

文章编号:1001-9014(2007)04-0297-05

基于脊波和神经网络的大压缩比遥感图像压缩

杨淑媛, 王敏, 焦李成

(西安电子科技大学 智能信息处理研究所, 陕西 西安 710071)

摘要:为了实现大压缩比的遥感图像压缩,利用神经网络的自组织、并行计算和分布式存储的能力,提出一种基于神经网络的压缩方法.在传统单隐层前向神经网络的基础上,该网络使用一种新的能有效处理直线型和曲线型奇异性的多尺度几何分析工具-脊波,作为隐层神经元的激活函数.它不仅具有神经网络压缩的优点;并且由于脊波良好的时、频和方向局域化特性,能够对遥感图像的边缘和轮廓实现更加有效的表示.仿真结果表明:该方法不仅能实现较高的压缩比,而且具有重建图像质量好、学习快速和鲁棒性强等优点.

关键词:遥感图像压缩;脊波;神经网络

中图分类号:TP311.56 **文献标识码:**A

HIGH-RATIO COMPRESSION OF REMOTE SENSING IMAGE BASED ON RIDGELET AND NEURAL NETWORK

YANG Shu-Yuan, WANG Min, JIAO Li-Cheng

(Institute of Intelligent Information Processing, Xidian Univ., Xi'an 710071, China)

Abstract: To get a high-ratio compression of remote sensing images, a neural network (NN)-based compression method was advanced. By using the characteristics of self-learning, parallel processing and distributed storage of NN, a single hidden layer feed-forward NN was constructed for getting high-ratio compression of remote sensing images. Moreover, we employ ridgelet, which is a new geometrical multiscale analysis (GMA) tool and is powerful in dealing with linear singularities (and curvilinear singularities with a localized version), as the activation function in the hidden layer of the network. Therefore the network has both the advantages of NN-based image compression method and more effective representation of edges and contours for the localization properties of ridgelet in scale, location and direction. The simulation results show that the proposed network can not only get high compression ratio but also present promising results, such as high reconstruction quality, fast learning and robustness, as compared to available techniques in the literature.

Key words: remote sensing image compression; ridgelet; neural network

引言

遥感图像具有分辨率高、信息量大和码速率高的特点,图像产生的大量数据必须经过压缩才能适应图像传输和存储的需求.小波变换编码是广受关注的一种高品质压缩算法^[1],用小波变换对遥感图像压缩3倍及其3倍以下均能取得好的效果,对于更大的压缩比则效果明显下降.然而,3倍的压缩远不能满足卫星遥感图像存储和传输的要求.在传统图像压缩方法中,目前未见可以有效实现大压缩比遥感图像压缩的方法.利用前向神经网络(Feed-forward Neural Network-FNN)进行图像压缩是一种新

颖的压缩方法^[2-5].它利用一个隐含层单元远少于输入层和输出层少的三层网络实现数据的压缩,网络的输入为原图像,输出代表重建图像,隐层神经元的输出是需存储的图像特征.由于隐含层神经元数目远少于输入层和输出层的节点数目,则学习后的网络将以较少的数据量有效的表示图像,从而达到压缩的目的.解码为压缩的逆过程,只需隐含层神经元的输出值和该网络的右侧权值,即可恢复出原始图像.首先,这种方法压缩比取决于隐含单元的数目,从而可以实现大压缩比的图像压缩;其次,神经网络具有分布式存储和内在并行处理的特点,可以实现快速的压缩编码;此外,神经网络还具有自适应性和容错

收稿日期:2006-08-11,修回日期:2007-01-08

基金项目:国家自然科学基金(60601029)资助项目

作者简介:杨淑媛(1978-),女,山东聊城人,副教授,博士,主要从事智能信号与图像处理研究.

Received date: 2006-08-11, revised date: 2007-01-08

性的特点. 这些良好的特性都为设计一个实时、高效和自适应的图像压缩系统提供了可能.

遥感图像具有局部相关性较弱、纹理丰富的特点,大量的直线状、曲线状的方向信息存在于图像中. 近年来发展起来的后小波分析-多尺度几何分析 MGA 是小波分析的高维推广^[6]. 不同于多维张量积小波维数可分离的构造方式, MGA 系统提供了具有特殊几何结构的维数不可分的基函数. 作为 MGA 工具之一,脊波能更好的处理直线状和超平面状的奇异性^[7,8],因此对图像中的纹理和边缘等有更好的压缩. 同小波变换类似,脊波变换在大压缩比时也存在性能下降的问题,因此本文提出了一种基于脊波和神经网络的遥感图像压缩方法. 该方法不仅可以获得大的压缩比,而且能更有效的实现遥感图像中边缘、轮廓等空间方向性信息的压缩.

1 基于脊波理论和神经网络的图像压缩

1.1 脊波

在表示图像的直线状或曲线状的边缘时,小波基并不是最优基. 脊波被证明在逼近一些具有空间不均匀性(直线状和超平面状的奇异性)的函数时是最优的,并且这种逼近相对于 Fourier 变换和小波变换来说能获得更好的逼近速率^[7]. 1998 年, E. J. Candes 首先给出脊波函数的定义:

若函数 $\psi: R \rightarrow R$ 满足条件:

$$K_\psi = \int \frac{|\hat{\psi}(\xi)|^2}{|\xi|^d} d\xi < \infty, (\hat{\psi}(\cdot) \text{ 为函数 } \psi \text{ 的 Fourier 变换}) \quad (1)$$

则称由 ψ 产生的脊函数 $\psi_\gamma(x) = a^{-1/2} \psi\left(\frac{u \cdot x - b}{a}\right)$ 为脊波,参数 $\gamma = (a, u, b)$ (分别表示脊波的尺度、方向和位置)属于参数空间 $\Gamma = \{\gamma = (a, u, b) | a, b \in R, a > 0, u \in S^{d-1}, \|u\| = 1\}$. 定义连续脊波变换:

$$R(f)(\gamma) = \langle f, \psi_\gamma \rangle = \int_R \psi_\gamma(x) f(x) dx \quad , \quad (2)$$

记 d 维空间中单位球 S^{d-1} 的表面积为 σ_d ,对于任何 $f \in L^1 \cap L^2(R^d)$,均可以展开为脊函数叠加的形式:

$$\begin{aligned} f &= c_\psi \int \langle f, \psi_\gamma \rangle \psi_\gamma \mu(d\gamma) \\ &= \pi(2\pi)^{-d} K_\psi^{-1} \int \langle f, \psi_\gamma \rangle \psi_\gamma \sigma_d da/a^{d+1} dudb \quad , \quad (3) \end{aligned}$$

即:任何函数能被分解成基函数 ψ_γ 的叠加. 此外,由于脊波 $\psi_\gamma(x)$ 是局部化在窄带 $\{x: |u \cdot x - b| < a\}$ 上的,脊波的横截面是一条类似于小波的曲线,而沿着脊线是一条直线,正是这样的几何结构使脊波能有




图1 脊波和局域化脊波
Fig.1 Ridgelet and localized ridgelet




图2 脊波神经网络
Fig.2 Neural network with ridgelet neurons

效处理线状的奇异性,如图 1(a)所示. 不仅如此,经过局域化的脊波函数还具有曲线状的脊线,所以能更好处理曲线状的奇异性,如图 1(b)所示.

1.2 用于图像压缩的脊波神经网络

在前向神经网络中采用脊波作为激活函数,就可以得到实现大压缩比图像压缩的神经网络模型. 如前所述,脊波对方向信息非常敏感,当图像中存在线状或曲线状的奇异性时,如果它能够调整方向向量,找到合适的脊波函数“套住”具有奇异性的部分,就能对原始数据给出更加稀疏的表示;另外,由于神经元采用的是维数不可分的脊波神经元,它具有将高维信息映射到低维的能力,从而在一定程度上能够克服网络的规模膨胀问题.

设待压缩的图像大小为 512×512 ,每像素用 8 位灰度值表示. 网络的输入为像素的灰度值. 如直接将一幅图像输入脊波网络中进行学习,则网络的输入层需要 512×512 个神经元. 假设压缩比为 16:1,网络的隐层则需要 512×32 个神经元. 这样得到的网络结构非常庞大,不利于网络的学习. 为降低网络的学习难度,采取以下措施减小网络规模:对原始图像进行分块处理,先将图像分为多个子图,图像子块大小选为 16×16 ,则网络结构为 256-16-256.

1.3 网络的训练

在训练前,对网络的输入即原始图像进行归一化处理,将取值在 $[0, 255]$ 的灰度值图像变换到 $[0, 1]$. 设训练中有 P 对学习样本 $\{X, Y\}$ ($X = [x_1, \dots, x_p], Y = [y_1, \dots, y_p]$),其中 $x_p = [x_{1p}, \dots, x_{mp}]^T, y_p$

$= [y_{1p}, \dots, y_{mp}]^T (p=1, \dots, P)$ 分别表示输入的第 i 个样本和其对应的输出, w_{ji} 表示第 i 个脊函数连接到第 j 个输出节点的权值, w_{j0} 为第 j 个目标节点的阈值, $Z_i = [z_{i1}, \dots, z_{ip}] (i=1, \dots, N)$ 为隐层的输出. 对于第 p 个样本, 网络隐层的输出为

$$z_{ip} = \psi(\zeta_{ip}) = \psi \left[\sum_{j=1}^m \left(\frac{u_{ij} \cdot x_{ip} - b_{ij}}{a_{ij}} \right) \right], \quad \left(\sum_{j=1}^m u_{ij}^2 = 1 \right) \quad (4)$$

接下来是一个线性输出层

$$y_{ip} = w_{j0} + \sum_{i=1}^N w_{ji} z_{ip}, \quad (j=1, \dots, m) \quad (5)$$

记网络的期望输出为 d (即为原图像), 定义网络误差:

$$J = \frac{1}{2} \sum_{p=1}^P e_p^2 = \frac{1}{2} \sum_{p=1}^P \sum_{j=1}^m (y_{jp} - d_{jp})^2 \quad (6)$$

采用最陡梯度下降法最小化误差来完成输入到输出的非线性映射, 令 η 为学习步长, 网络的权值更新如式(7)~式(10)所示

$$\begin{aligned} w_{ji}(k+1) &= w_{ji}(k) - \eta \frac{\partial J(k)}{\partial w_{ji}} \\ &= w_{ji}(k) - \eta \times \sum_{p=1}^P \sum_{l=1}^m (y_{lp} - d_{lp}) z_{lp}, \\ (i=0 \text{ 时}, z_{ip} &= 1) \end{aligned} \quad (7)$$

$$\begin{aligned} a_{ij}(k+1) &= a_{ij}(k) - \eta \frac{\partial J(k)}{\partial a_{ij}} \\ &= a_{ij}(k) + \eta \times \sum_{p=1}^P \sum_{l=1}^m (y_{lp} - d_{lp}) w_{li} \\ &\quad - d_{lp} w_{li} \frac{\partial \psi(\zeta_{lp})}{\partial \zeta_{lp}} \left[\frac{u_{il}(k) x_{lp} - b_{il}(k)}{a_{ij}(k)} \right]^2, \end{aligned} \quad (8)$$

$$\begin{aligned} b_{ji}(k+1) &= b_{ji}(k) - \eta \frac{\partial J(k)}{\partial b_{ji}} \\ &= b_{ji}(k) + \eta \times \sum_{p=1}^P \sum_{l=1}^m (y_{lp} - d_{lp}) w_{li} \\ &\quad - d_{lp} w_{li} \frac{\partial \psi(\zeta_{lp})}{\partial \zeta_{lp}}, \end{aligned} \quad (9)$$

$$\begin{aligned} u_{ij}(k+1) &= u_{ij}(k) - \eta \frac{\partial J(k)}{\partial u_{ij}} \\ &= u_{ij}(k) - \eta \sum_{p=1}^P e_p(k) \sum_{l=1}^m (y_{lp} - d_{lp}) w_{li} \frac{\partial \psi(\zeta_{lp})}{\partial \zeta_{lp}} \left(\frac{x_{lp}}{a_{ij}} \right) \\ &\quad \left[\sum_{r=1, r \neq j}^m u_{lr}^2(k) / \left(\sum_{r=1}^m u_{lr}^2(k) \right)^{3/2} \right]. \end{aligned} \quad (10)$$

众所周知, 在 FNN 的实际应用中, 隐层节点数目 K 的确定是网络训练中的关键内容之一. 在本文压缩模型中, 隐节点数 K 同时也决定着压缩比. 然而, 这种固定结构的网络不一定能达到最佳的性能. 若以容许误差作为终止条件, 误差太小, 网络可能训练不出来, 误差太大, 则网络可能未达到最高的计算




图3 压缩系统

Fig. 3 The compression system

精度. 因此, 本文在前述工作的基础上^[9], 对网络结构的确定方法进行了改进. 目前常用方法有凑试法、经验公式法、增长法、修剪法、复杂性调整法、交叉验证法、最小二乘法、模糊聚类法和黄金分割法等. 这里我们选择逐渐增加隐节点数目的增长法. 给定容许误差, 令 K 从 1 开始以步长 1 逐渐增加, 直到网络的输出满足要求. 这种训练方法更为灵活合理, 算法如下:

算法:

1. 将图像划分为子块;

2. 执行

1) 令学习步长 $\eta = 0.01$, 最大迭代次数 $T = 1000$ 和容许误差 ε ;

2) 令隐单元初始数目 $K = 1$, 初始化网络的权值, 输入子块图像;

3) 重复

3.1) 计算网络输出;

3.2) 判断误差 J ; 如果比 ε 小, 记录 K , 转到 3, 否则继续;

3.3) 根据公式(7-10)更新连接权值;

直到达到最大迭代数目 T .

4) $K = K + 1$; 转到 3)

3. 编码图像, 输出.

1.4 量化和编码

每个图像子块在编码前必须量化. 通过在每次迭代训练来纠正量化误差, 可以提高输出图像的峰值信噪比 (Peak signal-to-noise ratio-PSNR). 量化后的系数可以用不同方法编码, 如 Huffman 编码、算术编码等. 压缩系统的结果如图 3 所示.

2 仿真实验

以如图 4 所示的 SAR 遥感图像为例 (来自 USC-SIPI Image Database, Univ. of Southern California Signal and Image Processing Institute) 进行实验, 其中包括了边缘、轮廓清晰的图像, 具有复杂目标和地貌的图像, 图像大小均为 512×512 .




图4 遥感图像

Fig. 4 The remote sensing images

实验 1:为了检验本文方法的性能,将它和小波神经网络(WNN)^[10]进行比较. WNN 属于前向神经网络的一种,实现图像压缩的原理和本文方法相同,采用小波函数作为隐层传递函数. 首先我们将图像图 4(a)分为 1×8 , 8×1 , 2×4 , 4×2 大小的子块,令 $\varepsilon = 1$. 表 1(a)给出了压缩比为 8:1 时的结果. 从压缩的结果可以看出:在 4 种不同的分块方式中,本文方法均比 WNN 方法具有更高的逼近精度. 接着,再分别令 $\varepsilon = 2$ 和 $\varepsilon = 10$ 来分别得到压缩比 16:1(如表 1(b)所列)和 32:1(如表 1(c)所列),这是传统压

表 1 小波神经网络方法和本文方法的峰值信噪比
Table 1 The PSNR of the wavelet-based method and our method

(a) 压缩比 8:1		
分块大小	小波神经网络方法 (dB)	本文方法 (dB)
1×8	51.390	52.228
8×1	50.829	52.488
2×4	56.061	56.368
4×2	53.099	53.623
(b) 压缩比 16:1		
分块大小	小波神经网络方法 (dB)	本文方法 (dB)
16×1	42.557	43.410
1×16	43.845	46.318
4×4	51.272	53.510
2×8	46.990	49.432
8×2	46.221	46.682
(c) 压缩比 32:1		
分块大小	小波神经网络方法 (dB)	本文方法 (dB)
32×1	38.383	38.615
1×32	32.915	37.926
4×8	44.462	46.861
8×4	44.041	44.875
16×2	40.474	40.762
2×16	41.497	43.046

表 2 小波神经网络和本文方法的性能
Table 2 The performance of the wavelet-based method and our method

图像	小波神经网络方法		本文方法	
	PSNR (dB)	Ratio	PSNR (dB)	Ratio
I1	48.897	33.805	52.608	35.764
I2	50.845	25.565	51.683	25.955
I3	46.877	29.485	46.948	30.271
I4	47.052	27.307	47.438	27.573
I5	48.692	26.255	49.028	26.340
I6	44.362	29.806	44.959	30.172

缩方法所难以实现的. 由所得结果可以看出:对于图像的不同分块方式,本文方法均得到高于 WNN 的 PSNR,而且较 WNN,图像的边缘和轮廓保持的更好.

实验 2:在本实验中我们将图像分为大小 8×8 的子块,令 $\varepsilon = 1$,得到的压缩结果如表 2 所列. 从结果中可以看出:本文方法不仅可以得到高的 PSNR,而且具有高于 WNN 的压缩比. 当图像中目标以及轮廓信息较复杂时,本方法的隐节点数目略有上升,但压缩比和 PSNR 仍高于 WNN 方法.

实验 3:在本实验中,我们比较了本文方法,基于 WNN 的压缩、BP 神经网络 (Back propagation Network, BPN) 的压缩^[4],以及 JPEG (DCT) 方案对于图 4(c)的压缩结果和复杂度. 基于 BPN 和 WNN 的方案均是基于神经网络的压缩方法,BPN 隐层中使用的是 Sigmoid 函数,WNN 如实验 1 所述. 实验中 JPEG 方法使用 8×8 的分块,先进行离散余弦变换,得到的系数用均匀量化器量化之后进行重排;然后使用差分脉冲编码调制对相邻图像块之间量化的直流系数进行编




图5 几种方法压缩结果的比较
Fig. 5 The compression result of the methods

表3 几种方法的实现时间比较(s)
Table 3 The consumed time of the methods(s)

方法	4 × 3	8 × 6	12 × 16
BPN	23.2	23.5	27.8
WNN	21.7	21.7	26.4
本文方法	16.0	19.2	24.9

码,使用行程长度编码对交流系数进行编码;最后用熵编码进行进一步的压缩.神经网络方法训练的时间与学习步长、容许误差、最大迭代次数以及分块方式等有关.学习步长越大和容许误差越大、最大迭代次数和分块大小越小,网络的单次训练所需的时间越短.实验中为实现12:1的压缩,3种网络采用相同的学习算法且 $\eta=0.01$, $\varepsilon=1.4$, $T=1000$.图像采用 4×3 , 4×6 , 12×3 , 8×6 , 12×6 , 8×12 , 12×16 等分块方式,分别对应的隐层节点数目为1,2,3,4,6,8,16等.取10次独立实验所耗时间的平均值,各方法在不同分块下实现整幅图像的时间如表3所列.

由于JPEG方法采用的是固定变换的实现方法,所耗时间为3.4s,具有最快的速度.几种神经网络方法在分块大小不同时,实现时间略有差异,分块越大时,由于单次训练的难度越大,因此所需的时间越长.由于在相同的结构下采用维数不可分的脊波神经元,本文方法能实现更快的训练,所需的时间少于其他方法,在分块小时这种优势更为明显.令3种网络均采用 8×6 的分块方式,得到PSNR随着压缩比的变化曲线,如图5所示.从图中可以看出:基于神经网络的方法能实现相对较高的压缩比.在3种神经网络方法中,本文方法的结果最佳.

3 结语

神经网络压缩方法是实现大压缩比图像压缩的一种新方法,压缩效果也比较理想.利用快速发展的计算机和数字专用集成电路技术,神经网络图像压缩将逐渐走向实用.本文利用一种能更有效处理图像边缘和轮廓的多尺度几何分析工具-脊波,结合神经网络方法,构造脊波神经网络模型对遥感图像实现大压缩比的图像压缩.由于脊波函数更适于处理具有线状和超平面状奇异性数据,本文采用的压缩方法不仅能得到较高的压缩比,而且能更好的保持边缘信息.仿真结果也验证了它的压缩效果.动态图像的编码,将是我们下一步研究的主要目标.

REFERENCES

- [1] WU Ying-Qian, FANG Tao, SHI Peng-Fei. Adaptive compression of hyper-spectral images based on uniform trellis-coded quantization[J]. *J. Infrared Millim. Waves* (吴颖谦, 方涛, 施鹏飞. 基于均匀网格编码量化的超光谱图像自适应压缩. *红外与毫米波学报*), 2004, 23(5): 349—352.
- [2] Mougeot M, Azencott R, Angeniol B. Image compression with back propagation: improve of the visual restoration using different cost functions[J]. *Neural Networks*, 1991, 4(4): 467—476.
- [3] Daugman J. Complete discrete 2-D Gabor transforms by neural networks for image analysis and compression[J]. *IEEE Trans. Acoust., Speech, Signal Proc*, 1998, 36(7): 1169—1179.
- [4] Abdel O, Wahhab, Fahmy M M, Image compression using multilayer neural networks[J]. *IEEE proc. Vis Signal Processing*, 1997, 144(5): 307—312.
- [5] Krishnamurthy A K, Ahalt S C, Melton D E, et al. Neural networks for vector quantization of speech and images[J]. *IEEE J. on Selected Areas in Communications*, 1990, 8(8): 1449—1457.
- [6] SHA Yu-Heng, CONG Lin, SUN Qiang, et al. Multi-scale image segmentation based on contourlet-domain hidden Markov trees model[J]. *J. Infrared Millim. Waves* (沙宇恒, 丛琳, 孙强, 等. 基于Contourlet域HMT模型的多尺度图像分割. *红外与毫米波学报*), 2005, 24(6): 472—476.
- [7] Candès E J. Ridgelet: theory and applications[D]. Ph. D. dissertation. Stanford Univ, 1998.
- [8] Minh N Do, Martin Vetterli. The finite ridgelet transform for image representation[J]. *IEEE Transactions on Image Processing*, 2003, 12(1): 16—28.
- [9] Yang Shuyuan, Wang Min, Jiao Licheng. Compression of remote sensing images based on ridgelet and neural network [C]. *Lecture Notes in Computer Science*, Springer-Verlag, 2005, 3497: 723—730.
- [10] Zhang Q, benveniste A. Wavelet network[J]. *IEEE Trans on Neural network*, 1992, 3(6): 889—898.