

基于一维自组织神经网络的图像数据融合算法研究

张兆礼, 孙圣和

(哈尔滨工业大学自动化测试与控制系, 哈尔滨 150001)

摘要: 多传感器数据融合技术最近在图像处理领域得到广泛的重视和应用. 传统图像处理是典型的二维信号处理, 图像数据融合也属此范畴. 为了融合来自同一景物的多幅带有不同噪声的图像, 本文提出了一种基于一维自组织特征映射神经网络的图像融合算法, 利用等灰度图法来确定自组织映射神经网络的聚类数, 并用一维的像素特征量直接进行二维图像信号处理. 仿真试验给出的详细结果表明了该图像融合算法的有效性.

关键词: 图像滤波; 一维自组织特征映射神经网络; 图像数据融合

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2000) 09-0074-04

Image Data Fusion Algorithm Based on the One-dimensional Self-organizing Neural Network

ZHANG Zhao2li, SUN Sheng2he

(Dept. of Automatic Test and Control, Harbin Institute of Technology, Harbin 150001, China)

Abstract: Multisensor data fusion has played an important role in image processing recently. Traditional image processing is a typical two-dimensional signal processing. The image data fusion belongs to this area as well. For some images from the same scene with different kinds of noise, this paper presents a new kind of image data fusion algorithm based on the one-dimensional self-organizing feature map neural network. This method uses equal gray density figure to determine the number of clusters, and utilizes one-dimensional pixel value to perform two-dimensional image processing. Simulation results demonstrate the effectiveness of the proposed image data fusion method.

Key words: image filter; one-dimensional self-organizing feature map neural network; image data fusion

1 引言

多传感器数据融合是一项正在快速发展的信息处理技术, 它在多个领域得到广泛应用. 该技术能从多源信息中融合信息, 减少信号的不确定度并再现出一个全面的信源^[1]. 多传感器数据融合技术业已应用在图像处理领域. 对于来自同一景物的多幅图像, 由于其成像传感器方向不同、景物本身的问题以及各种干扰的存在, 使得摄取的图像存在某些失真与程度不同的变质. 这就产生了如何从多幅图像中恢复出原始真实图像的问题. 多传感器数据融合技术在实现这一问题中得到广泛重视^[2].

利用多传感器数据融合技术恢复图像引起越来越多的人的研究兴趣. Deepa^[3]给出了一种基于盲目反卷积的盲图像融合方法, 由于盲目反卷积本身应用范围受限, 所以这种盲图像融合方法应用范围较窄; Pongsak^[4]给出了一种复杂的图像融合系统, 只能用于红外和可视两种图像的融合; Desachy^[5]给出了一种混合的图像融合算法, 但它实质上还是一种基于假设检验的融合方法, 实时处理能力差.

本文给出了一种基于一维自组织特征映射神经网络的数

据融合方法. 该方法可分为三步. 第一步是图像的预处理阶段, 在这一阶段, 根据每幅图像的性质进行滤波, 恢复出一个较好的结果; 第二步利用一维自组织特征映射神经网络对每幅图像的像素进行聚类分析, 得出每幅图像的分类结果; 第三步, 对第二步得到的结果按照一定规则进行融合, 然后再利用一维自组织特征映射神经网络进行聚类分析, 得出结果. 其原理框图如图1所示.

2 图像的预处理

对于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够理想的主要原因. 所以在做进一步处理前, 必须对原始图像进行预处理, 即首先进行图像滤波. 图像滤波的方法很多, 如何选择合适滤波器一直让人们困惑^[6]. 显然, 图像的性质和处理要求决定着图像滤波的方法.

对于高斯噪声图像, 滑动均值滤波是一种有效的滤波方法. 给定一幅大小为 $M \times N$ 的图像 $G(m, n)$, 灰度级在 L 范围内的数字图像, $P(m, n)$ 为图像内 (m, n) 点像素的灰度值 $(0 \leq P(m, n) \leq L-1)$. 设滤波窗内有 k 个元素, 则用滑动均值




图 1 图像融合原理框图

滤波法得到的平滑图像的对应像素值为:

$$pc(m, n) = \frac{1}{k} \sum_{(m, n) \in NE} p(m, n) \quad (1)$$

其中 (m, n) 表示滤波窗中心点的像素点, NE 表示所选滤波窗口.

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, 所以中值滤波不失为图像处理的一种好方法^[6]. 在简单的中值滤波器中, 窗口内所有的原始值对所产生的输出都有相同的影响. 在本文中希望窗口中心点有较大的影响, 选用了加权中值滤波. 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取中值的一种非线性滤波. 若 x_1, x_2, \dots, x_k 为滤波窗口内的元素, 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, 用 $B_{wk}(x_1, x_2, \dots, x_k)$ 表示窗口内元素的中值滤波函数, 则有:

$$B_{wk}(x_1, x_2, \dots, x_k) = \text{Med}(\underbrace{x_1, \dots, x_1}_{w_1}, \underbrace{x_2, \dots, x_2}_{w_2}, \dots, \underbrace{x_k, \dots, x_k}_{w_k}) \quad (2)$$

式中 Med 表示取 $x_1, \dots, x_1, x_2, \dots, x_2, \dots, x_k, \dots, x_k$ 按大小排序后取中值. 即:

$$\text{Med}(X) = \begin{cases} x_{(\sum_{i=1}^k w_i)/2}, & \text{当 } \sum_{i=1}^k w_i \text{ 为奇数时} \\ (x_{(\sum_{i=1}^k w_i)/2} + x_{(\sum_{i=1}^k w_i)/2 + 1})/2, & \text{当 } \sum_{i=1}^k w_i \text{ 为偶数时} \end{cases} \quad (3)$$

其中: X 为 $x_1, \dots, x_1, x_2, \dots, x_2, \dots, x_k, \dots, x_k$ 按大小排序后的集合. 对于脉冲噪声图像, 加权中值滤波是一理想的滤波器. 本文中, 滤波窗口大小为 $5@5$. 对于加权系数, 兼顾噪声去除效果以及边界保持^[9], 选用了如图 4(1) 所示的权值.

对于乘性噪声图像, 因为它满足平稳随机过程模型且其变质是一近似线性系统, 宜选用自适应维纳滤波. 二维维纳滤波器是寻找传输函数 $Y(u, v)$ 的过程, 有:

$$Y(u, v) = H^*(u, v) / (|H(u, v)|^2 + p_n(u, v) / p_f(u, v)) \quad (4)$$

则有:

$$F(u, v) = Y(u, v) G(u, v) = H^*(u, v) G(u, v) / (|H(u, v)|^2 + p_n(u, v) / p_f(u, v)) \quad (5)$$

其中: $Y(u, v)$ 表示自适应维纳滤波的传递函数; $H^*(u, v)$ 为变质系统的传输函数 $H(u, v)$ 的复共轭; $P_f(u, v)$, $P_n(u, v)$ 分别为目标图像和噪声的功率谱密度; $F(u, v)$ 为滤波后图像的二维傅立叶变换; $G(u, v)$ 为变质图像的二维傅立叶变换. 据此可以得到所要求的滤波器.

对于每幅图像, 按照上述各滤波算法在消除了部分噪声. 对于多幅带有噪声的污染图像分别进行上述滤波, 可得到一组改善的图像.

3 图像的融合

3.1 图像的聚类分析

对于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造成了图像间的差异, 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




图 2 自组织特征映射神经网络

等, 所以在进行融合前必须对每一幅图像信号进行归一化. 采用一维自组织神经网络对每一幅图像进行聚类分析是本文采用的方法. 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^[7], 如图 2 所示的一维自组织特征映射神经网络, 它采用 SOFM 学习算法, 其输出节点呈一维阵列分布, 每个输入节点与输出点之间有可变量值连接, 每个输出节点都有一个拓扑邻域, 其邻域大小随时间变化. Kohonen 自组织特征映射网络的学习是一种无监督的聚类方法, 对相近的输入模式, 输出节点也是拓扑意义上相邻的. 在 SOFM 学习算法中, 如何确定输出的类别数是一个理论上的难题. 本文中图像融合的目标是进行卫星云图分析, 有效地区分图像上的不同区域. 根据如图 3 所示的等灰度图, 可以清晰的发现原始图像的灰度集中点. 据此可以确定 Kohonen 神经网络的输出神经元为 15, 即分类数为 15. 在实际应用中, 可以对变质的图像进行等灰度分析, 得到大致的分类数, 然后再进行聚类分析.

如图 2 所示的神经网络, 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 算法如下所示:

第一步: 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 w_j 且使 $w_{ji} = w_j, j = 1, 2, \dots, c; i = 1, 2, \dots, n$; 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, 由于选取的输出神经元数等于 15, 即分类数 c 较小, 原始输出近邻距离确定为 2.

第二步: 提供一个新的输入模式.

第三步: 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 , 即输入样本与每个输出神经元 j 之间的 Euclidean 距离:

$$d_j^* = \min_{1 \leq j \leq c} (d_j) = \min_{1 \leq j \leq c} \left\{ \sum_{i=1}^n [x_{ji} - w_{ji}(t)]^2 \right\}, j^* \in [1, c] \quad (6)$$

其中 j^* 为使欧氏距离最小的输出神经元.

第四步: 按照下式来改变输出神经元与其邻接神经元的




图3 卫星云图的等灰度图

相应权值:

$$w_{ji}(t+1) = w_{ji}(t) + A(t)[x_{1j} - w_{ji}(t)] \quad (7)$$

式中, $j \in NE_j^*(t)$, $1 \in [1, c]$, t 为迭代次数, 其中 $NE_j^*(t)$ 为 j^* 的邻域, 且是 t 的减函数, $A(t)$ 为学习速率因子, 一般选 $0 < A(t) < 1$, 以保证算法的收敛.

第五步: 提供一个新的样本重复上面的学习过程, 直到兴奋神经元与输入样本稳定对应为止.

3.1.2 图像的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把每幅图像的像素点分割成了 c 类. 给定 $X = \{x_1, x_2, \dots, x_N\}$ 是 R^n 空间中的 N 个观测值, x_i 为 X 中的第 i 次采样. x_{ik} 为 x_i 的 k 维特征值. 则对于 X 有函数 $f: R^n \rightarrow R^c$, 取 $U = f(x) \in R^c$, 则有

$$U = \{u_1, u_2, \dots, u_N\} = \{f(x_1), f(x_2), \dots, f(x_N)\} \quad (8)$$

定义 $\{x_1, x_2, \dots, x_c\}$ 为 X 的硬分类, 则有:

$$\begin{aligned} x_i X 0, 1 F i F c \\ x_i H x_j = 0, i X j \\ \sum_{i=1}^c x_i = X \end{aligned} \quad (9)$$

此时 $U = \{0, 1\}$ 定义为:

$$u_j = \begin{cases} 1, & \text{if } d_j = \min\{d_i, 1 F 1 F c\} \\ 0, & \text{otherwise} \end{cases} \quad (10)$$

由于图像间的差异, 硬分类这种非此即彼的分类方法在做融合时往往失去意义. 拓展 $U = \{0, 1\} \cup U[0, 1]$, 即进行模糊分类, 定义如下^[3]:

$$u_j = \begin{cases} 1, & \text{if } d_j = 0 \\ 0, & \text{if } d_i = 0, (i X j, 1 F i, j F c) \\ \left(\sum_{i=1}^c \frac{d_i}{d_j} \right)^{-1}, & \text{otherwise} \end{cases} \quad (11)$$

利用 u_{ij} 表示图像中第 i 个像素点对应于类 j 的隶属度, 则有:

$$\sum_{j=1}^c u_{ij} = 1 \text{ and } 0 < \sum_{i=1}^N u_{ij} < N \quad (12)$$

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

3.1.3 图像的融合

图像在做聚类分析并模糊化后, 每幅图像的每一个像素点都有了一个隶属度. 显然, 要求多幅图像中的每个像素点具有相同的隶属度及分类是不现实的. 对于 N 幅二维图像中图像 G 中点 $P_i(m, n)$, 记 $U_{(m,n)i} = \{u_{1i}, u_{2i}, \dots, u_{ci}\}_{(m,n)}$ 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. 则该点在这幅图像中的灰度值计算如下:

$$p^i(m, n) = (u_{1i}w_{1i} + u_{2i}w_{2i} + \dots + u_{ci}w_{ci}) @ (L - 1) \quad (13)$$

其中 w_{ji} 表示对第 i 幅图像进行聚类分析时得到的第 j 类的归一化权值. 融合算法采用均值法, 则融合后图像对应像素点灰度值为:

$$p^{ri}(m, n) = \frac{1}{N} \sum_{i=1}^N P^i(m, n) \quad (14)$$

经过上述处理后的图像, 再进行聚类分析, 最终得到融合结果, 至此完成了整个融合过程.

4 仿真结果

为了简单起见, 图像取三幅. 原始图像为一幅 $256 @ 256, 8$ 位的灰度图像, 如图 4(2) 所示. 图 4(3) 为高斯噪声污染图像, 图 4(4) 为其滑动均值滤波后的图像; 图 4(5) 为 (4) 的分类结果; 图 4(6) 为脉冲噪声的图像, 图 4(7) 为其加权中值滤波后的图像, 图 4(8) 为其分类结果; 图 4(9) 为加了乘性噪声的图像, 图 4(10) 为其自适应维纳滤波后的图像, 图 4(11) 为其聚类分析的结果. 图 4(12) 为未进行滤波的图像 (3)、(6)、(9) 的融合结果; 图 4(13) 为进行了滤波的图像 (4)、(7)、(10) 的融合结果; 图 4(14) 为进行了分类后的图像 (5)、(8)、(11) 的融合结果. 加权中值滤波采用大小为 $5 @ 5$ 的滤波窗口, 加权系数如图 4(1) 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 20%. 乘性噪声的方差为 20. 表 1 给出了仿真过程各图像的性质, 其中峰值信噪比 PSNR, 均方误差 MSE 和绝对误差 MAE 分别定义为:

$$PSNR = 10 \log_{10} 255^2 \sqrt{\sum_{m=1}^{s_1} \sum_{n=1}^{s_2} [z(m, n) - o(m, n)]^2} \quad (15)$$

$$MSE = \sum_{m=1}^{s_1} \sum_{n=1}^{s_2} [z(m, n) - o(m, n)]^2 / 255^2 \quad (16)$$

$$MAE = \sum_{m=1}^{s_1} \sum_{n=1}^{s_2} |z(m, n) - o(m, n)| / 255^2 \quad (17)$$

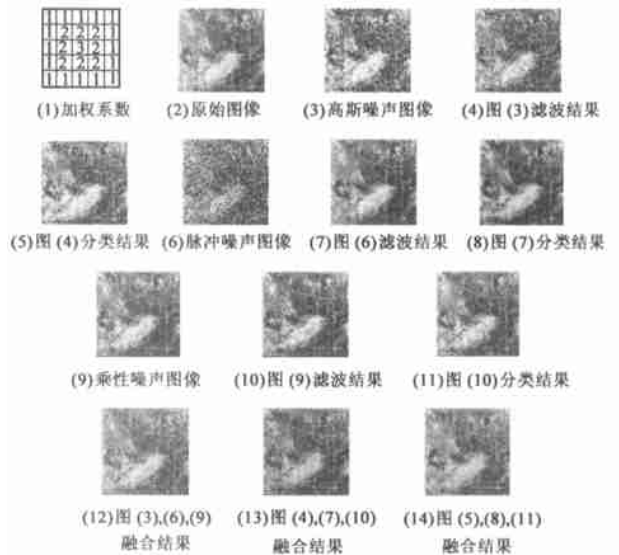


图4 仿真结果

其中 $z(m, n)$, $o(m, n)$ 分别为原图像和处理后图像像素点 (m, n) 的灰度值; s_1, s_2 为图像的像素表征的图像的长和

宽, 本文中均为 256. 由图 4 和表 1 可以看出, 融合后的图像不仅在视觉效果还是在噪声特性上都有了很大的改善.

表 1 仿真过程各图像性质比较

指标	高斯噪声图像			脉冲噪声图像			乘性噪声图像			融合后		
	PSNR	MSE	MAE	PSNR	MSE	MAE	PSNR	MSE	MAE	PSNR	MSE	MAE
滤波前	1413462	2390131	3915573	1216051	3569120	2516907	1818166	8531953	2419189	1917445	6891660	2019445
滤波后	2014810	5821071	1819949	2415756	2261735	6132167	2417353	2181550	1110711	2410935	2531358	1114244
分类后	2018842	5301465	1810728	2515067	1821982	7150854	2417738	2161620	1019417	2612199	1551272	817873

5 结论

本文提出了一种基于一维自组织特征映射神经网络的图像融合算法. 它利用一维的像素特征量直接进行二维图像信号处理, 能很好地完成多幅带有噪声图像的融合, 尤其对于图像中的物体的区分非常有效. 同时, 由仿真结果可以看出, 在对来自同一景物的多幅图像进行融合之前进行图像的预处理可以极大地提高融合的效果.

参考文献:

- [1] D. L. Hall, J. Llinas. An introduction to multisensor data fusion [J]. Proc. of IEEE, 1997, 85(1): 6- 23.
- [2] W. Wan, D. Fraser. Multisource data fusion with multiple selforganizing maps [J]. IEEE Trans. Geosci. Remote Sensing, 1999, 37(3): 1344- 1349.
- [3] Deepa Kundur, Dimitrios Hatzinakos. A novel approach to multispectral blind image fusion [J]. SPIE, 1997, 3067: 83- 93.
- [4] Pongsak Ajjimaranee. Neural network model for fusion of visible and infrared sensor outputs [J]. SPIE, 1988, 1003: 153- 160.

- [5] J. Desachy, L. Roux. Numeric and symbolic data fusion: a computing approach to remote sensing images analysis [J]. Pattern Recognition Letters, 1996, 17(13): 1361- 1378.
- [6] 黄煦涛, 胡光锐, 郑志航, 戚飞虎译. 二维数字信号处理 [M]. 北京: 科学出版社, 1985: 202- 272.
- [7] Kohonen. Selforganized Formation of Feature Maps [M]. Cybern. Syst. Recognit., Leam, 1984: 3- 12.

作者简介:



孙圣和 (见本期第 12 页)

张兆礼 1972 年生. 1998 年毕业于华北工学院电子工程系, 获硕士学位. 现在哈尔滨工业大学自动化测试与控制系攻读博士学位. 主要从事神经网络、传感器信息处理的研究工作.

(上接第 87 页)

- [3] Tamashiro, R. N.; Aldana, S. L. 60 percent kband TWT using a new diamond rod technology [A]. International Electron devices Meeting 1989. Technical Digest (Cat. No. 89CH263727): 187- 190.
- [4] Aldana, S. L.; Tamashiro, R. N. High efficiency 20GHz traveling wave tube development for space communications [R]. Final report, Report

No:NAS1. 26: 187160; NASA2CR2187160, Date: Oct. 91: 2- 1~ 2- 8.

- [5] 谢扩军, 季天仁, 刘盛纲. 多功能微波等离子体应用基础研究设备 [J]. 电子科技大学学报, 1996, 25(4): 403- 407.