

Denoising of Brillouin Gain Spectra Based on Multi-Scale Deep Unfolding Network*

ZHENG Huan*, XU Nuo, SHU Han, XU Ke, PENG Yingsheng

(College of Information Engineering, Zhejiang University of Technology, Hangzhou Zhejiang 310023, China)

Abstract: The Brillouin gain spectrum (BGS) in Brillouin optical time domain analysis (BOTDA) often suffers from noise, making it difficult to accurately extract the Brillouin frequency shift (BFS). Effective BGS noise reduction is therefore crucial. Existing methods for reducing BGS noise fall into two main categories: model-based methods (e.g., BM3D) and learning-based methods (e.g., DnCNN). However, these methods have limitations—model-based approaches tend to be slow, while learning-based methods often lack interpretability. A novel BGS noise reduction technique based on the multi-scale deep unfolding network (MSDUN) is proposed, which combines superior noise reduction performance, faster processing speed, and improved interpretability. MSDUN achieves noise reduction by passing the input data through a series of noise reduction modules, each optimized with learnable parameters. These modules contain convolutional neural networks (CNNs), offering a clear and interpretable structure. Compared to model-based methods like BM3D, MSDUN demonstrates significantly faster noise reduction. Both simulation and experimental results show that MSDUN enhances the signal-to-noise ratio (SNR) of 3D BGS grayscale images by 8.14 dB, outperforming BM3D's 3.92 dB and DnCNN's 2.23 dB. Additionally, MSDUN completes the noise reduction process in just 4.8 seconds, nearly 30 times faster than BM3D. Furthermore, MSDUN offers a more interpretable hierarchical structure than DnCNN, making it a better solution for BGS noise reduction.

Key words: optical fiber sensing; Brillouin gain spectrum; denoising; multi-scale deep unfolding network; Brillouin optical time domain analyzer

EEACC: 7230; 7230E

doi: 10.3969/j.issn.1004-1699.2025.06.010

基于多尺度深度展开网络的布里渊增益谱降噪技术研究*

郑欢*, 徐诺, 舒涵, 许科, 彭银生

(浙江工业大学信息工程学院, 浙江 杭州 310023)

摘要: 布里渊光时域分析 (BOTDA) 系统中的布里渊增益谱 (BGS) 可能存在噪声, 造成布里渊频移等重要信息难以提取的问题, 故需对 BGS 降噪。现有 BGS 降噪方法分为基于模型的方法 (如 BM3D) 和基于学习方法 (如 DnCNN) 两大类, 分别存在降噪速度慢和可解释性差的问题。对此提出基于多尺度深度展开网络 (MSDUN) 的 BGS 降噪方法, 具有降噪效果好、降噪速度快、可解释性好的优点。MSDUN 通过将输入图像经过一系列参数可学习的降噪模块实现降噪, 卷积神经网络是隐含在每个降噪模块中的, 因此 MSDUN 结构层次清楚, 具有明晰的可解释性。由于在单个降噪模块中使用了卷积神经网络, 因此降噪速度相比 BM3D 这类基于模型的方法更快。仿真和实验结果表明, MSDUN 可以将三维 BGS 灰度图信噪比增强 8.14 dB, 降噪效果上优于 BM3D 的 3.92 dB 和 DnCNN 的 2.23 dB; 降噪速度上, MSDUN 只需 4.8 s, 比 BM3D 快了近 30 倍; 相比 DnCNN, MSDUN 算法层次结构更加清晰, 可解释性好。

关键词: 光纤传感; 布里渊增益谱; 降噪; 多尺度深度展开网络; 布里渊光时域分析

中图分类号: TP212.9; TU990.3

文献标识码: A

文章编号: 1004-1699(2025)06-1030-12

基于受激布里渊散射 (Stimulated Brillouin Scattering, SBS) 原理的布里渊光学时域分析系统 (Brillouin Optical Time Domain Analyzer, BOTDA) 的检测距离可达数百公里, 具有传感范围长、监测精度

高、空间分辨率好等优点^[1], 被广泛应用于石化管道监测^[2], 安防监测^[3-5]、结构物检测^[6]等领域并取得了良好效果。BOTDA 技术主要基于光纤中的布里渊散射效应, 泵浦光脉冲和连续探测光从光纤的

项目来源: 浙江省“尖兵领雁+X”科技计划项目 (2025C02013)

收稿日期: 2024-09-12 修改日期: 2024-11-07

两端入射到光纤中并在光纤中产生布里渊散射效应,泵浦光的能量转移到探测光,探测光得到增益。返回的散射光被接收模块接收,得到探测光增益在距离方向上的分布。对探测光进行扫频,即可得出每个位置点的布里渊增益谱(Brillouin Gain Spectra, BGS)^[7]。然而 BOTDA 中的 BGS 可能引入多种类型的噪声,包括 SBS 引起的相位—强度转换噪声、自发辐射引起的激光光源强度和相位噪声^[8-9]、泵浦光的自发布里渊散射与探测光相互作用产生的噪声^[10]、以及外界环境所引起的干扰噪声。BOTDA 的系统噪声可严重影响系统的传感范围、空间分辨率、解调精度等关键指标^[11-12],从而造成布里渊频移、峰值功率等重要信息难以提取。

目前用于 BOTDA 降噪的方法,主要可以分为基于模型的方法和基于学习的方法两大类^[13-15]。

基于模型的方法主要有非局部均值算法(NL-Means, NLM)、三维块匹配算法(Block Matching 3D, BM3D)、四元小波变换图像降噪算法等。2016年 Soto 等^[16]提出将图像降噪用于处理三维 BGS 灰度图,使用 NLM 方法对三维 BGS 进行处理,验证了在传感范围的末端,信噪比增强了 13.6 dB。2018年, Wu 等使用 BM3D 对 62km 光纤末端的 BOTDA 数据进行降噪。BM3D 主要可分为三个步骤:首先对每个参考块进行相似块匹配(Block Matching)并分别得到一个三维的组合,然后对其进行协同变换和滤波(3D-Transform),最后对各个参考块对应组合的滤波结果进行整合(Aggregation),从而得到最终的降噪结果。在此之上,为了进一步改善图像的质量, BM3D 实际进行了两次降噪,即将以上三个步骤再重复了一遍,但是具体的块匹配标准、滤波方式以及整合权重等等会有一些区别。Wu 等^[17]验证了 BM3D 相较于 NLM 具有更好的高保真降噪能力,信噪比(Signal-to-noise Ratio, SNR)改善达 13 dB。2022年 Wang 等^[18]提出了四元小波变换图像降噪算法,将原始 BOTDA 数据分为一个幅度图像和三个相位图像,提高信噪比和频率不确定性,经过四元小波变换降噪处理,40 km 光纤末端的 SNR 从降噪前数据的 2.14 dB 提高到 16.86 dB,布里渊频移的精度达到 0.2 MHz。

由于技术机器学习的快速发展,人们提出了各种基于机器的图像降噪方法,主要有去噪卷积神经网络(Denoising Convolutional Neural Network, DnCNN),人工神经网络(Artificial Neural Networks, ANN),卷积神经网络(Convolutional Neural Network, CNN)等,这些方法也被用来实现 BGS 降噪。2017年, Zhang 等^[19]提出了 DnCNN。DnCNN 以前馈去噪卷积神经网络为

基础,将其在深度架构、学习算法和正则化方法方面的进展融入到图像去噪中。具体来说,该方法采用了残差学习和批量归一化来加速训练过程,并提升去噪性能。与现有的判别去噪模型不同, DnCNN 能够处理具有未知噪声水平的信号(即盲高斯去噪)。通过残差学习策略, DnCNN 能够在隐藏层中隐式地去除潜在的噪声图像。这一特性促使我们训练单个 DnCNN 模型,以应对多种常见的图像去噪任务,如高斯去噪等。DnCNN 的核心在于浅层宽、深层窄的结构,这种设计旨在捕捉不同尺度的图像特征。它包含多个卷积层和批量归一化层,形成一个 U 型网络,有效去除高斯噪声而不损害图像细节。此外,模型使用了跳跃连接(skip connection),使信息可以直接从输入传递到输出,有助于保持原始图像的信息完整性,实验证明 DnCNN 在不同噪声水平下的平均峰值信噪比(PSNR)比传统方法提高了约 0.6 dB。2018年 Abbasnezhad 等^[20]提出了 ANN,用于提高 BGS 的信噪比和加速测量过程,可将 BGS 的 SNR 提高 20 dB,大幅缩短测量时间,代价是网络的可解释性较差。2019年 Wu 等^[21]将 CNN 用于三维 BGS 的图像降噪,通过训练后的 CNN 降噪器, BGS 的 SNR 提升了 13.43 dB,降噪速度上, CNN 只需要 0.045 s 来处理 15 150 000×50 000 图像。

就现有的 BGS 降噪方法而言,基于模型的方法具有可解释性强、数据需求少等优点,但存在计算复杂度高、收敛速度慢、超参数调节困难、泛化能力弱等问题^[16-18]。相比于基于模型的方法,基于学习的方法具有适应性强、能处理复杂数据、准确性高、泛化能力强、收敛快、降噪迅速等优点,但是基于学习的方法也有其不足,比如数据需求大、黑盒性强^[14,22]。于是,深度展开网络应运而生,深度展开网络将模型的迭代过程展开成网络,很好地结合了基于模型的方法和基于学习的方法的优点,并且在稀疏编码、压缩图像感知等领域取得成效^[15,23-25]。2010年, Gregor 等^[26]首次提出了深度展开模型的概念,提出了一种学习型的编码器架构,能够快速预测出近似最优的稀疏编码,而不需要进行昂贵的迭代优化过程,编码器架构基于截断版本的迭代收缩阈值算法和坐标下降算法,但将原本固定的矩阵参数改为可学习的参数,从而能够在有限的迭代次数内产生更好的近似稀疏编码。2021年, Zhang 等^[15]提出一种名为 AMP-Net 的新型深度展开模型,用于压缩图像感知, AMP-Net 将 CNN 和采样矩阵集成在一起,共同拟合噪声项,使图像先验的表示更加灵活直观,参数更少。他们在数据集 BSDS500 和 Set11 上进行了实验,证明了 AMP-

Net-2-BM 的性能优于其他 10 种最先进的方法。随着重构模块数量的增加,效果更好,CS 比为 30%重建的图像,PSNR 可达到 35.85 dB,结构相似度(SSIM)可达到 0.963 8。2023 年,Song 等^[27]提出了一种动态路径可控深度展开网络用于压缩感知重建,该网络引入了路径选择器,它可自适应地确定执行模块的数量和位置,以及路径可控选择器,它通过可控单元实现动态调整,提供合适的性能复杂度权衡,并且取得良好的重建功能,实验证明,在不同的 CS 率下,动态路径可控深度展开网络重建的图片指标(PSNR 与 SSIM)均高于其他九种方法。2022 年,Dutta 等^[28]提出了一种名为 Deep-De-QuIP 的深度学习网络,该网络是基于之前提出的量子交互修补(De-QuIP)算法展开,Deep-De-QuIP 通过量子物理中的相互作用引入局部修补相似性度量,为深度网络引入了非局部结构,并且嵌入了量子概念,如哈密顿算子,使网络具有自适应行为,融合了深度学习和量子力学的优势,在解决原始 De-QuIP 方案的超参数调整问题的同时,实现了最先进的去噪性能,实验数据表明,Deep-De-QuIP 在不同噪声水平下,在指标 PSNR 与 SSIM 上均高于其他几种方法。2023 年,Qin 等^[29]提出了一种新的端到端盲深度展开网络,称为 BDUNet。具体地说,他们将噪声图像中的噪声水平估计为退化信息,并设计一个算子将其纳入高维映射空间上的最大后验(MAP)框架中,使用分裂布雷格曼迭代算法将原问题解耦为两个子问题进行迭代求解,然后根据基于动量的梯度下降法进行求解。实验结果显示,BDUNet 在多个数据集(如 Set12、BSD68 和 Urban100)上,以不同噪声水平($\sigma=15,25,50$)均获得了较高的 PSNR 与 SSIM,优于传统和部分先进的去噪方法。

表 1 分别列出了几种基于模型的方法,基于学习的方法以及深度展开网络的方法,对比了它们在噪声标准差为 50 的情况下的指标(PSNR,SSIM),可以看出深度展开网络的指标明显优于其他几种方法。

深度展开网络在各领域的广泛使用证明了它的优越性,然而我们并未发现将深度展开网络应用于 BOTDA 系统中布里渊增益谱降噪的例子,因此,我们将多尺度深度展开网络(Multi-Scale Deep Unfolding Network, MSDUN)用于 BOTDA 降噪^[25],本工作的主要贡献如下:①深度展开网络用于 BOTDA 降噪:首次将深度展开网络技术用于三维 BGS 灰度图降噪,结合洛伦兹曲线拟合(Lorentz Curve Fitting, LCF)提取布里渊频移(Brillouin Frequency Shift, BFS),用于计算指标。②多尺度信息聚合:多尺度深度展开网络可以从多个分辨率学习

三维 BGS 灰度图的先验信息,扩大了感受野,捕获更多上下文信息,利用反投影特征融合(BPFF)聚合三维 BGS 灰度图多尺度信息,成为更强的先验信息,提升降噪效果。③兼具降噪速度与效果:实验结果表明,多尺度深度展开网络可以在 5 s 内将三维 BGS 灰度图信噪比增强 8.14 dB,降噪效果明显优于 BM3D 的 3.92 dB 和 DnCNN 的 2.23 dB,在同一组测试数据中,多尺度深度展开网络降噪速度比 BM3D 快了近 30 倍,兼顾了速度与降噪效果。

表 1 不同方法进行降噪的定量比较 单位: dB

方法大类	具体方法	PSNR	SSIM
基于模型的方法	BM3D ^[17]	26.73	0.768
	CBM3D ^[25]	27.48	0.766
	NLM ^[16]	26.15	0.710
基于学习的方法	ADNet ^[29]	26.44	0.716
	FFDNet ^[29]	27.96	0.788
	DnCNN ^[19]	26.10	0.751
深度展开网络	BDUNet ^[29]	29.92	0.842
	Deep-De-QuIP ^[28]	29.66	0.920

1 基本原理

1.1 仿真数据集生成

固定扫频步长在一定频率范围内扫描,得到一组扫频频率,分别记为 $\nu_1, \nu_2, \dots, \nu_m$ 。设光纤上各位置分别为 z_1, z_2, \dots, z_n 。设 $f(z_i, \nu_j, \mathbf{p})$ 为 BGS 的线型函数,如图 1 所示。其中 \mathbf{p} 为线型函数自身参数, z_i 为位置, $i=1, 2, \dots, n$, ν_j 为扫频频率, $j=1, 2, \dots, m$ 。当 \mathbf{p} 固定不变时,经剪裁得到三维 BGS 灰度图如图 1 中 clean 所示。改变 \mathbf{p} 则得到一个三维 BGS 灰度图的集合 \mathbf{P} ,将 \mathbf{P} 按一定比例分为 $\mathbf{P}_a, \mathbf{P}_b$ 。

BGS 采用 Pseudo-Voigt 线型,定义如下:

$$f_p(v) = g_B \left[\frac{c}{1 + \left(\frac{v - v_0}{\Delta v / 2} \right)^2} + (1 - c) e^{-\ln 2 \left(\frac{v - v_0}{\Delta v / 2} \right)^2} \right] \quad (1)$$

式中:参数分别为中心频率 v_0 、带宽 Δv 、峰值功率 g_B ,以及线型比重 c 。其中, $c=0$ 为高斯线型, $c=1$ 为洛伦兹线型。

1.2 训练过程

1.2.1 基本架构

MSDUN 分为训练过程和测试过程。图 1 所示为训练过程基本架构,MSDUN 对于 BGS 的降噪过程可以视为是一系列降噪模块 $q_i (i=1, 2, 3, \dots, t)$ 的线性叠加。训练过程的目的是将各个降噪模块的参数确定。具体描述如下。

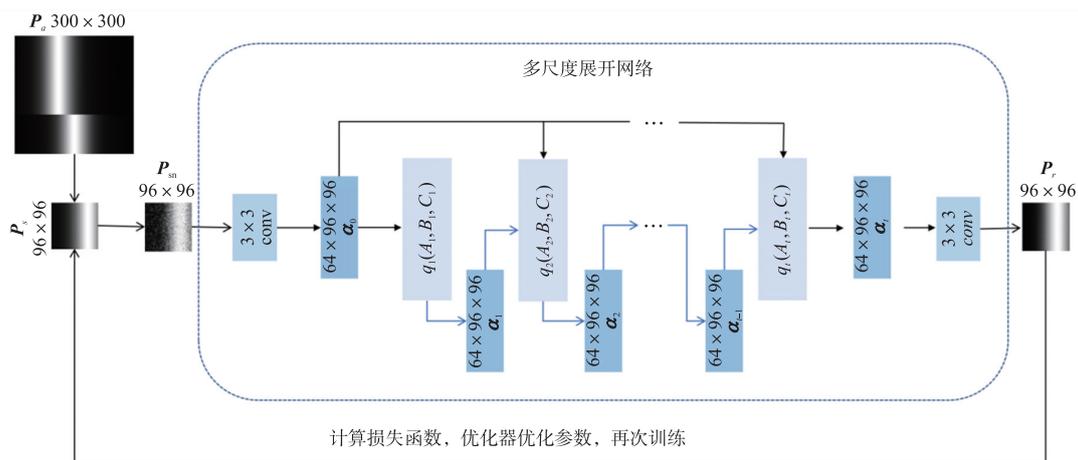


图 1 训练过程基本架构

图 1 所示训练过程基本架构中,将 P_a 中的每个元素切成正方形小片,得到集合 P_s 。需要指出的是,将图像大小调整为正方形的主要原因是为了提高计算效率。CNN 将图像处理为像素值矩阵,这些矩阵的大小直接影响网络的计算复杂度。我们通过将图像大小调整为正方形,可以确保输入尺寸一致,从而更轻松地设计和训练 CNN 模型。方形图像简化了神经网络输入层的数据格式,因此可以轻松的指定尺寸,而不需要进行复杂的计算和尺寸调整。在得到集合 P_s 后,可以再向 P_s 中加入高斯白噪声后得到集合 P_{sn} ,作为训练集,将 P_{sn} 输入多尺度深度展开网络,先经过特征提取器将图片映射到特征空间,得到特征 α_0 ,经过多个降噪模块降噪后得到 α_i , α_i 经过图像重构器得到降噪后图片,将降噪前后图片进行对比,计算损失函数与当前参数,并优化参数。图 2 的流程图展现了图 1 的更多细节。

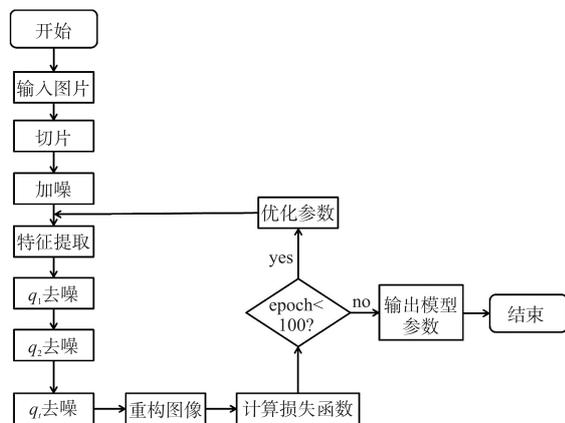


图 2 训练过程流程图

设迭代次数 $ep=1$,将 P_{sn} 输入多尺度深度展开网络 F ,输出为 $P_r = F(P_{sn}, A, B, S, t)$ 。其中, A, B, S 为当前多尺度深度展开网络的参数, t 代表降噪模块的个数;多尺度深度展开网络 F ,包含特征提取模

块 f, t 个深度展开降噪模块 $Q = qt$,图像重构模块 g 共 3 个部分。当给定输入 x ,则输出 $y = F(x, A, B, S, t) = g\{qt[f(x), A, B, S]\}$

1.2.2 特征提取模块

特征提取模块包含特征提取器,功能为将输入 x 映射到特征空间,输出初始特征值的集合 $\alpha_0 = f(x)$,其中初始特征集合 α_0 的每一个矩阵元素的宽 H 和高 W 分别为:

$$H = (H_{in} - \text{kernel_size} + 2 \times \text{padding}) / \text{stride} + 1 \quad (2)$$

$$W = (W_{in} - \text{kernel_size} + 2 \times \text{padding}) / \text{stride} + 1 \quad (3)$$

式中: H, W 代表输出图的高和宽,都设置为 96, H_{in}, W_{in} 为输入图的高和宽, kernel_size 为卷积核大小, padding 为填充的大小, stride 为步幅。

特征提取器就是一个 $\text{kernel_size} = 3, \text{stride} = 1, \text{padding} = 1$ 的卷积层,输出的通道数是 64,根据式上式计算出 α_0 的尺寸是 $64 \times 96 \times 96$ 。

1.2.3 降噪模块

深度展开降噪模块包含 t 个降噪模块,降噪模块的结构如图 3 所示,第 t 个降噪模块的输出为:

$$\alpha_t = \alpha_{t-1} + A_t[\alpha_{t-1} - \alpha_0 - S_t(\alpha_{t-1})] + B_t(\alpha_{t-1} - \alpha_{t-2}) \quad (4)$$

式中: A_t, B_t, S_t 是第 t 个降噪模块的网络参数, A_t 和

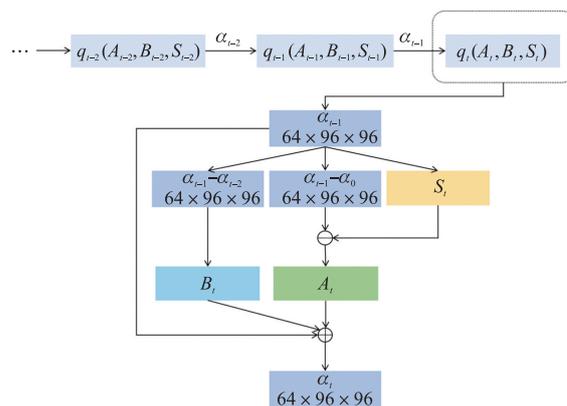


图 3 降噪模块结构

B_i 分别用一个残差块来实现,如图 4 所示。每个残差块包含两个 3×3 的卷积层和一个 ReLU 激活函数^[30]。卷积层的 $\text{kernel_size} = 3, \text{stride} = 1, \text{padding} = 1$, 卷积层的初始权重参数都是随机分配的。输入与输出的通道数都是 64, 由上式可知特征空间中的图像经过 A_i 和 B_i 后长宽都不改变, 所以 α_i 的尺寸一直都是 $64 \times 96 \times 96$ 。

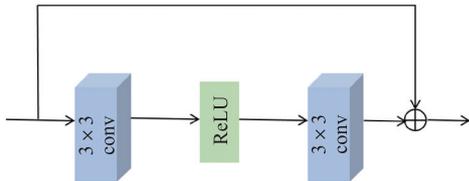


图 4 残差块结构

图 3 中 S_i 表示多尺度正则化器^[31], S_i 在多种分辨率下提取三维 BGS 灰度图的先验信息, 流程如图 5 所示。 S_i 被表示为:

$$S(\alpha) = Z[G_1(\alpha), G_2(\alpha \downarrow_2), G_3(\alpha \downarrow_4)] \quad (5)$$

式中: \downarrow_k 表示比例因子 k 的降采样算子, G_1, G_2, G_3 表示从不同尺度的特征学习三维 BGS 灰度图有用先验信息的深度 CNN, 称为多尺度卷积层, 结构如图 6 所示。每个 G 由两个卷积层组成, 卷积层的 $\text{kernel_size} = 3, \text{stride} = 1, \text{padding} = 1$, 输入与输出的通道数相同, 同时具有两个 ReLU 激活函数和一个残

差块, 残差块包含两个 3×3 的卷积层和一个 PReLU 激活函数, 所以 $G(\alpha)$ 的尺寸与 α 一致。 G_1, G_2, G_3 结构相同但通道维度不同, 在分辨率为 α 的 1、1/2、1/4 时, 信道数分别设置为 64、128、256, 因为下采样了以后, 输出的长宽变小了, 为了防止特征信息丢失, 输出通道数要加倍, 如果特征图像被缩小了一半, 又不增加通道数, 那么特征信息就会有很大概率被 ReLU 滤掉导致丢失。

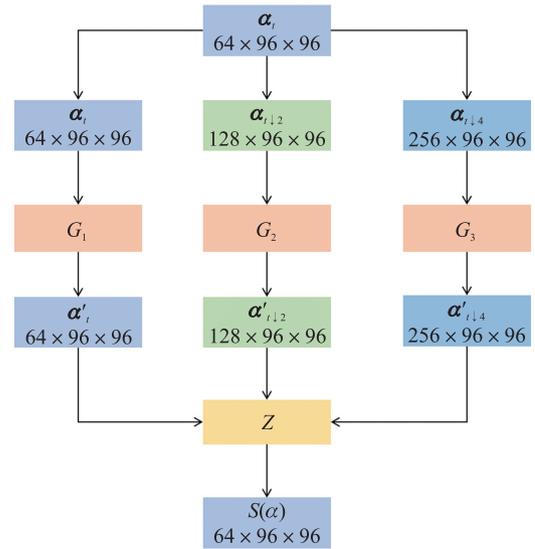


图 5 多种分辨率下提取的三维 BGS 灰度图的先验信息

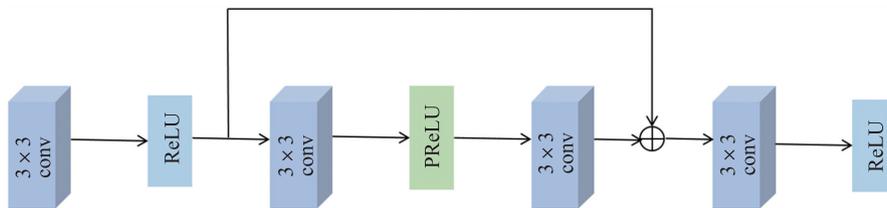


图 6 多尺度卷积层结构

然后使用反投影特征融合 (Back-Projection Feature Fusion, BPF) 块^[32]实现了 Z , 用于聚合三维 BGS 灰度图中的多尺度特征。不同分辨率的特征需要利用下采样或者上采样统一成相同的分辨率才能进行计算。我们分别使用卷积层和反卷积层来实现下采样和上采样, 卷积层和反卷积层的步幅均设置为 2, 反投影特征融合过程如图 7 所示, 其中 down 和 up 分别代表下采样与上采样。

由于 $G_2(\alpha \downarrow_2)$ 的尺寸是 48×48 , 长宽是 $G_1(\alpha)$ 的 1/2, 那么就要将 $G_1(\alpha)$ 下采样到与 $G_2(\alpha \downarrow_2)$ 相同的分辨率, 来计算它们的差值: $a_1 = G_1(\alpha) \downarrow_2 - G_2(\alpha \downarrow_2)$, 然后, 要利用反向投影的差值来增强先验信息 $G_1(\alpha)$, 但 a_1 的尺寸是 48×48 , $G_1(\alpha)$ 的尺寸是 96×96 , 需要将 a_1 进行 1 次上采样, 将 a_1 的尺寸统一成 96×96 , 然后利用 a_1 来增强先验信息 $G_1(\alpha)$,

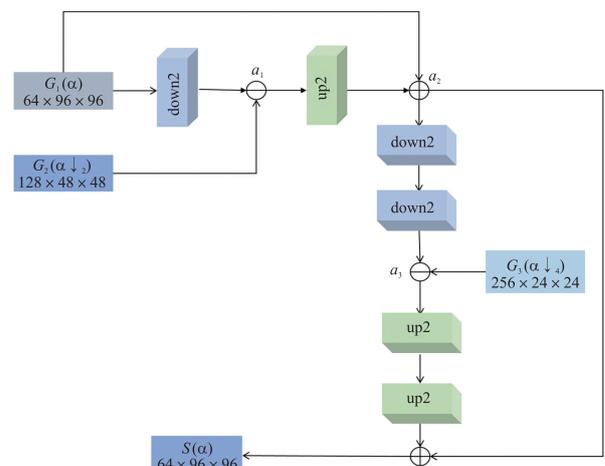


图 7 反投影特征融合流程

得到 $a_2 = G_1(\alpha) + (a_1) \uparrow_2$, 利用类似的步骤, 将 a_2 进行 2 次下采样转换成 $G_3(\alpha \downarrow_4)$ 相同的尺寸, 计算差

值得到 $a_3 = (a_2) \downarrow_4 - G_3(\alpha \downarrow_4)$, 最后将 a_3 进行 2 次上采样后来增强 a_2 , 得到融合后的三维 BGS 灰度图多尺度信息 $S(\alpha) = a_2 + (a_3) \uparrow_4$ 。

1.2.4 图像重构模块

图像重构模块 g 包含图像重构器, 就是一个 $\text{kernel_size} = 3, \text{stride} = 1, \text{padding} = 1$ 的卷积层, 输出的通道数为 1, 图的大小还是与输入一致, 可以将特征 α_i 映射回图像空间, 输出为 P_r 。

由 P_s 和 P_r , 计算损失函数 $L(P_s, P_r, A, B, S, t)$, 损失函数利用最小平方误差, 表示为:

$$L(P_s, P_r, A, B, S, t) = 1/N \sum_{i=1}^N \|F(y_i) - x_i\|^2 \quad (6)$$

式中: y_i 是 P_{sn} 中的一个元素, x_i 是 P_s 中的一个元素, F 表示多尺度深度展开网络函数; 利用 Python 中的 Adam

优化器求解 $\arg \min_{A, B, S} L(P_{sn}, P_r, A, B, S, t)$, 得到网络参数 A, B, S , 用来保存当前的状态, 并能够根据计算得到的梯度来更新参数, 每个 ep 训练结束保存一次参数 A, B, S 。迭代次数 ep 增加 1, 重复上述步骤, 直至损失函数的值下降趋势很缓慢, 几乎不再下降。在实际应用中发现, 当进行 100 次迭代之后, 损失函数的值下降趋势很缓慢, 几乎不再下降, 经综合考虑, 我们选择迭代次数为 100。在进行迭代后, 得到参数 A, B, S 。

1.3 测试过程

1.3.1 基本架构

图 8 给出多尺度深度展开网络的测试流程, 从集合 P_b 中随机抽取 1 个元素 P_1 , 加入噪声后输入到多尺度深度展开网络 F 中, 得到输出 $P_2 = (P_1, A, B, S, t)$; 由 P_1 和 P_2 , 可以衡量该方法的性能。

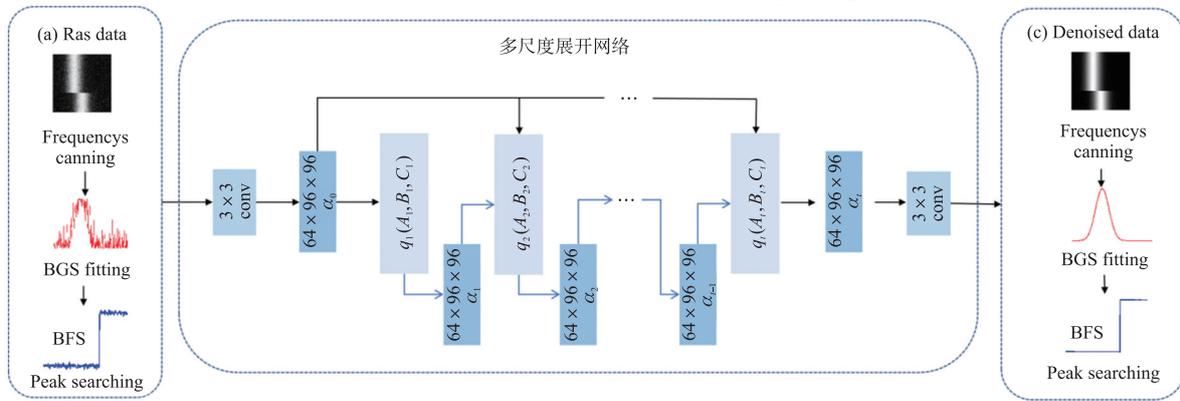


图 8 测试过程基本架构

1.3.2 模型指标

为了衡量和比较不同降噪方法的性能差别, 我们定义了模型指标 $D(t)$, 包括: 信噪比增强 (SNRen)^[33]、均方根误差 (Root Mean Square Error, RMSE) 和不确定度 (Uncertainty)。

$$\text{SNRen} = 10 \times \log_{10} \frac{X_i}{X_d} \quad (7)$$

式中: SNRen 表示信噪比增强的程度, X_i 表示降噪前数据的均方根误差或不确定度, X_d 表示降噪后数据的均方根误差或不确定度。

RMSE: 用于评估降噪前后 BFS 误差, 提取布里渊频移的方法是 LCF, RMSE 表示为:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n [f(x_i) - y_i]^2} \quad (8)$$

式中: $f(x_i)$ 是降噪后三维 BGS 灰度图提取的 BFS, y_i 是干净三维 BGS 灰度图提取的 BFS。

Uncertainty: 用于评估使用模型降噪后的 BFS 的标准偏差。其表示为:

$$\text{Uncertainty} = \sqrt{\frac{1}{n} \sum_{i=1}^n [f(x_i) - \bar{y}]^2} \quad (9)$$

式中: \bar{y} 是通过使用模型降噪后的 BFS 的统计平均值。

2 仿真

2.1 仿真数据生成

仿真数据生成参数具体如下:

一张 300×300 的三维 BGS 灰度图由两张参数不同的三维 BGS 灰度图组成, BGS 灰度图每一个像素点的值已进行归一化, 取值范围为 $0 \sim 255$ 。BGS 频率范围都是 $10\,750 \text{ MHz} \sim 11\,049 \text{ MHz}$, 扫频步长选择 1 MHz , 带宽选择 $30 \text{ MHz} \sim 65 \text{ MHz}$, 跨度为 5 MHz , 线型比重 c 的范围 $0 \sim 1$, 跨度为 0.2 , 第一张中心频率设为 $10\,860 \text{ MHz}$, BGS 就可以有 48 种组合, 保持参数不变拼接 200 条 BGS 形成第一张三维 BGS 灰度图; 第二张中心频率设置在 $10\,850 \text{ MHz} \sim 10\,855 \text{ MHz}$, 跨度为 1 MHz , 其他参数与第一段一致, BGS 有 6 种组合, 保持参数不变拼接 100 条 BGS 形成第二张三维 BGS 灰度图, 将两张三维 BGS 灰度图进行拼接, 这样就形成一个 300×300 的三维 BGS 灰度图, 参数的不同组合产生 288 个三维 BGS 灰度图。选取 261 个作为训练集, 其余 27 个作为测试集。

2.2 仿真结果

研究了降噪模块个数与 RMSE、降噪时间的变化规律;输入数据信噪比与 RMSE、Uncertainty 的关系;扫频步长与 RMSE、Uncertainty 的关系;并且将 MSDUN 与 BM3D、DnCNN 这几种常见的降噪方法做了比较。

2.2.1 降噪模块数量与降噪时间、RMSE 的关系

降噪模块的数量决定了多尺度深度展开网络降噪的深度,图 9 显示了随着 t 的增加, RMSE 与降噪时间的变化,随着降噪模块的增加,降噪时间也会随之增加,指标也会趋于优化,当 t 从 1 增加到 4 时, RMSE 会缓慢下降;当 t 从 4 到 5 时, RMSE 显著下降;当 t 大于 6 时, RMSE 下降趋于平缓,虽然 t 大于 5 指标仍会有所改善,但降噪时间增加,综合考虑下,我们选择了 $t=5$ 。

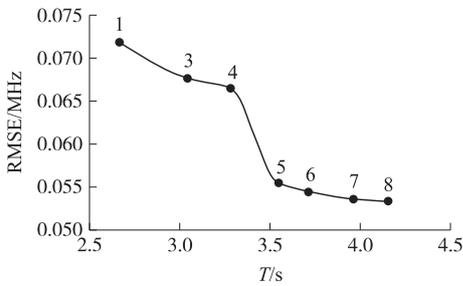
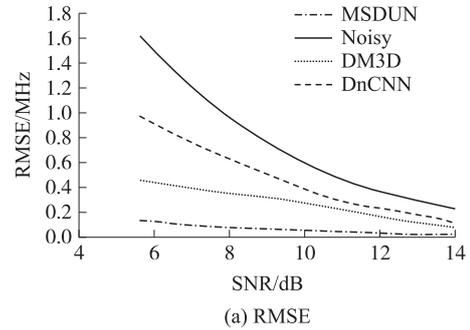


图 9 改变降噪模块个数,降噪时间与降噪后的 RMSE 的变化曲线

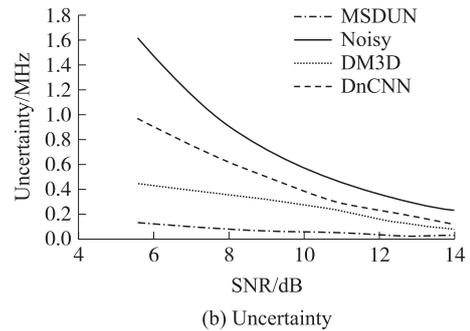
2.2.2 不同输入 SNR 下的指标曲线

输入数据的信噪比也是影响降噪效果的重要因素, Noisy 是降噪前的指标,从图 10 中可以看出,随着输入数据信噪比的增加,经过 MSDUN、BM3D、DnCNN 三种方法降噪后的 RMSE 与 Uncertainty 都在逐渐下降,并且都低于降噪前的指标,说明三种方法都具有一定的降噪效果。如图 10(a)所示,经过 MSDUN 降噪后的 RMSE 明显低于经过 DnCNN 与 BM3D 降噪后的 RMSE,在输入数据信噪比为 5.61 dB 时, MSDUN 的 SNR_{en} 可达到 10.82 dB,大于 BM3D 的 5.49 dB 和 DnCNN 的 2.23 dB;在输入数据信噪比为 12.5 dB 时, MSDUN 的 SNR_{en} 可达到 10.92 dB,大于 BM3D 的 3.84 dB 和 DnCNN 的 1.57 dB。如图 10(b)所示,与 RMSE 相似,经过 MSDUN 降噪后的 Uncertainty 明显低于经过 DnCNN 与 BM3D 降噪后的 Uncertainty,同样在输入数据信噪比为 5.61 dB 时, MSDUN 的信噪比增强了 10.90 dB,大于 BM3D 的 5.38 dB 和 DnCNN 的 2.20 dB;在输入数据信噪比为 12.5 dB 时, MSDUN 的 SNR_{en} 可达到 10.97 dB,大于 BM3D 的 3.84 dB 和 DnCNN 的 1.96 dB。上述数据说明,在仿真条件下,输入数据在高信噪比或低信噪比的情况下, MSDUN 都具有良好的降噪效果,始终优于 DnCNN 与 BM3D,

并且 MSDUN 的降噪时间比 BM3D 快了近 30 倍,稍慢于 DnCNN,由此可见 MSDUN 的优越性。



(a) RMSE



(b) Uncertainty

MSDUN 为经过 MSDUN 降噪后的指标曲线; Noisy 为降噪前的指标曲线; BM3D 为经过 BM3D 降噪后的指标曲线; DnCNN 为经过 DnCNN 降噪后的指标曲线。

图 10 不同输入数据信噪比下各方法降噪前后的 RMSE 和 Uncertainty(仿真)

2.2.3 不同扫频步长下的指标曲线

如图 11 所示,我们选择 SNR=7 的数据, Noisy 是降噪前指标,随着扫频步长的增加,由于信息的缺失,经过 MSDUN、BM3D、DnCNN 降噪后的 RMSE 与 Uncertainty 都在逐渐上升,但是都低于降噪前的指标,说明三种方法在不同步长下都具有一定的降噪效果。如图 11(a)所示,在不同扫频步长下,经过 MSDUN 降噪后的 RMSE 低于经过 DnCNN 与 BM3D 降噪后的 RMSE,在扫频步长为 1MHz 时, MSDUN 的信噪比增强可达到 9.82 dB,大于 BM3D 的 2.8 dB 和 DnCNN 的 1.90 dB,在扫频步长为 5 MHz 时, MSDUN 的信噪比增强可达到 10.38 dB,大于 BM3D 的 4.29 dB 和 DnCNN 的 3.05 dB。如图 11(b)所示,与 RMSE 相似,在不同扫频步长下,经过 MSDUN 降噪后的 Uncertainty 明显低于经过 DnCNN 与 BM3D 降噪后的 Uncertainty,同样在扫频步长为 1 MHz 时, MSDUN 的信噪比增强可达到 9.82 dB,大于 BM3D 的 2.8 dB 和 DnCNN 的 1.90 dB,在扫频步长为 5 MHz 时,经过 MSDUN 降噪后的信噪比增强了 10.32 dB,大于 BM3D 的 4.29 dB 和 DnCNN 的 3.11 dB,结果说明 MSDUN 在信息缺失的情况下,仍然有良好的降噪效果,并且明显优于 DnCNN 与 BM3D。

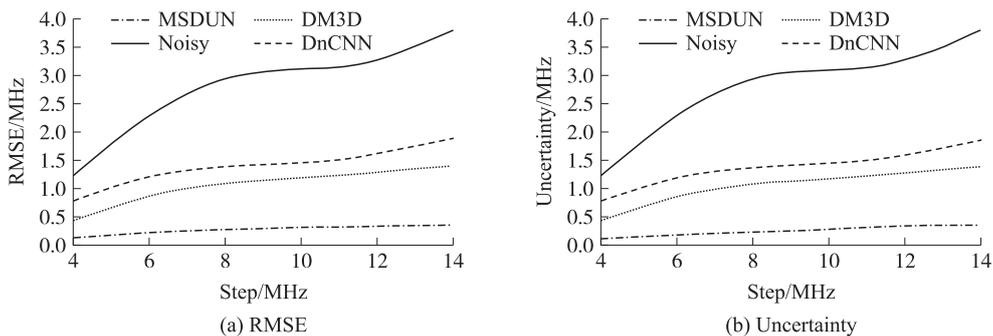
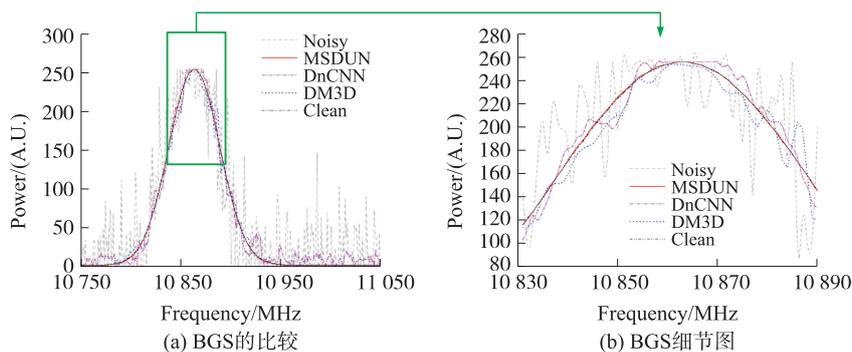


图 11 不同扫频步长下各方法降噪前后的 RMSE 和 Uncertainty (仿真)

2.2.4 不同降噪方法得到的 BGS 比较

如图 12(a) 所示,输入数据的信噪比设置为 7 dB,提取三维 BGS 灰度图中某一条 BGS 作比较, Noisy 代表降噪前的 BGS, Clean 代表干净的 BGS, MSDUN、BM3D、DnCNN 分别代表经过三种方法降噪的 BGS。图 12(b)是 10 830 Hz~10 890 Hz 频率范围内的细节图,可以看出加噪之后的 BGS 波动

大,可能导致洛伦兹拟合的偏差较大,经过 MSDUN、BM3D、DnCNN 降噪处理后 BGS 有明显的改善,说明三种方法都有一定的降噪效果,但是 BM3D、DnCNN 降噪后的 BGS 还是会有略微的抖动,与干净的 BGS 有一定偏差,而 MSDUN 降噪后的 BGS 几乎与干净的 BGS 重合,更直观地说明了 MSDUN 的降噪效果好。



Noisy 为降噪前的 BGS;MSDUN 为经过 MSDUN 降噪后的 BGS;DnCNN 为经过 DnCNN 降噪后的 BGS; BM3D 为经过 BM3D 降噪后的 BGS;Clean 为干净的 BGS。

图 12 降噪前 BGS 与各降噪方法得到的 BGS 的比较和 BGS 细节图 (仿真)

3 实验

3.1 实验装置

在本节中,通过实验验证多尺度深度展开网络的降噪效果。该设置如图 13 所示。窄线宽激光器的波长设置为 1 550 nm,并通过一个 50:50 的单模光纤耦合器分裂成两个分支。上部的分支由马赫-

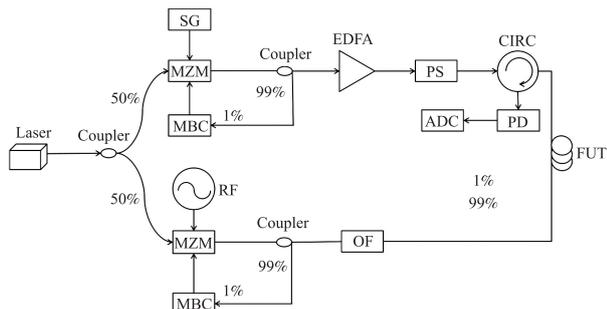


图 13 BOTDA 实验装置

曾德尔调制器 (Mach Zehnder Modulator, MZM) 和信号发生器 (Signal Generator, SG) 进行调制,以产生泵浦脉冲。为了抑制泵浦脉冲的泄漏,采用了一个调制器偏置控制器 (Modulator Bias Controller, MBC) 来控制 MZM 的偏置电压。在一个 1:99 的连接后,泵浦脉冲被分成两部分。1% 的脉冲被送回 MBC 以调整偏置电压,确保泵浦脉冲的泄漏几乎为零。其余 99% 的泵浦脉冲被一个掺铒光纤放大器 (Erbium-Doped Fiber Amplifier, EDFA) 放大,并通过一个偏振扰频器 (Polarization Scrambler, PS)。随后,泵浦脉冲通过光循环器 (Optical Circulator, CIRC) 进入被测光纤 (Fiber Under Test, FUT) 的一端。

下分支使用另一个 MZM 和一个射频源 (Radio Frequency Source, RF) 产生探测信号,频率范围从 10.500 GHz 到 11.000 GHz。另一种 MBC 用于控制 MZM 的偏置,以抑制光泄漏。在通过滤光器

(Optical Filter, OF)抑制噪声后,探针信号进入 FUT 的另一端。散射光被光电探测器(Photo Detector, PD)检测到,并转换为电信号。该数据由一个采样频率为 250 MSa/s 的模拟-数字转换器(Analog-Digital Converter, ADC)收集,并传输到计算机上。

3.2 实验数据生成

FUT 是一种长度为 1 000 m 的单模光纤。为了获得测量的 BGS, FUT 的最后 80 m 在水浴中加热。为了保证结果的可靠性,重复采集 FUT 5 次,以提供足够的数量。为了获得准确的 BFS 值,测量了不同温度下水浴中 80 m FUT 的 BGS。然后用线性曲线拟合来拟合数据以确定 BFS。为了保证 BFS 测量的精度,将平均时间设置为 10 000。计算结果如图 14 所示。

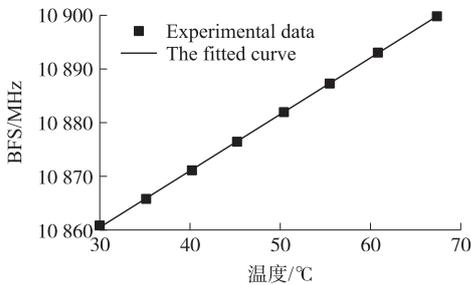


图 14 在不同的水浴温度下提取的 BFS

拟合优度超过 0.999,证实了温度与 BFS 之间的线性相关关系。因此,BFS 的实际值可以表示为:

$$y = 1.058 2x + 10 829 \quad (10)$$

式中: x 表示给定的温度, y 表示对应的 BFS。

温度系数为 1.0582 MHz/C。给定温度,我们可以用这个系数来近似 BFS 的真实值。

实验测试数据集构造如下: BGS 是从水浴中 FUT 的最后 80 m 中选择的,因为这段纤维保持了一个恒定的温度,对应于一个特定的 BFS 值。通过改变平均时间,可以得到不同信噪比的 BGS。实验的三维 BGS 灰度图构建方法与仿真一致,生成 27 张 300×300 的三维 BGS 灰度图作为实验的测试数据,我们将仿真部分得到的模型直接用于实验。

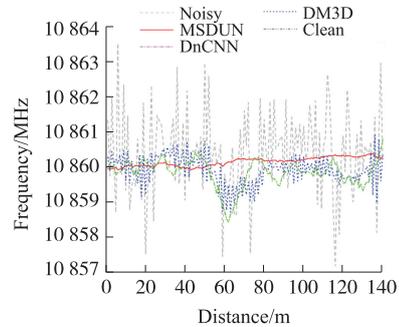
3.3 实验结果

研究了输入数据信噪比与 RMSE、Uncertainty 的关系;扫频步长与 RMSE、Uncertainty 的关系;并且将 MSDUN 与 BM3D、DnCNN 这几种常见的降噪方法做了比较。

3.3.1 不同降噪方法得到的 BFS 比较

图 15 显示了降噪前数据(Noisy)与几种降噪方法获得的降噪信号的比较,包括 MSDUN、BM3D、DnCNN,设置降噪前的信噪比为 8 dB。图中曲线代表每种方法降噪后的 BFS,可以看出每种方法降噪后的 BFS 都趋于平缓,说明每种方法都具有一定的降噪

效果。降噪前数据和经过 MSDUN、BM3D、DnCNN 三种方法降噪后数据的波动幅度分别为 6.32 MHz、0.47 MHz、2.18 MHz、2.34 MHz,从图和数据都不难看出,经过 MSDUN 降噪后的 BFS 曲线波动幅度小,更平稳,而且趋近于中心频率 10 860 Hz,更直观地体现出 MSDUN 降噪效果优于其他几种方法。

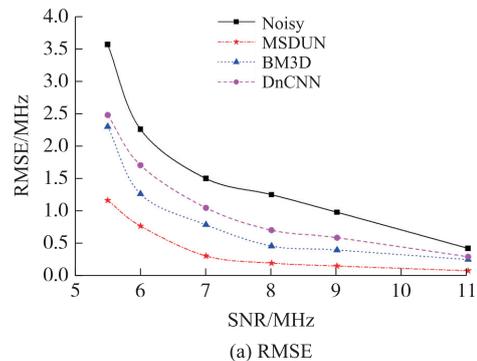


Noisy 为降噪前的 BFS;MSDUN 为经过 MSDUN 降噪后的 BFS;DnCNN 为经过 DnCNN 降噪后的 BFS;BM3D 为经过 BM3D 降噪后的 BFS。

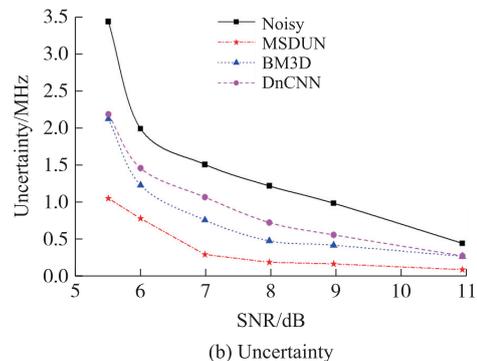
图 15 降噪前 BFS 与不同降噪方法得到的 BFS 的比较(实验)

3.3.2 不同输入 SNR 下的指标曲线

输入数据的信噪比也是影响降噪效果的重要因素, Noisy 是降噪前的指标,从图 16 中可以看出,随着输入数据信噪比的增加,经过 MSDUN、BM3D、DnCNN 降噪后的 RMSE 与 Uncertainty 都在逐渐下降,并且都低于降噪前的指标,说明三种方法都具有一定的



(a) RMSE



(b) Uncertainty

图 16 不同输入数据信噪比下各方法降噪前后的 RMSE 和 Uncertainty(实验)

降噪效果。如图 16(a) 所示,经过 MSDUN 降噪后的 RMSE 明显低于经过 DnCNN 与 BM3D 降噪后的 RMSE,在输入数据信噪比为 9 dB 时,MSDUN 的 SNRen 可达到 8.14 dB,大于 BM3D 的 3.92 dB 和 DnCNN 的 2.32 dB。如图 16(b) 所示,与 RMSE 相似,经过 MSDUN 降噪后的 Uncertainty 明显低于经过 DnCNN 与 BM3D 降噪后的 Uncertainty,同样在输入数据信噪比为 9 dB 时,MSDUN 的信噪比增强了 8.29 dB,大于 BM3D 的 3.87 dB 和 DnCNN 的 2.55 dB。而且 MSDUN 的降噪时间比 BM3D 快了近 30 倍,稍慢于 DnCNN,由此可见 MSDUN 的兼具速度与降噪效果。

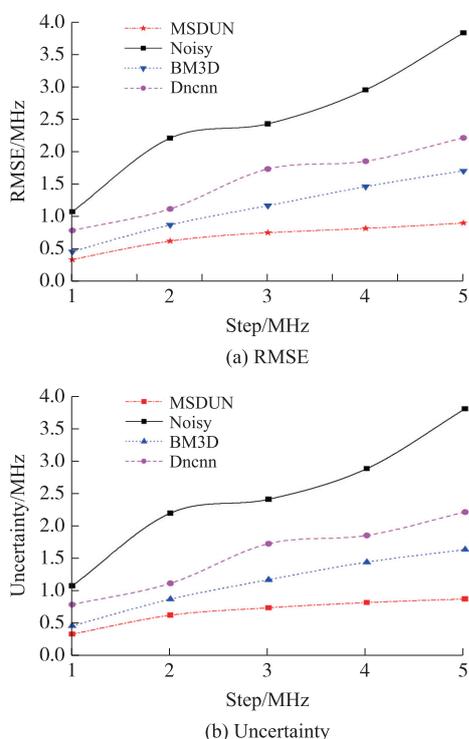


图 17 不同扫频步长下各方法降噪前后的 RMSE 和 Uncertainty (实验)

3.3.3 不同扫频步长下的指标曲线

在图 17 中,我们选择 SNR = 7 的数据, Noisy 是降噪前指标,随着扫频步长的增加,由于信息的缺失,经过 MSDUN、BM3D、DnCNN 降噪后的 RMSE 与 Uncertainty 都在逐渐上升,但是都低于降噪前的指标,说明三种方法在不同步长下都具有一定的降噪效果。如图 17(a) 所示,在不同扫频步长下,经过 MSDUN 降噪后的 RMSE 低于经过 DnCNN 与 BM3D 降噪后的 RMSE,在扫频步长为 1 MHz 时,MSDUN 的信噪比增强可达到 5.19 dB,大于 BM3D 的 3.78 dB 和 DnCNN 的 1.37 dB,在扫频步长为 5 MHz 时,MSDUN 的信噪比增强可达到 6.34 dB,大于 BM3D 的 3.54 dB 和 DnCNN 的 2.41 dB。如

图 17(b) 所示,与 RMSE 相似,在不同扫频步长下,经过 MSDUN 降噪后的 Uncertainty 明显低于经过 DnCNN 与 BM3D 降噪后的 Uncertainty,同样在扫频步长为 1 MHz 时,MSDUN 的信噪比增强可达到 5.25 dB,大于 BM3D 的 3.78 dB 和 DnCNN 的 1.37 dB,在扫频步长为 5 MHz 时,经过 MSDUN 降噪后的信噪比增强了 6.45 dB,大于 BM3D 的 3.69 dB 和 DnCNN 的 2.36 dB,说明 MSDUN 在信息缺失的情况下,仍然有良好的降噪效果,并且优于 DnCNN 与 BM3D。

表 2 显示了几种方法的运行时间,我们将实验得到的 27 张三维 BGS 灰度图用于测试,MSDUN 速度比 BM3D 快了近 30 倍,比 DnCNN 稍慢,但降噪效果却有较大的提升。

表 2 不同降噪方法的运行时间

Method	MSDUN	BM3D	DnCNN
Running time	4.8 s	141.8 s	1.72 s

4 结论

在本文中,我们的目的是对三维 BGS 灰度图进行降噪处理。为了实现这一点,我们将 MSDUN 应用于 BOTDA,对 BGS 进行降噪,并采用仿真和实验方法进行研究。MSDUN 结合基于模型的方法和基于学习的方法的优点,能够高效降低三维 BGS 灰度图中的噪声。为了明确 BGS 降噪性能,我们采用 RMSE 和 Uncertainty 两个指标来评估 BGS 降噪的最终效果。除此之外,我们还研究了输入 SNR、扫频步长与各指标的关系,并将 MSDUN 与 BM3D、DnCNN 方法的降噪效果进行了比较。结果表明,随着 MSDUN 降噪模块的增加,MSDUN 的降噪时间也会随之增加, RMSE 则趋于优化;随着输入数据信噪比的增加, RMSE 与 Uncertainty 都在逐渐下降。随着扫频步长的增加,由于信息的缺失, RMSE 和 Uncertainty 都会随之上升。从降噪效果上看, MSDUN、BM3D、DnCNN 三种方法中, MSDUN 的降噪效果最好, SNRen 达到 8.14 dB, 其次是 BM3D, SNRen 为 3.92 dB, 而 DnCNN 方法的表现最差, SNRen 为 2.23 dB; 从降噪速度上看, 三种方法中, MSDUN 进行 BGS 降噪只需 4.8 s, 比 BM3D 快了近 30 倍, 稍慢于 DnCNN。从可算法结构上看, MSDUN 通过将输入图像经过一系列参数可学习的降噪模块实现降噪, 卷积神经网络是隐含在每个降噪模块中的, 因此 MSDUN 结构层次清楚, 具有明晰的可解释性。由于在单个降噪模块中使用了卷积神经网络, 因此降噪速度相比 BM3D 这类基于模型的

方法更快。

后续工作将在以下几个方面开展,一是进一步提高算法的降噪性能,并在布里渊光时域反射计、分布式声传感等领域探索新的应用场景;二是结合实际工程数据进行分析,以挖掘更多有意义的特征信息;三是研究算法的稳定性和鲁棒性。

参考文献:

- [1] 刘戈. 大动态应变范围分布式光纤布里渊传感技术研究[D]. 广西:广西师范大学,2023.
- [2] 刘大卫. 基于分布式光纤传感技术的天然气管道泄漏监测研究[D]. 安徽:安徽理工大学,2019.
- [3] 张洪波,余志强,陈启锋,等. 基于 Sagnac 环的分布式光纤周界安防监测系统[J]. 光通信技术,2016,40(7):29-31.
- [4] 叶彬. 分布式光纤传感车辆振动识别及车速算法研究[D]. 杭州:浙江大学,2018.
- [5] 王茂宁. 基于分布式光纤传感的高速公路车辆检测与轨迹预测关键技术研究[D]. 成都:四川大学,2022.
- [6] 毛江鸿. 分布式光纤传感技术在结构应变及开裂监测中的应用研究[D]. 杭州:浙江大学,2013.
- [7] 孙士杰. 基于布里渊散射的分布式光纤温度传感器的关键技术研究[D]. 北京:北京交通大学,2014.
- [8] Ren C,Zhang S. Abnormal Intensity Noise of LD-Pumped Mi-Erochip Nd: YAG Laser [J]. Journal of Applied Optics,2012,33(3):609-613.
- [9] Zhou H,Chen W,Meng Z,et al. Phase Noise Characteristics of Narrow-Linewidth Fiber Laser and Laser Diode in Unbalanced Interferometers[J]. Chinese Optics Letters,2013,11(2):55-57.
- [10] Urricelqui J,Soto M A,Thévenaz L. Sources of Noise in Brillouin Optical Time-Domain Analyzers[C]//24th International Conference on Optical Fibre Sensors,Curitiba,Brazil,SPIE,2015:377-380.
- [11] Liu R X,Zhang M J,Zhang J Z,et al. Temperature Measurement Accuracy Enhancement in the Brillouin Optical Time Domain Reflectometry System Using the Sideband of Brillouin Gain Spectrum Demodulation[J]. Acta Physica Sinica,2016,65(24):609-613.
- [12] Li Y,Bao X,Dong Y,et al. A Novel Distributed Brillouin Sensor Based on Optical Differential Parametric Amplification[J]. Journal of Lightwave Technology,2010,28(18):2621-2626.
- [13] Hershey J R,Le Roux J,Weninger F. Deep Unfolding: Model-based Inspiration of Novel Deep Architectures [EB/OL]. (2014-11-20). <https://arxiv.org/abs/1409.2514>.
- [14] Ning Q,Dong W,Shi G,et al. Accurate and Lightweight Image Super-Resolution with Model-Guided Deep Unfolding Network[J]. IEEE Journal of Selected Topics in Signal Processing,2020,15(2):240-252.
- [15] Zhang Z,Liu Y,Liu J,et al. AMP-Net: Denoising-Based Deep Unfolding for Compressive Image Sensing[J]. IEEE Transactions on Image Processing,2021,19(30):30-35.
- [16] Soto M A,Ramírez J A,Thévenaz L. Intensifying the Response of Distributed Optical Fibre Sensors Using 2D and 3D Image Restoration[J]. Nature Communications,2016,7(1):10870.
- [17] Wu H,Wang L,Zhao Z Y,et al. Brillouin Optical Time Domain Analyzer Sensors Assisted by Advanced Image Denoising Techniques[J]. Optics Express,2018,26(5):5126-5139.
- [18] Wang Y J,Yao H P,Wang J J,et al. Distributed Optical Fiber Sensing System for Large Infrastructure Temperature Monitoring[J]. IEEE Internet of Things Journal,2022,9(5):3333-3345.
- [19] 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.
- [20] Abbasnezhad M,Alizadeh B. FPGA-Based Implementation of an Artificial Neural Network for Measurement Acceleration in BOTDA Sensors[J]. IEEE Transactions on Instrumentation and Measurement,2019,68(11):4326-4334.
- [21] Wu H,Wan Y Y,Tang M,et al. Real-Time Denoising of Brillouin Optical Time Domain Analyzer with High Data Fidelity Using Convolutional Neural Networks[J]. Journal of Lightwave Technology,2019,37(11):2648-2653.
- [22] 李晨玉,洪丹枫,张兵. 深度展开网络的高光谱异常探测[J]. 遥感学报,2024,28(1):69-77.
- [23] 杨贵江,钱宇昊,周旖艺,等. 分布式布里渊光纤传感系统中的数字信号处理技术研究进展[J]. 光学学报,2024,44(1):90-102.
- [24] Zhang K, Van Gool L, Timofte R. Deep Unfolding Network for Image Super-Resolution [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, SA, USA, IEEE, 2020:3214-3223.
- [25] Xu J, Yuan M, Yan D M, et al. Deep Unfolding Multi-Scale Regularizer Network for Image Denoising[J]. Computational Visual Media,2023,9(2):335-350.
- [26] Gregor K, LeCun Y. Learning Fast Approximations of Sparse Coding [C]//27th International Conference on International Conference on Machine Learning, Haifa, Israel,2010:399-406.
- [27] Song J,Chen B,Zhang J. Dynamic Path-Controllable Deep Unfolding Network for Compressive Sensing [J]. IEEE Transactions on Image Processing,2023,32:2202-2214.

- [28] Dutta S, Basarab A, Georgeot B, et al. Deep Unfolding of Image Denoising by Quantum Interactive Patches [C]//2022 IEEE International Conference on Image Processing (ICIP), Bordeaux, France, IEEE, 2022: 491–495.
- [29] Qin M, Ren C, Yang H, et al. Blind Image Denoising via Deep Unfolding Network with Degradation Information Guidance[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2023, 70(8): 3179–3183.
- [30] Nair V, Hinton G E. Rectified Linear Units Improve Restricted Boltzmann Machines [C]//27th International Conference on Machine Learning, Haifa, Israel, 2010: 807–814.
- [31] Zontak M, Mosseri I, Irani M. Separating Signal from Noise Using Patch Recurrence Across Scales [C]//2013 IEEE Conference on Computer Vision and Pattern Recognition, Portland, OR, USA, IEEE, 2013: 1195–1202.
- [32] Dong H, Pan J S, Xiang L, et al. Multi-Scale Boosted Dehazing Network with Dense Feature Fusion [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA, IEEE, 2020: 2154–2164.
- [33] Wang Q, Bai Q, Liu Y, et al. SNR ENHANCEMENT for BOTDR with Spatial-Adaptive Image Denoising Method [J]. Journal of Lightwave Technology, 2022, 41(8): 2562–2571.



郑欢(1982—),男,2009年中国科学技术大学获得博士学位,现为浙江工业大学副教授,高级工程师,硕士生导师。主要研究方向为:分布式光纤传感技术、物联网传感技术及应用, zhenghuan@zjut.edu.cn。