

基于生成对抗网络的布里渊分布式光纤传感器降噪

罗阔^{1,2}, 王宇瑶³, 朱柏蓉^{1,2}, 余贻球^{1,2*}

¹北京交通大学信息科学研究所, 北京 100044;

²现代信息科学与网络技术北京市重点实验室, 北京 100044;

³香港理工大学电子及信息工程系光子研究所, 香港 999077

摘要 首先,利用自洽约束生成对抗网络(SCGAN)建模布里渊增益谱(BGS)中的真实噪声分布,生成噪声数据用于去噪卷积神经网络训练。通过对高斯噪声和SCGAN生成噪声进行直方图统计和幅度谱分析,证明了两种噪声的差异。然后,利用2种噪声分别训练3种最新的去噪卷积神经网络,在不同温度、不同信噪比的实验数据上对比了各网络的性能。实验结果表明,所提方法能准确获取低信噪比BGS的布里渊频移,说明基于生成对抗网络的噪声提取方式能够有效地建模真实噪声,更好地训练有监督网络。

关键词 光纤光学; 布里渊分布式光纤传感; 图像去噪; 生成对抗网络; 自洽约束; 噪声建模

中图分类号 O436

文献标志码 A

DOI: 10.3788/AOS231120

1 引言

最近几十年,基于布里渊散射的分布式光纤传感器得到了广泛的研究^[1-3],其中布里渊光时域分析(BOTDA)因具有长距离分布式传感、双参量监测、测量精度高等优势,在大型基础设施结构健康监测和故障诊断等领域得到广泛的应用^[4-5]。

信噪比(SNR)是BOTDA系统的关键性能指标,如何提升SNR是科研人员的主要研究方向之一。目前,有科研人员提出利用拉曼增益^[6-7]、光脉冲编码^[8-10]等方法来提高光信号强度,以提升布里渊系统的SNR。拉曼光放大技术需要较高的拉曼泵浦功率,使得系统结构更加复杂,而且受到相对强度噪声的影响,该方法的应用受到一定限制。脉冲编码技术增加了数据处理复杂度和测量时间,实际应用中还面临脉冲码型、码长和调制格式选择的问题。另外,有科研人员通过改变光脉冲形状^[11]和调制器消光比^[12-13]等方式来提高系统SNR,这些方法虽然降低了测量的不确定度,提高了测量精度,但未充分考虑系统噪声的影响,因此又有科研人员提出从抑制系统噪声的角度来提升SNR,通过引入无源消偏器^[14]、布拉格光栅^[15]、正交偏振态^[16]等方式消除系统中噪声的影响,但增加了系统硬件复杂度。

此外,学者们还提出了针对已获得布里渊数据的噪声去除方案,可以在不增加硬件复杂度的情况下提高SNR,如数字图像算法^[17-22]、神经网络算法^[23]等。其中,数字图像算法将图像处理算法应用到布里渊增益谱(BGS)图像上,极大地提高了SNR,但随着处理数据量的增大,该算法难以满足实时性要求。相比之下,神经网络算法虽然在训练阶段消耗时间,但一经训练完毕就可以用于实时去噪。神经网络的有监督训练通常假设已知带噪数据(含噪BGS)和所对应的干净数据(无噪BGS),但在实际应用中无法获取这种配对BGS,所以现有方法使用高斯白噪声模拟真实噪声进行有监督训练。BOTDA系统信号传输、采集过程中包含的噪声种类较多,包括热噪声、相位带来的强度噪声、泵浦信号拍频噪声等^[24],用高斯噪声模拟的结果不够准确,所以现有网络所学习的噪声特征和真实噪声的特征必定存在差异。此外,也有研究人员提出采集泵浦光关闭后光电探测器的输出作为噪声,并结合理想的BGS进行有监督训练,但其采集到的噪声和光电探测器工作时的真实噪声也并不一致^[25]。

针对上述问题,本文首先使用基于自洽约束的生成对抗网络(SCGAN)来对BGS真实噪声进行建模,并将所得噪声与理想BGS合成配对数据,训练去噪卷积神经网络以实现BGS降噪。然后,利用2种噪声对

收稿日期: 2023-06-13; 修回日期: 2023-07-19; 录用日期: 2023-09-15; 网络首发日期: 2023-09-22

基金项目: 中央高校基础研究基金(021314380211)、国家重点基础研究发展计划(2021YFB2900704)、中国科协中外优秀青年交流计划

通信作者: *klyu@bjtu.edu.cn

3种去噪卷积神经网络进行有监督训练,这3种神经网络分别为去噪卷积神经网络(DnCNN)、基于注意力机制的卷积神经网络(ADNet)^[26]和基于批重归一化的卷积神经网络(BRDNet)^[27]。实际采集的BGS降噪结果表明,相比于高斯噪声,利用本文方法所获得的噪声能够在训练网络时保留BGS细节信息,而且在低SNR下获得极高的测量精度,证明了利用生成对抗方法提取的噪声更符合真实噪声分布,能够取得更好的降噪效果。本文还对高斯噪声和SCGAN生成噪声进行直方图统计和幅度谱对比分析,证明了所得噪声和高斯噪声的差异,也说明了传统基于高斯噪声进行去噪的方案并不准确。

2 相关理论

2.1 生成对抗网络

生成对抗网络(GAN)^[28]近年来被逐渐应用于分布式光纤传感的数据处理中,如BGS超分辨率重

构^[29]、相敏光学时域反射计(Φ -OTDR)数据增强等^[30]。图1展示了GAN的基本结构^[31],GAN包含一个生成器(G)和一个判别器(D),并将它们作为博弈的双方进行对抗学习。 G 的目标是学习如何能够生成与真实数据分布相似的样本, D 的目标则是通过二分类判断输入的数据是真或伪,真表示输入 D 的数据来自真实的数据分布,伪则表示数据来自生成器生成的假样本。GAN的训练过程是一个对抗性的过程, G 先从源噪声数据 z 中学习数据特征,生成一些虚假的数据 $G(z)$,再将其传递给 D , D 会将这些数据与真实数据 x 进行比较,并给出一个分类结果。 G 会根据 D 的结果进行更新,以生成更接近真实数据的数据,而 D 也会根据对 x 和 $G(z)$ 的分类结果进行反向更新,以提高自己的准确率。 G 和 D 通过交替训练,不断提高自己的生成能力和判别能力,以达到一个纳什均衡,使得 G 可以生成与真实数据非常相似的新数据,而 D 无法区分真实数据和虚假数据。




图1 GAN模型的基本结构

Fig. 1 Basic structure of GAN model

2.2 SCGAN 结构

目前,GAN虽然已经被证明能够有效地从大量输入样本中建模复杂的噪声数据分布^[32],但是GAN的训练目标是通过最小化生成样本与真实样本之间的差异来调整生成器网络,这可能导致生成器网络偏向于生成训练数据中最常见的模式,而忽略了其他潜在的模式和多样性。因此,仅使用对抗损失优化网络往往导致噪声建模受限。为了改善这个问题,采用SCGAN^[33]进行噪声建模,SCGAN在对抗损失的基础上增加了3个额外的损失函数来约束网络的训练,以便指导网络更好地进行噪声建模。

图2展示了本实验所用SCGAN的结构,其中生成器 G 的深度为17层,输入数据先经过第一层卷积(Conv)操作后,经过修正线性激活单元(ReLU)将数据限制在非负范围内,以避免梯度消失问题;再经过相同的15层操作,包括Conv、批归一化(BN)和ReLU,BN被用来加快训练的同时减少内部协变量偏移^[34],这15层的输入、输出特征数都为64,卷积核大小为 3×3 ,卷积操作默认填充0,padding设为1。数据最后经过一个Conv操作便得到估计噪声,利用原始数据减去估计噪声得到估计的干净数据,并将其输入判别

器 D 。判别器 D 含有4层,前3层经过Conv操作之后会经过带泄漏修正线性单元(LeakyReLU)激活函数,其negative-slope设为0.2,LeakyReLU函数是ReLU的变体,它可以有效减少静默神经元的出现^[35]。4层Conv的输出通道数分别为64、128、64、1,padding数都设为0。

在传统GAN中,当带噪数据 I_n 作为输入时,噪声建模网络 G 将会输出估计的噪声 $G(I_n)$,这里 $G(\cdot)$ 表示带噪数据到噪声的一个映射。由此 I_n 对应的干净数据可以被估计为 $I'_c = I_n - G(I_n)$,随后该数据将和真正的理想数据 I_c 一同输入到判别器 D ,以鉴别数据来源的真伪。由此,对抗网络生成的目标函数可以表示为

$$\min_G \max_D L_{GAN}(G, D) = -E_{I_c \sim p_{\text{data}}(c)} \left[\|D(I_c) - 1\|_2^2 \right] - E_{I_n \sim p_c(z)} \left[\|D(I'_c) - 0\|_2^2 \right], \quad (1)$$

式中: $p_{\text{data}}(c)$ 为理想数据分布; $p_c(z)$ 为真实数据分布; $D(\cdot)$ 为判别器映射,对应结果是0或1; E 为损失期望。

SCGAN在式(1)的基础上增加了3个额外的目标约束,对应的损失函数分别如下:

- 1) 干净数据一致性约束。将干净数据 I_c 输入 G

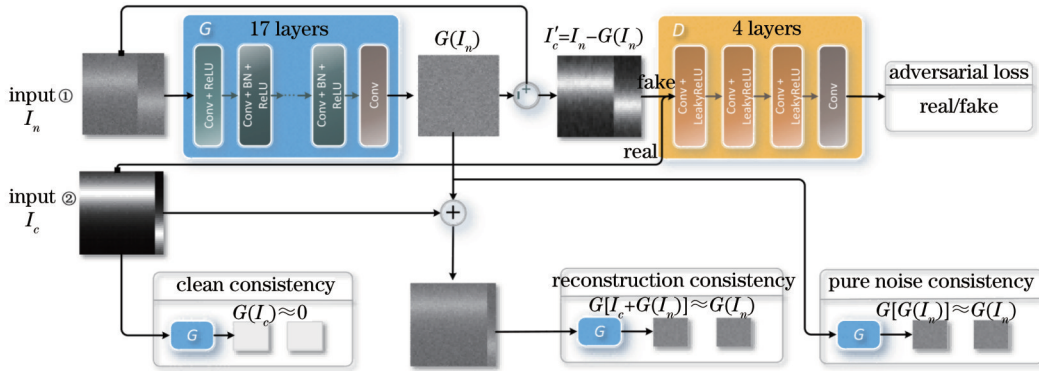


图 2 SCGAN 结构图

Fig. 2 Structure of SCGAN

时,输出噪声应当为0,对应的损失函数为

$$L_{\text{clean}} = E_{I_c \sim p_{\text{data}}(c)} \left[\|G(I_c) - 0\|_2^2 \right]. \quad (2)$$

2) 噪声数据一致性约束。将噪声 $G(I_n)$ 数据输入 G 时得到 $G(I_n)$, 对应的损失函数为

$$L_{\text{pn}} = E_{I_n \sim p_z(z)} \left[\|G[G(I_n)] - G(I_n)\|_2^2 \right]. \quad (3)$$

3) 重构数据一致性约束。将干净数据 I_c 和噪声 $G(I_n)$ 组合后输入 G , G 能够得到噪声 $G(I_n)$, 对应的损失函数为

$$L_{\text{rec}} = E_{I_c \sim p_{\text{data}}(c)} \left[\|G[I_c + G(I_n)] - G(I_n)\|_2^2 \right]. \quad (4)$$

通过在式(1)中添加自洽约束条件[式(2)~(4)], SCGAN 的总体目标如式(5)所示, 其中 $\lambda_1, \lambda_2, \lambda_3$ 都是非负权重。

$$\min_G \max_D L_{\text{GAN}}(G, D) + \lambda_1 L_{\text{clean}} + \lambda_2 L_{\text{pn}} + \lambda_3 L_{\text{rec}}. \quad (5)$$

3 实验设置

3.1 实验装置

所使用的 BOTDA 传感系统的实验装置如图 3 所示。1550 nm 激光器(LD)输出光被耦合器(coupler)分为两路, 上支路为探测光信号, 经过偏振控制器(PC)后进入强度调制器(EOM), 由射频信号源(RF)输出控制信号对探测光进行双边带调制。调制后探测

光信号的功率由掺铒光纤放大器(EDFA)放大, 然后经光纤布拉格光栅(FBG)滤波器和隔离器(ISO)后进入待测(FUT)一端。下支路为泵浦光, 任意波形发生器(AWG)输出脉冲并调制通过 EOM 2 的泵浦光, 经过扰偏器(PS)后被 EDFA 2 放大, 然后滤波并经过环形器(Cir)进入 FUT 的另一端。两路光在 FUT 中发生受激布里渊散射后, 由光电探测器(PD)接收, 最后由示波器采集。实验中扫频范围为 10.5~11.2 GHz, 扫频间隔为 1 MHz, 采样率为 500 MSa/s, 泵浦脉冲宽度为 20 ns, FUT 的总长约为 40 km, 末端的 120 m 和 2.6 m 两段光纤分别放入恒温水浴箱(water bath)中, 室温约为 26 °C。

3.2 实验数据及训练细节

本实验所用的训练数据大小为 200×200 , 共有两个数据集, 一个是带噪真实数据, 另一个是理想 BGS 构成的数据集。其中, 理想 BGS 数据集的生成基于如下公式:

$$g(\nu) = \frac{g_0}{1 + [(\nu - \nu_B) / (\Delta\nu_B / 2)]^2}, \quad (6)$$

式中: ν 表示入射光的频率; ν_B 表示布里渊频移(BFS); $\Delta\nu_B$ 表示 BGS 的半峰全宽; g_0 表示 BGS 的增益峰值。理想数据中 ν 的取值范围为 10.751~10.95 GHz, 间隔为 1 MHz, $\Delta\nu_B$ 在 30~80 MHz 范围内随机取值, g_0 取值为 1。图 4 展示了模拟数据的组成, 每幅图像由 200 条




图 3 BOTDA 传感系统实验装置图

Fig. 3 Experimental device diagram of BOTDA sensing system

随机生成的BGS组成,总共3000幅。带噪真实数据来自设备采集的不同温度、不同平均次数下的数据,采集温度分别设置为室温(26℃)、40℃、50℃、60℃、70℃,平均次数分别设置为1、5、10、25、50、100、150、200、250、500次,同一个温度和采集次数下重复采集5次,一共采集 $5 \times 10 \times 5 = 250$ 组数据。图4(a)展示了所采集

光纤数据的尾端640 m长光纤数据,数据大小为 3200×700 ,横轴(距离)代表沿光纤方向的采样点位置,纵轴(频率)代表扫频范围。为和理想BGS匹配,从采集的5组BGS中随机选取4组,在这200组数据中随机裁剪出 200×200 大小的数据,如图4(c)所示,一共得到3000幅图像作为训练集,剩余50组数据作为测试集。

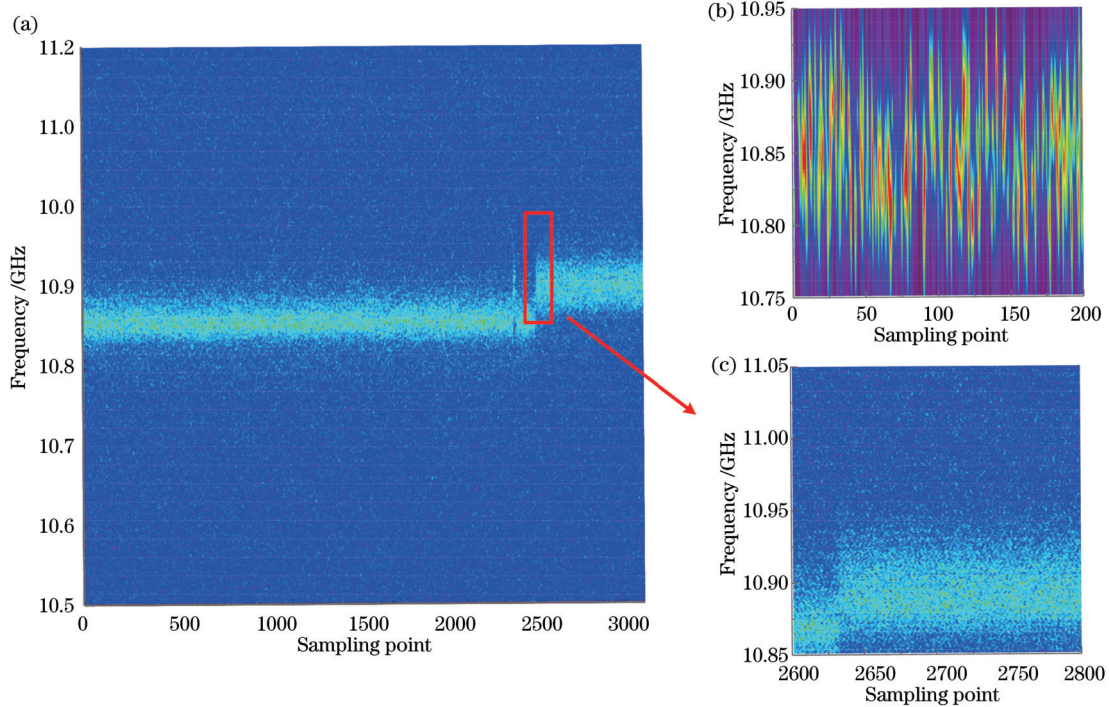


图4 BGS数据。(a)采集数据(最后640 m);(b)模拟数据;(c)裁剪后的采集数据

Fig. 4 BGS data. (a) Experimental BGS (last 640 m); (b) simulated BGS; (c) cropped experiment BGS

将SCGAN训练轮数设置为70,批大小设置为4,初始学习率设为0.0001,使用Adam优化器优化网络参数,生成器 G 和判别器 D 交替训练的频率设为每训练5次 G ,训练1次 D 。SCGAN的训练过程分为3个阶段:第一阶段对应训练轮数1~15,此阶段仅使用式(1)的损失函数来优化网络参数,主要目的是从带噪数据中提取噪声,但由于缺乏约束条件,所得噪声中包含数据图像的背景和纹理信息;第二阶段对应第16~45轮,此阶段开始引入式(2)、(3)的约束条件,经过这一阶段的训练 G 应该能够把干净数据映射为零噪声,并且从纯噪声数据中提取噪声的恒等映射,但是所得噪声数据仍然可能包含边缘信息;第三阶段对应第46轮到结束,此阶段引入式(4)中的损失函数来去除噪声数据包含的边缘信息。

4 实验结果和分析

4.1 降噪结果

SCGAN对噪声建模完成后即可生成噪声数据与理想BGS数据集的组合,从而得到配对的训练数据用于有监督网络的训练,本次实验分别将高斯噪声和SCGAN生成噪声加入理想BGS以探究两种噪声对降

噪结果的影响。训练所用卷积神经网络包括DnCNN、ADNet以及BRDNet。其中:DnCNN是利用残差学习实现去噪的经典卷积神经网络;ADNet利用稀疏机制、特征增强机制和注意力机制,可实现复杂背景中的噪声移除;BRDNet利用批重归一化和双层网络结构,显著提升了硬件资源受限和数据分布不均匀情况下的网络降噪效果。3种网络的训练超参数均参考文献[25-27]中的超参数进行设置,为比较两种噪声数据集对训练结果的影响,每次训练时网络超参数保持不变。

图5展示了测试数据降噪后的结果。图5(a)~(c)所示为高斯噪声训练网络的降噪结果,图5(d)~(f)所示为SCGAN生成噪声训练网络的降噪结果。可以看到,基于两种噪声训练的网络都能很好地去除布里渊数据中的噪声。接下来使用洛伦兹拟合算法提取布里渊频移,并计算对应的温度。图6展示了利用SCGAN噪声训练的BRDNet降噪后,测试数据对应的温度信息,其中实线表示原始数据,虚线表示降噪后的结果。可以看到,小峰部分(2.6 m)以及上升沿部分信息都得到了很好的保留,说明所提方法能够帮助去噪神经网络针对性去除噪声的同时保留细节信息。




图 5 不同网络的测试数据降噪结果。(a)(d)DnCNN; (b)(e)ADNet; (c)(f)BRDNet

Fig. 5 Test data noise reduction results of different networks. (a)(d) DnCNN; (b)(e) ADNet; (c)(f) BRDNet




图 6 测试数据利用基于 SCGAN 噪声训练的 BRDNet 降噪后所得温度分布

Fig. 6 Temperature distribution obtained after denoising test data using BRDNet trained on SCGAN noise

为了准确地说明所提方法提升 SNR 的效果,利用两种噪声训练后的去噪神经网络对不同温度和不同平均次数的测试数据进行去噪处理,结果如表 1 和表 2 所示。表 1 对比了平均次数为 500 时,不同温度下的测试数据经不同噪声训练的神经网络的 SNR,可以看到,在不同温度下,相较于高斯噪声训练的网络,基于 SCGAN 生成噪声训练的网络所得 SNR 更高,且 BRDNet 网络在 3 种去噪网络中性能最好,SNR 提升最高,约为 16.1 dB,高于高斯噪声训练网络的最大 SNR(14.9 dB)。表 2 展示了温度为室温(26 °C)时,不同采集平均次数下的测试数据经不同噪声训练的神经网络的 SNR,可以看到,在不同平均次数下,基于 SCGAN 生成噪声训练的网络所得 SNR 更高,且

BRDNet 的 SNR 提升最多,约为 15.2 dB,高于基于高斯噪声训练网络的最大 SNR 提升量(13.6 dB)。通常来说,更好的 SNR 意味着能得到更高的测量精度,这意味着利用所提方法在低 SNR 数据下依然能获得很高的测量精度,后续实验也证实了该结论的正确性。

在得到温度数据后计算对应的均方根误差(RMSE)和标准差(SD)。图 7 展示了采集次数为 500 次时,不同温度的测试数据经两种噪声训练的神经网络降噪后,利用洛伦兹拟合得到的结果。由图 7(a)~(c)可知,利用基于 SCGAN 生成噪声训练的 3 种去噪网络降噪后所拟合得到的 RMSE 均低于基于高斯噪声训练的 3 种网络的对应结果;类似地,图 7(d)~(f)中基于 SCGAN 生成噪声的 SD 结果也低于基于高斯

表 1 基于两种噪声训练的去噪网络对不同温度测试数据的 SNR 对比

Table 1 SNR comparison of experimental data at different temperatures by denoising networks trained on two types of noise

Temperature / °C	Raw SNR / dB	SNR in DnCNN / dB		SNR in ADNet / dB		SNR in BRDNet / dB	
		Gaussian	SCGAN	Gaussian	SCGAN	Gaussian	SCGAN
26	13.5075	27.7086	28.0158	27.0201	28.6580	28.2479	29.6317
40	13.6129	27.8218	28.2357	27.2484	28.8876	28.3616	29.1959
50	13.5443	27.6914	28.1440	27.1203	28.7308	28.2401	29.6505
60	13.6348	27.8036	28.1672	27.1721	28.7854	28.3438	29.5065
70	12.3321	26.9403	28.0238	26.4081	28.2484	27.5273	29.4539

表 2 基于两种噪声训练的去噪网络对不同平均次数测试数据的 SNR 对比

Table 2 SNR comparison of experimental data of different averaging times by denoising networks trained on two types of noise

Averaging times	Raw SNR / dB	SNR in DnCNN / dB		SNR in ADNet / dB		SNR in BRDNet / dB	
		Gaussian	SCGAN	Gaussian	SCGAN	Gaussian	SCGAN
1	-5.4766	3.9548	3.8272	4.1264	3.3162	4.4908	4.3208
5	-4.5424	7.7427	11.4619	8.5955	9.5528	8.5702	9.7921
10	-2.3383	11.1577	14.2687	11.9138	12.7696	11.5519	14.9751
25	1.0609	14.6377	17.4872	15.6181	16.4871	15.0304	17.5681
50	3.8668	17.4716	20.3283	18.6267	19.4804	17.9637	20.5342
100	6.6848	20.7458	23.2891	21.9693	22.7074	21.3077	23.5499
150	8.4353	21.6659	24.1926	22.9131	23.6646	22.2674	24.5940
200	9.6116	22.8649	25.2255	24.0988	24.8258	23.4732	25.6493
250	10.5648	23.7411	25.9811	24.9672	25.7109	24.3580	26.4586
500	13.5075	27.7086	28.0158	27.0201	28.6580	28.2479	28.7317

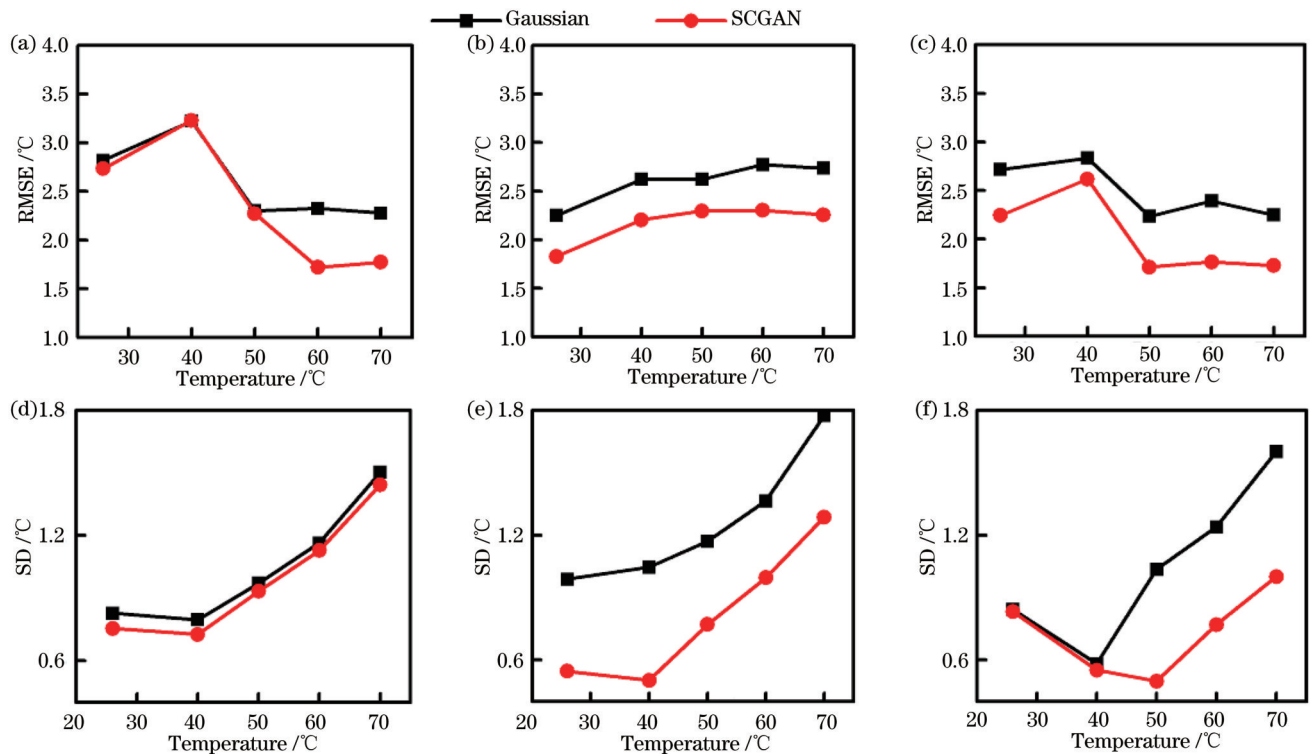


图 7 基于 2 种噪声训练的 3 种卷积网络对不同温度测试数据的降噪效果对比。(a)(d)DnCNN; (b)(e)ADNet; (c)(f)BRDNet

Fig. 7 Comparison of noise reduction effects of three convolutional networks training by two noise on test data at different temperatures. (a) (d) DnCNN; (b) (e) ADNet; (c) (f) BRDNet

噪声的相应结果,意味着基于 SCGAN 生成噪声数据训练的神经网络能够更好地去除噪声,获得更精确和

稳定的测量结果。

本文还比较了不同平均次数下的测试数据降噪效

果。图 8 展示了温度为 70 °C 时,不同采集次数下的数据经过两种噪声训练的神经网络降噪后,利用洛伦兹拟合得到的结果。随着平均次数逐渐增加,数据采集时间越来越长,采集数据的 SNR 越来越高,利用 SCGAN 生成噪声训练的去噪神经网络始终能够取得更低的 RMSE 和 SD。对于 BRDNet, SCGAN 噪声训练的结果在平均次数为 10 次时所得的 RMSE 为 5.12 °C,低于高斯噪声训练结果在平均次数为 250 次

时所得的 RMSE(5.19 °C),这意味着在实际应用中,所提方法能够在更短的采集时间内获得准确的温度信息,具有非常重要的实际意义。另外,尽管 GAN 的训练时间较长,其训练过程是一次性的,一旦训练好,就可将配对的数据用于去噪网络训练以进行针对性降噪,而且去噪网络的训练也是一次性的,训练完成后的网络是可以满足实时性使用需求的。

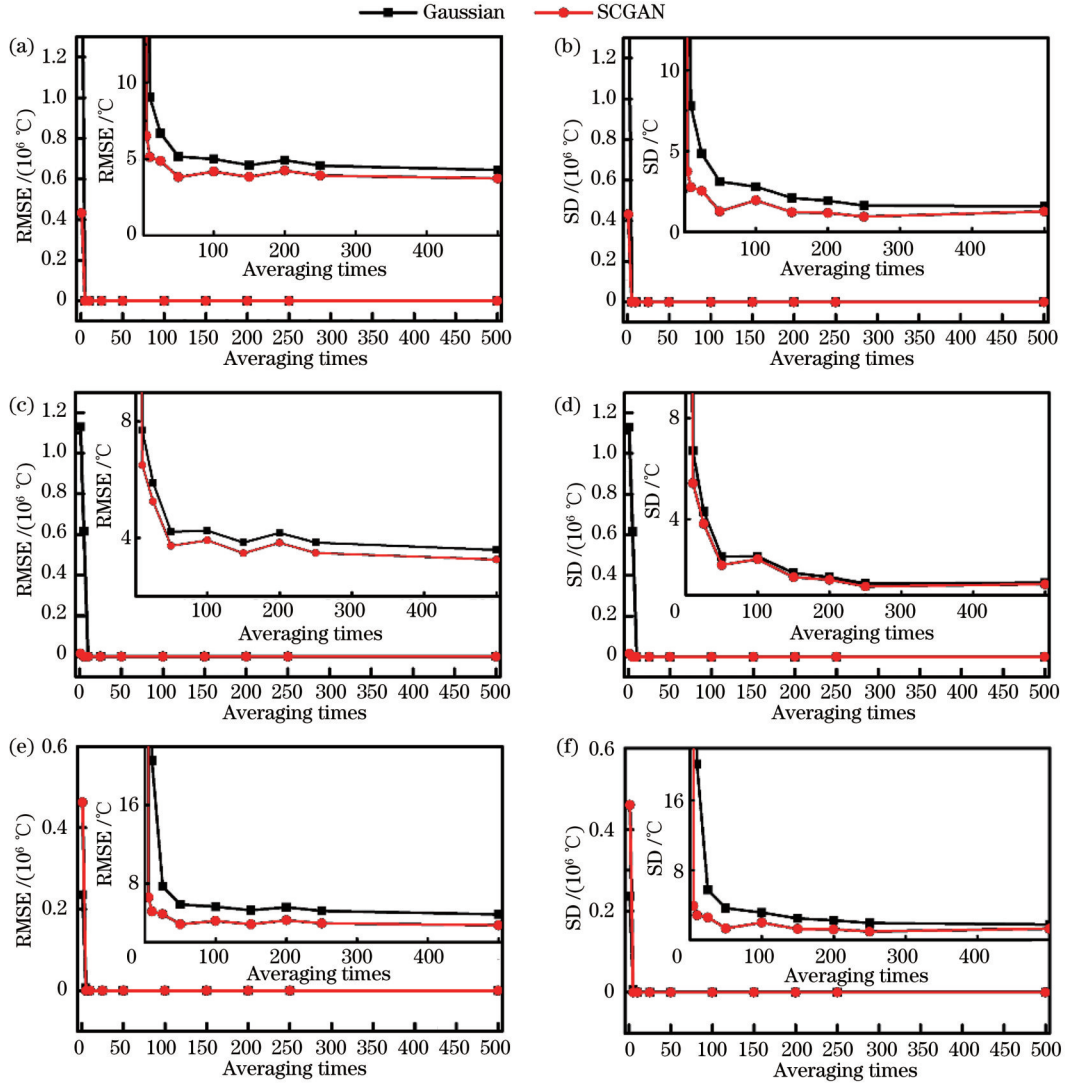


图 8 基于两种噪声训练的三种卷积网络对不同平均次数测试数据的降噪效果对比。(a)(b)DnCNN;(c)(d)ADNet;(e)(f)BRDNet
Fig. 8 Comparison of noise reduction effect of three convolutional networks training by two noise on test data with different averaging times. (a) (b) DnCNN; (c) (d) ADNet; (e) (f) BRDNet

4.2 噪声分析

在完成对 SCGAN 网络的训练后,就能得到大小为 200×200 的噪声数据。图 9(a)展示了裁剪后的大小为 200×200 的真实带噪训练数据,采样点数为 2601~2800,频率为 10.851~11.05 GHz。将其输入 G 后,得到对应的噪声图像,如图 9(b)所示。图 9(b)中已经没有明显的信息,仅有随机的噪声信息。图 9(c)展示了高斯噪声的图像。从图 9(b)、(c)可以看

到,从二维的角度来看,SCGAN 生成噪声和高斯噪声呈现的特征相似。图 9(d)、(e)中分别就二者在频率方向和采样点方向对应位置各取一条噪声曲线作为对比,可以发现,SCGAN 生成的噪声和高斯噪声在这两个维度的相似度也很高。

为对 SCGAN 生成噪声和高斯噪声进行对比分析,分别对两种噪声进行直方图统计和 Kolmogorov-Smirnov (KS) 检验^[36]以分析噪声分布,另外进行二维




图9 噪声分析。(a)带噪数据;(b)SCGAN生成的噪声;(c)高斯噪声;(d)沿频率方向的噪声对比;(e)沿采样点方向的噪声对比
Fig. 9 Noise analysis. (a) Noisy data; (b) noise generated by SCGAN; (c) Gaussian noise; (d) noise comparison along frequency direction; (e) noise comparison along the direction of sampling point

傅里叶变换来获得噪声幅度谱,从变换域中对噪声空间特性进行分析。

图 10 所示为对两种噪声的直方图统计结果,高斯噪声在噪声图像的统计直方图上呈正态分布,SCGAN 生成噪声在统计直方图上的分布规律和高斯噪声非常相似。为了更加准确地判断 SCGAN 生成噪声是否符合正态分布,实验引入了 KS 检验。KS 检验是一种统计检验方法,通过比较两个样本的频率分布或者一个

样本的频率分布与特定理论分布(如正态分布)之间的差异来推论两个分布是否来自同一分布。首先计算 SCGAN 生成噪声的均值和方差,然后判断其是否和以该均值和方差为正态分布的数据来自同一分布,计算结果返回一个置信度 P ,当 P 大于 0.05 时该假设成立。所提方法返回的结果显示,SCGAN 生成噪声和高斯噪声在是否符合正态分布上都取得了极高的置信度,说明 SCGAN 生成的噪声和高斯噪声具有相似的分布。




图 10 噪声直方图。(a)高斯噪声;(b)SCGAN 噪声
Fig. 10 Noise histograms. (a) Gaussian noise; (b) SCGAN noise

对 SCGAN 生成噪声和高斯噪声进行二维傅里叶变换所得到的噪声幅度谱如图 11 所示。傅里叶幅度谱上明暗不一的亮点是指图像上某一点与邻域点差异的强弱,即梯度的大小。图 11(a)所示为高斯噪声的幅度谱,无明显的模式特征,而在图 11(b)中展

示的 SCGAN 生成噪声幅度谱中能够发现中心零频点附近及图像左右两侧存在明显的模式信息,说明 SCGAN 生成噪声中包含一些高斯噪声所不具有的成分。结合图 9 和图 10 认为:虽然 SCGAN 生成的噪声数据和高斯噪声具有相似的分布,但是它们在空间

布局上不同,也就是 SCGAN 生成噪声带有一定的空间信息。为了进一步证明该结论的正确性,对降噪前后的测试数据作差,得到对应的噪声残差,并进行二维傅里叶变换,结果如图 11(c)所示。实验结果表明,真

实的噪声数据和 SCGAN 生成的噪声具有明显相似的模式特征,这从侧面证明了高斯噪声和真实噪声的差异性,因此传统基于高斯噪声训练的网络模型存在误差。




图 11 噪声幅度谱。(a)高斯噪声;(b)SCGAN生成噪声;(c)测试数据噪声

Fig. 11 Noise amplitude spectra. (a) Gaussian noise; (b) SCGAN generated noise; (c) noise obtained from collected data

5 结 论

传统有监督方案采用高斯噪声来模拟系统噪声,但真实系统中的噪声并不完全符合高斯噪声,故训练存在误差。针对这个问题,使用 SCGAN 对真实噪声数据进行建模,生成配对的噪声数据对用于有监督训练。实验针对 3 种有监督去噪神经网络 DnCNN、ADNet 和 BRDNet 进行分析,比较了基于高斯噪声和基于 SCGAN 生成噪声训练 3 种网络的降噪效果,证明了所提方法能够有效地去除布里渊数据中的噪声,同时保留细节信息,而且基于 SCGAN 噪声训练的神经网络能够更好地识别噪声特征,获得更优的测量结果,即使在低采样次数的情况下依旧能够保持良好的性能,可提升实际数据的采集速率。所提方法是生成对抗模型在布里渊分布式光纤传感器降噪这一领域的创新性应用,同时,基于生成对抗的数据生成方法有着非常丰富的参考模型,相信未来能够在分布式光纤传感领域获得更好的应用和推广。

参 考 文 献

- [1] 刘靖阳,王涛,张倩,等. BOTDA 系统温度应变双参量传感技术研究进展[J]. 激光与光电子学进展, 2021, 58(13): 1306021.
Liu J Y, Wang T, Zhang Q, et al. Research progress on temperature-strain dual-parameter sensing in BOTDA system [J]. Laser & Optoelectronics Progress, 2021, 58(13): 1306021.
- [2] 杨馥,陈唐嘉利,陆彦宇,等. 基于布里渊散射的海水参数测量反演算法研究[J]. 中国激光, 2022, 49(4): 0404001.
Yang F, Chen T J L, Lu Y Y, et al. Investigation on inversion algorithm of seawater parameters measurement based on Brillouin scattering[J]. Chinese Journal of Lasers, 2022, 49(4): 0404001.
- [3] Bao X Y, Chen L. Recent progress in distributed fiber optic sensors[J]. Sensors, 2012, 12(7): 8601-8639.
- [4] Dong Y K, Chen L, Bao X Y. Time-division multiplexing-based BOTDA over 100 km sensing length[J]. Optics Letters, 2011, 36(2): 277-279.
- [5] Galindez C A, Quintela A, Quintela M A, et al. 30 cm of

spatial resolution using pre-excitation pulse BOTDA technique [J]. Proceedings of SPIE, 2011, 7753: 77532H.

- [6] Alahbabi M N, Cho Y T, Newson T P. Long-range distributed temperature and strain optical fibre sensor based on the coherent detection of spontaneous Brillouin scattering with in-line Raman amplification[J]. Measurement Science and Technology, 2006, 17(5): 1082-1090.
- [7] Song M P, Xia Q L, Feng K B, et al. 100 km Brillouin optical time-domain reflectometer based on unidirectionally pumped Raman amplification[J]. Optical and Quantum Electronics, 2016, 48(1): 30.
- [8] 罗源,闫连山,邵理阳,等. 基于布里渊光时域分析传感系统的格雷-差分脉冲混合编码技术[J]. 光学学报, 2016, 36(8): 0806002.
- [9] Luo Y, Yan L S, Shao L Y, et al. Golay-differential pulse hybrid coding technology based on Brillouin optical time domain analysis sensors[J]. Acta Optica Sinica, 2016, 36(8): 0806002.
- [9] Wang F, Zhu C H, Cao C Q, et al. Enhancing the performance of BOTDR based on the combination of FFT technique and complementary coding[J]. Optics Express, 2017, 25(4): 3504-3513.
- [10] Li Y Q, Li X J, Fan H B, et al. SNR improvement in self-heterodyne detection Brillouin optical time domain reflectometer using Golay pulse codes[J]. Optoelectronics Letters, 2017, 13 (6): 414-418.
- [11] Hao Y Q, Ye Q, Pan Z Q, et al. Effects of modulated pulse format on spontaneous Brillouin scattering spectrum and BOTDR sensing system[J]. Optics & Laser Technology, 2013, 46: 37-41.
- [12] Zhang Y X, Wu X L, Ying Z F, et al. Performance improvement for long-range BOTDR sensing system based on high extinction ratio modulator[J]. Electronics Letters, 2014, 50 (14): 1014-1016.
- [13] Bai Q, Xue B, Gu H, et al. Enhancing the SNR of BOTDR by gain-switched modulation[J]. IEEE Photonics Technology Letters, 2019, 31(4): 283-286.
- [14] Wang F, Li C L, Zhao X D, et al. Using a Mach-Zehnder-interference-based passive configuration to eliminate the polarization noise in Brillouin optical time domain reflectometry [J]. Applied Optics, 2012, 51(2): 176-180.
- [15] Zhao Y, Zhang Y N, Han B, et al. High sensitive BOTDR demodulation method by using slow-light in fiber grating[J]. Journal of Lightwave Technology, 2013, 31(21): 3345-3351.
- [16] Cao Y L, Ye Q, Pan Z Q, et al. Mitigation of polarization fading in BOTDR sensors by using optical pulses with

- orthogonal polarizations[J]. Proceedings of SPIE, 2014, 9157: 915764.
- [17] 张倩, 王涛, 赵婕茹, 等. 基于局部均值分解的布里渊光时域分析传感系统降噪算法[J]. 光学学报, 2021, 41(13): 1306009. Zhang Q, Wang T, Zhao J R, et al. Denoising algorithm for Brillouin optical time-domain analysis sensing systems based on local mean decomposition[J]. Acta Optica Sinica, 2021, 41(13): 1306009.
- [18] Nie T Y, Li J Q, Ding Y J, et al. Fast extraction for Brillouin frequency shift in BOTDA system[J]. Optical and Quantum Electronics, 2021, 53(2): 1-9.
- [19] 李想, 汪立新, 段志强. 改进自适应小波降噪在激光陀螺仪信号处理中的应用[J]. 激光与光电子学进展, 2020, 57(21): 210401. Li X, Wang L X, Duan Z Q. Application of improved adaptive wavelet noise reduction in laser gyroscope signal processing[J]. Laser & Optoelectronics Progress, 2020, 57(21): 210401.
- [20] Luo K, Wang B W, Guo N, et al. Enhancing SNR by anisotropic diffusion for Brillouin distributed optical fiber sensors[J]. Journal of Lightwave Technology, 2020, 38(20): 5844-5852.
- [21] Zhang P X, Wang B W, Yang Y N, et al. SNR enhancement for Brillouin distributed optical fiber sensors based on asynchronous control[J]. Optics Express, 2022, 30(3): 4231-4248.
- [22] Buades A, Coll B, Morel J M. Non-local means denoising[J]. Image Processing on Line, 2011, 1: 208-212.
- [23] Zheng H, Yan Y X, Wang Y Y, et al. Deep learning enhanced long-range fast BOTDA for vibration measurement[J]. Journal of Lightwave Technology, 2022, 40(1): 262-268.
- [24] Urricelqui J, Soto M A, Thévenaz L. Sources of noise in Brillouin optical time-domain analyzers[J]. Proceedings of SPIE, 2015, 9634: 963434.
- [25] 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.
- [26] Yang Y N, Dong Y, Yu K L. SNR improvement based on attention-DNet for Brillouin distributed optical fiber sensors[C]// 2022 27th OptoElectronics and Communications Conference (OECC) and 2022 International Conference on Photonics in Switching and Computing (PSC), July 3-6, 2022, Toyama, Japan. New York: IEEE Press, 2022.
- [27] Tian C W, Xu Y, Zuo W M. Image denoising using deep CNN with batch renormalization[J]. Neural Networks, 2020, 121: 461-473.
- [28] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [29] Hu Y T, Shang Q F. Performance enhancement of BOTDA based on the image super-resolution reconstruction[J]. IEEE Sensors Journal, 2022, 22(4): 3397-3404.
- [30] Shi Y, Dai S W, Liu X Y, et al. Event recognition method based on dual-augmentation for a Φ -OTDR system with a few training samples[J]. Optics Express, 2022, 30(17): 31232-31243.
- [31] Creswell A, White T, Dumoulin V, et al. Generative adversarial networks: an overview[J]. IEEE Signal Processing Magazine, 2018, 35(1): 53-65.
- [32] Chen J W, Chen J W, Chao H Y, et al. Image blind denoising with generative adversarial network based noise modeling[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 3155-3164.
- [33] Yan H S, Tan V, Yang W H, et al. Unsupervised image noise modeling with self-consistent GAN[EB/OL]. (2019-06-13) [2023-02-04]. <https://arxiv.org/abs/1906.05762>.
- [34] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[EB/OL]. (2015-02-11)[2023-03-05]. <https://arxiv.org/abs/1502.03167>.
- [35] Xu B, Wang N Y, Chen T Q, et al. Empirical evaluation of rectified activations in convolutional network[EB/OL]. (2015-04-05)[2023-05-04]. <https://arxiv.org/abs/1505.00853>.
- [36] Massey F J, Jr. The Kolmogorov-Smirnov test for goodness of fit[J]. Journal of the American Statistical Association, 1951, 46(253): 68-78.

Noise Reduction of Brillouin Distributed Optical Fiber Sensors Based on Generative Adversarial Network

Luo Kuo^{1,2}, Wang Yuyao³, Zhu Borong^{1,2}, Yu Kuanglu^{1,2*}

¹*Institute of Information Science, Beijing Jiaotong University, Beijing 100044, China;*

²*Beijing Key Laboratory of Advanced Information Science and Network Technology, Beijing 100044, China;*

³*Photonics Research Institute, Department of Electronic and Information Engineering, The Hong Kong Polytechnic University, Hong Kong 999077, China*

Abstract

Objective The signal-to-noise ratio (SNR) is a crucial performance metric in Brillouin distributed optical fiber sensors. Ensuring accurate noise characterization is essential for effective targeted denoising. However, collecting real noise data poses practical challenges. Gaussian noise, traditionally used in supervised methods, is somewhat effective but lacks accuracy. In this paper, we propose to utilize a self-consistent generative adversarial network (SCGAN) to model real noise distribution using collected Brillouin gain spectrum (BGS) data. This enables us to generate noise data for training denoising convolutional neural networks (CNNs). By training the SCGAN to replicate real noise intricacies, we can effectively train a CNN to discern between signal and noise, resulting in more precise noise reduction. By addressing the limitations of conventional Gaussian noise models, our method bridges the gap between artificial noise simulations and

complex real-world BOTDA system noise patterns. This innovative approach has the potential to significantly enhance noise reduction techniques for BOTDA systems, improving accuracy and efficiency.

Methods While generative adversarial networks (GANs) have showcased their effectiveness in modeling intricate noise distributions from extensive datasets, they harbor a notable training limitation. GANs optimize their generator networks by minimizing dissimilarities between generated and real samples. Unfortunately, this process might inadvertently prioritize prevalent training data patterns, sidelining other potential variations. To transcend this limitation, this paper introduces a SCGAN as a solution for noise modeling. Going beyond conventional GANs, SCGAN introduces a novel approach. It supplements the adversarial loss with three additional loss functions, effectively offering more guidance and constraints during network training. This augmentation facilitates a more holistic approach to noise modeling by steering the network towards a broader representation of noise patterns. To substantiate the differentiation between Gaussian noise and SCGAN-generated noise, we employ histogram statistics and amplitude spectrum analysis. Subsequently, both types of noise are harnessed to train three state-of-the-art denoising CNNs. The performances of networks are then compared across experimental BGS encompassing varying temperatures and SNRs. This approach reflects a holistic exploration, encompassing both noise modeling and denoising neural network evaluation.

Results and Discussions To enable a thorough comparative analysis between SCGAN-generated noise and Gaussian noise, we employ histogram statistics and the Kolmogorov-Smirnov test for both noise sources. Furthermore, a two-dimensional Fourier transform is executed to acquire the noise amplitude spectrum, with the findings visualized in Figs. 10 and 11. These analyses distinctly display the divergences between Gaussian noise and real noise. To effectively showcase the enhanced SNR brought forth by our method, we assess denoising neural networks trained with distinct noise sources across various temperature settings and averaging times. The outcomes are tabulated in Table 1 and Table 2. Importantly, networks trained using SCGAN-generated noise consistently exhibit elevated SNR values compared with their Gaussian noise-trained counterparts. Following the acquisition of temperature data, we compute the corresponding root mean square error (RMSE) and standard deviation (SD). Figures 7 and 8 provide the comprehensive outcomes achieved by different neural networks trained with varying noise sources under diverse temperature conditions and SNRs. Remarkably, networks trained with SCGAN-generated noise consistently outperform their counterparts, delivering superior denoising outcomes characterized by precision and stability. These results underscore the efficacy of SCGAN-based noise training in achieving remarkable noise reduction, generating highly accurate and dependable measurement outcomes across a spectrum of temperature conditions and averaging times.

Conclusions We introduce the utilization of SCGAN for modeling real noise data and generating paired noise data tailored for supervised training. The research entails a comparative study involving three supervised denoising neural networks—DnCNN, ADNet, and BRDNet—trained with both Gaussian and SCGAN-generated noise. The outcomes distinctly illustrate the method's efficacy in noise reduction for Brillouin distributed optical fiber sensor data, while preserving intricate details. Notably, networks trained on SCGAN-generated noise exhibit superior proficiency in identifying noise features, leading to enhanced measurement outcomes. This advantage remains consistent even under conditions of low averaging times, suggesting the potential for heightened data acquisition rates. Importantly, this paper pioneers the application of generative adversarial models in the domain of Brillouin distributed optical fiber sensor denoising, presenting a novel frontier. Leveraging the diverse arsenal of generative adversarial data generation methods, the technique introduced here has the potential for broader adoption in the realm of distributed optical fiber sensing. This pioneering approach sets the stage for substantial advancements in the accuracy and efficiency of noise reduction methods, ultimately contributing significantly to practical sensor data acquisition rates.

Key words fiber optics; Brillouin distributed optical fiber sensing; image denoising; generative adversarial network; self-consistent constraints; noise modeling