

王小伟, 高明, 孙希霞. 基于混合 TLBO-DE 算法的图像去噪卷积神经网络[J]. 智能计算机与应用, 2024, 14(8): 102-108.
DOI:10.20169/j.issn.2095-2163.240817

基于混合 TLBO-DE 算法的图像去噪卷积神经网络

王小伟, 高明, 孙希霞

(南京邮电大学 物联网学院, 南京 210003)

摘要: 针对用于图像去噪的卷积神经网络 (Convolutional Neural Networks, CNN) 的超参数与结构难以确定的问题, 本文提出了一种基于混合教与学优化算法 (Teaching-Learning-Based Optimization, TLBO) 和差分进化算法 (Differential Evolution, DE) 的 CNN 网络并应用于图像去噪。首先, 建立了 CNN 超参数与结构优化的数学模型; 其次, 提出了一种混合 TLBO-DE 算法, 并将其用于去噪 CNN 超参数与结构的优化。在该混合 TLBO-DE 算法的进化前期, 种群以较大的概率采用 DE 算法的进化机制进行进化, 从而提高种群多样性; 在进化后期, 种群以较大的概率采用 TLBO 算法的“教”机制进行进化, 从而提高算法收敛速度; 最后, 在公共的医学图像数据集上对所提方法进行测试。实验结果表明, 与基于遗传算法、DE 和 TLBO 等算法的 CNN 去噪方法相比, 本文所提方法具有更好的优化性能和图像去噪性能。与目前去噪性能较好的块匹配滤波 (Block-Matching and 3D filtering, BM3D)、去噪卷积神经网络 (Denoising Convolutional Neural Network, DnCNN) 方法相比, 本文所提方法具有更好的去噪性能。

关键词: 卷积神经网络; 图像去噪; 教与学优化算法; 差分进化算法; 遗传算法

中图分类号: TP183

文献标志码: A

文章编号: 2095-2163(2024)08-0102-07

Image denoising convolutional neural network based on hybrid TLBO-DE algorithm

WANG Xiaowei, GAO Ming, SUN Xixia

(School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: Considering the problem that the hyper-parameters and structure of convolutional neural networks (CNN) for image denoising are difficult to determine, a hyper-parameter and structure optimization method of CNN network based on hybrid teaching-learning-based optimization (TLBO) algorithm and differential evolution (DE) algorithm is proposed. First, a mathematical model of the hyper-parameter and structure optimization of CNN network for image denoising is established. Then, an hybrid TLBO-DE algorithm is proposed, and it is adopted to optimize the hyper-parameters and structure of the CNN for image denoising. In the early stage of the evolution process of the hybrid TLBO-DE algorithm, the population evolves based on the evolution mechanism of the DE algorithm with a large probability, thereby increasing the diversity of the population. In the late stage of evolution process, the population evolves based on the teaching mechanism of the TLBO algorithm with a large probability, thereby increasing the convergence speed of the algorithm. Finally, the proposed method is tested on a public medical image dataset. Experimental results show that the proposed method has better optimization and image denoising performances than the image denoising methods based on CNN optimized by the genetic algorithm, DE and TLBO algorithms. Compared with the image denoising methods based on block-matching and 3D filtering (BM3D) and denoising convolutional neural network (DnCNN) with good denoising performance at present, the proposed method has better denoising performanc.

Key words: convolutional neural networks; image denoising; teaching-learning-based optimization; differential evolution algorithm; genetic algorithm

0 引言

在医疗系统中, 医学图像在各种疾病的诊断和治疗方面发挥着不可替代的作用。然而, 医学图像

中往往含有复杂的噪声。所以, 在对医学图像进行处理前要进行去噪处理, 去除不必要的干扰信号, 提高图像的质量。

传统的图像去噪方式可分为空间域滤波和变换

基金项目: 国家自然科学基金面上项目 (62071244)。

作者简介: 王小伟 (1998-), 男, 硕士研究生, 主要研究方向: 优化算法; 高明 (1997-), 男, 硕士研究生, 主要研究方向: 优化算法和深度学习。

通讯作者: 孙希霞 (1988-), 女, 博士, 讲师, 主要研究方向: 计算机视觉与机器学习。Email: sxx1017@njupt.edu.cn

收稿日期: 2023-04-27

哈尔滨工业大学主办 ◆ 专题设计与应用

域滤波两类。空间域滤波算法有邻域平均法、中值滤波、低通滤波等^[1]。变换域滤波算法有傅里叶变换、沃尔什-哈达玛变换、余弦变换、K-L 变换以及小波变换等^[2]。随着深度学习技术的不断发展,深度神经网络因其适应性强等优点成为目前主流的图像去噪方法,典型的图像去噪深度神经网络有卷积神经网络(Convolutional Neural Networks, CNN)、生成对抗网络及循环神经网络等^[3-4]。

CNN 是目前最流行、研究最广的深度神经网络之一。Lecun^[4]在 1998 年首次提出基于梯度学习的 CNN LeNet^[5],并将其成功用于手写数字字符识别。此后,学者们对 CNN 进行不断地改进,He 等提出了 ResNet 结构^[6],在网络结构上增加了残差模块用于解决网络过深引起的退化问题。

虽然 CNN 在图像处理领域有着独特的优越性,但 CNN 的超参数与结构通常是基于经验知识和大量的实验设置的,需要尝试超参数与结构的指数组合。寻找合适的参数设置方式需要花费大量的时间和精力,超参数与网络结构的设置在本质上为优化问题。按照搜索方式的不同,优化算法可以划分为确定性算法和随机性算法。确定性算法有梯度下降法、牛顿法、Frank-Wolfe 算法等;与传统的确定性算法相比,随机性算法更加适合于复杂优化问题的求解。

作为一类新型的随机性算法,进化算法具有自组织、自适应、自学习的特性,能够不受问题性质的限制,有效地处理传统优化算法难以解决的复杂问题^[7-8]。越来越多的学者使用进化算法优化神经网络的超参数与结构^[7-10],Liu 等应用候选超参数集对超参数进行初始化,应用遗传(Gene Algorithm, GA)算法对超参数进行优化^[9]。但 GA 的交叉及变异算子往往是根据经验选取的,各种算子均有优缺点和适用场景,难以选取最优算子。此外,GA 不能及时利用种群的反馈信息,导致算法的搜索速度较慢。Rajesh 等^[10]采用差分进化(Differential Evolution, DE)算法对 CNN 的超参数与结构进行优化。尽管 DE 算法具有鲁棒性强、收敛速度快、全局搜索能力强等特点,但仍存在搜索易停滞等不足。

教与学优化(Teaching - Learning - Based Optimization, TLBO)算法是 Rao 等于 2010 年提出的一种较新的进化算法^[11]。TLBO 算法具有收敛速度快、所需参数少等优点。现有研究表明,与粒子群、DE 和 GA 等其他众所周知的进化算法相比,该算法具有更强的优化性能^[12]。

TLBO 算法自提出以来,众多学者对其进行了

研究和改进。改进机制主要围绕种群初始化方法、学习因子及混合算法等方面。Tang 等提出了一种混合 TLBO 算法,通过引入三层编码器和多种群初始化策略解决分布式柔性车间调度问题^[13];Kaveh 等将 TLBO 的“教”阶段与量子计算相结合,通过定义量子“教”阶段预测优化算法最优解可能的位置,有效地提高了 TLBO 算法的稳定性和鲁棒性^[14];Tsai 等在“教”阶段引入 8 种新的变异策略,在“学”阶段引入 4 种新的变异策略,以增强 TLBO 算法的搜索能力^[15]。目前,TLBO 算法在车间调度等领域有着十分广泛的应用^[16]。但鲜有研究将 TLBO 算法应用于 CNN 超参数与结构的优化。此外,传统 TLBO 算法及其相关改进算法仍存在容易陷入局部极值等缺点。因此,如何对 TLBO 算法进行改进并将其应用于 CNN 超参数与结构的优化需要进一步研究。

本文提出了一种混合 TLBO-DE 算法,并将其融合入 CNN 网络,应用于医学图像去噪。首先,建立了 CNN 超参数与结构优化的数学模型;其次,设计了一种混合 TLBO-DE 算法,用于优化去噪 CNN 的超参数与结构。TLBO 算法具有较强的局部搜索能力,但容易陷入局部极值,因此本文将 DE 算法引入到 TLBO 中,以提高 TLBO 算法的全局搜索能力。实验结果表明,与基于 GA、DE 和 TLBO 等算法的去噪 CNN 及目前去噪性能较好的块匹配滤波(Block-Matching and 3D filtering, BM3D)、去噪卷积神经网络(Denoising Convolutional Neural Network, DnCNN)相比,本文所提网络具有更好的去噪性能。

1 CNN 超参数与结构优化模型

传统的图像去噪 CNN 网络如图 1 所示。去噪 CNN 是由多个卷积层、激活函数层以及批归一化层连接而成。卷积层的主要作用为提取图像特征;激活函数的作用为引入非线性映射,让网络能够学习更为复杂的数据;批归一层的作用是将数据的分布转换为均值为 0、方差为 1 的正态分布,加快网络的训练和收敛速度。




图 1 图像去噪 CNN 示意图

Fig. 1 Schematic diagram of an image denoising CNN

在本文中,CNN去噪网络由多个残差网络块或者密集网络块串联而成。残差网络和密集网络在结构上具有相似性但又各自具有不同的特性如图2所示。残差网络块和密集网络块中包含基本的卷积层、激活函数层以及批归一化层,残差网络块结构如图2(a)所示。残差网络可以在保留深层网络深度的同时保留浅层网络特征优势,避免网络退化问题。密集网络块结构如图2(b)所示,通过直接级联来自不同层的特征图可以实现特征重用,以此提升效率^[17]。




图2 残差网络块与密集网络块示意图

Fig. 2 Schematic diagram of residual network blocks versus dense network blocks

构成CNN的最为关键的超参数^[18]分别为:网络块的类型(Type Of Block, TOB)、网络块的个数(Number Of Blocks, NOB)、卷积层层数(Number of Conv layers, NOC)、卷积核大小(Filter Size, FS)、卷积核个数(Number Of Filters, NOF)、激活函数(Activation, ACT)、优化器(Optimizer, OPT)、批归一化处理(Batch Normalization, BN)、学习率(Learning Rate, LR)、损失函数(Loss Function, LF)、批量大小(Batch Size, BS)。学习率控制网络模型的学习进度^[19];损失函数计算预测数值与真实数值的差异,即损失值^[20];批量大小为一次训练所抓取的数据样本

数量。利用11维的向量[TOB, NOB, NOC, FS, NOF, ACT, OPT, BN, LR, LF, BS]可以完整地表示一个CNN去噪网络,如图3所示。




图3 实例向量表示的具体网络

Fig. 3 Specific network represented by the instance vector

去噪CNN的11个超参数的类型、范围及参数的下标表示见表1。根据表1,可以将一个网络块类型为Residual即TOB[0]、网络块个数为2即NOB[0]、卷积层层数为1即NOC[0]、卷积核大小为 3×3 即FS[0]、卷积核个数为8即NOF[0]、激活函数为ReLU即ACT[0]、优化器为Adam即OPT[0]、批归一化处理为True即BN[1]、学习率为0.1即LR[0]、损失函数为(Mean Absolute Error, MAE)即LF[0]、批量大小为8即BS[0]的网络结构用一个11维的实例向量 $P = [0, 0, 0, 0, 0, 0, 1, 0, 0, 0]$ 表示。例如,图3所表示的去噪CNN由两个残差网络块组成。残差网络块由8层卷积层、激活函数层以及批归一化层组成,其中卷积核的大小为 3×3 。所以,每个网络都可以由[TOB, NOB, NOC, FS, NOF, ACT, OPT, BN, LR, LF, BS]这种形式的向量表示。

表1 超参数的类型、范围及参数的下标表示

Table 1 Type, scope, and subscript representation of the hyperparameters

| 超参数 | 超参数的选择范围 | 下标表示 |
|--------|--------------------------------------|------------------------|
| 网络结构类型 | Residual, Dense | TOB=[0, 1] |
| 网络块个数 | 2, 3, 4, 5, 6, 7 | NOB=[0, 1, 2, 3, 4, 5] |
| 卷积层层数 | 1, 2, 3, 4 | NOC=[0, 1, 2, 3] |
| 卷积核大小 | $3 \times 3, 5 \times 5, 7 \times 7$ | FS=[0, 1, 2] |
| 卷积核个数 | 8, 16, 32, 64, 128 | NOF=[0, 1, 2, 3, 4] |
| 激活函数 | ReLU, Tanh, Leaky ReLU | ACT=[0, 1, 2] |
| 优化器 | Adam, Adadelta, Adamax, SGD, Adagrad | OPT=[0, 1, 2, 3, 4] |
| 批归一化处理 | False, True | BN=[0, 1] |
| 学习率 | 0.1, 0.01, 0.001 | LR=[0, 1, 2] |
| 损失函数 | MAE, MSE | LF=[0, 1] |
| 批量大小 | 8, 16, 32, 64, 96 | BS=[0, 1, 2, 3, 4] |

2 基于混合 TLBO-DE 的去噪 CNN 超参数与结构的优化

2.1 TLBO 算法

构建具有最佳去噪能力的 CNN 网络本质上为寻找最佳 CNN 超参数与结构的组合, 即从给定超参数与结构取值空间中寻找最优解, 所以 CNN 超参数与结构的设置在本质上为最优化问题^[21]。

TLBO 算法作为一种较新的进化算法, 与 DE 和 GA 等进化算法相比, 具有参数少、求解速度快和精度高等优点^[12]。TLBO 算法通过模拟人类在学习过程中的“教”和“学”两个阶段的学习方法, 提高群体中个体的能力。然而, TLBO 算法的全局搜索能力有限, 容易陷入局部极值^[14]。

为进一步提高 TLBO 算法的全局搜索能力, 本文将 DE 引入 TLBO 算法, 提出了一种混合 TLBO-DE 算法, 用于 CNN 超参数与结构的优化。在该算法的进化前期, 种群以较大的概率采用 DE 算法的进化机制进行全局搜索; 在进化后期, 种群以较大的概率采用 TLBO 的“教”阶段进行进化, 从而提高进化后期的收敛速度。

2.2 混合 TLBO-DE 算法

混合 TLBO-DE 算法基本流程如图 4 所示。首先, 基于精细向量参数集 θ_d 随机生成个体 $P_i = (P_{i,1}, P_{i,2}, \dots, P_{i,d}) (i = 1, 2, \dots, N)$, 每个个体的适应度值设置为该个体对应的 CNN 用训练集进行训练后获得的所有去噪图像与干净图像的峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 值的均值。

为平衡全局搜索和局部搜索, 种群在进化过程中分别以概率 $\omega = t/T$ 和 $1 - \omega$ 采用 TLBO 算法的“教”和 DE 算法的进化机制进行进化, t 和 T 分别表示当前进化代数和最大进化代数。当种群选择 DE 算法的进化机制进化时, 个体的更新机制为: 首先, 从种群中随机选出 3 个与当前个体 $P_i (i = 1, 2, \dots, NP)$ 不同的 3 个个体 P_{i1}, P_{i2}, P_{i3} 。通过 P_{i1}, P_{i2}, P_{i3} 和常数因子 F 产生一个全新的个体 $V_i (i = 1, 2, \dots, NP)$, 如公式(1)所示:

$$V_i = P_{i1} + F \times (P_{i2} - P_{i3}) \quad (1)$$

其次, 利用 P_i 和 V_i 生成个体 U_i , 如公式(2)所示:

$$U_{i,j} = \begin{cases} P_{i,j}, & Rv \leq Cr \text{ 或 } j = \bar{j}, \bar{j} = 1, 2, \dots, d \\ V_{i,j}, & \text{otherwise} \end{cases} \quad (2)$$

其中, d 为 P_i 的维度; Rv 为 0 和 1 之间的随机

数; Cr 为交叉概率, 用来控制由 V_i 生成 U_i 的概率; \bar{j} 为随机生成的索引。

如果 U_i 的适应度值大于 P_i 的适应度值, 即 $f(U_i) > f(P_i)$, 则用 U_i 更新 P_i ; 否则, 不更新 P_i 。根据此方法, 更新种群中的每个个体。

当种群选择 TLBO 算法的“教”机制进行优化时, 个体的更新机制为: 首先从种群中选出最优个体 P_t , 然后利用公式(3)计算种群 P 的均值向量 $Mean$:

$$Mean = \frac{1}{NP} \sum_{i=1}^{NP} P_i \quad (3)$$

对于群体中的个体 $P_i (i = 1, 2, \dots, NP)$, 利用公式(4)得到新个体 P_{new} :

$$P_{new} = P_i + TF \times (P_i - \text{round}(1 + TF) \times Mean) \quad (4)$$

其中, TF 用于控制教学机制的参数, 其大小由随机函数 $TF = \text{round}[1 + \text{rand}(0, 1)]$ 控制。

如果新个体 P_{new} 的适应度值大于原个体 P_i 的适应度值, 即 $f(P_{new}) > f(P_i)$, 则用 P_{new} 更新 P_i ; 否则, 不更新 P_i 。根据此方法, 更新整个种群。

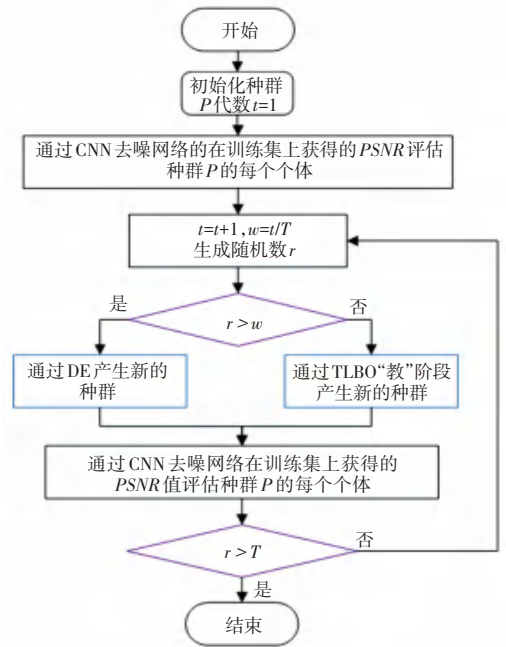


图 4 混合 TLBO-DE 算法的流程

Fig. 4 Flowchart of hybrid TLBO-DE algorithm

3 实验结果与分析

3.1 数据集及参数设置

采用公开可用的医学图像数据集 MRI 对所提基于混合 TLBO-DE 算法的去噪 CNN 进行训练、测

试和验证, MRI 数据集由1 250张像素大小为 256×256 的图像组成, 60% 设置为训练集、20% 为测试集、20% 为验证集。由于实际医学图像中噪声的产生方式过于复杂, 所以用标准偏差 $\sigma = 20$ 的高斯噪声模拟医学图像中的噪声。

本文实验运行环境为 Ubuntu 20.04.3 LTS 操作系统, CPU 为 Intel(R) Xeon(R) Silver 4214 CPU @ 2.20 GHz, 内存为 32 G RAM, 显卡为 NVIDIA Corporation GeForce RTX 2080 Ti, 算法使用 TensorFlow 框架在 Visual Studio Code 软件上运行 10 小时。

为验证所提基于混合 TLBO-DE 算法的去噪 CNN 的性能, 将其与基于 GA、DE、TLBO 的去噪 CNN 及去噪性能较好的 BM3D、DnCNN 进行对比实验。基本参数设置如下: 种群大小 NP 设置为 20, 进化代数 T 设置为 10。初始精细基因集 θ_d 设置: 网络块的类型为 [Redisual, Dense]、网络块个数为 [3, 4, 5]、卷积层层数为 [2, 3]、卷积核大小为 [3×3, 5×5]、卷积核个数为 [16, 32, 64]、激活函数为 [ReLU, Tanh]、优化器为 [Adagrad, Adam, SGD]、批归一化处理为 [False, True]、学习率为 [0.1, 0.01]、损失函数为 [MSE, MAE]、批量大小为 [16, 32]。GA 的保留率设置为 0.4, 交叉率设置为 0.3, 变异率设置为 0.1^[9]。DE 的交叉率 Cr 设置为 0.7, 常数 F 设置为 0.5^[10]。BM3D 和 DnCNN 采用公开代码, 参数设置与原文保持一致。鉴于进化算法的随机性, 基于 TLBO-DE、TLBO、DE 及 GA 的去噪 CNN 分别在 MRI 数据集上独立运行 10 次。

3.2 评价指标

峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 是一种衡量图像质量的指标。本文将单个去噪 CNN 的适应度值定义为该网络在训练集上训练结束后获得的所有去噪图像与干净图像的 PSNR 值的均值。峰值信噪比的计算方法如公式 (5) 所示:

$$PSNR = 10 \times \log_{10} \left(\frac{(2^n - 1)^2}{MSE} \right) \quad (5)$$

其中, MSE 为原始图像与去噪后的图像之间的均方误差。

PSNR 取值范围为 20~40 dB, PSNR 值越大, 图片质量越好。

结构相似性 (Structural Similarity, SSIM) 分别从亮度、对比度、结构三方面度量图像相似性。均值作为亮度的估计, 标准差作为对比度的估计, 协方

差作为结构相似程度的度量。SSIM 取值范围 [0, 1], 值越大, 表示图像失真越小, 越相似。SSIM 的计算方法如公式 (6) 所示:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (6)$$

其中, C_1 和 C_2 为常数; μ_x 和 μ_y 分别为图像 x 和 y 的均值; σ_x 和 σ_y 分别为图像 x 和 y 的方差; σ_{xy} 为图像 x 和 y 的协方差。

3.3 实验结果对比分析

为了验证本文所提出的基于 TLBO-DE 的去噪 CNN 的性能, 与基于 GA、DE、TLBO 的去噪 CNN 及 BM3D 和 DnCNN 进行性能对比, 从主观和客观两个角度对实验结果进行评价。

为了客观地评估网络的去噪质量, 本文实验使用 PSNR 和 SSIM 对 6 种不同的去噪网络进行评价。

由于每种网络在训练集、验证集和测试集上获得的 PSNR 和 SSIM 较为一致, 所以本文仅展示 6 种网络在测试集上获得的 PSNR 和 SSIM。6 种网络在用训练集进行训练后在测试集上获得的所有去噪图像与原始干净图像的 PSNR 和 SSIM 的均值见表 2, 括号中的值为基于 DE、GA、TLBO、TLBO-DE 的去噪 CNN 在 10 次实验中获得的 PSNR 和 SSIM 的标准差。由于 BM3D 和 DnCNN 算法并不是随机算法, 所以表 2 没有给出基于 BM3D 和 DnCNN 算法获得的 PSNR 和 SSIM 的标准差。

表 2 噪声等级 $\sigma=20$ 时, 不同网络的平均 PSNR 和 SSIM
Table 2 Average PSNR and SSIM for different networks when noise level $\sigma=20$

| 模型 | 指标 | |
|---------|---------------------|------------------|
| | PSNR | SSIM |
| BM3D | 20.836 5dB | 0.280 5 |
| DnCNN | 26.756 6dB | 0.785 5 |
| DE | 31.991 6dB(0.578 5) | 0.874 4(0.057 1) |
| GA | 30.685 8dB(1.524 8) | 0.815 9(0.114 2) |
| TLBO | 31.099 7dB(0.685 5) | 0.814 5(0.062 8) |
| TLBO-DE | 32.190 7dB(0.456 9) | 0.885 8(0.051 9) |

由表 2 可以看出, 本文方法在两个指标上均取得最优值, 说明本文方法具有更好的去噪性能。此外, 与基于 DE、GA 及 TLBO 算法的去噪 CNN 相比, 本文基于混合 TLBO-DE 算法的去噪 CNN 的 PSNR 和 SSIM 的标准差最小, 说明本文方法具有更好的稳定性。

4 种基于不同的进化算法的去噪 CNN 在训练集上获得的 PSNR 的均值在 10 次实验中的平均收

敛曲线如图 5 所示,横坐标表示进化代数(在 TLBO 算法中,种群按照“教”或“学”阶段完成一次更新即认为种群进化一代),纵坐标表示 10 次实验中峰值信噪比的均值。由图 5 可以看出,DE 的收敛精度较高,其全局搜索能力较强;TLBO 算法的局部搜索能力较强而全局搜索能力较差,其收敛精度低于 DE 的收敛精度;本文将 TLBO 的局部搜索能力和 DE 的全局搜索能力进行结合,混合 TLBO-DE 算法能够更好地平衡全局搜索和局部搜索,具有更高的收敛精度和稳定性。

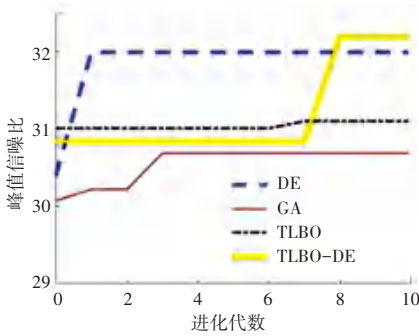


图 5 基于 4 种进化算法的去噪 CNN 的 PSNR 收敛曲线

Fig. 5 PSNR convergence curve of denoising CNN based on four evolutionary algorithms

6 种算法对 MRI 测试集中的两幅典型的图像的去噪结果如图 6 所示。由图 6 可以看出,与 BM3D 及 DnCNN 去噪后的图像相比,经过 TLBO-DE 的去噪 CNN 网络去噪后的图像具有更为明显的轮廓,更强的亮度,更少的噪声和更为清晰的纹理。




图 6 噪声水平 $\sigma=20$ 时, MRI 数据集脑图 1 和 2 的视觉结果

Fig. 6 Visual results of the MRI dataset brain map 1, 2 when noise level $\sigma=20$

4 结束语

针对 CNN 超参数与结构难以确定的问题,本文提出了一种混合 TLBO-DE 算法,并将其应用于去噪 CNN 超参数与结构的优化。该算法将 DE 算法引入到 TLBO 算法,提高了算法的全局优化能力和稳定性。实验结果表明与 BM3D、DnCNN 以及基于 DE、GA、TLBO 算法的去噪 CNN 相比,本文所提出的基于混合 TLBO-DE 算法的去噪 CNN 具有更优的图像去噪效果。

本文模型仍存在着一些不足,如容易陷入局部极值等,今后将结合鲸鱼算法等进化算法对所提算法进一步改进,以提高其优化能力和去噪性能。此外,本文所提算法需要将每个个体对应的 CNN 网络在整个训练集上训练,计算复杂度较高。今后将使用迁移学习等技术,将在小型图像数据集上训练获得的有效去噪网络模型应用于大型数据集的去噪任务中,从而降低算法计算复杂度。

参考文献

- [1] 张雪峰, 闫慧. 基于中值滤波和分数阶滤波的图像去噪与增强算法[J]. 东北大学学报(自然科学版), 2020, 41(8): 482-487.
- [2] 张绘娟, 张达敏, 闫威. 基于改进阈值函数的小波变换图像去噪算法[J]. 计算机应用研究, 2020, 37(5): 1545-1552.
- [3] GAO M J, JEFFREY A F, CHAN H P. Deep convolutional neural network with adversarial training for denoising digital breast tomosynthesis images[J]. IEEE Transactions on Medical Imaging, 2021, 40(7): 1805-1816.
- [4] LECUN Y, BOSER B, DENKER J S, et al. Handwritten digit recognition with a back-propagation network [C]// Proceedings of the 2nd International Conference on Neural Information Processing Systems (NIPS '89). Cambridge, USA: IEEE, 1989: 396-404.
- [5] LEE C, DE G. Color image processing in a cellular neural-network environment[J]. IEEE Transactions on Neural Networks, 1996, 7(5): 1086-1098.
- [6] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Imagenet classification with deep convolutional neural networks [C]// Proceedings of Advances in Neural Information Processing Systems. IEEE, 2012: 1097-1105.
- [7] MTRAN N, TRAN V, NGUYEN N, et al. On data augmentation for gan training [J]. IEEE Transactions on Image Processing, 2021, 30: 1882-1897.
- [8] 林景栋, 吴欣怡, 柴毅. 卷积神经网络结构优化综述[J]. 自动化学报, 2020, 46(1): 24-37.
- [9] 郭玥秀, 杨伟, 刘琦. 残差网络研究综述[J]. 计算机应用研究, 2020, 37(5): 1292-1297.
- [10] ZHANG Kai, ZUO Wangmeng, CHEN Yunjin. Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.

- [11] VARGAS H, GUSTAVO A, MEZURA M, et al. A review on convolutional neural network encodings for neuroevolution [J]. IEEE Transactions on Evolutionary Computation, 2022, 26(1): 12–27.
- [12] 吕帅, 龚晓宇, 张正昊. 结合进化算法的深度强化学习方法研究综述[J]. 计算机学报, 2022, 45(7): 1478–1499.
- [13] LIU P, MOHAMMAD D, BASHA E, et al. Deep evolutionary networks with expedited genetic algorithms for medical image denoising[J]. Medical Image Analysis, 2019, 54:306–315.
- [14] RAJESH C, KUMAR C. An evolutionary block based network for medical image denoising using differential evolution[J]. Applied Soft Computing, 2022, 121:1–15.
- [15] RAO R V, SAVSANI V J, VAKHARIA D P. Teaching-learning-based optimization: An optimization method for continuous non-linear large scale problems[J]. Information Sciences, 2012, 183(1):1–15.
- [16] ZOU Feng, CHEN Debao, XU Qingzheng. A survey of teaching-learning-based optimization[J]. Neuro Computing, 2019, 335: 366–383.
- [17] TANG Hongtao, FANG Bo, LIU Rong, et al. A hybrid teaching and learning-based optimization algorithm for distributed sand casting job-shop scheduling problem [J]. Applied Soft Computing, 2022, 120:1–21.
- [18] KAVEH A, KAMALINEJAD M, HAMEDANI K B. Quantum teaching-learning-based optimization algorithm for sizing optimization of skeletal structures with discrete variables [J]. Structures, 2021, 32:1798–1819.
- [19] TSAI H C. Confined teaching-learning-based optimization with variable search strategies for continuous optimization [J]. Information Sciences, 2019, 500:34–37.
- [20] KOSTADIN D, ALESSANDRO F, KATKOVNIK V. Image denoising by sparse 3-d transform-domain collaborative filtering [J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080–2095.
- [21] WANG Ruhua, LI Jun, CHEN Cho, et al. Densely connected convolutional networks for vibration based structural damage identification[J]. Engineering Structures, 2021, 245: 112871.