

去噪正则化与 FFDNet 结合的相位恢复算法

金焱, 杨敏

(南京邮电大学 自动化学院、人工智能学院, 江苏 南京 210023)

摘要: 相位恢复是图像逆问题的一种, 通过图像信号的幅值, 恢复出采样过程中缺失的相位信息。目前相位恢复算法使用稀疏先验以及传统去噪器先验, 存在特征表征不充分的问题。prDeep 算法使用 DnCNN 卷积神经网络作为去噪器先验, 结合去噪正则化模型提升了恢复效果, 但是仍存在对复杂噪声鲁棒性较差的问题。针对 prDeep 算法对复杂噪声鲁棒不足的问题, 提出了用 FFDNet 作为去噪器先验与去噪正则化模型相结合的算法。该算法利用 FFDNet 网络对噪声的自适应性, 使用去噪正则化 (RED) 构建优化模型, 解决了复杂正则化模型求导繁琐的问题。在保证卷积神经网络对特征表征能力的同时, 提高了对复杂噪声的鲁棒性以及算法的迭代效率。仿真实验结果表明, 该算法在不同噪声等级下, 恢复图像信噪比和迭代效率均有所提升。

关键词: 相位恢复; 去噪正则化; 即插即用先验; 去噪器先验; 卷积神经网络

中图分类号: TP391.9

文献标识码: A

文章编号: 1673-629X(2022)10-0137-06

doi: 10.3969/j.issn.1673-629X.2022.10.023

Phase Retrieval Algorithm Based on RED Combined with FFDNet

JIN Yan, YANG Min

(School of Automation & School of Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Phase retrieval is a kind of image inverse problem. Through the amplitude of the image signal, the missing phase information in the sampling process can be recovered. Current phase retrieval algorithms use sparse priors and traditional denoiser priors, which have the problem of insufficient feature representation. The prDeep algorithm uses the DnCNN as the denoiser prior, combined with the denoising regularization model to improve the recovery effect, but it still has the problem of poor robustness to complex noise. Aiming at the problem of insufficient robustness of the prDeep algorithm to complex noise, an algorithm combining FFDNet as the denoiser prior and the denoising regularization model is proposed. According to FFDNet network's adaptability to noise, the proposed algorithm uses regularization by denoising (RED) to construct an optimization model, which solves the cumbersome problem of complex regularization model derivation. While ensuring the ability of convolutional neural network to characterize features, it also improves the robustness to complex noise and the iterative efficiency of the algorithm. The simulation experiment shows that the proposed algorithm can improve the SNR and iterative efficiency of the restored image under different noise levels.

Key words: phase retrieval; regularization by denoising; plug-and-play priors; denoiser prior; convolutional neural network

0 引言

相位恢复 (phase retrieval, pr) 是在信号的相位信息缺失的情况下, 利用信号的振幅或强度信息复原相位信息, 从而恢复出完整图像信息的技术。因为传统相位恢复算法通常使用正反傅里叶变换反复迭代恢复出丢失的相位。但是随着压缩感知技术的流行, 众多算法开始使用各种先验知识结合迭代算法实现恢复效果。传统的算法包括使用稀疏、平滑等先验结合交替映射、半正定松弛进行恢复, 但是这类算法通常只能对

特定噪声鲁棒。

将先验知识引入相位恢复的另一种方式是使用模型重构^[1]构建正则化模型。通过融合数据保真项和蕴含图像先验知识的正则化项建立 pr 优化问题, 使用优化算法进行求解。此类算法根据噪声不同的分布构建数据保真项, 因此通常对不同的噪声都具有鲁棒性。正则化模型将图像先验融入迭代过程, 从而提高重建质量和迭代速度。例如即插即用先验^[2] (plug-and-play priors, PnP) 和去噪正则化^[3] (regularization by

收稿日期: 2021-10-23

修回日期: 2022-02-24

基金项目: 国家自然科学基金 (61971237)

作者简介: 金焱 (1996-), 男, 硕士研究生, 研究方向为图像相位恢复; 通讯作者: 杨敏 (1969-), 男, 博士, 副教授, 研究方向为计算机视觉。

denoising, RED) 等基于去噪器先验的正则化模型。由于先进去噪器应用成熟且广泛, 该类方法潜力巨大。例如 Bm3d-prgamp^[4] 算法融合数据保真项与 PnP 模型和 BM3D^[5] 相结合的正则化项, 求解对应的优化问题。但是传统的去噪器表征能力不足, 限制了基于去噪器先验的正则化模型的重建效果。

卷积神经网络 (convolutional neural networks, CNN) 解决了传统去噪器先验表征能力不足的问题。深度学习的快速发展为解决各类逆问题提供了全新的视角: 许多精心设计的网络架构在应用中都具有最先进的性能^[6-8]。CNN 去噪器先验广泛应用于各类不稳定图像恢复问题^[9]。在相位恢复问题中, 目前提出的 prDeep^[10] 恢复算法使用 DnCNN^[11] 与去噪正则化模型结合。综合了模型优化算法的灵活性和泛用性、判别式学习对复杂先验的强的优势, 对噪声鲁棒性强且应用广泛。但是由于 DnCNN 对不同噪声等级泛用性不是很好, 恢复过程依赖多次多套参数的迭代, 限制迭代效率的进一步提升。

针对上述恢复算法中存在的问题, 该文提出了一种使用 FFDNet^[12] 网络作为去噪器先验结合去噪正则化模型的恢复算法。FFDNet 网络具有神经网络强大表征能力, 同时提高了对复杂噪声的处理能力, 使用图像下采样作为输入参数的方式保证了结果精度和网络效率, 提高了改进算法的噪声鲁棒性, 提高了重构质量以及迭代效率。

1 使用去噪正则化构建优化模型

使用各式先验知识解决图像不稳定问题已经得到广泛应用。相位恢复问题通常可以构建成如下的优化模型。

$$\hat{x} = \underset{x}{\operatorname{argmin}} \{l(x) + s(x)\} \quad (1)$$

其中, $x \in R^n$ 或 $x \in C^n$, $l(x)$ 表示数据保真项, $s(x)$ 表示正则化项。构建优化模型依赖数据保真项和正则化项的实现。下面两小节分别介绍文中算法对这两项的具体实现。

1.1 模型重建中数据保真项的实现

在图像处理中, 问题的解往往不唯一, 所以不稳定性相当常见。一般描述如下:

$$y = Hx + e \quad (2)$$

其中, H 表示系统的测量矩阵, e 表示系统噪声。相位恢复系统通常可以描述为系统的前向算子作用于输入图像, 并对输出向量取模的结果。其观测矩阵为非线性映射, 可将式(2)替换为:

$$y = |Ax| + e \quad (3)$$

其中, A 表示测量系统的前向算子, $|\cdot|$ 表示对向量

中的每一项取模。将该描述引入式(1)中的数据保真项, 得到如下的关于输入项 x 的优化模型:

$$\hat{x} = \underset{x}{\operatorname{argmin}} \frac{1}{2} \|y - Ax\|_2^2 + s(x) \quad (4)$$

解决此类不适定性问题需要用正则化模型引入先验知识, 传统方法如 Bm3d-prgamp 使用 PnP 模型构建正则化项, 该文使用 RED 模型构建, 1.2 节详细阐述 RED 原理, 并比较 PnP 和 RED 二者的优劣。

1.2 去噪正则化

RED 使用图像自适应拉普拉斯, 依赖平滑约束实现对任意的逆问题建立正则化项。正则化项描述如下:

$$s(x) = \frac{1}{2} x^T [x - f(x)] \quad (5)$$

其中, $f(\cdot)$ 表示去噪器, 也就是第 1 节中去噪器所引入的位置。

正则化项主要由原始图像和去噪后的残差的内积组成。作为先验表达式, 带入可能的原始图像应当获得较低的值。为了满足该正则化项的最小化, 带入 RED 的原始图像 x 必须满足以下两个条件之一: $x - f(x)$ 趋向于 0, 即噪声残差相对较小, 图像 x 在去噪模型 $f(\cdot)$ 的解附近。 $x^T [x - f(x)]$ 趋向于 0, x 与去噪残差的互相关性较小, 即噪声更倾向于与 x 非相关的白噪声等。

RED 对去噪器有所要求。插入 RED 的去噪器需满足两个要求: 局部同质性和强被动性。强被动性要求去噪器的雅各比矩阵的谱半径小于等于 1, 确保迭代的收敛性:

$$\eta(\nabla_x f(x)) \leq 1 \quad (6)$$

同质性要求去噪器对于任意的正数 $c \geq 0$, 满足 $f(cx) = cf(x)$, 即图像先缩放再去噪的结果应与先去噪再缩放的结果一致。

虽然 RED 对去噪器有所要求, 但是绝大多数的去噪器基本都能满足。而且由于 RED 对去噪器的同质性要求, 使其在迭代方面优于 PnP。首先 RED 在迭代算法上不依赖于 ADMM 算法。根据 RED 的同质性要求, 可推导出如下等式:

$$\begin{aligned} \nabla_x f(x) x &= \frac{f(x + \varepsilon x) - f(x)}{\varepsilon} = \\ &= \frac{(1 + \varepsilon)f(x) - f(x)}{\varepsilon} = f(x) \end{aligned} \quad (7)$$

因此, 去噪器 $f(x)$ 有如下等式:

$$f(x) = \nabla_x f(x) x \quad (8)$$

于是 RED 目标函数的梯度可以通过如下方式求解:

$$E(x) = \ell(y, x) + \frac{\lambda}{2} x^T [x - f(x)] \quad (9)$$

$$\begin{aligned} \nabla_x E(x) &= \nabla_x \ell(y, x) + \frac{\lambda}{2} \nabla_x \{x^T [x - f(x)]\} = \\ &= \nabla_x \ell(y, x) + \frac{\lambda}{2} \nabla_x x^T x - \\ &= \frac{\lambda}{2} \nabla_x [x^T f(x)] = \\ &= \nabla_x \ell(y, x) + \lambda x - \frac{\lambda}{2} [f(x) + \\ &= \nabla_x f(x)x] \end{aligned} \quad (10)$$

其中,式(9)表示 RED 的目标函数。将式(8)引入式(10)可以得到:

$$\begin{aligned} \nabla_x E(x) &= \nabla_x \ell(y, x) + \lambda x - \frac{\lambda}{2} [f(x) + f(x)] = \\ &= \nabla_x \ell(y, x) + \lambda [x - f(x)] \end{aligned} \quad (11)$$

根据式(11),以梯度下降法为例,RED 的迭代公式如下:

$$x_{k+1} = x_k - \mu \{ \nabla_x \ell(y, x) + \lambda [x - f(x)] \} \quad (12)$$

由此可见,不同于 PnP 模型,RED 不仅可以使 ADMM 做优化,也可以使用传统的优化算法提高迭代速度,且可以获得确定的迭代公式。相关工作表明^[13-15],RED 模型对各类去噪器先验普遍具有适用性,在图像恢复框架中是最先进的模型之一,并且与深度图像先验结合的研究中拥有更好的恢复效果^[16]。

2 FFDNet 去噪器先验

RED 模型为引入去噪器先验确定下框架基础。利用迭代公式(12),可以将其中的 $f(x)$ 替换成各种去噪器先验,而不同的去噪器也会带来不一样的恢复效果。Christopher A. Metzler 等人结合 RED 与 DnCNN,提出 prDeep 算法解决相位恢复问题。该文将 prDeep 与 BM3D-prGAMP 进行对比,结果显示 prDeep 具有更好的 PSNR 指标。相关研究表明,使用卷积神经网络作为去噪器先验与 RED 模型结合可以获得更好的恢复效果。




图 1 DnCNN 结构

DnCNN 作为去噪器先验广泛应用于各种图像逆

问题,其结构如图 1 所示,整个神经网络共 17 或者 20 层。第一层使用 3×3 的卷积核并以零填充 (no padding) 的方式进行卷积运算,之后使用 ReLU 非线性激活运算获得第一层的图像输出。之后的每一层都在卷积运算和 ReLU 非线性激活运算中使用批量归一化 (batch normalization, BN),最后一层只用卷积获得图像最终的残差结果。

DnCNN 创造性地使用残差学习与批量归一化训练网络,使得网络较深时仍然有较快的收敛速度。在传统 CNN 中通常使用 SGD (随机梯度下降法) 训练,但是受内部协变量偏移的影响,训练速度会变慢。BN 在激活函数进行非线性处理之前加入归一化处理,避免层输入逐渐偏移导致激活函数的取值接近上下限,从而发生反向传播时梯度消失的情况^[17]。CNN 的训练常使用 mini-batch, BN 通过计算 mini-batch 的均值和方差再将其归一化。对于一个 d 维输入 $x = \{x_1, x_2, \dots, x_d\}$,将每一项归一化:

$$\hat{x}_k = \frac{x_k - E[x_k]}{\sqrt{\text{Var}[x_k] + \varepsilon}} \quad (13)$$

其中, ε 是为了避免分母为 0。虽然归一化解决了分布偏移问题,但是降低了表征能力,为了增强表征能力,对归一化的结果 \hat{x}_k 进行变换重构,并引入可学习的参数 γ_k 和 β_k :

$$y_k = \gamma_k \hat{x}_k + \beta_k \quad (14)$$

最终将 y_k 作为结果传播到网络的其他层。而残差学习又解决了深层网络引起的收敛困难以及性能退化的问题^[18],二者相辅相成,使得 DnCNN 具有良好的去噪效果。

但是 DnCNN 仍存在一些缺陷,对不同噪声类型和等级自适应性差。在 prDeep 算法中,为平衡 DnCNN 在不同噪声水平的恢复效果,不得不使用 10 个对应不同噪声等级的 DnCNN 网络参数,在迭代过程中需遍历 10 个网络以获得最佳重建效果。该缺陷限制了迭代速度和恢复效果。

FFDNet 在 DnCNN 的基础上进行改进,它不仅继承了 DnCNN 的以上特点,还解决了 DnCNN 对噪声要求苛刻的问题。DnCNN 可以有效地去除均匀高斯噪声,且对一定噪声等级范围的噪声都有抑制作用。但是实际的噪声通常信号依赖、与各颜色信道相关且不均匀,甚至随空间位置变化。FFDNet 额外添加了噪声估计图作为输入,结构如图 2 所示。添加的噪声估计图改进了 DnCNN 主要针对高斯噪声去噪的问题,使 FFDNet 可以处理更加真实的噪声。由于 DnCNN 针对不同噪声等级只能训练多个不同的网络,在恢复过程中需要提前确定图像的噪声等级,或者在不知道输入图像的噪声等级的前提下需要把图像代入众多网络




图 2 FFDNet 结构

中进行对比,而 FFDnet 对于不同等级的噪声只需要训练一个网络。除此之外,FFDNet 将输入图像下采样,再将输出的图像上采样,这样做的好处是在不影响结果精度的情况下增加感受野,一个 15 层和 3×3 卷积的 FFDNet 网络拥有 62×62 的感受野,相比之下一个普通的 15 层 CNN 网络只有 31×31 的感受野,而大部分先

进去噪方法的感受野一半都在 35×35 到 61×61 之间。同时,FFDNet 的卷积层数为 15 层,与 17 或 20 层的 DnCNN 相比减少了网络参数,使得 FFDNet 更有效率。

综合上述优点,该创新性地将 FFDNet 与 RED 相结合,在 prDeep 算法的基础上改进去噪器,不再使用多个 DnCNN 网络(prDeep 中使用了 10 个不同参数的 DnCNN 网络应对各种噪声等级),而使用一个 FFDNet 网络实现图像相位恢复。

3 实验

为了测试文中方法与 prDeep 以及基于其他去噪器先验方法的相位恢复效果,选取 BSD (Berkeley segmentation dataset) 中部分图片数据进行对比实验。硬件环境选用 Matlab2019b, CPU 为 Intel Core i7 - 8750H, 8 GB 内存, Windows 10 系统的笔记本。该文用 5 组测试图像,分别为 barbara (512 × 512)、cameraman (256 × 256)、boat (512 × 512)、peppers (512 × 512)、Pollen (512 × 512), 测试图像如图 3 所示。



图 3 测试图像

由于在众多的相位恢复的应用中,散粒噪声是噪声的主要来源^[19],因此本次实验噪声使用泊松噪声来模拟。实验的输入信号分别采用编码衍射^[20](coded diffraction)和傅里叶变换,从而获得输入信号的幅值,模拟以图像为信号的相位恢复。之后对幅值信号分别加入不同强度的泊松噪声,并分别使用不同的恢复算

法恢复出完整图像。本实验的测试的算法为 HIO、BM3D-prGAMP、RED-BM3D、prDeep 以及文中算法。实验的部分恢复图像如图 4 所示,它们分别为 128 × 128 的原始图像通过编码衍射获取的幅值信号,并加入噪声强度 $\alpha = 27$ 的泊松噪声后各个算法的恢复效果。



图 4 各算法恢复效果对比

为评价算法的整体性能,使用恢复图像的 PSNR 以及算法的迭代速度作为评价标准。峰值信噪比 PSNR 主要通过输入真实图像和恢复后的图像,基于二者的误差对恢复的图像效果进行评价,PSNR 值越大,代表图像越不失真。

对 cameraman 图像在不同噪声强度下不同恢复算法的对比如表 1 所示。每个算法进行 4 × 200 次迭代,PSNR 取最优效果,时间为 4 次的平均值, α 表示 cameraman 图像的噪声强度。所有算法都处于相同的硬件环境下。

表 1 相位恢复算法对比

算法	s							
	$\alpha = 4$		$\alpha = 9$		$\alpha = 27$		$\alpha = 81$	
	PSNR	时间	PSNR	时间	PSNR	时间	PSNR	时间
HIO	42.01	6.33	31.16	6.71	25.20	6.32	14.39	7.56
BM3D-prGAMP	44.33	17.71	34.12	20.47	31.46	24.05	22.50	25.77
RED-BM3D	44.06	402.46	38.34	404.22	33.87	422.16	24.90	229.48
prDeep	44.56	53.74	39.97	47.98	34.23	39.20	27.24	20.09
文中算法	44.69	34.71	40.03	29.31	34.21	13.68	27.50	10.76

所有测试图像在各个算法中的恢复效果如表 2 所示。每个算法每张图片进行 4×200 次迭代, PSNR 和

时间分别取最优值和平均值, 所有测试图像的噪声强度统一为 $\alpha = 27$, 所有算法使用相同的硬件环境。

表 2 不同测试图像的算法对比

算法	s									
	barbara		cameraman		boat		peppers		Pollen	
	PSNR	时间	PSNR	时间	PSNR	时间	PSNR	时间	PSNR	时间
HIO	23.98	7.41	25.15	6.48	26.33	6.79	27.09	5.59	29.20	6.96
BM3D-prGAMP	30.83	26.34	31.05	25.91	30.59	27.85	32.52	25.10	29.74	26.33
RED-BM3D	31.39	439.79	33.51	407.84	32.44	395.48	31.95	436.90	33.66	412.99
prDeep	33.76	46.85	34.02	41.73	34.48	40.85	35.55	35.62	34.60	39.20
文中算法	35.88	15.67	36.21	15.26	37.27	14.04	36.80	14.84	36.95	16.04

对比表 1 和表 2 可以发现, RED-BM3D、prDeep 和文中算法都是使用去噪正则化模型和各自的去噪器结合的算法, 它们相较于传统的 HIO 算法和 BM3D-prGAMP 算法在峰值信噪比 (PSNR) 上恢复效果更好。文中算法使用的去噪器为 FFDNet, 相较于 RED-BM3D 的去噪器 BM3D 和 prDeep 的去噪器 DnCNN 具有更优的峰值信噪比和更短的迭代时间, 说明先进的卷积神经网络去噪器在表征图像特征和先验上的优势。文中算法对比 prDeep, 在保证图像基本优于 prDeep 的同时, 在迭代速度上有明显的优势, 说明 FFDNet 很好地解决了 DnCNN 使用多套网络参数应对不同噪声等级从而限制 prDeep 算法迭代速度的问题。综上所述, 文中算法在处理各噪声等级下的相位恢复问题都略优于以上算法。

正则化模型与去噪器先验的结合在现阶段具有很好的重建效果和对噪声的自适应性, 且关于去噪器先验在相位恢复中的应用肯定还远不止这些。更多更先进的去噪器例如 CBNNet、RIDNet 等作为先验知识, 在处理相位恢复等图像反问题上可能获得更好的恢复效果。

4 结束语

相位恢复问题是仅获取幅值信号的情况下恢复出原信号的相位信息从而恢复出完整的输入信号。现阶段相位恢复算法仍存在对图像特征和先验知识提取不足导致重建效果不充分, 或者对复杂噪声自适应性较差限制迭代效率等问题。文中算法在 RED 与去噪器

先验的框架下, 利用 FFDNet 网络的特征表征能力和复杂噪声的自适应性尝试解决这些问题。相比 prDeep 等算法, 迭代更为简单。仿真实验结果表明, 该算法在信噪比和效率上都有所提升。在后续研究中, 可以尝试引进新的去噪器先验。

参考文献:

- [1] VENKATAKRISHNAN S V, BOUMAN C A, WOHLBERG B. Plug-and-play priors for model based reconstruction [C]//2013 IEEE global conference on signal and information processing. Piscataway: IEEE, 2013: 945-948.
- [2] ZHANG K, LI Y, ZUO W, et al. Plug-and-play image restoration with deep denoiser prior [J]. arXiv:2008.13751v2, 2020.
- [3] ROMANO Y, ELAD M, MILANFAR P. The little engine that could: regularization by denoising (RED) [J]. SIAM Journal on Imaging Sciences, 2017, 10(4): 1804-1844.
- [4] METZLER C A, MALEKI A, BARANIUK R G. BM3D-PRGAMP: compressive phase retrieval based on BM3D denoising [C]//2016 IEEE international conference on image processing (ICIP). Phoenix: IEEE, 2016: 2504-2508.
- [5] DABOV K, FOI A, KATKOVNIK V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering [J]. IEEE Transactions on image processing, 2007, 16(8): 2080-2095.
- [6] CHEN W, WIPF D, RODRIGUES M. Deep learning for linear inverse problems using the plug-and-play priors framework [C]//ICASSP 2021-2021 IEEE international conference on acoustics, speech and signal processing (ICASSP).

- Toronto;IEEE,2021;8098–8102.
- [7] ZHANG K,ZUO W,GU S,et al. Learning deep CNN denoiser prior for image restoration [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu;IEEE,2017;3929–3938.
- [8] DONG W,WANG P,YIN W,et al. Denoising prior driven deep neural network for image restoration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2018,41 (10):2305–2318.
- [9] GU S,TIMOFTE R,VAN GOOL L. Integrating local and non-local denoiser priors for image restoration [C]//2018 24th international conference on pattern recognition (ICPR). Beijing;IEEE,2018;2923–2928.
- [10] METZLER C, SCHNITER P, VEERARAGHAVAN A. prDeep:robust phase retrieval with a flexible deep network [C]//International conference on machine learning. Cambridge;JMLR,2018;3501–3510.
- [11] ZHANG K,ZUO W,CHEN Y,et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising [J]. IEEE Transactions on Image Processing,2017,26 (7): 3142–3155.
- [12] ZHANG K,ZUO W,ZHANG L. FFDNet:toward a fast and flexible solution for CNN-based image denoising [J]. IEEE Transactions on Image Processing,2018,27 (9):4608–4622.
- [13] REEHORST E T, SCHNITER P. Regularization by denoising;clarifications and new interpretations [J]. IEEE Transactions on Computational Imaging,2018,5 (1):52–67.
- [14] YOGEV-OFER E,TIRER T,GIRYES R. An interpretation of regularization by denoising and its application with the back-projected fidelity term [J]. arXiv:2101.11599,2021.
- [15] BENNING M,BURGER M. Modern regularization methods for inverse problems [J]. Acta Numerica,2018,27:1–111.
- [16] MATAEV G,MILANFAR P,ELAD M. Deepred:deep image prior powered by red [C]//Proceedings of the IEEE/CVF international conference on computer vision workshops. Piscataway;IEEE,2019.
- [17] IOFFE S,SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]//International conference on machine learning. Cambridge;JMLR,2015;448–456.
- [18] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. [s. l.]: IEEE, 2016:770–778.
- [19] YEH L H,DONG J,ZHONG J,et al. Experimental robustness of Fourier ptychography phase retrieval algorithms [J]. Optics Express,2015,23 (26):33214–33240.
- [20] CANDES E J,LI X,SOLTANOLKOTABI M. Phase retrieval from coded diffraction patterns [J]. Applied and Computational Harmonic Analysis,2015,39 (2):277–299.
- +++++
- (上接第 136 页)
- IEEE conference on computer vision and pattern recognition (CVPR). Hawaii;IEEE,2017;4700–4708.
- [18] SUN Y,XUE B,ZHANG M,et al. Evolving deep convolutional neural networks for image classification [J]. IEEE Transactions on Evolutionary Computation,2019,24 (2):394–407.
- [19] ESFAHANIAN P,AKHAVAN M. GACNN: training deep convolutional neural networks with genetic algorithm [J]. arXiv:1909.13354,2019.
- [20] LUO X J,OYEDELE L O,AJAYI A O,et al. Feature extraction and genetic algorithm enhanced adaptive deep neural network for energy consumption prediction in buildings [J]. Renewable and Sustainable Energy Reviews, 2020, 131: 109980.
- [21] SUN Y,XUE B,ZHANG M,et al. Automatically designing CNN architectures using the genetic algorithm for image classification [J]. IEEE Transactions on Cybernetics, 2020, 50 (9):3840–3854.
- [22] 席亮,王瑞东. 基于自适应遗传算法的神经网络结构优化算法 [J]. 哈尔滨理工大学学报,2021,26 (1):39–44.
- [23] 刘浩然,赵翠香,李轩,等. 一种基于改进遗传算法的神经网络优化算法研究 [J]. 仪器仪表学报,2016,37 (7): 1573–1580.
- [24] SRINIVAS M,PATNAIK L M. Adaptive probabilities of crossover and mutation in genetic algorithms [J]. IEEE Transactions on Systems, Man, and Cybernetics, 1994, 24 (4):656–667.
- [25] SPRINGENBERG J T,DOSOVITSKIY A,BROX T,et al. Striving for simplicity: the all convolutional net [J]. arXiv: 1412.6806,2014.
- [26] BI Y,XUE B,ZHANG M. An evolutionary deep learning approach using genetic programming with convolution operators for image classification [C]//2019 IEEE congress on evolutionary computation (CEC). Wellington;IEEE,2019;3197–3204.