

(12) 按照专利合作条约所公布的国际申请

(19) 世界知识产权组织
国际局



(10) 国际公布号

WO 2023/019685 A1

(43) 国际公布日

2023 年 2 月 23 日 (23.02.2023)

(51) 国际专利分类号:

G06T 5/00 (2006.01)

G06N 3/04 (2006.01)

G06T 3/40 (2006.01)

G06N 3/08 (2006.01)

G06K 9/62 (2022.01)

(21) 国际申请号: PCT/CN2021/120521

(22) 国际申请日: 2021 年 9 月 26 日 (26.09.2021)

(25) 申请语言: 中文

(26) 公布语言: 中文

(30) 优先权:

202110940469.3 2021年8月17日 (17.08.2021) CN

(71) 申请人: 上海交通大学 (SHANGHAI JIAO TONG UNIVERSITY) [CN/CN]; 中国上海市闵行区东川路800号, Shanghai 200240 (CN)。

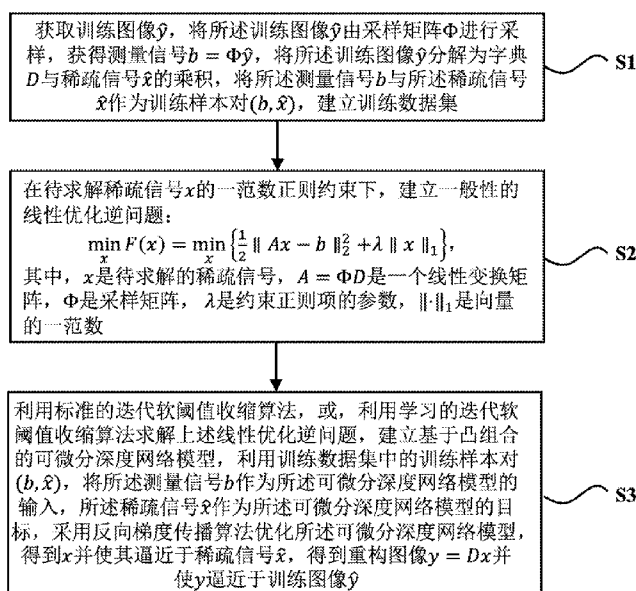
(72) 发明人: 戴文睿 (DAI, Wenrui); 中国上海市闵行区东川路800号, Shanghai 200240 (CN)。郑紫阳 (ZHENG, Ziyang); 中国上海市闵行区东川路800号, Shanghai 200240 (CN)。李成林 (LI, Chenglin); 中国上海市闵行区东川路800号, Shanghai 200240 (CN)。邹君妮 (ZOU, Junni); 中国上海市闵行区东川路800号, Shanghai 200240 (CN)。熊红凯 (XIONG, Hongkai); 中国上海市闵行区东川路800号, Shanghai 200240 (CN)。

(74) 代理人: 上海恒慧知识产权代理事务所 (特殊普通合伙) (SHANGHAI HENGHUI INTELLECTUAL PROPERTY AGENCY); 中国上海市徐汇区桂平路555号45幢6层603室徐红银, Shanghai 200233 (CN)。

(81) 指定国 (除另有指明, 要求每一种可提供的国家保护): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG,

(54) Title: IMAGE PROCESSING METHOD, SYSTEM AND APPARATUS, AND STORAGE MEDIUM

(54) 发明名称: 一种图像处理方法、系统、装置及存储介质



S1 Acquire a training image $\hat{y}$, sample the training image $\hat{y}$ by a sampling matrix Φ , obtain a measurement signal $b = \Phi\hat{y}$, decompose the training image $\hat{y}$ into the product of a dictionary D and a sparse signal $\hat{x}$, and establish a training data set by taking the measurement signal b and the sparse signal $\hat{x}$ as a training sample pair $(b, \hat{x})$, and establish a training data set

S2 Under a 1-norm regular constraint of a sparse signal x to be solved for, establish a general linear optimization inverse problem: [Equation 1], where x is the sparse signal to be solved for, $A = \Phi D$ is a linear transformation matrix, Φ is the sampling matrix, λ is a parameter of a constrained regular term, and $\|\cdot\|_1$ is a 1-norm of a vector

S3 Solve the linear optimization inverse problem by using a standard iterative shrinkage soft thresholding algorithm or using a learned iterative shrinkage soft thresholding algorithm; establish a differentiable deep network model based on a convex combination; and optimize the differentiable deep network model by using the training sample pair $(b, \hat{x})$ in the training data set, taking the measurement signal b as an input of the differentiable deep network model, taking the sparse signal $\hat{x}$ as an objective of the differentiable deep network model, and using a gradient back-propagation algorithm, obtain x and make x approximate the sparse signal $\hat{x}$, and obtain a reconstructed image $y = Dx$ and make y approximate the training image $\hat{y}$

图 1

(57) Abstract: Provided in the present invention are an image processing method, system and apparatus, and a storage medium, which are used for image sparse reconstruction, image denoising, compressed sensing image reconstruction or image restoration. The method comprises: under a 1-norm regular constraint of a sparse signal, establishing a general linear optimization inverse problem; on the basis of a standard or learned iterative shrinkage soft thresholding algorithm, establishing a differentiable deep network model based on a convex combination, so as to solve the problem; and introducing a deep neural network of any structure into a solution step, so as to accelerate the solution step, thereby reducing the number of iterations required by the algorithm to achieve convergence. By means of the present invention, a traditional iterative optimization algorithm and a deep neural network of any structure are combined, thereby

BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, IT, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS, ZA, ZM, ZW。

- (84) 指定国 (除另有指明, 要求每一种可提供的地区保护): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), 欧亚 (AM, AZ, BY, KG, KZ, RU, TJ, TM), 欧洲 (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG)。

本国际公布:

— 包括国际检索报告 (条约第21条(3))。

improving the image reconstruction performance, ensuring the fast convergence, and meeting the current requirements of image sparse reconstruction.

(57) 摘要: 本发明提供了一种图像处理方法、系统、装置及存储介质, 用于图像稀疏重构、图像去噪、压缩感知图像重构或图像复原, 包括: 在稀疏信号的一范数正则约束下建立一般性的线性优化逆问题; 在标准的或学习的迭代软阈值收缩算法基础上, 建立基于凸组合的可微分深度网络模型求解该问题; 在求解步骤中引入任意结构的深度神经网络加速求解步骤, 减少算法达到收敛所需的迭代次数。本发明将传统迭代优化算法和任意结构的深度神经网络结合, 提高图像重构性能, 并保证快速收敛, 满足图像稀疏重构的当前需求。

一种图像处理方法、系统、装置及存储介质

技术领域

本发明涉及信号处理领域，具体地，涉及一种图像处理方法、系统、装置及存储介质。

背景技术

随着媒体技术的发展，海量数据在实时传输、分析、存储方面都面临着巨大的挑战。比如媒体图像在各方面大量应用发展，对图像分辨率以及成像速度等提出更高需求，图像稀疏重构能解决由于图像信息量大而导致压缩过程中图像信号部分丢失、图像压缩效率低的问题，以便重构出应用所需要的图像。

针对上述的技术需求，已有研究人员提出了解决方法，比如中国专利 CN201611029446.2, CN106780636A，提出了一种图像的稀疏重构方法及装置，根据信号的压缩感知理论，将图像的重构问题转换为优化问题，并通过图像的压缩矩阵，确定了该优化问题中的待优化目标，对该优化目标进行多次的优化，根据优化结果获得该图像的稀疏系数矩阵，得到重构后的图像，从而不仅实现了图像的重构，而且通过提高整个优化过程的收敛速度和收敛能力，有效地降低了图像重构过程中软硬件资源的消耗，提高了图像的重构效率和重构精。再比如，中国专利申请 CN201811059265.3, CN109345453A，公开了一种利用标准化组稀疏规则化的图像超分辨率重构系统及方法，采用双线性插值方法得到图像超分辨率重构的初始估计值；然后再利用图像块组的标准化稀疏先验，通过多次迭代图像块组 PCA 域自适应软阈值滤波与图像像素域的规则化最小二乘，有效提升超分辨率图像重构的质量。

传统迭代优化方法通常具有收敛性保证，然而优化结构过于僵硬，且性能相较于深度神经网络差距较大。随着深度神经网络的发展，对于深度神经网络的应用也越来越多，比如中国专利申请 CN202110108699.3, CN112884851A，公开了一种展开迭代优化算法的深度压缩感知网络，该深度压缩感知网络应用于编码端图像自适应压缩采样，并在解码端利用优化算法引导深度神经网络结构设计，从而精确重建原始图像的方法。重构网络模块分为两部分：第一部分将快速迭代软阈值收缩优化算法（FISTA）展开为深度神经网络形式，第二部分使用一组卷积滤波器和非线性激活函数减少分块压缩感知带来的块伪影现象。

近年来，有学者结合深度学习及传统迭代优化方法，设计在优化理论指导下的可解释的

可微分深度神经网络模型。但是，当前可微分神经网络无法兼顾模型灵活性和理论收敛性，其中一些具备理论收敛性的方法对引入的网络参数有严格的维度和运算限制，而允许引入灵活的网络参数的方法却并不能从优化的角度论证方法的收敛性。因此，很难满足图像稀疏重构的当前需求。

发明内容

本发明针对现有技术的不足，提供了一种图像处理方法、系统、终端及存储介质，在迭代软阈值收缩算法的基础上引入无限制的网络学习参数，能重构出应用所需要的图像，满足图像稀疏重构的当前需求。

根据本发明的第一方面，提供一种图像处理方法，用于图像稀疏重构、图像去噪、压缩感知图像重构或图像复原，包括：

获取训练图像，将所述训练图像进行处理，获得测量信号；

将所述训练图像分解为字典与稀疏信号的乘积，将所述测量信号与所述稀疏信号作为训练样本对，建立训练数据集；

在一范数约束下，建立图像处理的线性逆问题；利用迭代软阈值收缩算法求解所述线性逆问题，根据所述迭代软阈值收缩算法与深度神经网络的凸组合，建立凸组合的可微分深度神经网络；

利用所述训练数据集中的训练样本对，将所述测量信号作为所述可微分深度网络模型的输入，所述稀疏信号作为所述可微分深度网络模型的目标，采用反向梯度传播算法优化所述可微分深度网络模型，得到重构稀疏信号，并使所述重构稀疏信号逼近于所述稀疏信号，得到最终图像，所述最终图像为所述字典与所述重构稀疏信号的乘积，且使所述最终图像逼近于所述训练图像。

可选地，将所述训练图像进行处理，获得测量信号，包括如下任一种：

- 当所述图像处理为图像稀疏重构时：获取训练图像 $\hat{y}$ ，将所述训练图像 $\hat{y}$ 由采样矩阵 Φ 进行采样，获得测量信号 $b = \Phi\hat{y}$ ；

- 当所述图像处理为图像去噪时：获取训练图像 $\hat{y}$ ，将所述训练图像 $\hat{y}$ 与噪声矩阵相加，获得测量信号 $\hat{b}$ ，该测量信号 $\hat{b}$ 为带噪图像；

- 当所述图像处理为压缩感知图像重构时：获取训练图像 $\hat{y}$ ，将所述训练图像 $\hat{y}$ 与一个随机采样矩阵 Φ 相乘，获得测量信号 $\hat{b} = \Phi\hat{y}$ ，该测量信号 $\hat{b}$ 为采样值；

- 当所述图像处理为图像复原时：获取训练图像 $\hat{y}$ ，将所述训练图像 $\hat{y}$ 与一个 0-1 对角采

样矩阵 $\tilde{\Phi}$ 相乘, 获得测量信号 $\tilde{b} = \tilde{\Phi}y$, 该测量信号为丢失像素点待复原的图像, 所述 0-1 对角采样矩阵 $\tilde{\Phi}$ 是一个对角矩阵, 且对角元素非 0 即 1。

可选地, 所述在一范数约束下, 建立图像处理的线性逆问题, 包括如下任一种:

- 当所述图像处理为图像稀疏重构时: 在重构稀疏信号 x 的一范数正则约束下, 建立一般性的线性优化逆问题:

$$\min_x F(x) = \min_x \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_1 \right\},$$

其中, x 是重构稀疏信号, $A = \Phi D$ 是一个线性变换矩阵, Φ 是采样矩阵, D 是字典, λ 是约束正则项的参数, $\|\cdot\|_1$ 是向量的一范数;

- 当所述图像处理为图像去噪时: 在一范数约束下, 建立图像去噪的线性逆问题:

$$\min_x \left\{ \frac{1}{2} \|\hat{A}x - \hat{b}\|_2^2 + \lambda \|x\|_1 \right\}, \text{ 其中 } x \text{ 是重构稀疏信号, 线性变换矩阵 } \hat{A} \text{ 为字典 } D, \text{ 即 } \hat{A} = D, \lambda \text{ 是约束正则项的参数, } \|\cdot\|_1 \text{ 是向量的一范数;}$$

- 当所述图像处理为压缩感知图像重构时: 在一范数约束下, 建立压缩感知图像重构的线性逆问题: $\min_x \left\{ \frac{1}{2} \|\hat{A}x - \hat{b}\|_2^2 + \lambda \|x\|_1 \right\}$, 其中 x 是重构稀疏信号, 线性变换矩阵 $\hat{A}$ 是随机采样矩阵 $\tilde{\Phi}$ 与字典 D 的乘积, 即 $\hat{A} = \tilde{\Phi}D$, λ 是约束正则项的参数, $\|\cdot\|_1$ 是向量的一范数;

- 当所述图像处理为图像复原时: 在一范数约束下, 建立图像复原的线性逆问题:

$$\min_x \left\{ \frac{1}{2} \|\tilde{A}x - \tilde{b}\|_2^2 + \lambda \|x\|_1 \right\}, \text{ 其中 } x \text{ 是重构稀疏信号, 线性变换矩阵 } \tilde{A} \text{ 是 0-1 对角采样矩阵 } \tilde{\Phi} \text{ 与字典 } D \text{ 的乘积, 即 } \tilde{A} = \tilde{\Phi}D, \lambda \text{ 是约束正则项的参数, } \|\cdot\|_1 \text{ 是向量的一范数。}$$

可选地, 所述利用迭代软阈值收缩算法求解所述线性逆问题, 包括利用标准的迭代软阈值收缩算法求解所述线性逆问题, 或, 利用学习的迭代软阈值收缩算法求解所述线性逆问题, 其中:

所述利用标准的迭代软阈值收缩算法求解所述线性逆问题, 具体为: $x^{n+1} = \text{prox}_{\|\cdot\|_1 \lambda t^n}(t^n A^T b + (I - t^n A^T A)x^n)$, 其中 x^n 表示在第 n 次迭代时求解所述线性逆问题得到的稀疏信号, A^T 表示矩阵 A 的转置, I 表示单位矩阵, t^n 表示第 n 次迭代时的步长; $\text{prox}_{\|\cdot\|_1 \lambda t^n}$ 表示在一范数约束 $\|\cdot\|_1$ 和超参数 λt^n 下的近端投影算子, 具体表示为求解优化问题: $\text{prox}_{\|\cdot\|_1 a}(x) = \underset{r}{\operatorname{argmin}} \left\{ \frac{1}{2} \|r - x\|_2^2 + a \|r\|_1 \right\}$, 其中 r 为近端投影算子表示的优化问题的求解目标变量, a 为阈值参数;

所述利用学习的迭代软阈值收缩算法求解所述线性逆问题, 具体为: $x^{n+1} = \text{prox}_{\|\cdot\|_1 \theta^n}(x^n + (W^n)^T(b - Ax^n))$, 其中 x^n 表示在第 n 次迭代时求解所述线性逆问题得到的

重构稀疏信号, W^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵, θ^n 表示在第 n 次迭代时的阈值参数。

可选地, 所述建立基于凸组合的可微分深度网络模型, 包括:

初始化得到未迭代时的稀疏信号 x^0 , 根据迭代软阈值收缩算法与深度神经网络的凸组合, 构建由 K 个凸组合块构成的可微分深度网络模型, 分别对应所述迭代软阈值收缩算法的第 $n = 1$ 至 $n = K$ 次迭代, 其中, 将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入, 通过凸组合块, 更新并得到第 n 个块对应输出 x^n , $n = 1, \dots, K$ 。

可选地, 所述可微分深度网络模型, 其损失函数定义为训练数据集中稀疏信号重构误差的均方误差 L_{MSE} :

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N \|\hat{x}_i - x_i\|_2^2;$$

上式中, N 为训练数据集中稀疏信号的数目, $\hat{x}_i$ 为训练数据集中第 i 个信号, x_i 为所述深度神经网络根据第 i 个信号 $\hat{x}_i$ 的测量信号 b_i 获得的重构稀疏信号。

可选地, 所述将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入, 通过凸组合块, 更新得到第 n 个块的输出 x^n , 具体包括:

第一近端投影: 根据输入 x^{n-1} , 基于所述迭代软阈值收缩算法求解, 输出第一近端投影 v^n ;

深度神经网络映射: 输入第一近端投影 v^n , 经过深度神经网络进行映射, 输出 u^n , 计算为 $u^n = \mathcal{N}_{p^n}(v^n)$, 其中 $\mathcal{N}_{p^n}$ 表示第 n 次迭代时引入的深度神经网络, p^n 表示需要神经网络训练得到的网络参数;

第二近端投影: 根据输入 u^n , 基于所述迭代软阈值收缩算法求解, 输出第二近端投影 w^n ;

凸组合计算: 输入第一近端投影 v^n 和第二近端投影 w^n , 输出第 n 次迭代的结果 x^n , 计算步骤为 $x^n = \alpha^n v^n + (1 - \alpha^n) w^n$, 其中 α^n 为介于 0 和 1 之间的需要神经网络训练得到的凸组合参数。

根据本发明的第二方面, 提供一种图像处理系统, 包括:

训练数据集建立模块: 获取训练图像, 将所述训练图像进行处理, 获得测量信号; 将所述训练图像分解为字典与稀疏信号的乘积, 将所述测量信号与所述稀疏信号作为训练样本对, 建立训练数据集;

可微分深度神经网络建立模块: 在一范数约束下, 建立图像处理的线性逆问题, 利用迭代软阈值收缩算法求解所述线性逆问题, 根据所述迭代软阈值收缩算法与深度神经网络的凸

组合，建立凸组合的可微分深度神经网络；

处理模块：利用所述训练数据集中的训练样本对，将所述测量信号作为所述可微分深度神经网络模型的输入，所述稀疏信号作为所述可微分深度神经网络模型的目标，采用反向梯度传播算法优化所述可微分深度神经网络模型，得到重构稀疏信号，并使所述重构稀疏信号逼近于所述稀疏信号，得到最终图像，所述最终图像为所述字典与所述重构稀疏信号的乘积，且使所述最终图像逼近于所述训练图像。

根据本发明的第三方面，提供一种图像处理装置，包括存储器、处理器及存储在存储器上并可在处理器上运行的计算机程序；所述处理器可用于执行所述计算机程序时可用于执行上述所述的图像处理方法。

根据本发明的第四方面，提供一种计算机可读存储介质，其上存储有计算机程序，该程序被处理器执行时可用于执行上述的图像处理方法。

根据本发明的第五方面，提供一种计算机程序产品，所述计算机程序产品包括存储了计算机程序的非瞬时性计算机可读存储介质，所述计算机程序可操作来使计算机执行所述的图像处理方法。

根据本发明的第六方面，提供一种芯片系统，包括处理器，所述处理器与存储器的耦合，所述存储器存储有程序指令，当所述存储器存储的程序指令被所述处理器执行时实现所述的图像处理方法。

根据本发明的第七方面，提供一种计算机设备，包括：

通信接口；

存储器，用于储存实现所述的图像处理方法的程序；

处理器，用于加载并执行所述存储器存储的程序，以实现所述的图像处理方法的各个步骤。

本发明与现有技术相比，具有如下至少一项的有益效果：

本发明提供的图像处理方法、装置及存储介质，相较于标准的深度神经网络方法，保证了重构精度的同时，可以从优化的角度解释网络架构，保证了网络训练的收敛性。

本发明提供的图像处理方法、装置及存储介质，相较于现有的可微分深度神经网络方法，保证了网络训练的收敛性同时，不限制引入的神经网络结构，具有更高的重构精度。

本发明提供的图像处理方法、装置及存储介质，相较于传统的迭代优化算法，提高了运算速度和重构精度。

附图说明

通过阅读参照以下附图对非限制性实施例所作的详细描述，本发明的其它特征、目的和优点将会变得更明显：

图 1 为本发明一优选实施例提供的基于深度神经网络的图像稀疏重构方法的流程图；

图 2 为本发明一优选实施例中建立网络模型求解线性逆问题的流程图；

图 3 为本发明一优选实施例中第 n 个凸组合块（ $n = 1, \dots, K$ ）的设计方法示意图。

具体实施方式

下面结合具体实施例对本发明进行详细说明。以下实施例将有助于本领域的技术人员进一步理解本发明，但不以任何形式限制本发明。应当指出的是，对本领域的普通技术人员来说，在不脱离本发明构思的前提下，还可以做出若干变形和改进。这些都属于本发明的保护范围。以下没有详细说明的部分可以采用现有技术实现。

本发明实施例提供的图像处理方法，可以用于图像稀疏重构、图像去噪、压缩感知图像重构或图像复原，其中，在稀疏信号的一范数正则约束下建立一般性的线性优化逆问题；在迭代软阈值收缩算法基础上，建立基于凸组合的可微分深度网络模型求解该问题；在求解步骤中引入任意结构的深度神经网络加速求解步骤，减少算法达到收敛所需的迭代次数。其中，图像稀疏重构时，采用基于迭代软阈值收缩算法，建立基于凸组合的可微分深度网络模型求解一般线性逆问题，且允许引入自由结构的深度神经网络提升性能，能够从图像的测量信号，恢复出稀疏信号，再根据稀疏信号重构出图像。其他实施例中的图像去噪、压缩感知图像重构和图像复原方法，可以看作这种图像稀疏重构方法一般化方法的具体应用，它们区别在于根据不同应用定义不同的测量信号、采样矩阵和线性变换，构成不同的训练集来训练可微分深度网络模型，用于对应的图像去噪、压缩感知图像重构和图像复原应用。

图 1 为本发明一优选实施例提供的基于深度神经网络的图像稀疏重构方法的流程图。

如图 1 所示，该优选实施例提供的图像稀疏重构方法，可以包括如下步骤：

S1，获取训练图像 $\hat{y}$ ，将训练图像 $\hat{y}$ 由采样矩阵 Φ 进行采样，获得测量信号 $b = \Phi\hat{y}$ ，将训练图像 $\hat{y}$ 分解为字典 D 与稀疏信号 $\hat{x}$ 的乘积，将测量信号 b 与稀疏信号 $\hat{x}$ 作为训练样本对 $(b, \hat{x})$ ，建立训练数据集。

测量信号是实际能够观测或者测量得到的信号。在训练时，训练图像已知，测量信号通过采样训练图像获得。具体的，在不同任务中测量信号的具体意义不同，例如图像去噪中为实际得到的有噪声图像，图像复原中为丢失像素点待复原的图像，压缩感知重构中为测量到

的采样值。

S2, 在重构稀疏信号 x 的一范数正则约束下, 建立一般性的线性优化逆问题:

$$\min_x F(x) = \min_x \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_1 \right\},$$

其中, x 是重构稀疏信号, $A = \Phi D$ 是一个线性变换矩阵, Φ 是采样矩阵, D 是字典, λ 是约束正则项的参数, $\|\cdot\|_1$ 是向量的一范数。

S3, 利用标准的迭代软阈值收缩算法, 或, 利用学习的迭代软阈值收缩算法求解上述线性优化逆问题, 建立基于凸组合的可微分深度网络模型, 利用训练数据集中的训练样本对 $(b, \hat{x})$, 将测量信号 b 作为可微分深度网络模型的输入, 稀疏信号 $\hat{x}$ 作为可微分深度网络模型的目标, 采用反向梯度传播算法优化可微分深度网络模型, 得到 x 并使其逼近于稀疏信号 $\hat{x}$, 得到重构图像 $y = Dx$ 并使 y 逼近于训练图像 $\hat{y}$ 。

本实施例中, 重构稀疏信号 x 是可微分深度网络模型的输出。稀疏信号 $\hat{x}$ 由于直接来自训练图像 $\hat{y}$, 仅用于训练可微分深度网络模型。

本发明上述实施例相较于标准的深度神经网络的图像重构方法, 保证了重构精度的同时, 可以从优化的角度解释网络架构, 保证了网络训练的收敛性。

如图2所示, 作为一优选实施例, S3可以包括如下步骤:

S31, 利用标准的迭代软阈值收缩算法, 或, 利用学习的迭代软阈值收缩算法求解线性优化逆问题。

具体的:

利用标准的迭代软阈值收缩算法求解线性逆问题, 具体为: $x^{n+1} = \text{prox}_{\|\cdot\|_1 \lambda t^n}(t^n A^T b + (I - t^n A^T A)x^n)$, 其中 x^n 表示在第 n 次迭代时求解线性逆问题得到的稀疏信号, A^T 表示矩阵 A 的转置, I 表示单位矩阵, t^n 表示第 n 次迭代时的步长; $\text{prox}_{\|\cdot\|_1 \lambda t^n}$ 表示在一范数约束 $\|\cdot\|_1$ 和超参数 λt^n 下的近端投影算子, 具体表示为求解优化问题: $\text{prox}_{\|\cdot\|_1 a}(x) = \underset{r}{\operatorname{argmin}} \left\{ \frac{1}{2} \|r - x\|_2^2 + a \|r\|_1 \right\}$, 其中 r 表示上述优化问题中的求解目标, a 表示阈值参数。

利用学习的迭代软阈值收缩算法求解线性逆问题, 具体为: $x^{n+1} = \text{prox}_{\|\cdot\|_1 \theta^n}(x^n + (W^n)^T(b - Ax^n))$, 其中 x^n 表示在第 n 次迭代时求解线性逆问题得到的稀疏信号, W^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵, θ^n 表示在第 n 次迭代时的阈值参数。

S32, 初始化得到未迭代时的稀疏信号 x^0 , 根据迭代软阈值收缩算法与深度神经网络的凸组合, 构建由 K 个凸组合块构成的可微分深度网络模型, 分别对应的标准的或学习的迭代软阈值收缩算法的第 $n = 1$ 至 $n = K$ 次迭代。其中, 将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块

的输入, 通过凸组合块, 更新并得到第 n 个块对应输出 x^n , $n = 1, \dots, K$ 。

作为一优选实施例, S32 根据 S31 中选择的迭代软阈值收缩算法, 构建相应的可微分深度神经网络模型, 相较于传统迭代优化算法可以在更少的时间复杂度和计算复杂度下达到相同的精度; 相较于标准的深度神经网络模型具有理论上的可收敛性和基于优化理论的可解释性。

如图 3 所示, 在该过程中, 作为一优选实施例, 将第 $n-1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入, 通过凸组合块, 更新得到第 n 个块的输出 x^n , 可以包括如下步骤:

S321, 第一近端投影: 输入 x^{n-1} , 基于标准的或学习的迭代软阈值收缩算法求解, 输出第一近端投影 v^n ; 基于标准的迭代软阈值收缩算法时, 计算步骤为 $v^n = \text{prox}_{\|\cdot\|_1 \lambda^n t^n} [t^n A^T b + (I - t^n A^T A)x^{n-1}]$, 其中 λ^n 和 t^n 分别表示在第 n 次迭代时需要神经网络训练得到的约束正则项的参数和步长; 基于学习的迭代软阈值收缩算法时, 计算步骤为 $v^n = \text{prox}_{\|\cdot\|_1 \theta_1^n} [x^{n-1} + (W_1^n)^T (b - Ax^{n-1})]$, 其中 W_1^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵。

S322, 深度神经网络映射: 输入第一近端投影 v^n , 经过深度神经网络进行映射, 输出 u^n , 计算步骤为 $u^n = \mathcal{N}_{p^n}(v^n)$, 其中 $\mathcal{N}_{p^n}$ 表示第 n 次迭代时引入的深度神经网络, p^n 表示需要神经网络训练得到的网络参数。

作为一优选实施例, S322 中的深度神经网络的结构在各个凸组合块中相同, 可适用任意组成结构, 包括但不限于卷积层、全连接层、非线性激活层、池化层、块归一化层、跳层连接等; 可学习参数通过反向传播算法最小化的稀疏信号重构的均方误差学习得到, 可以加速算法的收敛, 使算法相较于传统的或学习的迭代软阈值收缩算法, 可以在更少的时间复杂度和计算复杂度下达到相同的精度。

S323, 第二近端投影: 输入 u^n , 基于标准的或学习的迭代软阈值收缩算法求解, 输出第二近端投影 w^n ; 基于标准的迭代软阈值收缩算法时, 计算步骤为 $w^n = \text{prox}_{\|\cdot\|_1 \lambda^n t^n} [t^n A^T b + (I - t^n A^T A)u^n]$; 基于学习的迭代软阈值收缩算法时, 计算步骤为 $w^n = \text{prox}_{\|\cdot\|_1 \theta_2^n} [u^n + (W_2^n)^T (b - Au^n)]$, 其中 W_2^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵。

S324, 凸组合计算: 输入第一近端投影 v^n 和第二近端投影 w^n , 输出第 n 次迭代的结果 x^n , 计算步骤为 $x^n = \alpha^n v^n + (1 - \alpha^n)w^n$, 其中 α^n 为介于 0 和 1 之间的需要神经网络训练得到的凸组合参数。

S33, 利用训练数据集中的训练样本对 $(b, \hat{x})$, 将测量信号 b 作为可微分深度网络模型的输入, 将稀疏信号 $\hat{x}$ 作为可微分深度网络模型的目标, 将第 K 个块的输出 x^K 作为求解得到的

x , 采用反向梯度传播算法优化可微分深度网络模型的损失函数, 使 x^K 逼近于目标信号 $\hat{x}$ 。其中, 将可微分深度网络模型的损失函数定义为训练数据集中稀疏信号重构误差的均方误差 $L_{MSE} = \frac{1}{N} \sum_{i=1}^N \|\hat{x}_i - x_i^K\|_2^2$, 其中, N 为训练数据集中稀疏信号的数目, $\hat{x}_i$ 为训练数据集中第 i 个信号, x_i^K 为深度神经网络根据第 i 个信号 $\hat{x}_i$ 的测量信号 b_i 获得的第 K 个块的输出。

上述实施例中, S33 利用端到端地网络训练获得最优性能的网络参数, 相较于传统迭代优化算法中需要人工选取的超参数, 可以自适应的更新以获取更高的重构性能。

上述实施例中, S3 引入了任意合理可行的结构的深度神经网络模型, 构建了基于凸组合的可微分深度神经网络, 相较于传统迭代优化算法可以在更少的时间复杂度和计算复杂度下达到相同的精度; 相较于标准的深度神经网络模型具有理论上的可收敛性和基于优化理论的可解释性。

本发明上述实施例中, 凸组合块使用的深度神经网络结构相同, 可学习参数通过反向传播算法最小化的稀疏信号重构的均方误差学习得到, 可以加速算法的收敛, 使算法相较于传统的或学习的迭代软阈值收缩算法, 可以在更少的时间复杂度和计算复杂度下达到相同的精度。凸组合块使用的深度神经网络可适用任意组成结构, 包括但不限于卷积层、全连接层、非线性激活层、池化层、块归一化层、跳层连接等。

本发明上述实施例提供的基于深度神经网络的图像稀疏重构方法, 可应用于一般的线性逆问题求解及其相关实际应用场景, 如图像去噪、压缩感知、图像复原等。为了更好地理解, 以下结合具体应用实例对本发明上述实施例提供的技术方案进一步详细描述如下。

在该具体应用实例中, 实现稀疏信号重建, 具体的, 基于深度神经网络的图像稀疏重构方法包括以下 3 个主要步骤:

步骤 1, 获得若干稀疏的维度为 500 的训练图像 $\hat{y}$, 因 $\hat{y}$ 具有稀疏性, 所以可令字典 D 等于单位矩阵, 此时训练图像 $\hat{y}$ 与稀疏信号 $\hat{x}$ 相等。将训练图像 $\hat{y}$ 由给定的维度为 (250, 500) 的采样矩阵 Φ 进行采样, 获得测量信号 $b = \Phi \hat{y}$, 将测量信号 b 与稀疏信号 $\hat{x}$ 作为训练样本对 $(b, \hat{x})$, 建立训练数据集 Γ ;

步骤 2, 在重构稀疏信号 x 的一范数正则约束下, 建立一般性的线性优化逆问题:

$$\min_x F(x) = \min_x \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_1 \right\},$$

其中, x 是重构稀疏信号, 线性变换矩阵 A 与采样矩阵 Φ 相等, λ 是约束正则项的参数, $\|\cdot\|_1$ 是向量的一范数。

步骤 3, 利用学习的迭代软阈值收缩算法求解上述线性优化逆问题, 建立基于凸组合的

可微分深度网络模型，利用训练数据集中的训练样本对 $(b, \hat{x})$ ，将测量信号 b 作为可微分深度网络模型的输入，稀疏信号 $\hat{x}$ 作为可微分深度网络模型的目标，采用反向梯度传播算法优化可微分深度网络模型，得到 x 并使其逼近于稀疏信号 $\hat{x}$ ，得到重构图像 $y = x$ 并使 y 逼近于训练图像 $\hat{y}$ 。

步骤3中，利用学习的迭代软阈值收缩算法求解上述线性优化逆问题，具体为： $x^{n+1} = \text{prox}_{\|\cdot\|_1 \theta^n}(x^n + (W^n)^T(b - Ax^n))$ ，其中 x^n 表示在第 n 次迭代时求解线性逆问题得到的稀疏信号， W^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵， θ^n 表示在第 n 次迭代时的阈值参数。

步骤3中，建立基于凸组合的可微分深度网络模型，具体为：初始化得到未迭代时的稀疏信号 x^0 ，根据迭代软阈值收缩算法与深度神经网络的凸组合，构建由16个凸组合块构成的可微分深度网络模型，分别对应的标准的或学习的迭代软阈值收缩算法的第 $n = 1$ 至 $n = 16$ 次迭代。其中，将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入，通过凸组合块，更新并得到第 n 个块对应输出 x^n ， $n = 1, \dots, 16$ 。

上述的将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入，通过凸组合块，更新并得到第 n 个块对应输出 x^n ，具体包括如下步骤：

S321，第一近端投影：输入 x^{n-1} ，基于学习的迭代软阈值收缩算法，输出 $v^n = \text{prox}_{\|\cdot\|_1 \theta_1^n}[x^{n-1} + (W_1^n)^T(b - Ax^{n-1})]$ ，其中 W_1^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵。

S322，深度神经网络映射：输入第一近端投影 v^n ，经过深度神经网络进行映射，输出 u^n ，计算步骤为 $u^n = \mathcal{N}_{p^n}(v^n)$ ，其中 $\mathcal{N}_{p^n}$ 表示第 n 次迭代时引入的深度神经网络， p^n 表示需要神经网络训练得到的网络参数。

作为一具体应用实例，引入的深度神经网络包含三个维度分别为 $(9, 1, 16)$ 、 $(9, 16, 16)$ 、 $(9, 16, 1)$ 的卷积层，其中维度的含义为（卷积核的尺寸，输入信号的特征维度，输出信号的特征维度）。每个卷积层后有一个非线性激活单元 ReLU。第一个卷积层的输入信号和第三个卷积层的输出信号进行加法连接。

S323，第二近端投影：输入 u^n ，基于学习的迭代软阈值收缩算法，输出 $w^n = \text{prox}_{\|\cdot\|_1 \theta_2^n}[u^n + (W_2^n)^T(b - Au^n)]$ ，其中 W_2^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵。

S324，凸组合计算：输入第一近端投影 v^n 和第二近端投影 w^n ，输出第 n 次迭代的结果 x^n ，计算步骤为 $x^n = \alpha^n v^n + (1 - \alpha^n)w^n$ ，其中 α^n 为介于0和1之间的需要神经网络训练得到

的凸组合参数。

步骤3的利用训练数据集中的训练样本对 $(b, \hat{x})$ ，将测量信号 b 作为可微分深度网络模型的输入，稀疏信号 $\hat{x}$ 作为可微分深度网络模型的目标，根据线性变换矩阵 $A = \Phi$ 求解的线性优化逆问题，具体为：利用训练数据集中的训练样本对 $(b, \hat{x})$ ，将测量信号 b 作为可微分深度网络模型的输入，将稀疏信号 $\hat{x}$ 作为可微分深度网络模型的目标，将第16个块的输出 x^{16} 作为求解得到的 x ，采用反向梯度传播算法优化可微分深度网络模型的损失函数，使 x^{16} 逼近于目标信号 $\hat{x}$ 。其中，将可微分深度网络模型的损失函数定义为训练数据集中稀疏信号重构误差的均方误差 $L_{MSE} = \frac{1}{N} \sum_{i=1}^N \|\hat{x}_i - x_i^{16}\|_2^2$ ，其中， N 为训练数据集中稀疏信号的数目， $\hat{x}_i$ 为训练数据集中第 i 个信号， x_i^{16} 为深度神经网络根据第 i 个信号 $\hat{x}_i$ 的测量信号 b_i 获得的第16个块的输出。

在数值试验中，本实施例随机生成不同的500维的稀疏图像信号 $\hat{y}$ 用于模型训练，直至模型达到收敛条件，随机生成1000个不同的500维的稀疏图像信号 $\hat{y}'$ 用于模型测试。对于每个稀疏信号 $\hat{y}$ 和 $\hat{y}'$ ，用维度为 $(250, 500)$ 的高斯随机矩阵 Φ 作为采样矩阵，得到测量信号 b 和 b' ；在图像信号稀疏的情况下，令字典 D 等于单位矩阵，此时图像信号 $\hat{y}$ 与稀疏信号 $\hat{x}$ 相等， $\hat{y}'$ 与 $\hat{x}'$ 相等；将每个对应的稀疏信号 $\hat{x}$ 与测量信号 b 作为一个训练样本对 $(b, \hat{x})$ ，用于网络模型的训练，将每个对应的稀疏信号 $\hat{x}'$ 与测量信号 b' 作为一个测试样本对 $(b', \hat{x}')$ ，用于网络模型的测试。按照本实施例的基于深度神经网络的图像稀疏重构方法，设计网络结构，待模型训练完毕，将1000个稀疏测试信号的测量信号 b' 输入网络，得到网络的输出 x' 。计算测试的稀疏信号 $\hat{x}'$ 和深度神经网络输出的 x' 的归一化均方误差(NMSE)，以此作为性能评估准则，评估本实施例的基于任意神经网络结构的可收敛稀疏信号重构方法的性能。

本实施例比较了其他三种基于迭代软阈值收缩算法展开的稀疏信号重构方法，分别是在2018年的 *Conference and Workshop on Neural Information Processing Systems (NeurIPS)* 会议上发表的“Theoretical Linear Convergence of Unfolded ISTA and Its Practical Weights and Thresholds”中提出的 LISTA-CP 和 LISTA-CPSS 方法，以及在2019年的 *International Conference on Learning Representations (ICLR)* 会议上发表的“ALISTA: Analytic weights are as good as learned weights in LISTA”中提出的 ALISTA 方法。具体的对比试验结果如表1所示，评估标准为归一化均方误差(NMSE)，单位为dB，数值越低效果越好。

表1 实验结果表明，本实施例系统重建出来的信号在重构质量上明显优于另外三种方法得到的信号。另外三种方法均是现有的可微分深度神经网络模型，具有收敛性的保证，但

是由于限制引入的神经网络结构，因此性能收到限制。本实施例在提高重构精度的同时，依然可以保证理论的收敛性。

表 1: LISTA-CP、LISTA-CPSS、ALISTA 和本发明提出的方法（HLISTA）在稀疏信号重构时每一个可微分深度网络块上的 NMSE (dB)比较

块数	1	2	3	4	5	6	7	8
LISTA-CP	-3.97	-9.34	-10.50	-12.33	-16.28	-22.35	-26.10	-27.63
LISTA-CPSS	-4.65	-9.25	-11.26	-10.39	-15.28	-18.22	-18.08	-22.53
ALISTA	-3.96	-9.54	-10.49	-11.83	-18.00	-19.53	-20.84	-22.89
HLISTA	-7.32	-11.73	-14.80	-17.35	-19.48	-21.54	-23.55	-25.90
块数	9	10	11	12	13	14	15	16
LISTA-CP	-28.91	-31.33	-31.88	-32.75	-34.33	-35.15	-35.93	-36.77
LISTA-CPSS	-24.28	-27.60	-30.25	-33.35	-37.85	-42.25	-46.96	-50.96
ALISTA	-23.34	-23.96	-32.24	-36.90	-40.85	-44.12	-45.22	-48.91
HLISTA	-28.28	-31.21	-34.54	-38.88	-43.99	-50.62	-57.97	-66.51

在另一实施例中，本发明提供了一种图像去噪方法，可以包括如下步骤：

S100，获取训练图像 $\hat{y}$ ，将训练图像 $\hat{y}$ 与噪声矩阵相加，获得测量信号 $\dot{b}$ ，该测量信号 $\dot{b}$ 为带噪图像；将训练图像 $\hat{y}$ 分解为字典 D 与稀疏信号 $\hat{x}$ 的乘积；将每对稀疏信号 $\hat{x}$ 和带噪图像 $\dot{b}$ 作为一个训练样本对，建立训练数据集。

S101，在一范数约束下，建立图像去噪的线性逆问题：

$$\min_x \left\{ \frac{1}{2} \| \dot{A}x - \dot{b} \|_2^2 + \lambda \| x \|_1 \right\},$$

其中 x 是重构稀疏信号，线性变换矩阵 $\dot{A}$ 为字典 D ，即 $\dot{A} = D$ ， λ 是约束正则项的参数， $\|\cdot\|_1$ 是向量的一范数。

S102，利用标准的迭代软阈值收缩算法，或，利用学习的迭代软阈值收缩算法求解上述图像去噪的线性逆问题，建立凸组合的可微分深度神经网络，利用训练数据集中的训练样本对，将测量信号 $\dot{b}$ 作为可微分深度网络模型的输入，稀疏信号 $\hat{x}$ 作为可微分深度网络模型的目标，采用反向梯度传播算法优化可微分深度网络模型，得到 x 并使其逼近于稀疏信号 $\hat{x}$ ，得到

重构图像 $y = Dx$ 并使 y 逼近于训练图像 $\hat{y}$ 。

作为一实施例，S102 可以包括如下步骤：

S1021，利用标准的迭代软阈值收缩算法，或，利用学习的迭代软阈值收缩算法求解线性优化逆问题，包括：

利用标准的迭代软阈值收缩算法求解线性逆问题，具体为： $x^{n+1} = \text{prox}_{\|\cdot\|_1 \lambda t^n} (t^n \dot{A}^T \dot{b} + (I - t^n \dot{A}^T \dot{A})x^n)$ ，其中 x^n 表示在第 n 次迭代时求解线性逆问题得到的稀疏信号， $\dot{A}^T$ 表示矩阵 $\dot{A}$ 的转置， I 表示单位矩阵， t^n 表示第 n 次迭代时的步长； $\text{prox}_{\|\cdot\|_1 \lambda t^n}$ 表示在一范数约束 $\|\cdot\|_1$ 和超参数 λt^n 下的近端投影算子，具体表示为求解优化问题： $\text{prox}_{\|\cdot\|_1 a}(x) = \underset{r}{\operatorname{argmin}} \left\{ \frac{1}{2} \|r - x\|_2^2 + a \|r\|_1 \right\}$ ，其中 r 表示上述优化问题中的求解目标， a 表示阈值参数；

利用学习的迭代软阈值收缩算法求解线性逆问题，具体为： $x^{n+1} = \text{prox}_{\|\cdot\|_1 \theta^n} (x^n + (W^n)^T (\dot{b} - \dot{A}x^n))$ ，其中 x^n 表示在第 n 次迭代时求解线性逆问题得到的稀疏信号， W^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵， θ^n 表示在第 n 次迭代时的阈值参数。

S1022，初始化得到未迭代时的稀疏信号 x^0 ，根据迭代软阈值收缩算法与深度神经网络的凸组合，构建由 K 个凸组合块构成的可微分深度网络模型，分别对应的标准的或学习的迭代软阈值收缩算法的第 $n = 1$ 至 $n = K$ 次迭代。其中，将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入，通过凸组合块，更新并得到第 n 个块对应输出 x^n ， $n = 1, \dots, K$ 。

在该过程中，将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入，通过凸组合块，更新得到第 n 个块的输出 x^n ，可以包括如下步骤：

S10221，第一近端投影：输入 x^{n-1} ，基于标准的或学习的迭代软阈值收缩算法求解，输出第一近端投影 v^n ；基于标准的迭代软阈值收缩算法时，计算步骤为 $v^n = \text{prox}_{\|\cdot\|_1 \lambda^n t^n} [t^n \dot{A}^T \dot{b} + (I - t^n \dot{A}^T \dot{A})x^{n-1}]$ ，其中 λ^n 和 t^n 分别表示在第 n 次迭代时需要神经网络训练得到的约束正则项的参数和步长；基于学习的迭代软阈值收缩算法时，计算步骤为 $v^n = \text{prox}_{\|\cdot\|_1 \theta_1^n} [x^{n-1} + (W_1^n)^T (\dot{b} - \dot{A}x^{n-1})]$ ，其中 W_1^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵。

S10222，深度神经网络映射：输入第一近端投影 v^n ，经过深度神经网络进行映射，输出 u^n ，计算步骤为 $u^n = \mathcal{N}_{p^n}(v^n)$ ，其中 $\mathcal{N}_{p^n}$ 表示第 n 次迭代时引入的深度神经网络， p^n 表示需要神经网络训练得到的网络参数。

作为一优选实施例，S10222 中的深度神经网络的结构在各个凸组合块中相同，可适用任意组成结构，包括但不限于卷积层、全连接层、非线性激活层、池化层、块归一化层、跳

层连接等；可学习参数通过反向传播算法最小化的稀疏信号重构的均方误差学习得到，可以加速算法的收敛，使算法相较于传统的或学习的迭代软阈值收缩算法，可以在更少的时间复杂度和计算复杂度下达到相同的精度。

S10223，第二近端投影：输入 u^n ，基于标准的或学习的迭代软阈值收缩算法求解，输出第二近端投影 w^n ；基于标准的迭代软阈值收缩算法时，计算步骤为 $w^n = \text{prox}_{\|\cdot\|_1 \lambda^n t^n} [t^n \dot{A}^T \dot{b} + (I - t^n \dot{A}^T \dot{A})u^n]$ ；基于学习的迭代软阈值收缩算法时，计算步骤为 $w^n = \text{prox}_{\|\cdot\|_1 \theta_2^n} [u^n + (W_2^n)^T (\dot{b} - \dot{A}u^n)]$ ，其中 W_2^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵。

S10224，凸组合计算：输入第一近端投影 v^n 和第二近端投影 w^n ，输出第 n 次迭代的结果 x^n ，计算步骤为 $x^n = \alpha^n v^n + (1 - \alpha^n)w^n$ ，其中 α^n 为介于 0 和 1 之间的需要神经网络训练得到的凸组合参数。

S1023，利用训练数据集中的训练样本对 $(\dot{b}, \hat{x})$ ，将测量信号 $\dot{b}$ 作为可微分深度网络模型的输入，将稀疏信号 $\hat{x}$ 作为可微分深度网络模型的目标，将第 K 个块的输出 x^K 作为求解得到的 x ，采用反向梯度传播算法优化可微分深度网络模型的损失函数，使 x^K 逼近于目标信号 $\hat{x}$ 。其中，将可微分深度网络模型的损失函数定义为训练数据集中稀疏信号重构误差的均方误差 $L_{MSE} = \frac{1}{N} \sum_{i=1}^N \|\hat{x}_i - x_i^K\|_2^2$ ，其中， N 为训练数据集中稀疏信号的数目， $\hat{x}_i$ 为训练数据集中第 i 个信号， x_i^K 为深度神经网络与 $\hat{x}_i$ 对应的第 K 个块的输出。

在该具体应用实例中，实现自然图像的去高斯噪声，并比较了在 2019 年的 *International Conference on Learning Representations (ICLR)* 会议上发表的“ALISTA: Analytic weights are as good as learned weights in LISTA”中提出的 ALISTA 方法。评估标准为峰值信噪比(PSNR)，单位为 dB。实验结果表明，在高斯噪声信噪比 30 分贝的实验条件下，本实施例系统重建出来的自然图像的 PSNR 高于 ALISTA 方法获得的自然图像约 1dB，即本实施例系统去高斯噪声的效果优于 ALISTA 方法。

在本发明另一实施例中，还提供一种压缩感知图像重构方法，可以包括如下步骤：

S200，获取训练图像 $\hat{y}$ ，将训练图像 $\hat{y}$ 与一个随机采样矩阵 $\hat{\Phi}$ 相乘，获得测量信号 $\hat{b} = \hat{\Phi}\hat{y}$ ，该测量信号 $\hat{b}$ 为采样值；将训练图像 $\hat{y}$ 分解为字典 D 与稀疏信号 $\hat{x}$ 的乘积，将每对稀疏信号 $\hat{x}$ 和采样值 $\hat{b}$ 作为一个训练样本对，建立训练数据集。

S201，在一范数约束下，建立压缩感知图像重构的线性逆问题：

$$\min_x \left\{ \frac{1}{2} \|\hat{A}x - \hat{b}\|_2^2 + \lambda \|x\|_1 \right\},$$

其中 $\mathbf{x}$ 是重构稀疏信号，线性变换矩阵 $\hat{A}$ 是随机采样矩阵 $\hat{\Phi}$ 与字典 D 的乘积，即 $\hat{A} = \hat{\Phi}D$ ， λ 是约束正则项的参数， $\|\cdot\|_1$ 是向量的一范数。

S202，利用标准的迭代软阈值收缩算法，或，利用学习的迭代软阈值收缩算法求解上述压缩感知图像重构的线性逆问题，建立凸组合的可微分深度神经网络，利用训练数据集中的训练样本对，将测量信号 $\hat{\mathbf{b}}$ 作为可微分深度网络模型的输入，稀疏信号 $\hat{\mathbf{x}}$ 作为可微分深度网络模型的目标，采用反向梯度传播算法优化可微分深度网络模型，得到 $\mathbf{x}$ 并使其逼近于稀疏信号 $\hat{\mathbf{x}}$ ，得到重构图像 $\mathbf{y} = D\mathbf{x}$ 并使其逼近于训练图像 $\hat{\mathbf{y}}$ 。

作为一实施例，S202 可以包括如下步骤：

S2021，利用标准的迭代软阈值收缩算法，或，利用学习的迭代软阈值收缩算法求解线性优化逆问题，包括：

利用标准的迭代软阈值收缩算法求解线性逆问题，具体为： $\mathbf{x}^{n+1} = \text{prox}_{\|\cdot\|_1 \lambda t^n} (t^n \hat{A}^T \hat{\mathbf{b}} + (I - t^n \hat{A}^T \hat{A}) \mathbf{x}^n)$ ，其中 $\mathbf{x}^n$ 表示在第 n 次迭代时求解线性逆问题得到的稀疏信号， $\hat{A}^T$ 表示矩阵 $\hat{A}$ 的转置， I 表示单位矩阵， t^n 表示第 n 次迭代时的步长； $\text{prox}_{\|\cdot\|_1 \lambda t^n}$ 表示在一范数约束 $\|\cdot\|_1$ 和超参数 λt^n 下的近端投影算子，具体表示为求解优化问题： $\text{prox}_{\|\cdot\|_1 \lambda t^n}(\mathbf{x}) = \underset{\mathbf{r}}{\text{argmin}} \left\{ \frac{1}{2} \|\mathbf{r} - \mathbf{x}\|_2^2 + \alpha \|\mathbf{r}\|_1 \right\}$ ，其中 $\mathbf{r}$ 表示上述优化问题中的求解目标， α 表示阈值参数；

利用学习的迭代软阈值收缩算法求解线性逆问题，具体为： $\mathbf{x}^{n+1} = \text{prox}_{\|\cdot\|_1 \theta^n} (\mathbf{x}^n + (W^n)^T (\hat{\mathbf{b}} - \hat{A} \mathbf{x}^n))$ ，其中 $\mathbf{x}^n$ 表示在第 n 次迭代时求解线性逆问题得到的稀疏信号， W^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵， θ^n 表示在第 n 次迭代时的阈值参数。

S2022，初始化得到未迭代时的稀疏信号 $\mathbf{x}^0$ ，根据迭代软阈值收缩算法与深度神经网络的凸组合，构建由 K 个凸组合块构成的可微分深度网络模型，分别对应的标准的或学习的迭代软阈值收缩算法的第 $n = 1$ 至 $n = K$ 次迭代。其中，将第 $n - 1$ 个块的输出 $\mathbf{x}^{n-1}$ 作为对第 n 个块的输入，通过凸组合块，更新并得到第 n 个块对应输出 $\mathbf{x}^n$ ， $n = 1, \dots, K$ 。

在该过程中，将第 $n - 1$ 个块的输出 $\mathbf{x}^{n-1}$ 作为对第 n 个块的输入，通过凸组合块，更新得到第 n 个块的输出 $\mathbf{x}^n$ ，可以包括如下步骤：

S20221，第一近端投影：输入 $\mathbf{x}^{n-1}$ ，基于标准的或学习的迭代软阈值收缩算法求解，输出第一近端投影 $\mathbf{v}^n$ ；基于标准的迭代软阈值收缩算法时，计算步骤为 $\mathbf{v}^n = \text{prox}_{\|\cdot\|_1 \lambda^n t^n} [t^n \hat{A}^T \hat{\mathbf{b}} + (I - t^n \hat{A}^T \hat{A}) \mathbf{x}^{n-1}]$ ，其中 λ^n 和 t^n 分别表示在第 n 次迭代时需要神经网络训练得到的约束正则项的参数和步长；基于学习的迭代软阈值收缩算法时，计算步骤为 $\mathbf{v}^n = \text{prox}_{\|\cdot\|_1 \theta_1^n} [\mathbf{x}^{n-1} + (W_1^n)^T (\hat{\mathbf{b}} - \hat{A} \mathbf{x}^{n-1})]$ ，其中 W_1^n 表示在第 n 次迭代时需要神经网络训练得到

的系数矩阵。

S20222, 深度神经网络映射: 输入第一近端投影 v^n , 经过深度神经网络进行映射, 输出 u^n , 计算步骤为 $u^n = \mathcal{N}_{p^n}(v^n)$, 其中 $\mathcal{N}_{p^n}$ 表示第 n 次迭代时引入的深度神经网络, p^n 表示需要神经网络训练得到的网络参数。

作为一优选实施例, S20222 中的深度神经网络的结构在各个凸组合块中相同, 可适用任意组成结构, 包括但不限于卷积层、全连接层、非线性激活层、池化层、块归一化层、跳层连接等; 可学习参数通过反向传播算法最小化的稀疏信号重构的均方误差学习得到, 可以加速算法的收敛, 使算法相较于传统的或学习的迭代软阈值收缩算法, 可以在更少的时间复杂度和计算复杂度下达到相同的精度。

S20223, 第二近端投影: 输入 u^n , 基于标准的或学习的迭代软阈值收缩算法求解, 输出第二近端投影 w^n ; 基于标准的迭代软阈值收缩算法时, 计算步骤为 $w^n = \text{prox}_{\|\cdot\|_1 \lambda^n t^n} [t^n \hat{A}^T \hat{b} + (I - t^n \hat{A}^T \hat{A})u^n]$; 基于学习的迭代软阈值收缩算法时, 计算步骤为 $w^n = \text{prox}_{\|\cdot\|_1 \theta_2^n} [u^n + (W_2^n)^T (\hat{b} - \hat{A}u^n)]$, 其中 W_2^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵。

S20224, 凸组合计算: 输入第一近端投影 v^n 和第二近端投影 w^n , 输出第 n 次迭代的结果 x^n , 计算步骤为 $x^n = \alpha^n v^n + (1 - \alpha^n)w^n$, 其中 α^n 为介于 0 和 1 之间的需要神经网络训练得到的凸组合参数。

S2023, 利用训练数据集中的训练样本对 $(\hat{b}, \hat{x})$, 将测量信号 $\hat{b}$ 作为可微分深度网络模型的输入, 将稀疏信号 $\hat{x}$ 作为可微分深度网络模型的目标, 将第 K 个块的输出 x^K 作为求解得到的 x , 采用反向梯度传播算法优化可微分深度网络模型的损失函数, 使 x^K 逼近于目标信号 $\hat{x}$ 。其中, 将可微分深度网络模型的损失函数定义为训练数据集中稀疏信号重构误差的均方误差 $L_{MSE} = \frac{1}{N} \sum_{i=1}^N \|\hat{x}_i - x_i^K\|_2^2$, 其中, N 为训练数据集中稀疏信号的数目, $\hat{x}_i$ 为训练数据集中第 i 个信号, x_i^K 为深度神经网络与 $\hat{x}_i$ 对应的第 K 个块的输出。

在该具体应用实例中, 实现自然图像的压缩感知重构, 并比较了其他三种基于迭代软阈值收缩算法展开的稀疏信号重构方法, 分别是在 2018 年的 *Conference and Workshop on Neural Information Processing Systems (NeurIPS)* 会议上发表的“Theoretical Linear Convergence of Unfolded ISTA and Its Practical Weights and Thresholds”中提出的 LISTA-CP 和 LISTA-CPSS 方法, 以及在 2019 年的 *International Conference on Learning Representations (ICLR)* 会议上发表的“ALISTA: Analytic weights are as good as learned weights in LISTA”中提出的 ALISTA 方

法。评估标准为峰值信噪比 (PSNR)，单位为 dB。实验结果表明，在采样率为百分之 50 的实验条件下，本实施例系统重建出来的自然图像的 PSNR 分别高于 LISTA-CP 方法、LISTA-CPSS 方法和 ALISTA 方法获得的自然图像 0.95、0.90 和 0.98dB。

在本发明另一实施例中，还提供一种图像复原方法，可以包括如下步骤：

S300，获取训练图像 $\hat{y}$ ，将训练图像 $\hat{y}$ 与一个 0-1 对角采样矩阵 $\tilde{\Phi}$ 相乘，获得测量信号 $\tilde{b} = \tilde{\Phi}\hat{y}$ ，该测量信号为丢失像素点待复原的图像，0-1 对角采样矩阵 $\tilde{\Phi}$ 是一个对角矩阵，且对角元素非 0 即 1；将训练图像 $\hat{y}$ 分解为字典 D 与稀疏信号 $\hat{x}$ 的乘积；将每对稀疏信号 $\hat{x}$ 和丢失像素点待复原的图像 $\tilde{b}$ 作为一个训练样本对，建立训练数据集。

S301，在一范数约束下，建立图像复原的线性逆问题：

$$\min_x \left\{ \frac{1}{2} \| \tilde{A}x - \tilde{b} \|_2^2 + \lambda \| x \|_1 \right\},$$

其中 x 是重构稀疏信号，线性变换矩阵 $\tilde{A}$ 是 0-1 对角采样矩阵 $\tilde{\Phi}$ 与字典 D 的乘积，即 $\tilde{A} = \tilde{\Phi}D$ ， λ 是约束正则项的参数， $\|\cdot\|_1$ 是向量的一范数。

S302，利用标准的迭代软阈值收缩算法，或，利用学习的迭代软阈值收缩算法求解上述图像复原的线性逆问题，建立凸组合的可微分深度神经网络，利用训练数据集中的训练样本对，将测量信号 $\tilde{b}$ 作为可微分深度网络模型的输入，稀疏信号 $\hat{x}$ 作为可微分深度网络模型的目标，采用反向梯度传播算法优化可微分深度网络模型，得到 x 并使其逼近于稀疏信号 $\hat{x}$ ，得到重构图像 $y = Dx$ 并使 y 逼近于训练图像 $\hat{y}$ 。

作为一实施例，S302 可以包括如下步骤：

S3021，利用标准的迭代软阈值收缩算法，或，利用学习的迭代软阈值收缩算法求解线性优化逆问题，包括：

S30211，利用标准的迭代软阈值收缩算法求解线性逆问题，具体为： $x^{n+1} = \text{prox}_{\|\cdot\|_1 \lambda t^n} (t^n \tilde{A}^T \tilde{b} + (I - t^n \tilde{A}^T \tilde{A})x^n)$ ，其中 x^n 表示在第 n 次迭代时求解线性逆问题得到的稀疏信号， $\tilde{A}^T$ 表示矩阵 $\tilde{A}$ 的转置， I 表示单位矩阵， t^n 表示第 n 次迭代时的步长； $\text{prox}_{\|\cdot\|_1 \lambda t^n}$ 表示在一范数约束 $\|\cdot\|_1$ 和超参数 λt^n 下的近端投影算子，具体表示为求解优化问题： $\text{prox}_{\|\cdot\|_1 \lambda t^n}(x) = \underset{r}{\operatorname{argmin}} \left\{ \frac{1}{2} \|r - x\|_2^2 + a \|r\|_1 \right\}$ ，其中 r 表示上述优化问题中的求解目标， a 表示阈值参数；

S30212，利用学习的迭代软阈值收缩算法求解线性逆问题，具体为： $x^{n+1} = \text{prox}_{\|\cdot\|_1 \theta^n} (x^n + (W^n)^T (\tilde{b} - \tilde{A}x^n))$ ，其中 x^n 表示在第 n 次迭代时求解线性逆问题得到的稀疏信号， W^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵， θ^n 表示在第 n 次迭代时的阈值参数。

S3022, 初始化得到未迭代时的稀疏信号 x^0 , 根据迭代软阈值收缩算法与深度神经网络的凸组合, 构建由 K 个凸组合块构成的可微分深度网络模型, 分别对应的标准的或学习的迭代软阈值收缩算法的第 $n = 1$ 至 $n = K$ 次迭代。其中, 将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入, 通过凸组合块, 更新并得到第 n 个块对应输出 x^n , $n = 1, \dots, K$ 。

在该过程中, 将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入, 通过凸组合块, 更新得到第 n 个块的输出 x^n , 可以包括如下步骤:

S30221, 第一近端投影: 输入 x^{n-1} , 基于标准的或学习的迭代软阈值收缩算法求解, 输出第一近端投影 v^n ; 基于标准的迭代软阈值收缩算法时, 计算步骤为 $v^n = \text{prox}_{\|\cdot\|_1 \lambda^n t^n} [t^n \tilde{A}^T \tilde{b} + (I - t^n \tilde{A}^T \tilde{A})x^{n-1}]$, 其中 λ^n 和 t^n 分别表示在第 n 次迭代时需要神经网络训练得到的约束正则项的参数和步长; 基于学习的迭代软阈值收缩算法时, 计算步骤为 $v^n = \text{prox}_{\|\cdot\|_1 \theta_1^n} [x^{n-1} + (W_1^n)^T (\tilde{b} - \tilde{A}x^{n-1})]$, 其中 W_1^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵。

S30222, 深度神经网络映射: 输入第一近端投影 v^n , 经过深度神经网络进行映射, 输出 u^n , 计算步骤为 $u^n = \mathcal{N}_{p^n}(v^n)$, 其中 $\mathcal{N}_{p^n}$ 表示第 n 次迭代时引入的深度神经网络, p^n 表示需要神经网络训练得到的网络参数。

作为一优选实施例, S30222 中的深度神经网络的结构在各个凸组合块中相同, 可适用任意组成结构, 包括但不限于卷积层、全连接层、非线性激活层、池化层、块归一化层、跳层连接等; 可学习参数通过反向传播算法最小化的稀疏信号重构的均方误差学习得到, 可以加速算法的收敛, 使算法相较于传统的或学习的迭代软阈值收缩算法, 可以在更少的时间复杂度和计算复杂度下达到相同的精度。

S30223, 第二近端投影: 输入 u^n , 基于标准的或学习的迭代软阈值收缩算法求解, 输出第二近端投影 w^n ; 基于标准的迭代软阈值收缩算法时, 计算步骤为 $w^n = \text{prox}_{\|\cdot\|_1 \lambda^n t^n} [t^n \tilde{A}^T \tilde{b} + (I - t^n \tilde{A}^T \tilde{A})u^n]$; 基于学习的迭代软阈值收缩算法时, 计算步骤为 $w^n = \text{prox}_{\|\cdot\|_1 \theta_2^n} [u^n + (W_2^n)^T (\tilde{b} - \tilde{A}u^n)]$, 其中 W_2^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵。

S30224, 凸组合计算: 输入第一近端投影 v^n 和第二近端投影 w^n , 输出第 n 次迭代的结果 x^n , 计算步骤为 $x^n = \alpha^n v^n + (1 - \alpha^n)w^n$, 其中 α^n 为介于 0 和 1 之间的需要神经网络训练得到的凸组合参数。

S3023, 利用训练数据集中的训练样本对 $(\tilde{b}, \hat{x})$, 将测量信号 $\tilde{b}$ 作为可微分深度网络模型

的输入，将稀疏信号 $\hat{x}$ 作为可微分深度网络模型的目标，将第 K 个块的输出 x^K 作为求解得到的 x ，采用反向梯度传播算法优化可微分深度网络模型的损失函数，使 x^K 逼近于目标信号 $\hat{x}$ 。其中，将可微分深度网络模型的损失函数定义为训练数据集中稀疏信号重构误差的均方误差 $L_{MSE} = \frac{1}{N} \sum_{i=1}^N \|\hat{x}_i - x_i^K\|_2^2$ ，其中， N 为训练数据集中稀疏信号的数目， $\hat{x}_i$ 为训练数据集中第 i 个信号， x_i^K 为深度神经网络与 $\hat{x}_i$ 对应的第 K 个块的输出。

在该具体应用实例中，实现医学核磁共振图像的复原，并比较了在 2018 年的 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* 会议上发表的“ISTA-Net: Interpretable Optimization-Inspired Deep Network for Image Compressive Sensing”中提出的 ISTA-Net 方法。评估标准为峰值信噪比 (PSNR)，单位为 dB。实验结果表明，在丢失像素点百分之 20 的实验条件下，本实施例系统重建出来的医学图像的 PSNR 高于 ISTA-Net 方法获得的医学图像约 1.5dB。

基于上述相同的技术构思，本发明另一实施例中，提供一种图像处理系统，用于实现上述实施例中的图像处理方法，实现图像稀疏重构、图像去噪、压缩感知图像重构或图像复原等目的。具体的，图像处理系统包括：

训练数据集建立模块：获取训练图像，将训练图像进行处理，获得测量信号；将训练图像分解为字典与稀疏信号的乘积，将测量信号与稀疏信号作为训练样本对，建立训练数据集；

可微分深度神经网络建立模块：在一范数约束下，建立图像处理的线性逆问题，利用迭代软阈值收缩算法求解线性逆问题，根据迭代软阈值收缩算法与深度神经网络的凸组合，建立凸组合的可微分深度神经网络；

处理模块：利用训练数据集中的训练样本对，将测量信号作为可微分深度网络模型的输入，稀疏信号作为可微分深度网络模型的目标，采用反向梯度传播算法优化可微分深度网络模型，得到重构稀疏信号，并使重构稀疏信号逼近于稀疏信号，得到最终图像，最终图像为字典与重构稀疏信号的乘积，且使最终图像逼近于训练图像。

本发明在另一实施例中，还提供一种图像处理装置，包括存储器、处理器及存储在存储器上并可在处理器上运行的计算机程序，处理器执行程序时可用于执行上述实施例中任一项的方法。

可选地，存储器，用于存储程序；存储器，可以包括易失性存储器（英文：volatile memory），例如随机存取存储器（英文：random-access memory，缩写：RAM），如静态随机存取存储器（英文：static random-access memory，缩写：SRAM），双倍数据率同步动态随机存取存储器（英文：Double Data Rate Synchronous Dynamic Random Access Memory，缩写：DDR SDRAM）

等；存储器也可以包括非易失性存储器（英文：non-volatile memory），例如快闪存储器（英文：flash memory）。存储器用于存储计算机程序（如实现上述方法的应用程序、功能模块等）、计算机指令等，上述的计算机程序、计算机指令等可以分区存储在一个或多个存储器中。并且上述的计算机程序、计算机指令、数据等可以被处理器调用。

上述的计算机程序、计算机指令等可以分区存储在一个或多个存储器中。并且上述的计算机程序、计算机指令、数据等可以被处理器调用。

处理器，用于执行存储器存储的计算机程序，以实现上述实施例涉及的方法中的各个步骤。具体可以参见前面方法实施例中的相关描述。

处理器和存储器可以是独立结构，也可以是集成在一起的集成结构。当处理器和存储器是独立结构时，存储器、处理器可以通过总线耦合连接。

在本发明一实施例中，提供一种计算机可读存储介质，其上存储有计算机程序，该程序被处理器执行时可用于执行上述实施例中任一项的图像处理方法。

在本发明一实施例中，还提供一种计算机程序产品，所述计算机程序产品包括存储了计算机程序的非瞬时性计算机可读存储介质，所述计算机程序可操作来使计算机执行所述的图像处理方法。

在本发明一实施例中，还提供一种芯片系统，包括处理器，所述处理器与存储器的耦合，所述存储器存储有程序指令，当所述存储器存储的程序指令被所述处理器执行时实现所述的图像处理方法。

在本发明一实施例中，还提供一种计算机设备，包括：通信接口、存储器和处理器，其中：存储器，用于储存实现上述任一项实施例中的图像处理方法的程序；处理器用于加载并执行所述存储器存储的程序，以实现上述任一项实施例中的图像处理方法的各个步骤。

通信接口、存储器和处理器的数量可以为至少一个，且通信接口、存储器和处理器相互之间可以通过通信总线进行通信。通信接口可以用来接收其他设备发送的数据，可以包括计算机设备与其他设备进行通信的接口，也可以包括该计算机设备内部各部件之间通信所使用的通信接口。处理器和存储器的具体说明可以参照以上实施例，不再说明。

在实际应用中，该计算机设备可以是服务器、电脑等。因此，计算机设备的结构组成并不局限于通信接口、存储器和处理器，还可以包括其他硬件设备，如其他存储设备等，可以根据该计算机设备所具有的功能确定。

本发明提供的图像处理方法、系统、装置及可读介质，相较于标准的深度神经网络，保证了重构精度的同时，可以从优化的角度理论证明收敛性；相较于现有的可微分深度神经网络

络，保证了收敛性的同时，不限制引入的神经网络结构，具有更高的重构精度；相较于传统的迭代优化算法，提高了运算速度和重构精度；该重构方法可应用于一般的线性逆问题求解，同时可以应用于相关实际场景，如图像去噪、压缩感知、图像复原等。

需要说明的是，本发明提供的方法中的步骤，可以利用系统中对应的模块、装置、单元等予以实现，本领域技术人员可以参照方法的技术方案实现系统的组成，即，方法中的实施例可理解为构建系统的优选例，在此不予赘述。

本领域技术人员知道，除了以纯计算机可读程序代码方式实现本发明提供的系统及其各个装置以外，完全可以通过将方法步骤进行逻辑编程来使得本发明提供的系统及其各个装置以逻辑门、开关、专用集成电路、可编程逻辑控制器以及嵌入式微控制器等的形式来实现相同功能。所以，本发明提供的系统及其各项装置可以被认为是一种硬件部件，而对其内包括的用于实现各种功能的装置也可以视为硬件部件内的结构；也可以将用于实现各种功能的装置视为既可以是实现方法的软件模块又可以是硬件部件内的结构。

本说明书中各个实施例采用递进的方式描述，每个实施例重点说明的都是与其他实施例的不同之处，各个实施例之间相同相似部分互相参见即可。对于实施例公开的系统、装置、计算机设备而言，由于其与实施例公开的方法对应，所以描述的比较简单，相关之处参见方法部分说明即可。

以上对本发明的具体实施例进行了描述。需要理解的是，本发明并不局限于上述特定实施方式，本领域技术人员可以在权利要求的范围内做出各种变形或修改，这并不影响本发明的实质内容。

权利要求书

1、一种图像处理方法，用于图像稀疏重构、图像去噪、压缩感知图像重构或图像复原，其特征在于，包括：

获取训练图像，将所述训练图像进行处理，获得测量信号；

将所述训练图像分解为字典与稀疏信号的乘积，将所述测量信号与所述稀疏信号作为训练样本对，建立训练数据集；

在一范数约束下，建立图像处理的线性逆问题；利用迭代软阈值收缩算法求解所述线性逆问题，根据所述迭代软阈值收缩算法与深度神经网络的凸组合，建立凸组合的可微分深度神经网络；

利用所述训练数据集中的训练样本对，将所述测量信号作为所述可微分深度网络模型的输入，所述稀疏信号作为所述可微分深度网络模型的目标，采用反向梯度传播算法优化所述可微分深度网络模型，得到重构稀疏信号，并使所述重构稀疏信号逼近于所述稀疏信号，得到最终图像，所述最终图像为所述字典与所述重构稀疏信号的乘积，且使所述最终图像逼近于所述训练图像。

2、根据权利要求1所述的图像处理方法，其特征在于，将所述训练图像进行处理，获得测量信号，包括如下任一种：

- 当所述图像处理为图像稀疏重构时：获取训练图像 $\hat{y}$ ，将所述训练图像 $\hat{y}$ 由采样矩阵 Φ 进行采样，获得测量信号 $b = \Phi\hat{y}$ ；

- 当所述图像处理为图像去噪时：获取训练图像 $\hat{y}$ ，将所述训练图像 $\hat{y}$ 与噪声矩阵相加，获得测量信号 $\tilde{b}$ ，该测量信号 $\tilde{b}$ 为带噪图像；

- 当所述图像处理为压缩感知图像重构时：获取训练图像 $\hat{y}$ ，将所述训练图像 $\hat{y}$ 与一个随机采样矩阵 $\tilde{\Phi}$ 相乘，获得测量信号 $\hat{b} = \tilde{\Phi}\hat{y}$ ，该测量信号 $\hat{b}$ 为采样值；

- 当所述图像处理为图像复原时：获取训练图像 $\hat{y}$ ，将所述训练图像 $\hat{y}$ 与一个0-1对角采样矩阵 $\tilde{\Phi}$ 相乘，获得测量信号 $\tilde{b} = \tilde{\Phi}\hat{y}$ ，该测量信号为丢失像素点待复原的图像，所述0-1对角采样矩阵 $\tilde{\Phi}$ 是一个对角矩阵，且对角元素非0即1。

3、根据权利要求2所述的图像处理方法，其特征在于，所述在一范数约束下，建立图像处理的线性逆问题，包括如下任一种：

- 当所述图像处理为图像稀疏重构时：在重构稀疏信号 x 的一范数正则约束下，建立一般性的线性优化逆问题：

$$\min_x F(x) = \min_x \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_1 \right\},$$

其中, x 是重构稀疏信号, $A = \Phi D$ 是一个线性变换矩阵, Φ 是采样矩阵, D 是字典, λ 是约束正则项的参数, $\|\cdot\|_1$ 是向量的一范数;

- 当所述图像处理为图像去噪时: 在一范数约束下, 建立图像去噪的线性逆问题: $\min_x \left\{ \frac{1}{2} \|\hat{A}x - \hat{b}\|_2^2 + \lambda \|x\|_1 \right\}$, 其中 x 是重构稀疏信号, 线性变换矩阵 $\hat{A}$ 为字典 D , 即 $\hat{A} = D$, λ 是约束正则项的参数, $\|\cdot\|_1$ 是向量的一范数;

- 当所述图像处理为压缩感知图像重构时: 在一范数约束下, 建立压缩感知图像重构的线性逆问题: $\min_x \left\{ \frac{1}{2} \|\hat{A}x - \hat{b}\|_2^2 + \lambda \|x\|_1 \right\}$, 其中 x 是重构稀疏信号, 线性变换矩阵 $\hat{A}$ 是随机采样矩阵 $\hat{\Phi}$ 与字典 D 的乘积, 即 $\hat{A} = \hat{\Phi}D$, λ 是约束正则项的参数, $\|\cdot\|_1$ 是向量的一范数;

- 当所述图像处理为图像复原时: 在一范数约束下, 建立图像复原的线性逆问题: $\min_x \left\{ \frac{1}{2} \|\tilde{A}x - \tilde{b}\|_2^2 + \lambda \|x\|_1 \right\}$, 其中 x 是重构稀疏信号, 线性变换矩阵 $\tilde{A}$ 是 0-1 对角采样矩阵 $\tilde{\Phi}$ 与字典 D 的乘积, 即 $\tilde{A} = \tilde{\Phi}D$, λ 是约束正则项的参数, $\|\cdot\|_1$ 是向量的一范数。

4、根据权利要求 1 所述的图像处理方法, 其特征在于, 所述利用迭代软阈值收缩算法求解所述线性逆问题, 包括利用标准的迭代软阈值收缩算法求解所述线性逆问题, 或, 利用学习的迭代软阈值收缩算法求解所述线性逆问题, 其中:

所述利用标准的迭代软阈值收缩算法求解所述线性逆问题, 具体为: $x^{n+1} = \text{prox}_{\|\cdot\|_1, \lambda t^n}(t^n A^T b + (I - t^n A^T A)x^n)$, 其中 x^n 表示在第 n 次迭代时求解所述线性逆问题得到的稀疏信号, A^T 表示矩阵 A 的转置, I 表示单位矩阵, t^n 表示第 n 次迭代时的步长; $\text{prox}_{\|\cdot\|_1, \lambda t^n}$ 表示在一范数约束 $\|\cdot\|_1$ 和超参数 λt^n 下的近端投影算子, 具体表示为求解优化问题: $\text{prox}_{\|\cdot\|_1, a}(x) = \argmin_r \left\{ \frac{1}{2} \|r - x\|_2^2 + a \|r\|_1 \right\}$, 其中 r 为近端投影算子表示的优化问题的求解目标变量, a 为阈值参数;

所述利用学习的迭代软阈值收缩算法求解所述线性逆问题, 具体为: $x^{n+1} = \text{prox}_{\|\cdot\|_1, \theta^n}(x^n + (W^n)^T(b - Ax^n))$, 其中 x^n 表示在第 n 次迭代时求解所述线性逆问题得到的重构稀疏信号, W^n 表示在第 n 次迭代时需要神经网络训练得到的系数矩阵, θ^n 表示在第 n 次迭代时的阈值参数。

5、根据权利要求 1 所述的图像处理方法, 其特征在于, 所述建立基于凸组合的可微分深度网络模型, 包括:

初始化得到未迭代时的稀疏信号 x^0 ，根据迭代软阈值收缩算法与深度神经网络的凸组合，构建由 K 个凸组合块构成的可微分深度网络模型，分别对应所述迭代软阈值收缩算法的第 $n = 1$ 至 $n = K$ 次迭代，其中，将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入，通过凸组合块，更新并得到第 n 个块对应输出 x^n ， $n = 1, \dots, K$ 。

6、根据权利要求5所述的图像处理方法，其特征在于，所述可微分深度网络模型，其损失函数定义为训练数据集中稀疏信号重构误差的均方误差 L_{MSE} ：

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N \|\hat{x}_i - x_i\|_2^2;$$

上式中， N 为训练数据集中稀疏信号的数目， $\hat{x}_i$ 为训练数据集中第 i 个信号， x_i 为所述深度神经网络根据第 i 个信号 $\hat{x}_i$ 的测量信号 b_i 获得的重构稀疏信号。

7、根据权利要求5所述的图像处理方法，其特征在于，所述将第 $n - 1$ 个块的输出 x^{n-1} 作为对第 n 个块的输入，通过凸组合块，更新得到第 n 个块的输出 x^n ，具体包括：

第一近端投影：根据输入 x^{n-1} ，基于所述迭代软阈值收缩算法求解，输出第一近端投影 v^n ；

深度神经网络映射：输入第一近端投影 v^n ，经过深度神经网络进行映射，输出 u^n ，计算为 $u^n = \mathcal{N}_{p^n}(v^n)$ ，其中 $\mathcal{N}_{p^n}$ 表示第 n 次迭代时引入的深度神经网络， p^n 表示需要神经网络训练得到的网络参数；

第二近端投影：根据输入 u^n ，基于所述迭代软阈值收缩算法求解，输出第二近端投影 w^n ；

凸组合计算：输入第一近端投影 v^n 和第二近端投影 w^n ，输出第 n 次迭代的结果 x^n ，计算步骤为 $x^n = \alpha^n v^n + (1 - \alpha^n) w^n$ ，其中 α^n 为介于0和1之间的需要神经网络训练得到的凸组合参数。

8、一种图像处理系统，其特征在于，包括：

训练数据集建立模块：获取训练图像，将所述训练图像进行处理，获得测量信号；将所述训练图像分解为字典与稀疏信号的乘积，将所述测量信号与所述稀疏信号作为训练样本对，建立训练数据集；

可微分深度神经网络建立模块：在一范数约束下，建立图像处理的线性逆问题，利用迭代软阈值收缩算法求解所述线性逆问题，根据所述迭代软阈值收缩算法与深度神经网络的凸组合，建立凸组合的可微分深度神经网络；

处理模块：利用所述训练数据集中的训练样本对，将所述测量信号作为所述可微分深度网络模型的输入，所述稀疏信号作为所述可微分深度网络模型的目标，采用反向梯

度传播算法优化所述可微分深度网络模型，得到重构稀疏信号，并使所述重构稀疏信号逼近于所述稀疏信号，得到最终图像，所述最终图像为所述字典与所述重构稀疏信号的乘积，且使所述最终图像逼近于所述训练图像。

9、一种图像处理装置，包括存储器、处理器及存储在存储器上并可在处理器上运行的计算机程序，其特征在于，所述处理器执行所述程序时可用于执行权利要求 1-7 任一项所述的图像处理方法。

10、一种计算机可读存储介质，其上存储有计算机程序，其特征在于，该程序被处理器执行时可用于执行权利要求 1-7 任一项所述的图像处理方法。

11、一种计算机程序产品，其特征在于，所述计算机程序产品包括存储了计算机程序的非瞬时性计算机可读存储介质，所述计算机程序可操作来使计算机执行如权利要求 1-7 任一项所述的图像处理方法。

12、一种芯片系统，包括处理器，所述处理器与存储器的耦合，所述存储器存储有程序指令，其特征在于，当所述存储器存储的程序指令被所述处理器执行时实现权利要求 1-7 任一项所述的图像处理方法。

13、一种计算机设备，包括：通信接口；其特征在于，还包括：

存储器，用于储存实现如权利要求 1-7 任一项所述的图像处理方法的程序；

处理器，用于加载并执行所述存储器存储的程序，以实现如权利要求 1-7 任一项所述的图像处理方法的各个步骤。

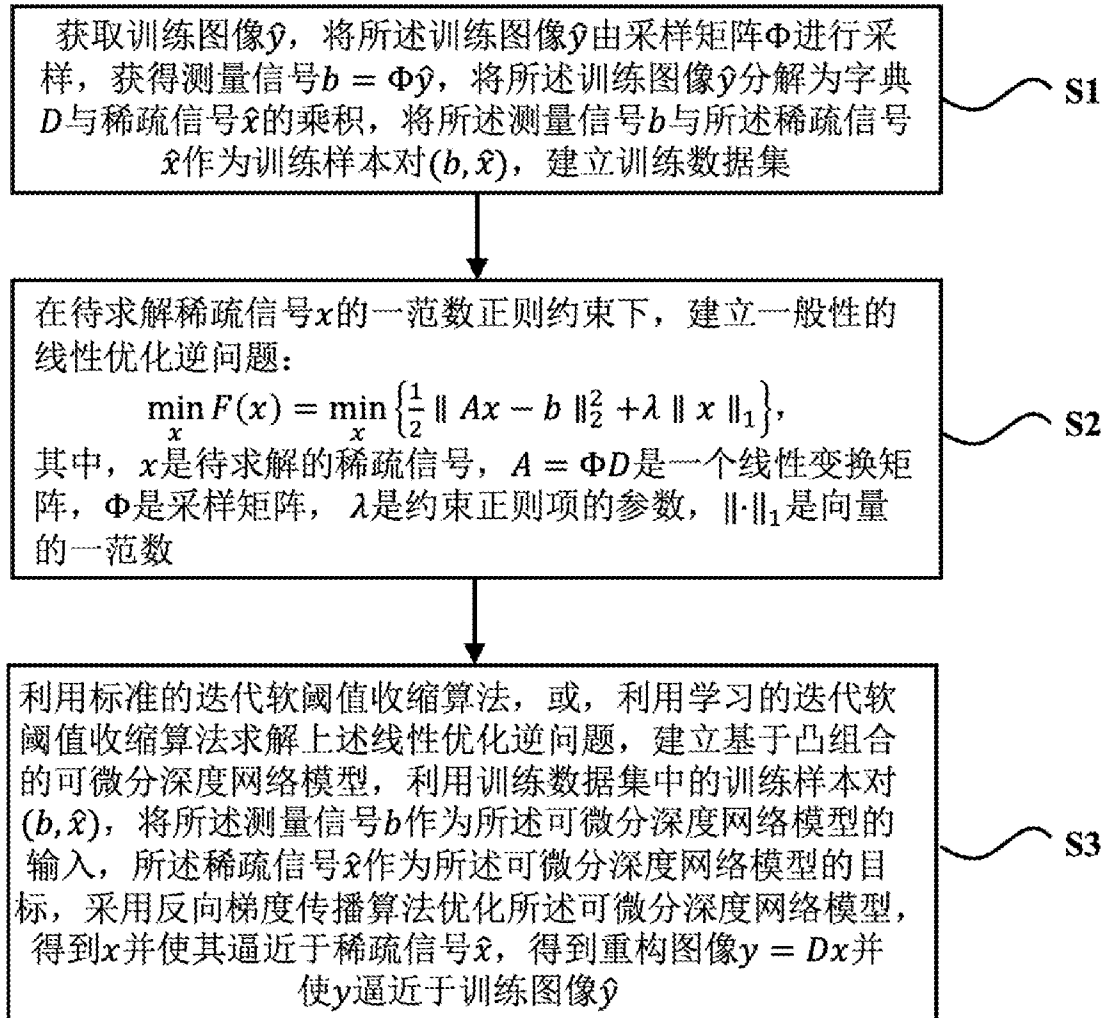


图 1




图 2




图 3

INTERNATIONAL SEARCH REPORT

International application No.

PCT/CN2021/120521

A. CLASSIFICATION OF SUBJECT MATTER

G06T 5/00(2006.01)i; G06T 3/40(2006.01)i; G06K 9/62(2022.01)i; G06N 3/04(2006.01)i; G06N 3/08(2006.01)i

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)

G06T; G06K; G06N

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)

CNPAT, WPI, EPODOC, CNKI, IEEE: 图像, 稀疏, 重构, 字典, 训练, 线性逆问题, 迭代软阈值收缩, 深度神经网络, 凸组合, 梯度传播, image, sparse reconstruction, dictionary, train, linear inverse problem, Iterative Shrinkage Thresholding Algorithm, ISTA, Deep Neural Networks, DNN, convex combination, back propagation

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	CN 113034414 A (SHANGHAI JIAO TONG UNIVERSITY) 25 June 2021 (2021-06-25) description, paragraphs [0058]-[0104]	1-13
A	CN 112884851 A (WUHAN UNIVERSITY) 01 June 2021 (2021-06-01) entire document	1-13
A	CN 110678899 A (MITSUBISHI ELECTRIC CORP.) 10 January 2020 (2020-01-10) entire document	1-13
A	US 2010246920 A1 (IOWA STATE UNIVERSITY RESEARCH FOUNDATION, INC.) 30 September 2010 (2010-09-30) entire document	1-13
A	US 2021158548 A1 (MICROSOFT TECHNOLOGY LICENSING, LLC) 27 May 2021 (2021-05-27) entire document	1-13



Further documents are listed in the continuation of Box C.



See patent family annex.

* Special categories of cited documents:

“A” document defining the general state of the art which is not considered to be of particular relevance

“E” earlier application or patent but published on or after the international filing date

“L” document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

“O” document referring to an oral disclosure, use, exhibition or other means

“P” document published prior to the international filing date but later than the priority date claimed

“T” later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

“X” document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

“Y” document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art

“&” document member of the same patent family

Date of the actual completion of the international search

24 April 2022

Date of mailing of the international search report

12 May 2022

Name and mailing address of the ISA/CN

China National Intellectual Property Administration (ISA/
CN)
No. 6, Xitucheng Road, Jimenqiao, Haidian District, Beijing
100088, China

Facsimile No. (86-10)62019451

Authorized officer

Telephone No.

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.

PCT/CN2021/120521

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)			Publication date (day/month/year)
CN	113034414	A	25 June 2021	None			
CN	112884851	A	01 June 2021	None			
CN	110678899	A	10 January 2020	WO	2018221540	A1	06 December 2018
				US	2018349319	A1	06 December 2018
				JP	2020505692	A	20 February 2020
				DE	112018002793	T5	02 April 2020
US	2010246920	A1	30 September 2010	None			
US	2021158548	A1	27 May 2021	WO	2021108129	A1	03 June 2021

国际检索报告

国际申请号

PCT/CN2021/120521

A. 主题的分类

G06T 5/00(2006.01)i; G06T 3/40(2006.01)i; G06K 9/62(2022.01)i; G06N 3/04(2006.01)i; G06N 3/08(2006.01)i

按照国际专利分类(IPC)或者同时按照国家分类和IPC两种分类

B. 检索领域

检索的最低限度文献(标明分类系统和分类号)

G06T; G06K; G06N

包含在检索领域中的除最低限度文献以外的检索文献

在国际检索时查阅的电子数据库(数据库的名称, 和使用的检索词(如使用))

CNPAT, WPI, EPDOC, CNKI, IEEE: 图像, 稀疏, 重构, 字典, 训练, 线性逆问题, 迭代软阈值收缩, 深度神经网络, 凸组合, 梯度传播, image, sparse reconstruction, dictionary, train, linear inverse problem, Iterative Shrinkage Thresholding Algorithm, ISTA, Deep Neural Networks, DNN, convex combination, back propagation

C. 相关文件

类 型*	引用文件, 必要时, 指明相关段落	相关的权利要求
A	CN 113034414 A (上海交通大学) 2021年6月25日 (2021 - 06 - 25) 说明书第[0058]-[0104]段	1-13
A	CN 112884851 A (武汉大学) 2021年6月1日 (2021 - 06 - 01) 全文	1-13
A	CN 110678899 A (三菱电机株式会社) 2020年1月10日 (2020 - 01 - 10) 全文	1-13
A	US 2010246920 A1 (IOWA STATE UNIVERSITY RESEARCH FOUNDATION, INC.) 2010年9月30日 (2010 - 09 - 30) 全文	1-13
A	US 2021158548 A1 (MICROSOFT TECHNOLOGY LICENSING, LLC) 2021年5月27日 (2021 - 05 - 27) 全文	1-13

☐ 其余文件在C栏的续页中列出。

☒ 见同族专利附件。

* 引用文件的具体类型:

“A” 认为不特别相关的表示了现有技术一般状态的文件

“E” 在国际申请日的当天或之后公布的在先申请或专利

“L” 可能对优先权要求构成怀疑的文件, 或为确定另一篇引用文件的公布日而引用的或者因其他特殊理由而引用的文件(如具体说明的)

“O” 涉及口头公开、使用、展览或其他方式公开的文件

“P” 公布日先于国际申请日但迟于所要求的优先权日的文件

“T” 在申请日或优先权日之后公布, 与申请不相抵触, 但为了理解发明之理论或原理的在后文件

“X” 特别相关的文件, 单独考虑该文件, 认定要求保护的发明不是新颖的或不具有创造性

“Y” 特别相关的文件, 当该文件与另一篇或者多篇该类文件结合并且这种结合对于本领域技术人员为显而易见时, 要求保护的发明不具有创造性

“&” 同族专利的文件

国际检索实际完成的日期

2022年4月24日

国际检索报告邮寄日期

2022年5月12日

ISA/CN的名称和邮寄地址

中国国家知识产权局(ISA/CN)

中国北京市海淀区蓟门桥西土城路6号 100088

传真号 (86-10)62019451

受权官员

孔昕

电话号码 86-(10)-53961371

国际检索报告
关于同族专利的信息

国际申请号

PCT/CN2021/120521

检索报告引用的专利文件			公布日 (年/月/日)	同族专利			公布日 (年/月/日)
CN	113034414	A	2021年6月25日	无			
CN	112884851	A	2021年6月1日	无			
CN	110678899	A	2020年1月10日	W0	2018221540	A1	2018年12月6日
				US	2018349319	A1	2018年12月6日
				JP	2020505692	A	2020年2月20日
				DE	112018002793	T5	2020年4月2日
US	2010246920	A1	2010年9月30日	无			
US	2021158548	A1	2021年5月27日	W0	2021108129	A1	2021年6月3日