

基于极限学习机的图像压缩算法

刘作志, 刘欢, 林耀海

(西安电子科技大学 电子工程学院, 陕西 西安 710071)

摘要:神经网络具有并行分布处理、自学习、自适应和很强的鲁棒性及容错性等优点,已被广泛应用于图像压缩领域,为图像压缩提供了一个新途径。极限学习机是一种单隐层前向神经网络算法,与传统神经网络算法相比,具有学习速度快、泛化能力强等优点。文中旨在提出一种基于极限学习机的图像压缩算法。该算法主要利用极限学习机的非线性映射能力,对图像进行压缩编码和解码。首先利用极限学习机通过学习构建一个用于图像压缩的单隐层前向神经网络模型,其次利用该模型实现图像压缩和图像重建。实验结果表明,在相同压缩比下,所提算法的重建效果优于BP神经网络,并且具有较快的学习速度。

关键词:图像压缩;单隐层前向神经网络;极限学习机;Matlab 仿真

中图分类号:TP183

文献标识码:A

文章编号:1673-629X(2015)05-0013-04

doi:10.3969/j.issn.1673-629X.2015.05.004

Image Compression Algorithm Based on Extreme Learning Machine

LIU Zuo-zhi, LIU Huan, LIN Yao-hai

(School of Electronic Engineering, Xidian University, Xi'an 710071, China)

Abstract: With the advantages of parallel distributed processing, self-learning, self-adaption and strong robustness and fault tolerance, neural networks have been widely used in image compression, which provide a new approach to image compression. Extreme learning machine is a single hidden layer feedforward neural network algorithm, and has faster learning speed and better generalization performance than traditional neural network algorithms. In this paper, aim at proposing an image compression algorithm based on extreme learning machine. The algorithm achieves image compression coding and decoding with the nonlinear mapping capability of extreme learning machine. Firstly, a single hidden layer feedforward neural network model for image compression is established through training the samples by using extreme learning machine. And then the model is used to compress and reconstruct image. The simulation results show that this algorithm has better reconstruction performance and faster learning speed than BP neural network.

Key words: image compression; single hidden layer feedforward neural network; extreme learning machine; Matlab simulation

0 引言

随着计算机网络和通信技术的飞速发展,人们对文字、图像和视频等多媒体信息的需求也与日俱增^[1]。图像作为网络通信中一种重要的信息载体,在政治、经济、军事和医疗等诸多领域都发挥了重大作用。然而,过大的信息量极大地限制了图像的存储、处理和传输,海量图像数据的表示与存储成为信息技术发展中最大的难题之一^[1]。图像压缩则是解决这一难题的有效方法。

图像压缩作为图像处理中的一个重要研究课题,主要是指利用图像自身固有的冗余性和相关性,去掉

图像中的冗余信息,将一幅较大的图像转换成较小的图像^[2]。目前存在许多图像压缩方法,但大多数存在压缩比低、重建效果差的缺点。随着人工神经网络神经理论不断完善和发展,神经网络已被广泛应用于系统识别、故障诊断、经济预测、图像处理等领域^[3]。神经网络技术的应用为图像压缩和重建提供了一个新途径。在过去的二十年中,研究学者们提出了一系列基于神经网络的图像压缩方法^[4-12]。但传统神经网络(如BP神经网络)学习速度远不能满足现实需求,成为制约其发展的主要瓶颈。

极限学习机(Extreme Learning Machine, ELM)是

收稿日期:2014-07-04

修回日期:2014-10-08

网络出版时间:2015-04-22

基金项目:国家青年科学基金项目(31300473);福建省自然科学基金项目(2014J0101)

作者简介:刘作志(1988-),男,博士,CCF会员,研究方向为智能信息处理;林耀海,在职博士,任职于福建农林大学计算机与信息学院,研究方向为智能信息处理、高光谱成像。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20150422.1005.017.html>

由黄广斌于 2006 年提出的一种单隐层前向神经网络 (Single hidden Layer Feedforward Neural networks, SLFNs) 算法^[13]。与传统神经网络算法相比,该算法无需迭代调整隐层参数,具有学习速度快、泛化能力强等优点。文中提出一种基于极限学习机的图像压缩方法。实验结果表明,将极限学习机应用于图像压缩可以取得更好的图像压缩重建效果,并且具有较快的学习速度。

1 极限学习机

极限学习机由黄广斌于 2006 年提出并得到迅速发展,显示出比传统的 BP 神经网络和其他计算智能技术更强的学习能力,目前已成功应用于模式识别、医学诊断、图像处理等领域^[14-16]。极限学习机是一种单隐层前向神经网络算法,在学习过程中,该算法采用随机机制选取隐层参数,大大提高了学习速度并保证泛化能力。

给定训练样本 $\{(x_j, t_j)\}_{j=1}^N \in R^d \times R^m$, 如果网络输出等于目标输出可得

$$f_L(x_j) = \sum_{i=1}^L \beta_i G(a_i, b_i, x_j) = t_j, j = 1, 2, \dots, N \quad (1)$$

进一步写成矩阵形式

$$H\beta = T \quad (2)$$

其中,

$$H = \begin{pmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_1) \\ \vdots & \dots & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{pmatrix}_{N \times L}$$

$$\beta = (\beta_1, \beta_2, \dots, \beta_L)^T_{m \times L}, T = (t_1, t_2, \dots, t_N)^T_{m \times N}$$

H 称为网络的隐层输出矩阵,其第 i 行表示 L 个隐单元关于第 i 个样本的输出,而第 j 列则表示第 j 个隐节点关于所有样本的输出。

在极限学习机算法中,当隐单元参数服从某种连续概率分布随机选取之后, H 即为已知。因此,训练 SLFNs 等价于寻找线性方程(1)的最优解 $\hat{\beta}$ 使得误差 $\|H\beta - T\|$ 达到最小,即

$$\hat{\beta} = \arg \min_{\beta} \|H\beta - T\| \quad (3)$$

式(3)的最优解为

$$\hat{\beta} = \begin{cases} H^{-1}T, H \text{ 为非奇异矩阵} \\ H^{+1}T, H \text{ 为奇异矩阵} \end{cases} \quad (4)$$

其中, H^{+1} 为 H 的 Moore-Penrose 广义逆。

极限学习机算法的具体步骤可总结如下:给定训练样本集,选取适当的激活函数和隐单元个数。

第一步:随机选取输入权重和隐层阈值;

第二步:计算隐层输出矩阵 H ;

第三步:计算输出权重 $\hat{\beta}$ 。

与传统学习算法相比,极限学习机具有如下优点:

- (1) 无需迭代调整网络参量;
- (2) 学习速度更快、泛化能力更好;
- (3) 避免了传统梯度学习算法经常面临的一些问题,如易陷入局部极小、停止准则和学习率的设定等;
- (4) 不仅适用于激活函数无限可微的 SLFNs, 同样也适用于激活函数不可微的 SLFNs。

2 基于极限学习机的图像压缩算法

在基于神经网络的图像压缩技术中^[4-12],输入层和隐层之间的变换相当于编码过程,主要是将图像信号变换成压缩信号。而隐层和输出层之间的变换则相当于解码过程,将压缩信号反变换为图像信号。具体过程是:原始图像由输入层进入网络,经过隐层处理得到压缩编码,最后压缩编码在输出层经过解压得到压缩后重建的图像。其中输入层和输出层具有相同的节点数,隐层节点数少于输入、输出层。压缩比率=输入(输出)层节点数/隐层节点数。

图 1 给出了用于图像压缩的 BP 神经网络模型和极限学习机模型。通过对比发现,在 BP 神经网络中需要利用梯度反向调整网络参量,直至收敛,但其收敛速度往往比较慢。而极限学习机在学习过程中无需迭代过程调整网络参量,结构简单易实现。

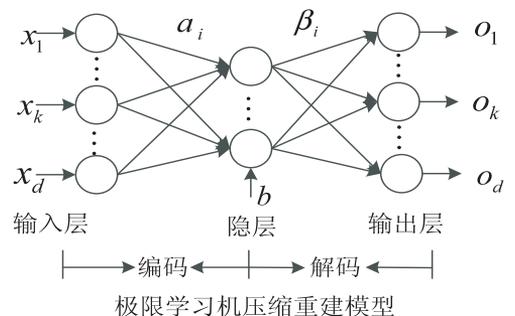
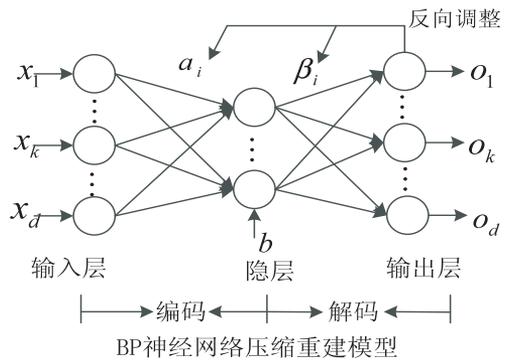


图 1 用于图像压缩的 BP 神经网络和极限学习机模型

将极限学习机算法用于图像压缩,其流程如下:

- (1) 图像预处理。首先输入待压缩图像,并将其进行归一化处理;其次为了减少输入变量提高学习训练的速度,将整幅图像分割成 M 个 $n \times n$ 的图像块,并将每幅图像变成一个列向量。

(2)网络训练。首先建立一个单隐层神经网络模型,输入层和输出层的节点个数由训练样本的大小决定,而隐层节点数则由压缩比决定,即隐层节点数=输入(输出)层节点数/压缩比率;其次随机抽取一部分图像向量数据作为网络的训练样本,利用极限学习机训练网络,确定网络参数。

(3)图像重建。将所有图像向量数据输入训练后的网络进行压缩,并输出仿真向量,然后将仿真向量还原成图像块并合成完整的图像,即可得到根据压缩数据重建后的图像。由于极限学习机算法中,输入权值和隐层阈值是采用随机机制选取的,每次的仿真结果具有一定的偏差,在实验中可采用多次取平均的方法降低偏差。

(4)质量评价。压缩比主要用于评价图像的压缩性能,而重建图像的质量主要通过归一化均方误差和峰值信噪比来评价。归一化均方误差和峰值信噪比分别表示如下:

$$NMSE = \frac{\frac{1}{M \times N} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [f(x,y) - g(x,y)]^2}{\frac{1}{M \times N} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [f(x,y)]^2}$$

PSNR =

$$10 \times \lg \left(\frac{255^2}{\frac{1}{M \times N} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [f(x,y) - g(x,y)]^2} \right)$$

其中, $f(x,y)$, $g(x,y)$ 分别表示原图像和压缩重建后的图像。

3 实验结果

文中以 Lena 图像作为实验对象进行压缩处理,如图 2 所示。为了加快学习速度,将图像分割成 4×4 的图像块,再将每个小图像块变换成 16×1 的列向量。这样就建立了一个具有 16 个输入节点和 16 个输出节点的单隐层前向神经网络。为了充分验证所提算法在不同压缩比下的重建效果,在实验中分别考虑压缩比为 2、4、8 时的重建效果,因此隐层节点数对应分别设为 8、4、2。在实验中极限学习机的仿真结果为 50 次的平均结果(训练时间为 50 次的总时间),并与 BP 神经网络作比较。在极限学习机和 BP 神经网络这两种算法中都选 Sigmoid 函数作为隐层激活函数,且输出层中采用线性函数作为激活函数。

图 3~5 分别是压缩比为 2、4、8 时 BP 神经网络和极限学习机压缩后重建的结果。从 3 幅图中可以看出,压缩比较低(即隐层节点较多)时,压缩后重建图像的效果会较好一些。并且在不同压缩比下,极限学习机的压缩重建图像要比 BP 神经网络的压缩重建图像清晰。



图 2 原始 Lena 图像



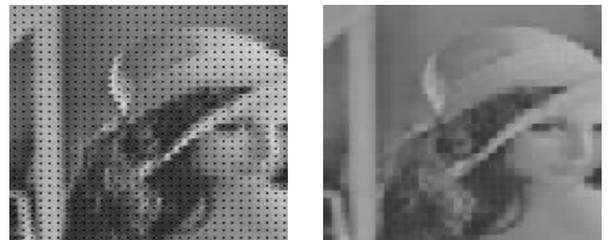
(a) BP 神经网络 (b) 极限学习机

图 3 压缩比为 2 时的重建图像



(a) BP 神经网络 (b) 极限学习机

图 4 压缩比为 4 时的重建图像



(a) BP 神经网络 (b) 极限学习机

图 5 压缩比为 8 时的重建图像

表 1 给出了两种算法的重建结果比较。从表中可以看出,通过极限学习机进行压缩重建后的图像的 NMSE 值小于 BP 神经网络压缩重建图像的 NMSE,即误差小。并且极限学习机的压缩重建图像的 PSNR 值大于 BP 神经网络压缩重建图像的 PSNR 值,特别在压缩比为 2、8 时,极限学习机的 PSNR 值明显大于 BP 神经网络的 PSNR 值。从中还可以看出,极限学习机的学习速度比 BP 神经网络快 70 多倍。

表 1 不同算法的结果比较

	BP 神经网络			极限学习机		
	训练时间	PSNR	NMSE	训练时间	PSNR	NMSE
压缩比为 2	3.857 6	28.604 1	0.004 8	0.050 7	30.553 1	0.003 5
压缩比为 4	3.685 4	25.288 3	0.011 7	0.045 4	25.858 1	0.010 3
压缩比为 8	7.593 0	17.302 2	0.073 9	0.038 7	21.827 0	0.026 1

4 结束语

文中主要利用极限学习机在学习过程中无需迭代调整隐层参数,具有学习速度快、泛化能力强等优点,提出一种基于极限学习机的图像压缩算法。与基于 BP 神经网络的图像压缩方法相比,该方法结构简单且易于实现。

实验结果表明,将极限学习机应用于图像压缩可以取得更好的图像压缩重建效果,并且具有较快的学习速度,比基于 BP 神经网络的图像压缩方法快 70 多倍。未来的研究方向在于如何在高压缩比率下,进一步提高基于极限学习机的图像压缩方法的重建效果。

参考文献:

[1] 吴乐南. 数据压缩原理与应用[M]. 北京:电子工业出版社,2003.

[2] Gonzalez R C, Woods R E. 数字图像处理[M]. 北京:电子工业出版社,2005.

[3] 许 锋,卢建刚,孙优贤. 神经网络在图像处理中的应用[J]. 信息与控制,2003,32(4):344-351.

[4] Sicuranza G L, Ramponi G, Marsi S. Artificial neural network for image compression[J]. Electronics Letters, 1990, 26(7):477-479.

[5] Mougeot M, Azencott R, Angeniol B. Image compression with back propagation: improvement of the visual restoration using different cost functions[J]. Neural Networks, 1991, 4(4):467-476.

[6] Reddy K S N, Vikram B R, Rao L K, et al. Image compression and reconstruction using a new approach by artificial neural network[J]. International Journal of Image Process-

ing, 2012, 6(2):68-85.

[7] Gaidhane V H, Singh V, Hote Y V, et al. New approaches for image compression using neural network[J]. Journal of Intelligent Learning Systems and Applications, 2011, 3(4):220-229.

[8] Seiffert U. ANNIE-artificial neural network-based image encoder[J]. Neurocomputing, 2014, 125:229-235.

[9] 张建宏. 基于混沌神经网络的图像压缩算法[J]. 煤炭技术, 2010, 29(5):167-168.

[10] 钱海军. 基于 BP 神经网络的图像压缩的 Matlab 实现[J]. 电脑开发与应用, 2011, 24(12):77-79.

[11] 张 尧,胡 骏,宋美荣,等. 神经网络在彩色图像压缩中的应用[J]. 计算机技术与发展, 2012, 22(11):9-12.

[12] 张福威,高振亮,李 军. 一种结合改进遗传算法和 BP 神经网络的图像压缩算法[J]. 长春理工大学学报:自然科学版, 2013, 36(6):136-139.

[13] Huang Guangbin, Zhu Qinyu, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1):489-501.

[14] Huang Guangbin, Chen Lei, Siew C K. Universal approximation using incremental constructive feedforward networks with random hidden nodes[J]. IEEE Trans on Neural Networks, 2006, 17(4):879-892.

[15] Zong W W, Huang G B. Face recognition based on extreme learning machine[J]. Neurocomputing, 2011, 74(16):2541-2551.

[16] Yuan Q, Zhou W D, Li S F, et al. Epileptic EEG classification based on extreme learning machine and nonlinear features[J]. Epilepsy Research, 2011, 96(1):29-38.

(上接第 12 页)

20 ms,完成了智能化、通用化、小型化的实时解码,可移植性强,易集成,取得了较好的效果。

参考文献:

[1] 张树华,窦维蓓,杨华中. MPEG-2/4 AAC 音频编码器的低复杂度优化[J]. 电声技术, 2010, 34(4):71-74.

[2] Yen C H, Lin Y S, Wu B F. A low-complexity MP3 algorithm that uses a new rate control and a fast dequantization[J]. IEEE Trans on Consumer Electronics, 2005, 51(2):571-579.

[3] 夏宇闻. Verilog 数字系统设计教程[M]. 北京:北京航空航天大学出版社, 2003:304-305.

[4] 陈树娟. MPEG-4 AAC 实时编解码系统研究[J]. 煤炭技术, 2011, 30(12):212-213.

[5] 王 婷,田 泽,许宏杰,等. MPEG-2/4 AAC 音频编码模块的验证[J]. 计算机技术与发展, 2012, 22(7):57-59.

[6] ISO/IEC 13818-7: MPEG-2 AAC, second edition[S]. [s.

l.]; ISO/IEC, 2003.

[7] ISO/IEC 14496-3: part 3: audio[S]. [s. l.]; ISO/IEC, 2004.

[8] Philips Semiconductor. I2S bus specification[S/OL]. 1996. <http://www.Semiconductor.Philips.com>.

[9] 邵富杰,张国利,周 勇. 基于 I2S 总线实现嵌入式语音采集与回放[J]. 微计算机信息, 2011, 27(6):72-74.

[10] 范飞虎. 基于 FPGA 的 MPEG-2/4 AAC 音频解码器的设计与验证[D]. 西安:西安电子科技大学, 2013.

[11] 田 靖,田 泽. AFDX-ES SoC 虚拟仿真平台的构建与应用[J]. 计算机技术与发展, 2010, 20(8):192-194.

[12] 刘 浩,田 泽. FC-AV 协议及实现方法研究[J]. 计算机技术与发展, 2012, 22(7):1-4.

[13] ISO/IEC 11172-4 information technology-coding of moving pictures and associated audio for digital storage media at up to 1.5 Mbits/s[S]. [s. l.]; ISO/IEC, 1993.

[14] 张轩磊,窦维蓓,董 明. 面向 SoC 的数字音频解码系统设计方法[J]. 电声技术, 2008, 32(8):72-76.

基于极限学习机的图像压缩算法

作者: [刘作志](#), [刘欢](#), [林耀海](#), [LIU Zuo-zhi](#), [LIU Huan](#), [LIN Yao-hai](#)
作者单位: [西安电子科技大学 电子工程学院, 陕西 西安, 710071](#)
刊名: [计算机技术与发展](#) 
英文刊名: [Computer Technology and Development](#)
年, 卷(期): 2015(5)

引用本文格式: [刘作志](#). [刘欢](#). [林耀海](#). [LIU Zuo-zhi](#). [LIU Huan](#). [LIN Yao-hai](#) 基于极限学习机的图像压缩算法[期刊论文]-[计算机技术与发展](#) 2015(5)