰度的选取、物体间的对比度以及具有不同的色度等,所以在进行融合前还必须首先对每一幅图象进行归一化,而采用自组织特性映射神经网络对每一幅图象进行聚类分析就是本文采用的方法. Kohonen 提出的自组织特征映射神经网络是一种具有侧向联想能力的两层结构网络(如图 2(a)所示),它采用 SOFM 学习算法,其输出节点呈二维阵列分布,每个输入节点与输出点之间以可变权值连接,而且每个输出节点都有一个拓扑邻域,其邻域大小随时间变化,一种可能的拓扑邻域变化如图 2(b)



(a) 基本网络



(b) 基本邻接神经元选择



(c) 邻接神经元选择

图 2 自组织特征映射神经网络

所示。由于 Kohonen 自组织特征映射神经网络的学习是一种无监督的聚类方法,因此对相近的输入模式,输出节点拓扑意义上也是相邻的。

如图 2 所示的神经网络,若输入信号取为  $X = (x_1, x_2, \dots, x_n)^T \in R^n$ ,  $n$  表示输入向量的维数或特征数,  $R^n$  表示  $n$  维向量空间;输出神经元  $j$  与输入神经元的连接权值为  $W_j = (w_{j1}, w_{j2}, \dots, w_{jn})^T$ , 输出神经元有  $c$  个,即我们把特征空间分割为  $c$  类,则以欧氏距离为测度的 Kohonen 算法如下:

第 1 步 初始化。从输入神经元到输出神经元的权值可以随机地取一个较小的值  $v_j$ ,且使  $w_{ji} = v_j, j=1, 2, \dots, c; i=1, 2, \dots, n$ ;确定各个输出神经元  $j$  的邻接神经元的集合  $NE_j(t)$ 。本文中,由于处理的图象有“山、水、船、桥、人、沙滩、倒影、云团”8 类,因此,选取的输出神经元数等于 8,即分类数  $c$  较小,原始输出近邻距离确定为  $c/2$ ,如图 2(c) 所示。

第 2 步 提供一个新的输入模式。

第 3 步 计算输入神经元与输出层神经元之间的欧几里德(Euclidean)距离  $d_j$ ,即计算输入样本与每个输出神经元  $j$  之间的欧氏距离

$$d_{j'} = \min_{1 \leq j \leq c} \left| \sum_{i=1}^n [x_{ji} - w_{ji}(t)]^2 \right| \quad j' \in [1, c] \quad (3)$$

其中,  $j'$  为使欧氏距离最小的输出神经元。

第 4 步 按照下式来改变输出神经元与其邻接神经元的相应权值

$$w_{ji}(t+1) = w_{ji}(t) + \alpha(t)[x_{ji} - w_{ji}(t)] \quad (4)$$

式中,  $j \in NE_{j'}(t), l \in [1, c], t$  为迭代次数,其中  $NE_{j'}(t)$  为  $j'$  的邻域,且是  $t$  的减函数,  $\alpha(t)$  为学习速率因子,一般选  $0 < \alpha(t) < 1$ ,以保证算法的收敛。

第 5 步 提供一个样本,重复上面的学习过程。

## 2.2 图象融合

### 2.2.1 图象聚类分析结果的模糊化

经过上述训练,自组织特征映射神经网络即把每幅图象的像素点分割成了  $c$  类。给定  $Z = \{z_1, z_2, \dots, z_N\}$  是  $R^n$  空间中的  $N$  个观测值,其中,  $z_i$  为  $Z$  中的第  $i$  次观测值,则对于  $Z$  有函数  $f: R^n \rightarrow R^c$ ,若取  $U = f(z) \in R^c$ ,则有

$$U = \{u_1, u_2, \dots, u_N\} = \{f(z_1), f(z_2), \dots, f(z_N)\} \quad (5)$$

定义  $\{z'_1, z'_2, \dots, z'_c\}$  为  $Z$  的硬分类,则有

$$z'_i \neq 0, \quad 1 \leq i \leq c$$

$$z'_i \cap z'_j = 0, \quad i \neq j$$

$$\sum_{i=1}^c z'_i = Z \quad (6)$$

此时,  $U = \{0, 1\}$  定义为

$$u_j = \begin{cases} 1 & \text{if } d_j = \min\{d_l, 1 \leq l \leq c\} \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

由于图象间的差异,硬分类这种非此即彼的分类方法在融合时往往失去意义,而拓展  $U = \{0, 1\} \rightarrow U \in [0, 1]$ ,即进行模糊分类,其定义如下<sup>[5]</sup>

$$u_j = \begin{cases} 1 & \text{if } d_j = 0 \\ 0 & \text{if } d_j = 0, (i \neq j, 1 \leq j, j \leq c) \\ \left( \sum_{i=1}^c \left( \frac{d_j}{d_i} \right) \right)^{-1} & \text{otherwise} \end{cases} \quad (8)$$

若利用  $u_{ij}$  来表示图象中第  $i$  个像素点对应于类  $j$  的隶属度,则有

$$\sum_{j=1}^c u_{ij} = 1 \quad \text{和} \quad 0 < \sum_{i=1}^N u_{ij} < N \quad (9)$$

模糊化结束后,则每幅图象的每个像素点都有了一个隶属度函数矢量组。下面将给出多幅图象的融合过程。

### 2.2.2 图象的融合

图象在做聚类分析并模糊化后,在进行融合之前必须进行类间的适配。对于二维图象  $G_i$  中点  $P_j(m, n)$ ,记  $U_{ji} = \{u_{1i}, u_{2i}, \dots, u_{ci}\}_j$  为分类的隶属度函数矢量,其中,  $u_{1i}, u_{2i}, \dots, u_{ci}$  为按照大小排序后的序列。若对于  $N$  幅图象中所有对应像素点分类是一致的,即对于  $N$  幅图象中对应点  $P_j(m, n)$  的分类序列与其它对应点分类序列是相同的,则称这些图象以欧氏距离为测度是可分的。显然,如果对于某一测度,  $N$  幅图象中对应点  $P_j(m, n)$  的分类是完全一致的,则融合过程将变得非常简单,且对于分类不完全一致的情况,还可采用模糊逻辑方法对其进行融合,融合规则如下

$$u_{j''} = \sum_{i=1}^N \sum_{j=1}^c u_{ji} = \max_{1 \leq i \leq N} \left\{ \max_{1 \leq j \leq c} (u_{ji}) \right\} \quad (10)$$

其中,  $j''$  即为所融合的像素点的分类。但有时这并不是最优的融合方法,因此还可通过改变 Kohonen 算法中的测度,如取马氏(Mahalanobis)距离作为新的测度,重新进行分类。按照上述规则融合后,图象中每一个像素点则都归属于某一类。至此就完成了整个融合过程。

## 3 仿真结果

为了简单起见,图象取 3 幅。原始图象为一幅

256×256×8bit 的灰度图象,如图 3(b)所示. 图 3(c)



(a) 加权系数



(b) 原始图象



(c) 高斯噪声图象



(d) (c) 的滤波结果



(e) 混合噪声图象




(f) (e) 的滤波结果



(g) 纹理噪声图象



(h) (g) 的滤波结果



(i) 未进行预处理的融合结果



(j) 进行了预处理的融合结果

图 3 仿真结果

为高斯模糊噪声污染图象;图 3(d)为其经过加权中值滤波后的图象;图 3(e)为加了高斯、脉冲混合噪声的图象;图 3(f)为其经过加权中值滤波后的图象;图 3(g)为加了纹理和脉冲噪声的图象;图 3(h)为其加权中值滤波后的图象;图 3(i)为未进行加权中值滤波的图象融合结果;图 3(j)为进行了加权中值滤波的图象融合结果. 本文为了兼顾噪声去除效果以及边界保持<sup>[9]</sup>, 加权中值滤波中采用了大小为  $5 \times 5$  的滤波窗口, 加权系数如图 3(a)所示. 上述所加高斯噪声均值为 0, 方差为 20; 脉冲噪声的脉冲概率为 10%. 在对图象进行聚类分析时, 聚类数取为 8.

## 4 结 论

由仿真结果可看出, 对来自同一景物的多幅图象

在融合之前先进行预处理, 可极大地提高融合的效果. 本文提出的基于自组织特征映射神经网络的图象融合算法, 对于图象中物体的区分非常有效. 今后要做的工作是, 在利用自组织神经网络对图象进行聚类分析时, 从融合效果角度进行进一步的定量分析.

## 参 考 文 献

1. Hall D L, Llinas J. An introduction to multisensor data fusion. Proc. IEEE, 1997, 85(1): 6~23.
2. Wan W, Fraser D. Multisource data fusion with multiple self-organizing maps. IEEE Trans. Geosci. Remote Sensing, 1999, 37(3): 1344~1349.
3. Lorenzo B, Diego F P, Sebastiano S. Neural-statistical approach to multitemporal and multisource remote-sensing image classification. IEEE Trans. Geosci. Remote Sensing, 1999, 37(3): 1350~1359.
4. Deepa Kundur, Dimitrios Hatzinakos. A novel approach to multispectral blind image fusion. SPIE, 1997, 3067: 83~93.
5. Pongsak Ajjimarange. Neural network model for fusion of visible and infrared sensor outputs. SPIE, 1988, 1003: 153~160.
6. Desachy J, Roux L. Numeric and symbolic data fusion: a computing approach to remote sensing images analysis. Pattern Recognition Letters, 1996, 17(13): 1361~1378.
7. Fitch J P, Coyle E J, Gallagher N C. Threshold decomposition of multidimensional rank-ed order operations. IEEE Trans. Circuits And Systems, 1985, 32(5): 445~450.
8. Lee Y H, Kassam S A. Generalized median filtering and related nonlinear filtering techniques. IEEE Trans. Acoust., Speech, Signal Processing, 1985, 33(3): 672~683.
9. 黄煦涛著. 二维数字信号处理 II. 胡光锐, 郑志航, 戚飞虎译. 北京: 科学出版社, 1985: 202~272.

张兆礼 1972 年生, 1998 年获哈尔滨工业大学电子工程系硕士学位. 现为哈尔滨工业大学自动化测试与控制系博士研究生. 主要从事神经网络、传感器信息处理的研究工作.

孙圣和 1937 年生, 教授, 博士生导师. 获多项国家和省部级奖. 目前的研究领域为计算机自动测试与控制、信号处理与系统辨识. 已发表 150 多篇文章.

赵春晖 1965 年生, 哈尔滨工程大学电子工程系教授, 1998 年获哈尔滨工业大学测试计量技术及仪器专业博士学位, 现为哈尔滨工程大学船舶与海洋流动站在职博士后, 中国电子学会高级会员, 中国图象图形学会会员. 已发表论文 60 多篇.