

FA-LMBP 混合神经网络算法在图像压缩中的应用

王海军^{1*}, 金涛¹, 门克内木乐²

¹鄂尔多斯应用技术学院数学与计算机工程系, 内蒙古 鄂尔多斯 017000;

²鄂尔多斯应用技术学院信息工程系, 内蒙古 鄂尔多斯 017000

摘要 提出基于萤火虫算法与 LM(Levenberg-Marquardt)算法相结合的 FA-LMBP 混合神经网络算法图像压缩模型。利用该模型进行求解时,通过萤火虫算法按照目标函数进行全局搜索,得到反向传播(BP)神经网络的一组权阈值最优近似解,以该近似解作为 BP 模型初值,利用 LM 算法对这组权阈值进行二次优化训练,得到最终的图像压缩模型。实验结果表明,在相同训练次数和相同误差精度下,基于 FA-LMBP 混合神经网络算法的压缩图像模型重建质量明显高于 BP 算法和 LMBP 算法模型。

关键词 图像处理; 图像压缩; 萤火虫算法; 神经网络; LMBP 算法

中图分类号 TP183; TP301.6

文献标识码 A

doi: 10.3788/LOP56.191005

Application of FA-LMBP Hybrid Neural Network Algorithm in Image Compression

Wang Haijun^{1*}, Jin Tao¹, Men Ke Neimule²

¹Department of Mathematics and Computer Engineering, Ordos Institute of Technology, Ordos, Inner Mongolia 017000, China;

²Department of Information Engineering, Ordos Institute of Technology, Ordos, Inner Mongolia 017000, China

Abstract An image compression model based on the FA-LMBP hybrid neural network algorithm is proposed by the combination of the firefly algorithm and LM (Levenberg-Marquardt) algorithm. First, a set of optimal approximate solutions of the backpropagation (BP) network weight threshold are obtained by the global search of the target function based on the firefly algorithm, then the approximate solution is used as the initial value of the BP model, and the LM algorithm is used to carry out the secondary optimization training for these weight thresholds, thereby obtaining the final image compression model. The experimental results show that the reconstruction quality of the compression image model based on the FA-LMBP hybrid neural network algorithm is obviously higher than that of the basic BP model and the LMBP model under the same training times and error accuracy.

Key words image processing; image compression; firefly algorithm; neural network; LMBP algorithm

OCIS codes 100.2980; 100.3010; 100.3020; 100.4996

1 引言

在“互联网+”时代,如何高效地压缩海量数据是数据传输和存储处理过程中面临的最基本问题,海量数据中图像数据的压缩是亟需解决的难题^[1]。目前采用的图像压缩方法主要有基于卡洛南-洛伊(K-L)变换的技术、基于矢量量化的技术和基于预

测方法的技术。其中,K-L 变换和矢量量化的计算复杂度高,实际应用困难;基于预测方法的压缩方法易实现,但可实现的压缩比有限;离散余弦变换(DCT)具有方块效应,图像压缩时质量下降明显^[2]。由此可见,这些传统压缩方法无法满足实际需要,众多学者开始探索更有效的新方法,其中尤其以采用神经网络进行图像压缩的研究最为活跃。相

收稿日期: 2019-02-27; 修回日期: 2019-04-01; 录用日期: 2019-04-22

基金项目: 国家自然科学基金(61741509,61205127,61167004)、内蒙古自治区高等学校科学研究项目(NJZY19260)

* E-mail: wanghaijun11249@126.com

比传统压缩方法,神经网络不仅具有大规模并行处理能力,而且具有良好的容错能力和联想记忆能力,因此在进行图像压缩时无需借助预先确定的压缩编码算法,完全根据图像本身携带的信息,便可自主地完成图像编码和压缩^[3]。

在众多神经网络图像压缩算法中,误差反向传播(BP)神经网络最具有代表性,目前80%以上的模型都采用BP神经网络^[4],但由于BP神经网络采用的是梯度下降算法,其对初始权阈值的随机选取,易导致模型在运行时存在陷入局部极小值、无法得到全局最优解的问题^[5-6]。为了克服该问题,通常采用改进BP算法的LM(Levenberg Marquardt)方法建模,该算法兼有 Gauss-Newton 法的局部收敛性和梯度下降法的全局收敛性,因此采用该方法建立 LMBP 模型进行图像压缩时的效率明显优于基本 BP 算法^[7]。但由于该算法的改进基础仍是梯度下降算法,因此无法从根本上解决由 BP 神经网络初始权阈值随机选取造成模型计算精度无法进一步提高的问题。已有研究表明,2008 年 Yang^[8]提出的一种新型群智能算法——萤火虫算法(FA),该算法能够很好地解决 BP 算法初始权阈值选择不当造成模型计算精度不高的问题^[9-10]。因此,本文提出萤火虫算法与 LMBP 算法相结合的 FA-LMBP 混合图像压缩算法,来提高 BP 神经网络的泛化能力和整体逼近能力,从而提高模型计算精度。实验结果证明,与基本 BP 算法和 LMBP 算法图像压缩模型相比,基于 FA-LMBP 混合算法的图像压缩模型对图像的重建效果更好。

2 FA-LMBP 算法设计

2.1 LMBP 算法引入

与基本 BP 算法利用每个样本反向计算误差信号来修正权值的计算过程不同,LM 算法利用所有样本的信息对权阈值进行修正。设 $t=(t_1, t_2, \dots, t_n)$ 为期望输出向量, $y=(y_1, y_2, \dots, y_n)$ 为实际输出向量, n 为样本个数, ϵ 为误差目标, $\mathbf{x}^{(k)}$ 为第 k 次迭代的权阈值组成的向量,误差函数值 $E[\mathbf{x}^{(k)}]$ 可表示为

$$E[\mathbf{x}^{(k)}] = \frac{1}{2} \sum_{h=1}^n (e_h)^2 = \frac{1}{2} \sum_{h=1}^n (t_h - y_h)^2, \quad (1)$$

式中: e_h 为单点期望输出与实际输出的差值; h 为样本计数变量。

如果 $E[\mathbf{x}^{(k)}] < \epsilon$ 或达到运行次数,则结束;否则,利用文献^[11]中的计算过程计算新的权阈值向量 $\mathbf{x}^{(k+1)}$ 。LM 算法可以使(1)式所示的误差函数值

$E[\mathbf{x}^{(k)}]$ 在保持较快下降速度的同时,在高斯-牛顿法与梯度下降法之间自适应调整模型权阈值,使每一次迭代不再沿着单一的负梯度方向进行,因此其优化效率高于基本 BP 算法。图 1、2 是在相同训练参数下,分别采用基本 BP 算法和 LMBP 算法构建图像压缩模型时的训练误差变化曲线,从图中可以看出, LMBP 算法的优化效率明显优于基本 BP 算法。

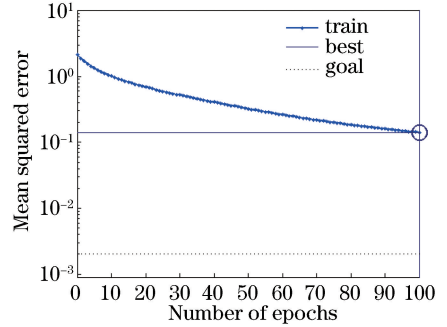


图 1 基本 BP 算法训练曲线

Fig. 1 Basic BP algorithm training curve

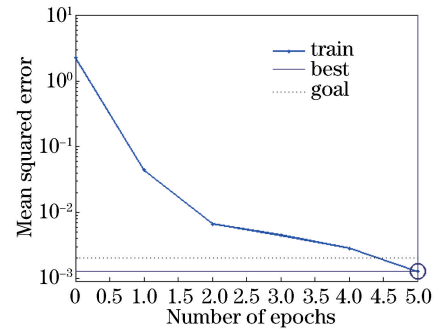


图 2 LMBP 算法训练曲线

Fig. 2 LMBP algorithm training curve

2.2 FA 算法原理

FA 是一种基于群体搜索行为的智能算法,其寻优过程模拟了自然界中萤火虫发光行为^[12]。在该算法中,萤火虫之间靠荧光亮度及其相互之间的吸引度来决定移动路径,亮度越高的萤火虫拥有越强的吸引力,在亮度与吸引度的作用下,最终亮度较低的萤火虫都会聚集在亮度较高的萤火虫周围,从而实现函数的寻优^[13]。

依据萤火虫的发光特性,将其数学描述如下^[14]。

1) 萤火虫发光亮度 I 可表示为

$$I = I_0 \times \exp(-\gamma \cdot r_{ij}), \quad (2)$$

式中: I_0 为萤火虫初始荧光亮度; γ 为光吸收系数,一般定义为 1。 r_{ij} 为萤火虫 i 与 j 在 d 维搜索空间位置 \mathbf{x}_i 和 \mathbf{x}_j 的空间距离, x_{iv} 、 x_{jv} 分别为萤火虫 i 和 j 在 d 维空间中的第 v 个分量, r_{ij} 的计算公式为

$$r_{ij} = \| \mathbf{x}_i - \mathbf{x}_j \| = \sqrt{\sum_{v=1}^d (x_{iv} - x_{jv})^2} \quad (3)$$

2) 萤火虫的吸引度 β 可表示为

$$\beta = \beta_0 \times \exp(-\gamma \cdot r_{ij}^2), \quad (4)$$

式中: β_0 表示最大荧光亮度处的吸引度。

3) 萤火虫 i 朝着比其更亮的萤火虫 j 移动的位置更新公式为

$$\mathbf{x}_{i+1} = \mathbf{x}_i + \beta_0 [\exp(-\gamma \cdot r_{ij}^2)] (\mathbf{x}_j - \mathbf{x}_i) + \alpha \zeta_i, \quad (5)$$

式中: α 为 $[0,1]$ 区间上的常数步长因子; ζ_i 为 $[0,1]$ 区间上与 \mathbf{x}_i 同维度的随机向量。

2.3 FA-LMBP 算法步骤设计

由于 FA 具有极强的全局优化能力, 将 FA 与 LMBP 算法相结合, 构建 FA-LMBP 算法流程, 如图 3 所示。经过 FA-LMBP 算法优化确定出 BP 模型权阈值参数后, 模型就可用于图像压缩, FA-LMBP 算法具体步骤如下:

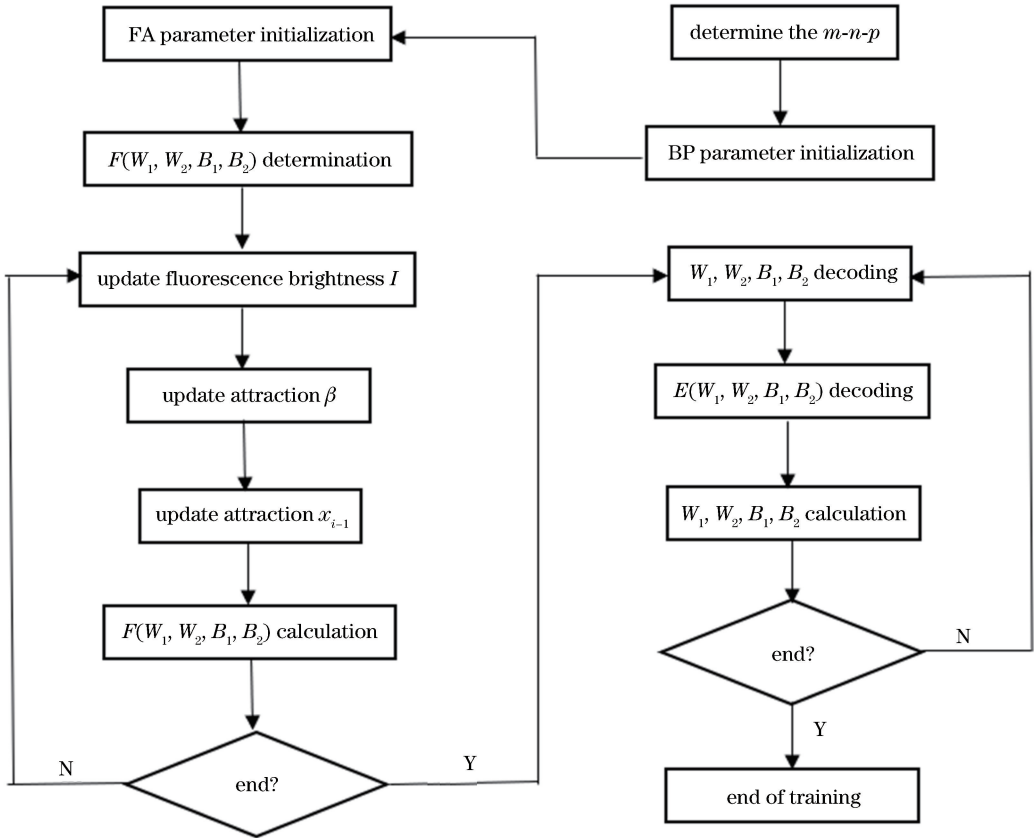


图 3 FA-LMBP 算法流程

Fig. 3 FA-LMBP algorithm flow

1) 对萤火虫所处位置采用实数编码方式进行初始化, 假设进行图像压缩采用的 BP 模型结构为 $m-n-p$ 三层结构, 则每个萤火虫位置均对应一组神经网络权值 W_1, W_2 和阈值 B_1, B_2 , 且这组参数的搜索空间维度为 $d = m \times n + n \times p + n + p$ 。同时初始化萤火虫群体数目 n_1 、初始荧光亮度 I_0 、最大吸引度 β_0 、光强吸收系数 γ 、步长因子 α 、搜索精度 ϵ_1 与最大迭代次数 T_{max} 。

2) 在萤火虫算法运行过程中不与外部进行信息交换, 仅以算法适应度函数作为评估群体中个体优劣的标准, 因此适应度函数设置恰当与否将直接影响算法的性能。本文采用 BP 模型实际输出值与

期望输出值之间的误差平方和倒数作为适应度函数, 这样可以有效地将 BP 神经网络算法与萤火虫算法的评估标准融为一体, 提高 BP 神经网络模型的性能, 故设定萤火虫算法优化 BP 神经网络权阈值的适应度函数 F 为

$$\begin{cases} F(W_1, W_2, B_1, B_2) = \\ E(W_1, W_2, B_1, B_2) = \frac{1}{N} \sum_{g=1}^N (y_g - o_g)^2, \\ \text{s.t. } W_1 \in R^{m \times p}, W_2 \in R^{p \times n}, \\ B_1 \in R^p, B_2 \in R^n \end{cases} \quad (6)$$

式中: y_g 为第 g 个样本的实际输出值; o_g 为第 g 个

样本的期望输出值; N 为训练样本个数; R 为权阈值的取值空间。利用萤火虫算法求解如(6)式所示的二次非线性优化问题,即可求得 BP 神经网络模型的最优权阈值 W_1, W_2, B_1, B_2 组合。

3) 按(2)~(4)式分别计算萤火虫 i 的亮度 I_i 、萤火虫 j 的亮度 I_j 及其相互之间的吸引度,如果 $I_i < I_j$,表示萤火虫 j 所处位置较好,吸引萤火虫 i 向自己移动,用(5)式更新位置,然后利用(6)式计算更新后位置的适应度值,进而更新全局最优值。

4) 判断是否满足停止条件 $\min[E(W_1, W_2, B_1, B_2)] < \epsilon_1$,或判断算法是否运行到最大迭代次数 T_{\max} ,若满足停止条件或算法运行到 T_{\max} ,则停止搜索,执行步骤 5);否则,返回步骤 3)继续搜索。

5) 利用 FA 优化得到的最优萤火虫个体对应的位置参数解码,得到 BP 神经网络初始权值 W_1, W_2 和阈值 B_1, B_2 ,并将其赋予基于 LMBP 算法的神经网络图像压缩模型,进行二次训练,直到计算得到的误差函数 $E(W_1, W_2, B_1, B_2) < g_{\text{opt}}$ 或达到最大运行次数 e_{pochs} ,其中 g_{opt} 表示神经网络二次训练目标。

3 参数选择

3.1 训练样本构造

设待压缩图像由 $T \times T$ 个像素点组成,为了减小输入层网络规模,将待压缩图像划分成 M 个子图像块,每个子图像块分别由 $q \times q$ 的子像素块构成,则 $T \times T$ 个像素点组成的图像可划分的子图像块数 $M = T^2 / q^2$,在进行 BP 神经网络模型训练时,每次以一个子图像块作为训练样本,依次训练,直到 M 个子图像块全部训练完成,则一幅像素点个数为 $T \times T$ 的灰度图像也训练完成。将 128 pixel \times 128 pixel 的图像划分为 4×4 子像素块图像的方法可表示为

$$\begin{bmatrix} [1]_{4 \times 4} & [2]_{4 \times 4} & \cdots & [32]_{4 \times 4} \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ [993]_{4 \times 4} & [994]_{4 \times 4} & \cdots & [1024]_{4 \times 4} \end{bmatrix}_{32 \times 32} \Rightarrow \begin{bmatrix} [1]_{4 \times 4} & [2]_{4 \times 4} & \cdots & [1024]_{4 \times 4} \end{bmatrix} \quad (7)$$

由上述方法生成子图像块向量后还必须进行归一化处理,此处采用的是均值分布处理方法;设待处理图像的灰度范围为 $[x_{\min}, x_{\max}]$,变换域为 $[y_{\min}, y_{\max}]$,令当前待处理的像素灰度为 x_{value} ,则处理后的像素点 y_{value} 可表示为

$$y_{\text{value}} = (y_{\max} - y_{\min})(x_{\text{value}} - x_{\min}) / (x_{\max} - x_{\min}) + x_{\min} \quad (8)$$

原始图像数据矩阵,图 5 为归一化转换后的部分样本矩阵。

I <128x128 uint8>					
	1	2	3	4	5
1	162	161	162	158	158
2	160	160	160	156	156
3	157	156	158	156	156
4	157	157	157	157	157
5	157	156	157	157	157
6	155	156	158	158	158
7	154	156	159	158	158
8	158	158	159	159	159

图 4 128 pixel \times 128 pixel 的 Lena 原图数据矩阵
Fig. 4 Data matrix of 128 pixel \times 128 pixel Lena original image

P <16x1024 double>					
	1	2	3	4	5
1	0.6353	0.6196	0.6157	0.6706	0.3686
2	0.6275	0.6118	0.6078	0.6706	0.3686
3	0.6157	0.6118	0.6118	0.6667	0.3608
4	0.6157	0.6157	0.6314	0.6549	0.3647
5	0.6314	0.6118	0.6392	0.6431	0.3765
6	0.6275	0.6039	0.6314	0.6392	0.3647
7	0.6118	0.6078	0.6431	0.6275	0.3569
8	0.6157	0.6078	0.6549	0.6157	0.3569

图 5 归一化转换后的部分样本矩阵
Fig. 5 Normalized partial sample matrix

从图 4、5 可以看出,采用分块方式对原始数据进行转换后,网络输入由 128 降为 16,网络结构大大简化,网络复杂度降低,从而为 BP 神经网络有效进行图像压缩提供了可行性和便利性。

3.2 BP 神经网络结构参数确定

采用 BP 神经网络进行图像压缩的基本思想是将一组输入模式通过隐含层映射到一组输出模式,且输出模式尽可能与输入模式相等。当隐含层结点数少于输入层时,意味着隐含层能有效地表示输入模式,并将其传送到输出层。在这一过程中,可将输入层与隐含层的变换看成图像压缩编码过程;而隐含层与输出层的变换可以看成解码重建图像过程^[15]。因此,BP 图像压缩模型输入层结点数 P_{in} 与输出层结点数 P_{out} 相等,即 $P_{\text{in}} = P_{\text{out}} = 16$ 。在进行图像压缩时,BP 神经网络用于图像编码的压缩比 K 与输入层结点数 P_{in} 、隐含层结点数 P_{hide} 有关,其具体计算公式^[16]为

$$K = P_{\text{in}} / P_{\text{hide}} \quad (9)$$

因此, P_{hide} 取值不同就可以实现 BP 神经网络图像压缩模型对同一图像的不同压缩比,当确定了压缩模型的层数、各层结点数和权阈值参数之后,需要确定的就是隐含层激活函数与输出层激活函数,根据压缩模型输入、输出数据的特点,在隐含层与输出层分别采用 tansig 函数和 purelin 函数,图 6 所示

图 4 为 128 pixel \times 128 pixel 像素图像的部分




图 6 压缩模型中采用的 BP 模型结构

Fig. 6 BP model structure used in compression model

为压缩比 $K=2$ 即 $P_{\text{hide}}=8$ 时的压缩模型中所采用的 BP 神经网络模型结构,图中 w 、 b 分别表示 BP 神经网络图像压缩模型的权值和阈值。

4 实验分析

为了验证 FA-LMBP 算法在图像压缩研究中的有效性,建立压缩比 $K=2$ 的图像压缩模型,同时构建基于 BP、LMBP 和 FA-LMBP 算法的图像压缩模

型,这 3 种算法的训练次数相同,建模精度一致。采用 $128 \text{ pixel} \times 128 \text{ pixel}$ 的 Lena 图作为训练、测试图像。图 7 显示的是压缩比 $K=2$ 时的 BP、LMBP 和 FA-LMBP 算法对 Lena 图的重建图像,从图中可以看出,基于 BP 算法的重建图像存在失真现象,图像无法辨别,而采用 LMBP 与 FA-LMBP 算法进行图像重建的效果比较理想。因为 Lena 图是模型的训练数据,所以无法确认模型对陌生图像的重建效果如何。为了进一步验证模型的有效性,分别采用 $128 \text{ pixel} \times 128 \text{ pixel}$ 的 Cameraman 图和 Brain 图对 BP、LMBP 和 FA-LMBP 算法模型进行图像压缩测试,图 8、9 显示的分别是不同 BP 算法对两张陌生图像的重建效果对比图,从图 8、9 可以得出与图 7 相同的结论,即采用 LMBP、FA-LMBP 算法进行图像重建的效果明显优于 BP 算法。




图 7 $K=2$ 时不同 BP 算法对于 Lena 训练图像的解压缩重建效果对比图。(a)原始图像;(b) BP 重建图像;
(c) LMBP 重建图像;(d) FA-LMBP 重建图像

Fig. 7 Comparison of decompression and reconstruction effects of different BP algorithms for Lena training images when $K=2$.

(a) Original image; (b) BP reconstruction image; (c) LMBP reconstruction image; (d) FA-LMBP reconstruction image




图 8 $K=2$ 时不同 BP 算法对于 Cameraman 测试图像的解压缩重建效果对比图。(a)原始图像;(b) BP 重建图像;
(c) LMBP 重建图像;(d) FA-LMBP 重建图像

Fig. 8 Comparison of decompression and reconstruction effects of different BP algorithms for Cameraman testing images when $K=2$. (a) Original image; (b) BP reconstruction image; (c) LMBP reconstruction image; (d) FA-LMBP reconstruction image




图 9 $K=2$ 时不同 BP 算法对于 Brain 测试图像的解压缩重建效果对比图。(a)原始图像;(b) BP 重建图像;
(c) LMBP 重建图像;(d) FA-LMBP 重建图像

Fig. 9 Comparison of decompression and reconstruction effects of different BP algorithms for Brain testing images when $K=2$.

(a) Original image; (b) BP reconstruction image; (c) LMBP reconstruction image; (d) FA-LMBP reconstruction image

进行直观比较后,采用结构相似度(SSIM)函数和峰值信噪比(PSNR)函数对图像重建质量进行进一步比较,SSIM值、PSNR值越大,表示重建图像与原图越接近,重建效果越好。表1给出了 $K=2$ 时基于3种算法的10次运算的平均SSIM值与PSNR值。对于基于BP算法的图像压缩模型,初始权阈值的随机性导致模型无法得到全局最优权阈值参数,模型整体计算精度不高,因此输出的重建图像与原图的相似度差别很大,重建图像基本不可用。采用LMBP算法构建重建模型时,对于训练图像,其重建图像的SSIM值、PSNR值与FA-LMBP算

法差别不大,效果都很好;而对于测试图像,由于LMBP算法模型权阈值无法取得像FA-LMBP算法模型那样的全局最优解,因此无论是SSIM值还是PSNR值均明显小于FA-LMBP算法模型。由此可以得出基于FA-LMBP算法的图像压缩模型的压缩效率优于LMBP算法和BP算法模型的结论。进一步对压缩比 $K=4$ 时3种算法模型的运行效率进行对比,表2给出了基于3种算法的10次运算的平均SSIM值和PSNR值,从表中可以得出与表1相同的结论,即采用FA-LMBP算法建立的压缩模型的图像重建效果明显优于BP和LMBP算法。

表1 $K=2$ 时基于不同算法的压缩模型重建图像评价Table 1 Reconstruction image evaluation of compression models based on different algorithms when $K=2$

Algorithm	Lena		Cameraman		Brain	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
BP	10.1538	0.0423	9.3761	0.0356	7.0835	0.0243
LMBP	28.059	0.8635	25.0034	0.7565	22.7934	0.7541
FA-LMBP	28.529	0.8829	26.7053	0.8069	24.7611	0.8148

表2 $K=4$ 时基于不同算法的压缩模型重建图像评价Table 2 Reconstruction image evaluation of compression models based on different algorithms when $K=4$

Algorithm	Lena		Cameraman		Brain	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
BP	9.8599	0.0373	9.1789	0.0261	7.1521	0.0208
LMBP	27.2878	0.8627	24.5302	0.7685	22.4939	0.711
FA-LMBP	27.3633	0.8638	25.4525	0.8124	23.3201	0.8193

5 结 论

首次将萤火虫算法与改进BP算法相结合,建立FA-LMBP混合神经网络算法,并将其应用到图像压缩研究中,利用萤火虫算法来指导BP神经网络初始权阈值的选取,然后采用改进的LMBP算法对神经网络权阈值进行二次训练,这样构建的模型可以有效地减少BP神经网络因初始权阈值选取不当而造成的模型计算精度不高的问题。实验结果表明,与基于BP和LMBP算法建立的图像压缩模型相比,基于FA-LMBP混合算法的图像压缩模型在压缩效率上明显更优,压缩后的解码图像重建质量更好。同时本文研究也可以进一步拓宽萤火虫神经网络模型的应用领域,为图像压缩提供一种新的研究思路。

参 考 文 献

- [1] Rahali M, Loukil H, Bouhleb M S. New image compression method using logarithmic quantization [C] // 2016 7th International Conference on Sciences

of Electronics, Technologies of Information and Telecommunications (SETIT), December 18-20, 2016, Hammamet, Tunisia. New York: IEEE, 2016: 432-436.

- [2] Yan H M, Wu D M. Application of improved BP neural network in hyper-spectral image compression [J]. Journal of Graphics, 2013, 34(5): 110-114.
闫红梅, 吴冬梅. 改进BP网络在超光谱图像压缩中的应用[J]. 图学学报, 2013, 34(5): 110-114.
- [3] Anjana B, Shreeja R. Image compression using artificial neural network [C] // Fourth International Conference on Advances in Recent Technologies in Communication and Computing (ARTCom2012), October 19-20, 2012, Bangalore, India. UK: IET, 2012: 288-290.
- [4] Hu Y, Li Z H, Lü T. Quantitative measurement of iron content in geological standard samples by laser-induced breakdown spectroscopy combined with artificial neural network [J]. Laser & Optoelectronics Progress, 2017, 54(5): 053003.

胡杨, 李子涵, 吕涛. 激光诱导击穿光谱结合人工神经网络测定地质标样中的铁含量[J]. 激光与光电子

- 学进展, 2017, 54(5): 053003.
- [5] Xu Z M, Zhou J Z, Huang S, *et al.* Quality prediction of laser milling based on optimized back propagation networks by genetic algorithms [J]. Chinese Journal of Lasers, 2013, 40(6): 0603004.
许兆美, 周建忠, 黄舒, 等. 基于遗传算法优化反向传播神经网络的激光铣削层质量预测[J]. 中国激光, 2013, 40(6): 0603004.
- [6] Sun S Q, Chu F H. Temperature compensation of fiber Bragg grating current sensor based on optimized neural network algorithm [J]. Acta Optica Sinica, 2017, 37(10): 1006001.
孙诗晴, 初凤红. 基于优化神经网络算法的光纤布拉格光栅电流传感器的温度补偿[J]. 光学学报, 2017, 37(10): 1006001.
- [7] Henn S. A Levenberg-Marquardt scheme for nonlinear image registration [J]. BIT Numerical Mathematics, 2003, 43(4): 743-759.
- [8] Yang X S. Nature-inspired metaheuristic algorithms [M]. 2th ed. Beckington: Luniver Press, 2008.
- [9] Weng S L, Shan W P, He G L. Bearing fault diagnosis based on FA-BP neural network [J]. Electronic Design Engineering, 2014, 22(24): 4-7.
翁胜龙, 单外平, 何国林. 基于萤火虫 BP 神经网络的轴承故障诊断研究[J]. 电子设计工程, 2014, 22(24): 4-7.
- [10] Li M T, Ji X F, Zhang J, *et al.* FA-BP neural network-based forecast for railway passenger volume [J]. Applied Mechanics and Materials, 2014, 641/642: 673-677.
- [11] Xu J, He Z, Yuan R. A optimization method for non-linear profile based LM-BP neural networks [J]. China Mechanical Engineering, 2016, 27(20): 2749-2753, 2758.
许静, 何桢, 袁荣. 基于 LM-BP 神经网络的非线性轮廓图优化方法研究[J]. 中国机械工程, 2016, 27(20): 2749-2753, 2758.
- [12] Yang X S. Firefly algorithms for multimodal optimization [M] // Watanabe O, Zeugmann T. Stochastic algorithms: foundations and applications. SAGA 2009. Lecture notes in computer science. 2009, 5792: 169-178.
- [13] Senthilnath J, Omkar S N, Mani V. Clustering using firefly algorithm: performance study [J]. Swarm and Evolutionary Computation, 2011, 1(3): 164-171.
- [14] Feng H, Luo L, Wang Y, *et al.* Path planning in wireless sensor networks for mobile sink based on glowworm swarm optimization algorithm [J]. Microelectronics & Computer, 2016, 33(5): 47-51.
俸皓, 罗蕾, 王勇, 等. 基于萤火虫算法的无线传感器网络移动 sink 节点路径规划方法[J]. 微电子学与计算机, 2016, 33(5): 47-51.
- [15] Wang S F, Li G L. Application of a BP neural network based on genetic algorithm in image compression [J]. Chinese Journal of Quantum Electronics, 2007, 24(4): 425-428.
王世芳, 李国丽. 基于遗传算法的 BP 神经网络在图像压缩中的应用[J]. 量子电子学报, 2007, 24(4): 425-428.
- [16] Xiong X L, Yang G L, Duan X H. Image compression of BP neural network with SPIHT algorithm [J]. Journal of Electronic Measurement and Instrument, 2008, 22(6): 7-11.
熊校良, 杨光临, 段晓辉. SPIHT 算法对 BP 神经网络图像压缩处理的改善[J]. 电子测量与仪器学报, 2008, 22(6): 7-11.