

# 基于 RBF 神经网络的图像融合复原方法研究\*

牛丽红<sup>1</sup> 倪国强<sup>2</sup> 苏秉华<sup>2</sup>

(1 深圳大学光电子学研究所, 深圳 518060)

(2 北京理工大学光电工程系, 北京 100081)

**摘 要** 提出了一种基于径向基函数(RBF)神经网络的多通道图像数据融合复原方法,研究了该方法在多光谱图像复原上的应用. 将软竞争学习策略和自适应调整隐节点相结合对网络进行优化训练. 利用多光谱卫星图像数据,对所提出的方法进行仿真实验. 实验结果表明:该融合复原方法提高了复原图像的质量;改进后的学习算法能够保证学习准确度和较短的训练时间;实验还表明 RBF 神经网络的多通道复原和单通道复原、传统的维纳滤波及最大后验概率方法相比,在改善图像像质上具有明显的优越性.

**关键词** 图像复原;数据融合;多光谱图像;神经网络;图像退化

**中图分类号** TP18 **文献标识码** A

## 0 引言

图像复原是数字图像处理中一个重要的研究课题,大量的学者致力于这一领域的研究和探索,提出了许多复原方法<sup>[1~3]</sup>. 这些图像复原方法大部分是基于单一传感器图像,并且通常都建立在一些假设的基础上. 例如系统是一个线性空间不变系统,图像服从一定的概率密度分布,图像是平稳的等等,其目的是便于进行数学处理. 而实际上,大多数成像系统或多或少存在着某种程度的非线性和非平稳,而且图像的先验概率也是未知的. 此外,在传统复原方法的求解过程中,均采用解巨大的方程组或迭代方法进行求解,其计算速度和收敛速度均比较慢,不适合于对图像的快速或实时处理.

神经网络有许多重要的特性适合于求解图像复原问题:① 是非线性系统,在输入和输出数据之间能够实现非线性映射;② 是非参量化系统,适合任何图像模型;③ 是自组织和自适应系统,通过学习实现对问题的求解和自动适应环境的变化,并且具有自动融合多源图像信息的能力;④ 是并行处理系统,适合对图像的快速和实时处理.

本文运用神经网络技术对多源图像复原问题进行新的探讨,提出一种基于径向基函数网络的图像融合复原方法.

## 1 径向基函数网络模型及其学习算法

### 1.1 径向基函数网络模型

RBF 网络结构是由输入层、隐含层(径向基层)

和输出层组成的前馈网络. 理论上已经证明对于一个给定的非线性函数,RBF 网络可以任意准确度逼近它,该网络具有全局最优和最佳逼近性能<sup>[4]</sup>.

输入层神经元与隐层神经元、隐层神经元与输出层神经元(除偏置单元外)均采用全连接,典型结构如图 1,其中各层的节点数目分别为  $n, H$  和  $m$ . 隐含层采用径向基函数作为网络的激活函数,需满足下面的定义:




图 1 径向基网络结构图

Fig. 1 The configuration of RBF network

定义:给定一个连续函数  $F: R^+ \rightarrow R$  和点集  $\{X_j | j=1, 2, \dots, P\}$ ,若存在一个函数序列

$$t_p(X) = \sum_{j=1}^p X_j \Phi(\|X - X_j\|) \quad (1)$$

和满足

$$\|t_p(X) - F(X)\| \rightarrow 0, \text{ 当 } P \rightarrow \infty \text{ 时} \quad (2)$$

的一个有界开区域  $D$ ,使得点  $X_j \in R^+$  在开区域  $D$  上是稠密的,其中  $\|\cdot\|$  表示欧氏范数,则称函数  $\Phi(\cdot)$  为径向基函数. 径向基函数网络输出节点的输出为

$$y_k = \sum_{j=1}^H Z_j W_{jk}, k=1, 2, \dots, m \quad (3)$$

\* 广东省自然科学基金(04300865)资助项目

Tel: 0755-26538558 Email: NIULH@szu.edu.cn

收稿日期: 2005-07-02

## 1.2 径向基函数网络的学习算法

考虑到图像的样本空间很大,并且图像的退化可能是多种因素造成的,退化函数一般具有非常复杂的形式.因此,为了在不增加网络规模的情况下,获得更高的函数映射准确度和泛化能力,本文综合软竞争策略和自适应调整隐节点的优势<sup>[6,7]</sup>,对网络进行优化训练.

学习步骤如下:

① 确定基函数的个数  $c$  和最大迭代次数  $T$ ; 初始化基函数中心  $\nu_l(0) = (\nu_{l1}(0), \nu_{l2}(0), \dots, \nu_{ln}(0))$

② 对于  $t=1$  to  $T$ ,  $i=1, 2, \dots, P, l=1, 2, \dots, H$  计算

$$P_{li}(t) = \frac{\exp(-\beta(t) \|x_i - \nu_l(t-1)\|^2)}{\sum_{r=1}^H \exp(-\beta(t) \|x_i - \nu_r(t-1)\|^2)} \quad (4)$$

调整  $\nu_l(t)$

$$\nu_l(t) = \nu_l(t-1) + \eta(t) P_{li}(t) (x_i - \nu_l(t-1)) \quad (5)$$

③ 计算

$$E(t+1) = \sum_{j=1}^H \sum_{i=1}^n |\nu_{ji}(t+1) - \nu_{ji}(t)| \quad (6)$$

④ 如果  $E(t+1) \geq \epsilon$  且  $t < T$ , 令  $t = t+1$ , 转入②; 否则按式(9)计算  $\sigma_i^2$ , 中心矢量训练完成, 进入下一阶段, 即调整隐层与输出层之间的权矢量. 这里有

$$\sigma_i^2 = \frac{\sum_{l=1}^H P_{li}(t) (x_i - \nu_l)^T (x_i - \nu_l)}{\sum_{l=1}^H P_{li}(t)} \quad (7)$$

式中  $P_{li}(t)$  为第  $i$  个样本,  $x_i$  属于第  $l$  类的模糊隶属度函数,  $\beta(t)$  是表征其模糊程度的模糊因子. 与硬竞争学习策略不同, 在每次迭代中, 所有隐节点的中心都同时进行调整, 此时输入空间的统计分布信息由所有节点共同参与表示, 不但克服死节点问题, 而且网络的学习准确度也得到改善.

$\beta(t)$  是迭代次数的递增函数, 且满足  $\lim_{t \rightarrow +\infty} \beta(t) = \infty$ . 在本文的仿真实验中, 基于模拟退火算法的思想来选取  $\beta(t)$

$$\beta(t) = \beta_0 + \frac{(\beta_T - \beta_0)t}{T} \quad (8)$$

$\beta_0$  和  $\beta_T$  为常量. 完成隐层参量学习后, 调整隐层与输出层之间的权矢量

$$w_j = (w_{j1}, w_{j2}, \dots, w_{jH}) (j=1, 2, \dots, m)$$

仍采用梯度下降法, 网络的误差  $E_i$  由式定义

$$E_i = \frac{1}{2} \sum_{j=1}^m (y_{ij} - o_{ij})^2, (i=1, 2, \dots, p) \quad (9)$$

可推导出第  $t+1$  次学习规则

$$w_{ji}(t+1) = w_{ji}(t) + \alpha(t) \frac{\partial E_i}{\partial w_{ji}} \quad (10)$$

式中

$$\frac{\partial E_i}{\partial w_{ji}} = (y_{ij} - o_{ij}) \Phi_l(x_i), \alpha(t) \text{ 为学习步长} \quad (11)$$

RBF 网络中用径向基函数作隐层神经元的“基”, 构成隐空间. 每个基函数对于全部输入矢量的非线性变换作用可由矢量

$\Phi_l = \{\Phi_l(x_1), \Phi_l(x_2), \dots, \Phi_l(x_p)\} \quad l=1, 2, \dots, H$  反映出来. 通过比较上面定义的矢量来判断 RBF 层中神经元对输入矢量的非线性变换作用的相似性. 若两神经元的作用相似, 则删除多余的神经元, 以达到在规定学习误差范围内精简网络规模的目的.

判断隐层神经元对输入矢量的非线性变换作用是否相似时, 可将  $H$  个矢量  $\Phi_l (l=1, 2, \dots, H)$  看成是  $\Phi^p$  空间的  $H$  个点. 当点间距离近时, 两矢量的差异小, 因此有

$$H_{ij} = \langle \bar{\Phi}_i, \bar{\Phi}_j \rangle$$

$$H_{i \cdot j \cdot} = \max\{H_{ij}\} \quad (i \neq j)$$

## 2 多光谱图像融合复原

### 2.1 多光谱图像融合复原思想

遥感图像的空间分辨力与许多因素有关<sup>[8]</sup>, 如探测器的灵敏度、观测的光谱范围、观测时间以及数据处理系统等等. 因此, 对于不同的遥感系统, 所获得的图像空间分辨力也不同. 近年来, 多源数据融合技术在图像复原领域受到了广泛的重视. 由于大多数传统的图像复原算法不适用于进行多源图像数据融合<sup>[9]</sup>. 这里利用神经网络进行数据融合的优势, 提高多光谱遥感图像的空间分辨力.

### 2.2 仿真实验与实验结果

实验选取若干组多通道影像图, 将低分辨力退化图像和与之相对应的高分辨力原图像分为两组, 一组作为训练样本集, 一组作为测试样本集. 将原始图像作为网络训练的目标图像, 虽然实际图像可能被各种噪音污染, 并且可能存在不同的成像畸变, 但是考虑到图像模糊和欠采样是造成实际遥感图像退化的主要因素, 因此这里采用高斯模糊和欠采样处理模拟实际成像系统中光学系统对图像造成的模糊和摄像系统有限的像元数目对图像的欠采样. 首先对图像进行点扩散函数为  $5 \times 5$  的高斯模糊处理, 然后采用  $2 \times 2$  像素的窗口进行积分采样, 得到退化的欠采样图像, 再采用双线性插值法进行预处理, 使欠采样图像恢复为和原始图像大小相同. 最后将退化图像同其它传感器的高分辨力图像一起组成神经网络的输入样本.

根据马尔可夫理论, 图像可看作为一个随机场, 图像中像素的灰度值和其相邻像素的灰度值有关.

因此这里设计了多点融合方案. 如何选择合适大小的子区域, 取决于点扩散函数和采样间隔. 网络输入层神经元的数目等于高分辨力图像和低分辨力图像输入网络的像元数目之和. 隐层神经元数目无法预先确定, 通常情况下预先选择不低于输入神经元数目两倍的值. 最终隐层神经元数目经过自适应选择后确定. 图 2 是子区域为  $3 \times 3$  的三通道多点融合网络结构示意图.




图 2 多通道图像复原的 RBF 网络结构  
Fig. 2 The schematic viewing of multi-channel image restoration

图 3 是 SPOT5 的 MARIGNANE 地区波段 3 的原始图像, 图 4 是对其进行退化处理后的图像, 将图 4 与波段 1 和波段 2 的未退化高分辨力图像组成神经网络的训练样本集, 图 5 是经过训练之后网络输出的复原图像. 为了考察多通道融合复原与单通道融合复原的差别, 让网络的输入仅有波段 3 的退化图像, 进行单通道复原, 图 6 是单通道图像复原结果. 显然, 其像质较融合复原效果差. 实验还同时完成了维纳滤波和最大后验概率 (MAP) 算法的图像复原. 维纳滤波方法所获得的复原结果较差, 并且伴有人工振荡条纹, 如图 7. MAP 法复原效果相



图 3 MARIGNANE 地区波段 3 的原始图像(局部)  
Fig. 3 The original image of band 3 of MARIGNANE region



图 4 退化处理后的图像  
Fig. 4 The degraded image



图 5 RBF 网络多光谱融合复原结果  
Fig. 5 The restoration image with RBF Network



图 6 RBF 网络单波段复原结果  
Fig. 6 The results of single band restoration




图 7 维纳滤波方法的复原结果  
Fig. 7 The restoration image with Wiener filtering



图 8 MAP 方法的复原结果  
Fig. 8 The restoration image with MAP



图 9 测试样本原始图像  
Fig. 9 The original image as testing sample



图 10 退化处理后的低分辨率图像  
Fig. 10 The degraded image with low resolution



图 11 融合复原的 RBF 网络泛化力测试结果  
Fig. 11 The testing results for generalizing ability of network  
对较好,如图 8,但是仍不如融合复原方法像质好. 为了验证网络的泛化能力,实验任意选择一幅图像

(图 9)为测试样本,图 10 是经过退化处理后的低分辨率图像. 将退化图像输入训练后的网络,图 11 是网络输出的测试结果.

### 2.3 像质评价

由于均方差(MSE)和峰值信噪比(PSNR)只表征了复原图像对于目标的逼真程度,没有表明复原图像相对于退化图像的改善程度,而这一点对于图像复原算法的评价是非常重要的. 因此,本文采用改善信噪比(ISNR)评价标准,其定义为

$$ISNR = 10 \log_{10} \frac{\|f - g\|^2}{\|f - \hat{f}\|^2} = PSNR_{\hat{f}} - PSNR_g \quad (12)$$

式中  $f$ 、 $\hat{f}$ 、 $g$  分别为理想图像、复原图像和退化图像,  $PSNR_{\hat{f}}$  和  $PSNR_g$  分别为

$$PSNR_{\hat{f}} = 10 \log_{10} \frac{1}{\frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N [f(i,j) - \hat{f}(i,j)]^2}$$

$$PSNR_g = 10 \log_{10} \frac{1}{\frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N [f(i,j) - g(i,j)]^2}$$

结果如表 1. 可以看到,如果  $ISNR > 0$ , 表明与退化图像相比复原图像更逼近于目标,且  $ISNR$  越大,表明相对于退化图像复原的改善程度越大,算法的图像复原能力越好. 如果  $ISNR < 0$ , 表明复原图像相对于退化图像更加远离目标,算法不能使退化图像得到改善.

表 1 MARIGNANE 地区图像复原结果的定量分析

复原方法	多通道融合复原	单通道复原	MAP 复原	网络测试
ISNR	33.07	19.83	22.56	25.98

## 3 结论

研究表明,文中提出的基于 RBF 网络的多通道图像融合复原方法是可行的. 通道之间的相关和冗余信息,可以提高复原图像的像质. 而单通道图像复原不能获得如此高的图像改善程度. 无论是改进信噪比还是图像的视觉效果,复原图像相对于经过退化处理的图像均有明显的改善. 尽管上述实验是初步的,但证明了神经网络融合复原方法较传统复原算法的优势.

### 参考文献

- Hunt B R. Super-Resolution of Imagery: Understanding the Basis for Recovery of Spatial Frequencies Beyond the Diffraction Limit. IEEE International Conference on IDC Adelaide, Australia, 8-10Feb, 1999; 243~248
- Cha I, Kassam S A. RBFN restoration of nonlinearly degraded images. IEEE Trans on Image Processing,

- 1996, **5**(6): 964~975
- 3 Su Binghua, Jin Weiqi. POCS-MPMAP based super-resolution image restoration. *Acta Photonica Sinica*, 2003, **32**(4): 502~504
- 4 Bianchini M, Frasconi P. Learning without local minima in radial basis function networks. *IEEE Transaction on Neural Networks*, 1995, **6**(3): 749~756
- 5 Wasserman P D. *Advanced Methods in Neural Computing*. New York: Van Nostrand Reinhold, 1993
- 6 Roger Jang J S, Sun C T. Functional equivalence between radial basis function networks and fuzzy inference system. *IEEE Trans on Neural Networks*, 1993, **4**(1): 156~159
- 7 牛丽红, 倪国强. 改进的对向传播网络及其在多传感器目标识别中的应用. *光子学报*, 2003, **32**(2): 244~248
- Niu L H, Ni G Q. *Acta Photonica Sinica*, 2003, **32**(2): 244~248
- 8 Valdes M C, Inamura M. Improvement of remotely sensed low spatial resolution images by back-propagated neural networks using data fusion techniques. *International Journal of Remote Sensing*, 2001, **22**(4): 629~642
- 9 苏秉华, 金伟其, 牛丽红. 基于 Markov 约束的 Poisson-MAP 超分辨率图像复原法. 的应用. *光子学报*, 2002, **31**(4): 492~496
- Su B H, Jin W Q, Niu L H. *Acta Photonica Sinica*, 2002, **31**(4): 492~496

## RBF Neural Network Based Image Fusion Restoration Approach

Niu Lihong<sup>1</sup>, Ni Guoqiang<sup>2</sup>, Su Binghua<sup>2</sup>

<sup>1</sup> Institute of Optoelectronics, Shenzhen University, Shenzhen 518060

<sup>2</sup> Optical Engineering Dept., Beijing Institute of Technology, Beijing 100081

Received date: 2005-07-02

**Abstract** A radial basis function (RBF) neural network based image fusion restoration approach for multiple spectrum images is proposed and investigated. The spatial resolution improvement of images with poor resolution can be achieved by fusing the images of various resolutions. The simulated experimental results show the effectiveness of the method. The image quality is improved by fusing the correlative and redundant information between images. The modified algorithms ensure quick training and mapping precision of the networks. The research also illustrates that using multi-channel information is more effective than using a single one and the scenario conducted has advantages over conventional methods.

**Keywords** Image restoration; Data fusion; Multi-spectrum image; Artificial neural networks; Image degradation



**Niu Lihong** Born in July, 1963. Received the Ph. D. degree in optical engineering from Beijing Institute of Technology in 2003 and M. S. degree in physics from Xian Institute of Optics and Precision Mechanics, Academic Sinica in 1988 respectively. She is working for Institute of Optoelectronics, Shenzhen University as a vice professor and director of Lab. She has recently been involved in research on image processing, photoelectronic detecting and imaging.