

基于 SPL 迭代思想的图像压缩感知 重构神经网络

裴翰奇¹, 杨春玲¹, 魏志超¹, 曹 燕²

(1. 华南理工大学电子与信息学院, 广东广州 510640; 2. 华南理工大学国家移动超声探测工程技术研究中心, 广东广州 510640)

摘 要: 由于神经网络强大的学习能力与快速的运行速度, 近年来基于深度学习的图像压缩感知 (Image Compressive Sensing, ICS) 研究备受关注. 然而, 大多数现有 ICS 神经网络的结构设计忽略了传统迭代重构算法中的数学理论基础, 无法有效利用信号中的先验结构知识, 可解释性较差. 为了保留优化算法核心思想并同时利用深度学习的高性能, 本文使用可学习的卷积层替代了传统平滑投影 Landweber 算法 (Smooth Projected Landweber, SPL) 中的人工设计参数, 提出一种新型 ICS 神经网络 SPLNet. 在 SPLNet 中, 设计了一个独特的网络结构 SPLBlock 实现 SPL 迭代过程中的三个核心步骤: (1) 去除块效应的维纳滤波器; (2) 在凸投影集合上的近似操作; (3) 实现稀疏表示及去噪的变换域双变量收缩. 仿真实验结果表明: 与现有最优的 ICS 优化迭代算法 GSR 相比, SPLNet 的重构图像平均 PSNR 提升了 0.78dB; 与最优的神经网络框架 SCSNet 相比, SPLNet 的重构图像平均 PSNR 提升了 0.92dB.

关键词: 压缩感知; 图像压缩感知; 深度网络; 卷积神经网络; 图像采样; 图像重构

中图分类号: TN919.8

文献标识码: A

文章编号: 0372-2112 (2021)06-1195-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20200618

Image Compressive Sensing Reconstruction Network Based on Iterative SPL Theory

PEI Han-qi¹, YANG Chun-ling¹, WEI Zhi-chao¹, CAO Yan²

(1. School of Electronic and Information Engineering, South China University of Technology, Guangzhou, Guangdong 510640, China;

2. The National Engineering Technology Research Center for Mobile Ultrasonic Detection, South China University of Technology, Guangzhou, Guangdong 510640, China)

Abstract: Due to its great learning ability and fast processing speed, deep learning-based image compressive sensing (ICS) methods attract a lot of attention in recent years. However, the design of most existing ICS neural networks architecture ignore the mathematical theory in iterative optimization-based methods and cannot effectively use the prior structure knowledge in the signal, leading to lack of the interpretability. In order to retain the core ideas of the optimization algorithm and utilize the high performance of deep learning, this paper uses learnable convolutional layers to replace the predefined filters and artificial design parameters in the traditional smooth projected Landweber algorithm (SPL), and proposes a ICS neural network named SPLNet. In SPLNet, we design a unique network structure SPLBlock to implement three key steps in SPL iteration: (1) Wiener filter for removal of blocking artifacts; (2) approximation with projection onto the convex set; (3) bivariate shrinkage on transform domain for sparse representation and denoising. Experimental results indicate that, compared with current state-of-the-art ICS optimization iterative algorithm GSR, the average reconstructed image PSNR of SPLNet are improved by 0.78dB, and compared with state-of-the-art neural network framework SCSNet, the average reconstructed image PSNR of SPLNet are improved by 0.92dB.

Key words: compressive sensing; image compressive sensing; deep networks; convolutional neural networks; image sampling; image reconstruction

1 引言

压缩感知 (Compressive Sensing, CS)^[1] 理论证明了当信号具备稀疏特性或者可以在某一变换域内被稀疏表示时,则能够通过优化算法从频率远低于奈奎斯特频率的采样信号中重构原始信号. 在 CS 框架下,采样与压缩过程同时完成,有效减轻了传统编码算法中先采样后压缩策略造成的计算资源浪费. 给定大小为 $N \times 1$ 维的原始信号 \mathbf{x} , CS 采样过程可以表示为线性映射 $\mathbf{y} = \Phi\mathbf{x}$, 其中 Φ 是 $M \times N$ 维的采样矩阵, \mathbf{y} 为 $M \times 1$ 的观测值. 然而在压缩感知中,由于 $M \ll N$, 从采样信号 \mathbf{y} 中恢复原始信号 \mathbf{x} 事实上是一个典型的病态逆问题.

自从 CS 理论提出以来,其在自然图像中的应用便受到了较高的重视. 为了有效地对二维图像进行采样,文献[2]中提出针对图像压缩感知 (Image Compressive Sensing, ICS) 的分块压缩感知框架 (Block-based Compressive Sensing, BCS). 在 BCS 框架下,原始图像 \mathbf{X} 被分为 N_b 个大小为 $B \times B$ 的非重叠图像块进行单独采样. 基于该框架, Mun 等人^[3] 将维纳滤波器结合到传统的投影 Landweber (Projected Landweber, PL) 迭代过程中,提出平滑投影 Landweber 算法 (Smooth Projected Landweber, SPL) 用于压缩感知图像重构. 在 SPL 算法的基础上, Fowler 等人^[4-6] 提出了多种改进算法以进一步提高重构性能. 在文献[7]中, Zhang 等人通过字典学习方法,对图像分块构建特殊字典进行稀疏表示,并在此基础上针对 ICS 问题提出基于组稀疏表示的重构算法 (Group based Sparse Representation, GSR), 在图像重构中取得了出色的性能表现.

在过去几年中,深度神经网络 (Deep Neural Networks, DNN) 被广泛用于许多不同的计算机视觉任务,其强大的学习能力与快速的运行速度受到了广泛的重视^[8-10]. 在文献[11]中, Kulkarni 等人首次使用卷积神经网络来学习从观测值到原始图像的逆映射关系,并提出一种用于 ICS 重构的全新神经网络 ReconNet. 文献[12]在 ReconNet 的基础上引入残差学习结构,将卷积层使用残差学习块进行替代,提出 DR²-Net. Zhang 等人^[13] 基于传统迭代阈值收缩算法,设计了一种特殊的 ICS 网络结构 ISTA-Net, 在 DNN 中保持了良好的数学可解释性. 文献[14]提出一种多尺度残差网络结构,以学习多种维度的图像信息辅助 ICS 重构,加强了算法对噪声的鲁棒性. 在 BCS 框架下, Shi 等人^[15] 提出一个端到端的 ICS 神经网络 CSNet, 利用卷积层对传统采样矩阵进行模拟并同时优化采样端与重构端,取得了不错的重构性能. 在之后的研究中, Shi 等人^[16-18] 从不同角度对 CSNet 进行改进,先后提出 MSCSNet, CSNet⁺ 与 SCS-Net, 进一步提升了网络的恢复效果. 基于 CSNet, Cui 等

人^[19] 提出在训练过程中对神经网络的采样端添加相应的先验条件,学习得到了特征提取效果更加优良的采样矩阵.

与传统 ICS 优化算法相比, ICS 神经网络显著地降低了重构算法的时间复杂度,提升了压缩感知框架的整体效率. 然而,大部分现有的深度学习重构方法依然存在两点不足: (1) 在神经网络重构过程中,作为关键参考信息的观测值仅仅参与了对图像的初始重构,却没有在后续的深度重构中起到相应的作用,限制了算法最终的性能表现; (2) 网络框架设计单纯以重构效果为导向,忽略了传统 ICS 优化算法中的数学先验知识,缺乏理论支持并可解释性较差.

为了同时利用 SPL 算法的可靠原理与深度学习的高效性能,本文提出一种基于 SPL 算法思想的 ICS 神经网络实现 (SPLNet), 有效地将传统 SPL 算法思路结合到 DNN 当中. 在 SPLNet 中,通过设计一个特殊的网络结构 SPLBlock, 利用深度学习成功复现了传统 SPL 迭代过程中的三个核心步骤: (1) 用于平滑图像的维纳滤波; (2) 用于减小误差的凸投影近似过程; (3) 实现滤波去噪的变换域双变量收缩. SPLNet 实现了 SPL 优化迭代算法中每次迭代都充分利用观测值信息重构图像的思想,并整合了深度学习方法强大的学习能力,得到了更好的变换矩阵与阈值参数,相比原始算法取得了更加优良的重构性能.

2 实现图像压缩感知及重构的 SPL 神经网络 (SPLNet)

2.1 网络整体结构

与大多数现有的 ICS 神经网络不同,本文提出的 SPLNet 既利用了深度学习的强大泛化能力与快速运行速度,又充分考虑了传统 SPL 迭代优化算法的核心思路与流程框架,进一步增强了网络的重构性能与可解释性. 参考图 1, SPLNet 是一个端到端的神经网络,在结构流程上分为三个部分: BCS 采样, 初始重构与 SPL 深度重构. 前两个子网络分别复现了传统 SPL 算法中的线性映射过程,而 SPL 深度重构子网络是一个由 SPL-Block 组成的多阶段神经网络结构,每个阶段对应 SPL 算法中的一次迭代. 接下来的内容将分别讨论这三部分网络结构,并重点讨论实现 SPL 迭代重构的 SPLBlock 的框架结构.

2.2 BCS 采样子网络

对于图像块 \mathbf{x}_b , BCS 中的分块采样过程可以表示为 $\mathbf{y}_b = \Phi_b \mathbf{x}_b$, 其中 \mathbf{y}_b 是分块观测值, Φ_b 是分块采样矩阵. 在 CSNet 中, Shi 等人^[15] 将 Φ_b 中的每一行视为一个单独的滤波器,并使用可学习的卷积层在神经网络下实现了传统的 BCS 采样. 本文的 SPLNet 采用相同的方

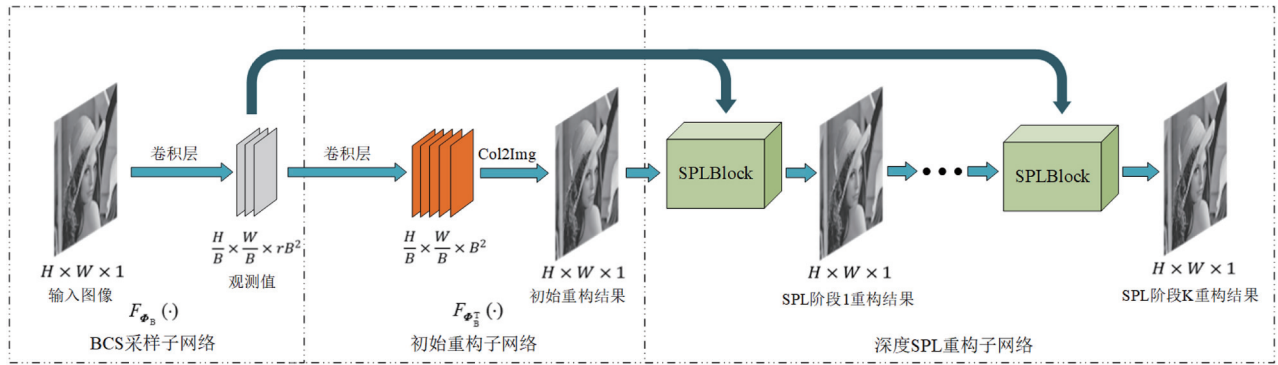


图1 SPLNet网络结构

式来设计 BCS 采样子网络. 对于采样率 r , 图像分块大小 $B \times B$, 该子网络使用一个含有 rB^2 个卷积核的卷积层 $F_{\phi_B}(\cdot)$ 对图像进行采样. 为了实现非重叠分块采样, 该层中每个卷积核的大小为 $B \times B \times 1$, 步长为 $B \times B$. 值得注意的是, $F_{\phi_B}(\cdot)$ 中的每个卷积核既没有偏置项也没有激活函数, 严格对应了传统 ICS 中的采样矩阵形式. 当要采集的图像为 $H \times W$ 的灰度图像时, 利用 BCS 采样子网络得到的观测值维度为 $(H/B) \times (W/B) \times rB^2$.

2.3 初始重构子网络

在重构阶段, SPL 算法首先使用采样矩阵的转置矩阵对观测值进行线性映射以得出初始重构结果, 表示为式 $\mathbf{x}_B^{\text{init}} = \Phi_B^T \mathbf{y}_B$. 为了模拟该过程, SPLNet 中的初始重构子网络利用了一个带有 B^2 个卷积核的卷积层来替换预定义的转置矩阵, 其中卷积核的大小为 $1 \times 1 \times rB^2$, 步长设置为 1×1 . 与 BCS 采样子网络类似, 此处的卷积层也没有添加偏置项以及激活函数. 此外, 该子网络还额外引入了一个由变形层与连接层构成的 Col-to-Img (Col2Img) 算子, 用来将卷积层的输出重新组合为图像. 综上所述, SPLNet 中的初始重构过程由一层卷积层与一个 Col-to-Img 算子构成, 表示为 $F_{\phi_S}(\cdot)$.

2.4 深度 SPL 重构子网络

在得到初始重构图像后, SPL 算法通过反复的迭代过程逐渐移除恢复图像中的不良噪声并对细节纹理信息进行重构. 参考传统 SPL 迭代中的优化策略, 本节中

提出了一个新颖的网络结构 SPLBlock, 并基于 SPLBlock 设计了一个多阶段的深度重构子网络来进一步细化初始重构图像(见图 1). 如图 2 所示, SPLBlock 由 6 个部分组成, 每一部分对应了传统 SPL 迭代过程中的一个步骤. 与传统算法不同的是, SPLBlock 中的每一步都是由卷积层组成, 替代了预定义参数或矩阵, 使得用于重构的参数更加合理.

(1) 维纳滤波的神经网络实现

在 SPL 迭代过程开始时, 首先使用了一个维纳滤波器对重构图像进行平滑处理, 以去除图像中的有害噪声. 在 SPLBlock 中, 维纳滤波器通过由 ReLU 激活函数连接的两层卷积层实现, 表示为 $WF^k(\cdot)$. 其中, 第一层卷积层包含 64 个大小为 $3 \times 3 \times 1$ 的卷积核, 而第二层包含 1 个大小为 $3 \times 3 \times 64$ 的卷积核.

(2) 凸投影近似优化的神经网络实现

借鉴 SPL 算法的思路, SPLBlock 中的凸投影近似优化过程分为两步: (a) 凸投影. 将平滑处理后的图像信号先投影到采样矩阵上, 得到平滑图像的观测值, 再求出该观测值与真实观测值之间的残差信号; (b) 优化. 利用初始重构子网络中的初始重构矩阵对残差信号进行反投影, 并基于该结果对平滑图像进行优化. 与 SPL 算法相比不同的是, SPLBlock 中的采样矩阵与初始重构矩阵是在前两个子网络中通过深度学习得到的, 替代了原始近似优化过程中人工设计的固定矩阵. 具体的优化过程可以表示为下式:

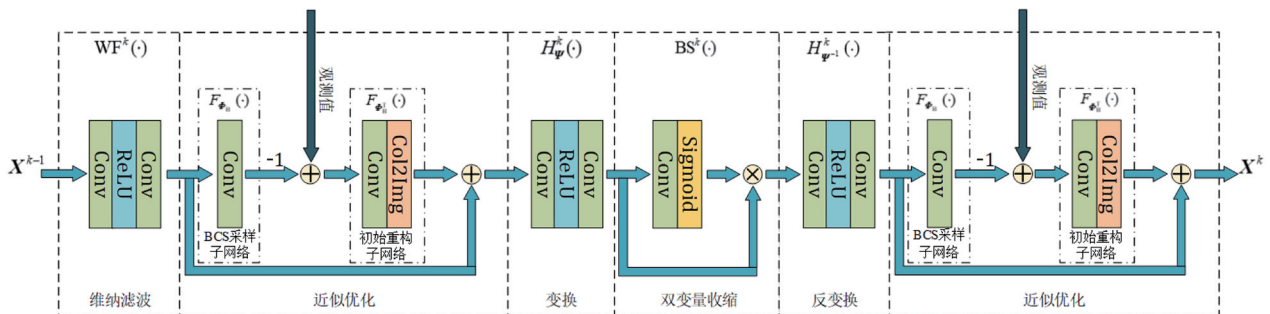


图2 SPLBlock结构框图

$$\bar{X}^k = \hat{X}^k + F_{\phi_s}(Y - F_{\phi_s}(\hat{X}^k)) \quad (1)$$

式中, Y 为 BCS 采样子网络输出的观测值, \hat{X}^k 为维纳滤波器的输出图像, \bar{X}^k 为近似优化过程得到的结果, $F_{\phi_s}(\cdot)$ 与 $F_{\phi_r}(\cdot)$ 分别代表了 BCS 采样子网络与初始重构子网络。

(3) 变换域双变量收缩及反变换的神经网络实现

在得出投影近似的结果后, SPL 迭代过程通常利用 DCT 或者 DWT 等变换方式, 将图像信号转换到变换域进行阈值处理, 以达到去噪与稀疏表示的目的。在文献 [13] 的启发下, SPLBlock 使用了两层由 ReLU 激活函数连接的卷积层 (H_{ψ}^k) 实现 DWT 变换。在设置上, H_{ψ}^k 中的两层卷积层分别包括 64 个 $3 \times 3 \times 1$ 的卷积核与 64 个 $3 \times 3 \times 64$ 的卷积核。

基于 DWT 变换, SPL 算法中采用双变量收缩对变换系数进行滤波, 在原理上, 双变量收缩可以理解为对于变换系数的加权过程, 而对应的权重大小则由系数间的数学关系决定。因此, SPLNet 采用一种独特的注意力网络结构 $BS^k(\cdot)$ 实现双变量收缩: 该结构以变换系数为输入, 利用一层带有 Sigmoid 激活函数的卷积层计算对应系数的权重, 再将得出的权重与变换系数进行点乘, 得出收缩后的结果。为了有效计算权重, $BS^k(\cdot)$ 中的卷积层包括了 64 个 $3 \times 3 \times 64$ 的卷积核。

之后, SPLNet 利用一个与 H_{ψ}^k 结构对称的反变换卷积操作 $H_{\psi^{-1}}^k$, 将加权后的变换系数从变换域映射到图像, 其中的两层卷积层分别包括 64 个 $3 \times 3 \times 64$ 的卷积核与 1 个 $3 \times 3 \times 64$ 的卷积核。最后, 针对反变换后的图像信号再进行一次凸投影近似优化操作, SPLBlock 便完整复现了 SPL 算法的一次迭代过程。

在 SPLBlock 中, 所有的卷积层的步长均设置为 1×1 , 并且都没有添加偏置项。与传统 SPL 算法相似, 作为采样矩阵与初始重构矩阵的卷积核 $F_{\phi_s}(\cdot)/F_{\phi_r}(\cdot)$ 在整个 SPLNet 中都是共享的。不同的是, SPLNet 中的每个 SPLBlock 都有其独立的维纳滤波器, 变换矩阵, 反变换矩阵与阈值处理参数, 这是 SPLNet 获得比 SPL 算法更好重构性能的重要原因。通过级联 N_p 个 SPLBlock, SPLNet 成功基于深度学习实现了 SPL 算法中的 N_p 次迭代, 完成对图像的重构过程。

2.5 损失函数

在 SPL 算法当中, 有两个重要的限制条件: (1) 理想情况下, 采样矩阵与初始重构矩阵互为逆矩阵, 即 $F_{\phi_s} \circ F_{\phi_r}(\cdot) = \mathbf{I}$; (2) 变换与反变换过程可逆, 即 $H_{\psi}^k \circ H_{\psi^{-1}}^k = \mathbf{I}$; 其中 \circ 代表了一种卷积层连接的抽象运算, 而 \mathbf{I} 为单位算子。为了满足以上两个限制条件, SPLNet 网络训练时在损失函数中增加了限制损失部分辅助训练。对应图像训练集 $\{X_i\}$, 限制损失表示为:

$$L_{\text{constraint}} = \sum_{i=1}^{N_b} \left(\|F_{\phi_s}(F_{\phi_r}(X_i)) - X_i\|_2^2 + \sum_{k=1}^{N_p} \|H_{\psi^{-1}}^k(H_{\psi}^k(X_i)) - X_i\|_2^2 \right) \quad (2)$$

其中 N_b, N_p 分别为训练集中的图像数和网络中 SPLBlock 的个数。此外, 与其他 ICS 神经网络类似, 本文使用均方误差损失, 作为主要损失函数对网络进行训练, 以减少输入图像与重构图像之间的误差。对应图像训练集 $\{X_i\}$, 均方误差损失可以表示为:

$$L_{\text{MSE}} = \sum_{i=1}^{N_b} \|f(X_i, \theta) - X_i\|_2^2 \quad (3)$$

式中 $f(X_i, \theta)$ 是 SPLNet 的最终输出结果, 而 θ 代表了网络中的可学习参数。在进行训练时, 将两部分损失函数结合到一起, 对 SPLNet 的整体损失函数进行优化:

$$L_{\text{total}} = L_{\text{MSE}} + \varepsilon L_{\text{constraint}} \quad (4)$$

其中, ε 为权重参数。

3 网络实现细节和实验结果

在本章中, 将详细介绍 SPLNet 的网络训练细节与对应的仿真实验结果, 验证所提出的网络结构的有效性。

3.1 网络训练细节

出于对重构性能与计算资源消耗的平衡考虑, 在本章的仿真实验中将 SPLNet 内包含的 SPLBlock 个数 N_p 默认设置为 3, 分块大小 B 统一设置为 32。在初始化网络参数时, 本节中选用了文献 [20] 中所使用的设置方法。

在训练中, 本文参考文献 [15], 选用了 BSDS500^[21] 数据集中的训练集 (200 张图像) 与测试集 (200 张图像) 共 400 张图像作为 SPLNet 的训练集。在开始训练前, 所有训练图像被转化为灰度格式并且随机裁剪为 256×256 的大小。此外, 旋转, 翻转等数据增广方法被用来进一步丰富训练数据的数量与类型。为了使优化过程平稳收敛, 训练时的 Batchsize 大小设置为 16, 网络优化算法选用默认超参数设置的 AdamOptimizer^[22]。整个训练过程总共持续 90 个 epoch: 初始 30 个 epoches, 第 31 ~ 60 个 epoches 和最后 30 个 epoches 的学习率分别为 $1E-4$, $1E-5$ 和 $1E-6$ 。每个 epoch 中总共循环 2000 次。关于网络实现, 整个 SPLNet 基于 python 平台的 Tensorflow^[23] 和 Tensorlayer^[24] 进行编写与调试。在实验中, 大概需要两天时间在 GPU GTX1080ti 上完成一次完整的网络模型训练。

3.2 仿真实验结果与分析

为了公平对比, 仿真实验中主要选用的测试集为在其他压缩感知工作中受到广泛应用的 Set8 图像集 (源链接: http://see.xidian.edu.cn/faculty/wsdong/NLR_Exps.htm), 其中包含了 8 张 256×256 大小的灰度图像: Barbara,

Boats, Cameraman, Foreman, House, Lena, Monarch, Parrots. 仿真硬件平台为配置了 CPU Intel 4-Cores i5 3.30GHz, GPU NVIDIA GTX 1080ti, RAM 8GB 的台式计算机。

3.2.1 不同算法重构图像质量对比

为了验证 SPLNet 相比其他压缩感知重构算法的优越性,本小节选取了五种具有代表性的图像压缩感知算法进行对比实验,其中包括:MH-SPL 算法^[6], GSR 算法^[7], ISTA-Net⁺^[13], CSNet⁺^[17] 与 SCSNet^[18]. 对比算法中的前两种为传统的优化重构算法,而后三种为基于神经网络的压缩感知方法. 在实验中,所有的对比算法均使用原作者发布的代码进行实现与仿真. 为了全面的比较,图像压缩感知重构实验总共在 5 个常用的采样率上进行仿真:0.5、0.4、0.3、0.2 和 0.1.

为了方便展示结果,表 1 中包含了 6 种算法在 Set8 测试集中部分图像上的详细重构 PSNR 与 SSIM 结果,而表 2 中则展示了在 Set8 测试集上对应的平均结果.

如结果所示,在大多数测试条件下,SPLNet 的重构性能要优于其他对比算法. 与 MH-SPL, GSR 算法对比,SPLNet 的重构图像 PSNR 在 5 个采样率下平均提升了 3.92dB 和 0.78dB,展现了神经网络的强大泛化能力. 另一方面,在与神经网络方法对比时,SPLNet 也在不同采样率下得到了出色的 PSNR 结果. 在 0.1~0.5 这五个采样率下,SPLNet 的重构图像平均 PSNR 比 ISTA-Net⁺ 分别提升了 2.24dB, 1.86dB, 1.95dB, 1.29dB 和 1.98dB. 同样是借鉴传统优化算法思路进行设计的神经网络,SPLNet 相比 ISTA-Net⁺ 引入了端到端的优化方式,并且在阈值处理上的设计更加巧妙,取得了更好的滤波效果. 凭借可靠的优化理论思路,SPLNet 在 5 个采样率下相比效果最好的 SCSNet 分别平均提升了 0.36dB, 0.87dB, 1.06dB, 1.18dB, 1.13dB. 在 SSIM 评价指标上,SPLNet 仍然明显地优于其他对比算法,在不同的采样率下均有不错的提高.

表 1 SPLNet 与几种不同算法在部分测试图像上的重构 PSNR (dB)/SSIM 结果对比

测试图像	采样率	MH-SPL ^[6]	GSR ^[7]	ISTA-Net ⁺ ^[13]	CSNet ⁺ ^[17]	SCSNet ^[18]	SPLNet
Monarch	0.1	23.19/0.7575	25.22/0.8613	25.98/0.8448	28.58/0.9050	28.87/0.9097	29.41/0.9112
	0.2	27.10/0.8659	30.75/0.9431	31.33/0.9359	32.76/0.9591	32.86/0.9598	33.64/0.9631
	0.3	29.20/0.9004	34.24/0.9658	34.95/0.9649	35.06/0.9742	35.58/0.9762	36.49/0.9774
	0.4	31.12/0.9237	36.86/0.9764	37.84/0.9772	37.06/0.9814	37.91/0.9841	38.88/0.9853
	0.5	32.93/0.9410	39.18/0.9832	40.25/0.9844	38.84/0.9863	40.01/0.9887	41.14/0.9901
Parrot	0.1	25.35/0.8220	26.36/0.8747	26.58/0.8495	28.11/0.8898	28.10/0.8921	28.32/0.8973
	0.2	29.21/0.8974	31.15/0.9249	30.48/0.9126	31.34/0.9341	31.29/0.9327	32.45/0.9409
	0.3	31.00/0.9254	33.75/0.9470	32.55/0.9396	33.84/0.9544	34.12/0.9563	35.59/0.9632
	0.4	33.48/0.9380	36.54/0.9628	35.31/0.9580	36.08/0.9691	36.41/0.9698	38.10/0.9752
	0.5	35.70/0.9561	38.58/0.9730	37.37/0.9701	38.19/0.9781	38.26/0.9786	40.27/0.9830
Boat	0.1	26.06/0.7456	28.32/0.8512	27.44/0.7955	29.98/0.8699	30.11/0.8728	30.18/0.8703
	0.2	29.91/0.8573	33.68/0.9383	31.84/0.9047	33.39/0.9351	33.57/0.9378	34.22/0.9411
	0.3	32.24/0.9034	36.91/0.9638	35.10/0.9461	35.83/0.9586	36.30/0.9625	37.15/0.9656
	0.4	34.20/0.9340	39.27/0.9758	37.80/0.9669	38.02/0.9707	38.61/0.9745	39.86/0.9787
	0.5	35.84/0.9482	41.13/0.9827	40.07/0.9780	40.38/0.9801	40.96/0.9827	41.88/0.9847
Foreman	0.1	33.09/0.8930	35.80/0.9279	33.51/0.9035	35.04/0.9292	35.17/0.9303	35.71/0.9332
	0.2	35.87/0.9287	38.66/0.9527	37.56/0.9452	38.65/0.9625	38.45/0.9616	38.99/0.9626
	0.3	37.63/0.9439	40.84/0.9676	40.28/0.9648	40.59/0.9749	40.82/0.9758	41.63/0.9772
	0.4	39.09/0.9566	42.53/0.9768	42.39/0.9759	42.18/0.9816	42.66/0.9833	43.76/0.9849
	0.5	40.34/0.9651	44.12/0.9833	44.25/0.9833	43.74/0.9864	44.32/0.9880	45.67/0.9901
Cameraman	0.1	22.12/0.6790	22.89/0.7668	23.66/0.7671	25.56/0.8255	25.71/0.8270	26.35/0.8394
	0.2	25.87/0.8110	26.86/0.8595	27.34/0.8553	28.63/0.8963	28.53/0.8970	29.78/0.9054
	0.3	28.08/0.8606	29.11/0.9003	30.04/0.8996	30.70/0.9253	30.64/0.9268	32.01/0.9333
	0.4	29.87/0.8935	31.27/0.9280	32.32/0.9298	32.43/0.9433	32.37/0.9457	33.74/0.9511
	0.5	31.69/0.9206	33.10/0.9475	34.41/0.9502	34.02/0.9571	34.33/0.9607	35.35/0.9642

表 2 SPLNet 与几种不同算法的整体平均重构 PSNR(dB)/SSIM 结果对比

	采样率	MH-SPL ^[6]	GSR ^[7]	ISTA-Net ^{+[13]}	CSNet ^{+[17]}	SCSNet ^[18]	SPLNet
平均重构 PSNR/SSIM	0.1	26.62/0.7932	28.72/0.8650	27.41/0.8141	29.18/0.8608	29.29/0.8629	29.65/0.8665
	0.2	30.30/0.8803	33.01/0.9278	31.43/0.9590	32.38/0.9199	32.42/0.9206	33.29/0.9270
	0.3	32.35/0.9131	35.66/0.9524	34.35/0.9381	34.99/0.9507	35.25/0.9527	36.30/0.9582
	0.4	34.14/0.9323	37.86/0.9666	36.83/0.9590	37.14/0.9667	37.57/0.9693	38.75/0.9734
	0.5	35.91/0.9503	39.77/0.9760	38.97/0.9717	39.31/0.9782	39.82/0.9804	40.95/0.9827




图3 0.1采样率下图像Cameraman的视觉恢复结果对比




图4 0.4采样率下图像Boat的视觉恢复结果对比

为了进一步对比分析 SPLNet 的重构效果,图 3 与图 4 中给出了不同算法的部分图像恢复视觉效果。如图 3 所示,在 0.1 采样率下的 Cameraman 图像上,前两种优化算法的结果中存在明显的振铃效应,视觉质

量较差,细节模糊不清。在神经网络方法中,ISTA-Net⁺的重构图像中块效应较为明显,人脸与相机的分界线混杂。后三种方法的恢复图像较为平滑,视觉质量好,但 SPLNet 在细节的恢复对比上要恢复的更加精致。

在图 4 更高采样率下的恢复结果中, SPLNet 依旧在纹理与边缘的恢复效果上比其他算法做的更好, 船舱上的窗户, 门框等细节十分清楚. 这些实验结果展现出 SPLNet 在重构性能上的优越性, 证明了传统优化算法对神经网络设计思路的参考价值.

3.2.2 不同算法复杂度对比

时间复杂度代表了算法的实际运行速度, 是一个

表 3 SPLNet 与几种不同算法的平均 CPU/GPU 运行时间对比 (s)

	采样率	MH-SPL ^[6]	GSR ^[7]	ISTA-Net ⁺ ^[13]	CSNet ⁺ ^[17]	SCSNet ^[18]	SPLNet
平均 CPU/GPU 运行时间	0.1	15.0760/-	349.2018/-	1.0488/0.0150	0.7847/0.0142	0.5821/0.0326	0.7516/ 0.0115
	0.2	11.8490/-	345.9944/-	1.0535/0.0154	0.7972/0.0140	0.5761/0.0404	0.7585/ 0.0113
	0.3	9.7846/-	344.2104/-	1.0884/0.0153	0.7912/0.0142	0.5940/0.0490	0.7630/ 0.0114
	0.4	9.7642/-	344.7779/-	1.0482/0.0156	0.7941/0.0143	0.6132/0.0572	0.7602/ 0.0118
	0.5	9.2386/-	347.8691/-	1.0913/0.0153	0.7970/0.0138	0.6065/0.0647	0.7637/ 0.0118

3.2.3 不同网络设置的重构性能对比

在这一节中, 将通过改变 SPLNet 中不同的网络设置, 深入探索不同参数, 不同网络结构对 SPLNet 性能的影响. 实验设计主要从三个角度出发: (1) 双变量收缩结构 $BS^k(\cdot)$ 对网络性能带来的影响; (2) SPLBlock 个数 N_p 不同对最终重构效果的影响; (3) 限制损失与权重系数 ε 对网络训练效果的影响. 表 4 给出了在 0.5 采样率下, 不同结构与参数设定的 SPLNet 在 Set8 部分测试图像上的重构 PSNR/SSIM 结果, 其中第一行为 3.2.1 节中仿真实验所采用的原始实验设置, 而其余实验按照考察方向总共分为了三个对照组.

表 4 不同网络设置下 SPLNet 重构 PSNR (dB)/SSIM 结果对比

	阈值处理	N_p	ε	Parrot	Barbara	House	Lena
原	双变量收缩	3	0.01	40.27/0.9830	39.85/0.9865	42.68/0.9763	40.83/0.9867
①	无	3	0.01	38.79/0.9784	37.46/0.9774	41.77/0.9716	39.26/0.9807
	软阈值处理	3	0.01	36.65/0.9709	36.62/0.9714	40.16/0.9677	36.63/0.9684
②	双变量收缩	4	0.01	37.05/0.9741	36.79/0.9736	40.50/0.9704	36.89/0.9718
	双变量收缩	2	0.01	38.79/0.9795	37.81/0.9796	41.78/0.9723	39.23/0.9819
③	双变量收缩	3	0	37.24/0.9757	37.37/0.9772	40.79/0.9737	37.09/0.9740
	双变量收缩	3	0.1	40.13/0.9830	39.51/0.9858	42.84/0.9773	40.86/0.9868

第二组实验主要探索了在网络中, 深度重构子网络的迭代重构次数对网络恢复效果的影响. 在其他实验条件保持一致时, SPLBlock 个数为 4 的网络重构性能有较大的滑坡, 重构 PSNR 平均下降了 3dB 左右. 当网络结构复杂时, 优化过程更加依赖限制损失, 训练难度加大, 网络难以完全收敛. 在另一次实验的结果中, SPLBlock 数量过少也会导致深度重构过程精度不高, 降低最终的恢复图像质量, 在 PSNR 结果上大约下降了 1.5dB.

在最后一组实验中, 通过控制损失函数中的权重

重要的性能评价标准. 表 3 中给出了在测试数据集上 6 种算法重构单张图像的平均 CPU/GPU 运行时间, 其中传统优化算法只给出了 CPU 版本下的结果. 因为深度学习技术的优势, 神经网络的时间复杂度比传统优化算法降低许多. 其中, SPLNet 在 GPU 上运行时, 平均重构速度达到了对比算法中的最快, 展现出了网络设计的轻量与高效.

实验对照组①对双变量收缩结构的有效性进行讨论, 分别对两个实验条件下的网络进行了测试: (1) 将双变量收缩结构直接移除; (2) 将双变量收缩结构替换为 ISTA-Net 中的可学习软阈值结构. 从结果中可以看出, 在两种结构设置上, 网络的重构 PSNR 分别下降了 1~2dB 与 2~4dB, SSIM 结果也表现出类似的趋势. 该结果说明在 SPLNet 中, 双变量收缩结构 $BS^k(\cdot)$ 对最终的恢复性能带来了较大的正收益, 而 ISTA-Net 中的软阈值处理策略在此处并不适用, 会对性能造成反面影响.

ε , 对限制损失在网络训练中的作用进行了测试与分析. 在移除限制损失的情况下, 第一次实验中的网络重构效果出现了较为明显的降低, 在不同测试图像上平均下降了 2~3dB. 这证实了在训练过程中, 限制损失对 SPLNet 的收敛有较好的辅助作用. 第二次实验将权重 ε 从原设定中的 0.01 增大到 0.1, 进一步观察更大权重的辅助损失对 SPLNet 的效果影响. 在调整权重后, 网络的整体重构性能并没有出现特别大的变化, 说明在相同的迭代重构次数下, SPLNet 的训练过程对权重参数 ε 的大小并不是特别敏感.

4 结论

本文提出了一种全新的图像压缩感知神经网络 SPLNet,成功在神经网络中实现了传统 SPL 算法中的迭代过程,利用可学习的卷积层替代了原算法中的人工参数.通过将深度学习与迭代算法中的优化思路相结合,SPLNet 既保留了良好的数学特性与可解释性,又进一步提升了原始算法的重构性能.仿真实验表明,在与其他的图像压缩感知算法对比时,SPLNet 在恢复图像质量上取得了显著提升,并保持了较快的运行速度.此外,本文还通过消融实验,对 SPLNet 中的主要结构与参数进行了详细的分析与测试,验证了网络中各个部分的有效性.在未来的工作中,我们将尝试基于本文的工作,探索深度学习技术在视频压缩感知下的应用.

参考文献

- [1] Donoho D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289 – 1306.
- [2] Gan L. Block compressed sensing of natural images[A]. 2007 15th International Conference on Digital Signal Processing[C]. Cardiff: IEEE, 2007. 403 – 406.
- [3] Mun S, Fowler J E. Block compressed sensing of images using directional transforms[A]. 2009 16th IEEE International Conference on Image Processing (ICIP)[C]. Cairo: IEEE, 2009. 3021 – 3024.
- [4] Fowler J E, Mun S, Tramel E W. Multiscale block compressed sensing with smoothed projected landweber reconstruction[A]. 2011 19th European Signal Processing Conference[C]. Barcelona: IEEE, 2011. 564 – 568.
- [5] Mun S, Fowler J E. Residual reconstruction for block-based compressed sensing of video[A]. 2011 Data Compression Conference[C]. Snowbird: IEEE, 2011. 183 – 192.
- [6] Chen C, Tramel E W, Fowler J E. Compressed-sensing recovery of images and video using multihypothesis predictions[A]. 2011 Conference Record of the Forty Fifth Asilomar Conference on Signals, Systems and Computers (ASILOMAR)[C]. USA: IEEE, 2011. 1193 – 1198.
- [7] Zhang J, Zhao D, Gao W. Group-based sparse representation for image restoration[J]. IEEE Transactions on Image Processing, 2014, 23(8): 3336 – 3351.
- [8] Fan Q, Zhuo W, Tang C K, et al. Few-shot object detection with attention-RPN and multi-relation detector[A]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition [C]. USA: IEEE, 2020. 4013 – 4022.
- [9] Chen Z, Zhong B, Li G, et al. Siamesebox adaptive network for visual tracking[A]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition [C]. USA: IEEE, 2020. 6668 – 6677.
- [10] Xiang X, Tian Y, Zhang Y, et al. Zooming Slow-Mo: Fast and accurate one-stage space-time video super-resolution[A]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition [C]. USA: IEEE, 2020. 3370 – 3379.
- [11] Kulkarni K, Lohit S, Turaga P, et al. ReconNet: Non-iterative reconstruction of images from compressively sensed measurements[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. Las Vegas: IEEE, 2016. 449 – 458.
- [12] Yao H, Dai F, Zhang S, et al. DR2-Net: Deep residual reconstruction network for image compressive sensing[J]. Neurocomputing, 2019, 359: 483 – 493.
- [13] Zhang J, Ghanem B. ISTA-Net: Interpretable optimization-inspired deep network for image compressive sensing[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. Salt Lake City: IEEE, 2018. 1828 – 1837.
- [14] 练秋生, 富利鹏, 陈书贞, 等. 基于多尺度残差网络的压缩感知重构算法[J]. 自动化学报, 2019, 45(11): 2082 – 2091.
LIAN Qiu-sheng, FU Li-peng, CHEN Shu-zhen, et al. A compressed sensing algorithm based on multi-scale residual reconstruction network[J]. Acta Automatica Sinica, 2019, 45(11): 2082 – 2091. (in Chinese)
- [15] Shi W, Jiang F, Zhang S, et al. Deep networks for compressed image sensing[A]. 2017 IEEE International Conference on Multimedia and Expo (ICME) [C]. Hong Kong: IEEE, 2017. 877 – 882.
- [16] Shi W, Jiang F, Liu S, et al. Multi-scale deep networks for image compressed sensing[A]. 2018 25th IEEE International Conference on Image Processing (ICIP) [C]. Athens: IEEE, 2018. 46 – 50.
- [17] Shi W, Jiang F, Liu S, et al. Image Compressed sensing using convolutional neural network[J]. IEEE Transactions on Image Processing, 2019, 29: 375 – 388.
- [18] Shi W, Jiang F, Liu S, et al. Scalable convolutional neural network for image compressed sensing[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. Long Beach: IEEE, 2019. 12290 – 12299.
- [19] Cui W, Jiang F, Gao X, et al. Deep neural network based sparse measurement matrix for image compressed sensing[A]. 2018 25th IEEE International Conference on Image Processing (ICIP) [C]. Athens: IEEE, 2018. 3883 – 3887.
- [20] He K, Zhang X, Ren S, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification[A]. Proceedings of the IEEE International Conference on Computer Vision [C]. Seoul: IEEE, 2015. 1026

- 1034.

- [21] Arbelaez P, Maire M, Fowlkes C, et al. Contour detection and hierarchical image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 33(5): 898 - 916.
- [22] Kingma D P, Ba J. Adam: A Method for Stochastic Optimization [EB/OL]. <https://arxiv.org/abs/1412.6980>, 2014.
- [23] Abadi M, Barham P, Chen J, et al. Tensorflow: A system

for large-scale machine learning [A]. 12th {USENIX} Symposium on Operating Systems Design and Implementation ({OSDI} 16) [C]. Savannah: USENIX, 2016. 265 - 283.

- [24] Dong H, Supratak A, Mai L, et al. Tensorlayer: A versatile library for efficient deep learning development [A]. Proceedings of the 25th ACM International Conference on Multimedia [C]. USA: ACM, 2017. 1201 - 1204.

作者简介



裴翰奇 男, 1997 年生于江西抚州, 华南理工大学电子与信息学院研究生. 研究方向: 图像压缩感知.
E-mail: AsukaHellkite@outlook.com



魏志超 男, 1996 年生于河南禹州, 华南理工大学电子与信息学院研究生. 研究方向: 视频压缩感知.
E-mail: zcw781432@outlook.com



杨春玲 (通信作者) 女, 1970 年生于河南新乡, 华南理工大学电子与信息学院博士生导师. 研究方向: 图像/视频压缩编码, 图像质量评价.
E-mail: eeclyang@scut.edu.cn



曹燕 女, 1980 年生于重庆江津, 华南理工大学国家移动超声探测工程技术研究中心副教授. 研究方向: 声信号处理.
E-mail: eeyancao@scut.edu.cn