

DOI: 10.19650/j.cnki.cjsi.J2311970

基于 DSC-U-Net 模型的光纤光栅信号去噪方法*

夏嘉斌¹, 祝连庆^{1,2}, 于明鑫², 邓超凡²

(1. 合肥工业大学仪器科学与光电工程学院 合肥 230009; 2. 北京信息科技大学光电测试技术及仪器教育部重点实验室 北京 100192)

摘要:近年来,光纤布拉格光栅(FBG)传感器凭借结构紧凑、抗电磁干扰、可准分布式集成等优势,在航空航天结构健康监测(SHM)中广泛应用,但长期处于恶劣环境中易受温度、振动等因素影响,出现光谱噪声、基线漂移等问题,导致信噪比(SNR)降低,严重影响解调精度。传统去噪算法如 Savitzky-Golay 滤波器、小波变换等,在低信噪比场景下依赖人工参数设定,适配性差,难以满足高精度监测需求。提出了一种新颖的 DSC-U-Net 深度神经网络模型,该模型融合 U-Net 架构的特征提取能力与深度可分卷积(DSC)的轻量化优势,能有效去除噪声和基线失真。基于耦合模理论与传输矩阵法,仿真生成涵盖-20~20 dB 信噪比的 90 000 条光谱样本,用于模型训练与测试,后续对模型训练所需数据量和模型训练结果进行讨论。模型测试显示,全部数据集训练的模型可将 0 dB 光谱信噪比提升至 13.266 dB,与纯净光谱相似度达 0.892,均方根误差(RMSE)仅 0.05,性能远超 arPLS 结合窗函数等传统算法。搭建-55℃~150℃恶劣环境实验系统进行实验数据采集,使用仿真数据训练的模型进行验证,DSC-U-Net 与 MLP 组合的解调算法使解调误差从 0.297 pm 降至 0.023 pm,精度提升 92.26%,通过仿真数据进行模型训练可大幅降低训练成本。DSC-U-Net 深度神经网络模型无需人工干预,兼具高精度与高效计算特性,解决了低信噪比下 FBG 信号解调难题,为航空航天恶劣环境下的长期稳定监测提供可靠方案。

关键词: 光纤光栅;信噪比;深度学习;降噪算法

中图分类号: TH123+.1 **文献标识码:** A **国家标准学科分类代码:** 460.99

Denoising method of fiber grating signal based on DSC-U-Net model

Xia Jiabin¹, Zhu Lianqing^{1,2}, Yu Mingxin², Deng Chaofan²

(1. School of Instrument Science and Opto-electronics Engineering, Hefei University of Technology, Hefei 230009, China;
2. Key Laboratory of Optoelectronic Measurement Technology and Instrument, Ministry of Education,
Beijing Information Science and Technology University, Beijing 100192, China)

Abstract: In recent years, fiber Bragg grating (FBG) sensors have been widely used in structural health monitoring (SHM) of aerospace structures due to their advantages, such as compact structure, electromagnetic interference resistance, and quasi-distributed integration. However, when exposed to harsh environments for a long time, they are susceptible to temperature, vibration, and other factors, resulting in problems such as spectral noise and baseline drift, which reduce the signal-to-noise ratio (SNR) and seriously affect demodulation accuracy. Traditional denoising algorithms, such as Savitzky-Golay filter and wavelet transform, rely on manual parameter setting in low-SNR scenarios, resulting in poor adaptability and difficulty in meeting high-precision monitoring requirements. This article proposes a novel DSC-U-Net deep neural network model, which integrates the feature extraction capability of the U-Net architecture and the lightweight advantage of depthwise separable convolution (DSC), enabling effective removal of noise and baseline distortion. Based on the coupled-mode theory and transfer matrix method, 90 000 spectral samples covering an SNR range of -20 dB to 20 dB are simulated for model training and testing. Subsequently, the data volume required for model training and the model training results were discussed. Test results show that the model trained with the full dataset can improve the SNR of 0 dB spectra to 13.266 dB, with a similarity of 0.892 to pure spectra and a root mean square error (RMSE) of only 0.05, outperforming traditional algorithms such as

收稿日期:2023-09-26 Received Date: 2023-09-26

* 基金项目:北京学者计划研究项目(BJXZ2021-012-00046)资助

arPLS combined with window functions. An experimental system for harsh environments ($-55^{\circ}\text{C} \sim 150^{\circ}\text{C}$) is established for experimental data collection, and verification is conducted using the model trained with simulated data. The demodulation algorithm combining DSC-U-Net and MLP reduces the demodulation error from 0.297 pm to 0.023 pm, with an accuracy improvement of 92.26%. Model training using simulated data can significantly reduce training costs. The DSC-U-Net deep neural network model requires no manual intervention, featuring both high precision and efficient computation. It solves the demodulation problem of FBG signals under low SNR and provides a reliable solution for long-term stable monitoring in harsh aerospace environments.

Keywords: fiber grating; signal-to-noise ratio; deep learning; noise reduction algorithm

0 引 言

在过去几十年中,光纤传感器技术因其结构紧凑、抗电磁干扰等优势,在结构健康监测、土木工程、生物化学传感和医疗应用等领域备受关注^[1-2]。光纤布拉格光栅传感器可沿单根光纤集成阵列,形成准分布式光纤布拉格光栅传感器通道,实现多点物理参数的实时监测^[3-5]。其优异性能使光纤布拉格光栅传感器广泛应用于航空航天设备中,尤其在飞机结构健康监测中^[6-8]。飞机结构健康监测是一个长期的过程,在实际的飞机飞行中,光纤布拉格光栅(fiber Bragg grating, FBG)传感器所处的环境是恶劣且多变的,光纤光栅传感器在机载环境中长期的监测,不可避免的会受到环境温度、湿度、霉菌、盐雾,酸性大气以及振动等外界因素的冲击,在长期的循环载荷和环境侵蚀的双重作用下,传感器网络会出现不同程度的光传输损耗,进而导致不同程度的反射光谱不均匀和光谱退化引起的低信噪比光谱等复杂背景光谱。传感系统信号会引入噪声信号,从而降低光谱信号中心波长的解调精度,降低系统应变、温度等物理量的测量精度,表现为光谱不均匀和低信噪比(signal-to-noise ratio, SNR)。为确保解调精度和长期监测的可靠性,需开发先进的去噪算法,以应对光谱不均匀和低信噪比问题,实现高精度中心波长解调。

在实际应用中,噪声会干扰 FBG 的反射光谱。光谱噪声包括干扰噪声、基线噪声、传感系统退化引入的白噪声以及 FBG 传感器退化造成的信号失真。之前已有多种去噪和基线去除算法,包括 Savitzky-Golay Filter^[8]、经验模式分解(empirical mode decomposition, EMD)^[9]、小波变换(lifting wavelet transform, LWT)^[10-13]等。一方面这些算法针对极低信噪比(比如信号与噪声强度相同时)时,主要是通过基线拟合与光谱平滑等方式进行去噪,无法有效提高去噪精度;另一方面,在机载环境中长期应用的光纤传感器光谱信号噪声情况多样,且不同通道光谱基线、噪声强度不一致,因此无法使用确定阈值或确定参数的频谱去噪方法,因此考虑到去噪精度、频谱适用性和阈值选择^[14-15],上述方法并不适合长期低信噪比的传感器信号。

本研究结合光纤光栅传感原理,利用耦合模理论和传输矩阵理论仿真不同信噪比的光纤光栅光谱信号。利用深度学习相关模型能有效提取光谱极弱信号的能力,融合 U-Net 架构的特征提取能力与深度可分卷积(depthwise separable convolution, DSC)的轻量化优势,提出了一种基于深度学习模型的自适应光谱去噪算法 DSC-U-Net,通过 DSC-U-Net 模型算法与多种降噪算法比较进行降噪效果评估。搭建光纤光栅复杂背景光谱采集系统,利用实验数据验证 DSC-U-Net 算法降噪效果,定量地展示了该算法对光纤光栅复杂背景信号解调精度提升的效果。

DSC-U-NET 模型不依赖任何人工干预,可全自动去除噪声和背景。该方法不仅解决了低信噪比条件下 FBG 信号解调精度下降的问题,而且保证了更高的计算效率,满足了大容量信号实时解调的要求。该方法为恶劣环境下光纤布拉格光栅传感器的精确解调提供了技术保障。

1 理论分析与数据仿真

光纤布拉格光栅的基本结构和工作原理如图 1 所示。

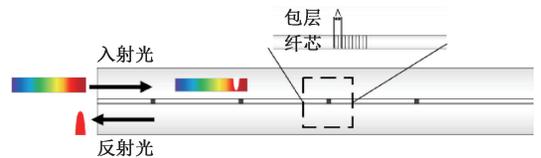


图 1 光纤光栅结构及传感示意图

Fig. 1 Diagram of fiber Bragg grating structure and sensing

由于光纤光栅能够选择性地反射某一特定波长,即对入射光反射效率最高处的波长称为布拉格波长 λ_B 。在光纤光栅中,相位匹配条件为:

$$\beta_1 - \beta_2 = \Delta\beta = \frac{2\pi}{\Lambda} \quad (1)$$

式中: β_1 和 β_2 是耦合模的传播常数; Λ 是光栅周期。对于光纤布拉格光栅,前向传播的纤芯模式耦合到反向传播的纤芯模式中。因此,相位匹配条件可以化简为:

$$2\beta = \Delta\beta = \frac{2\pi}{\Lambda} \quad (2)$$

而传播常数 β 可以表示为:

$$\beta = \frac{2\pi}{\lambda} n_{\text{eff}} \quad (3)$$

式中: n_{eff} 是光栅的有效折射率。由式(2)和(3)可得布拉格波长为:

$$\lambda_B = 2n_{\text{eff}}\Lambda \quad (4)$$

由式(4)可知,光纤有效折射率或者光栅周期的变化,都会导致布拉格波长的漂移。另外,在光栅刻写过程中,可以通过调整光栅周期来制备不同中心波长的布拉格光栅。

通过改变光纤纤芯的折射率,可以产生周期性调制,从而实现光纤的传感, $10^{-5} \sim 10^{-3}$ 是折射率变化数量级范围,目前最普遍的是采用紫外光和飞秒激光,在掺锗光敏光纤中形成这种周期性折射率分布,使得光波信号在通过光栅时产生周期性调制。

布拉格光纤光栅的光学特性是纤芯中前向运动的导模与反向运动的相互耦合作用的。曝光后某 t 时刻光纤纤芯沿 z 方向的折射率变化如式(5)所示。

$$n(z) = n_0 + \Delta n_{\text{eff}}(z) \left\{ 1 + \gamma \cos \left[\frac{2\pi}{\Lambda} z + \phi(z) \right] \right\} \quad (5)$$

式中: n_0 表示光纤纤芯的有效折射率(未被紫外曝光时的基模); γ 为折射率调制深度; $\phi(z)$ 描述光栅的相位变化。设 $\Delta n = \overline{\Delta n} [1 + \gamma \cos(2\pi/\Lambda + \phi(z))]$, $\overline{\Delta n}$ 为折射率变化的平均值即随着紫外曝光时间的增加,纤芯有效折射率增加,称 $\overline{\Delta n}$ 为光致折射率增量。

通常使用传输矩阵法(transfer matrix method, TMM)来计算 FBG 的反射光谱,它是一种基于耦合模式方程解的数值方法。布拉格光纤光栅的中心波长偏移量主要取决于其本身的中心波长 λ_B 、受到的轴向应变变量 ε 、以及温度的变化量 ΔT ^[16]。

传输矩阵法是基于对光栅的每个均匀部分识别 2×2 矩阵(见图2由传输矩阵表示的一系列不同周期的光栅),然后将所有矩阵相乘得到一个单独的 2×2 矩阵来描述整个光栅^[17-18]。

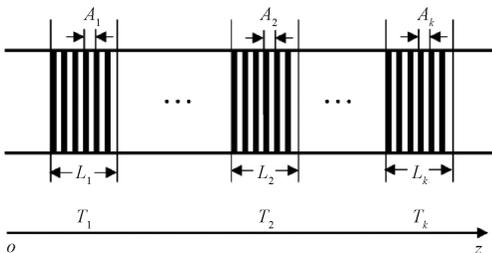


图2 传输矩阵表示的一系列不同周期的光栅

Fig.2 A series of gratings with different periods represented by the transfer matrix

每个均匀截面 k 的传播用矩阵 T 来描述,定义为:

$$\begin{bmatrix} B(z_{i+1}) \\ A(z_{i+1}) \end{bmatrix} = T_k \begin{bmatrix} B(z_i) \\ A(z_i) \end{bmatrix} \quad (6)$$

式中: $A(z_i)$ 和 $B(z_{i+1})$ 是光栅的输入; $A(z_{i+1})$ 和 $B(z_i)$ 是光栅的输出。传输矩阵 T_k 如式(7)所示。

$$T_k = \begin{bmatrix} \cosh(sd_z) & -i \frac{\kappa}{s} \sinh(sd_z) \\ i \frac{\kappa}{s} \sinh(sd_z) & \cosh(sd_z) + i \frac{\zeta}{s} \sinh(sd_z) \end{bmatrix} \quad (7)$$

式中: d_z 是布拉格光栅的第 k 个均匀截面的长度; ζ 和 κ 是第 k 个截面的局部耦合系数。 s 表达式如式(8)所示。

$$s = \sqrt{\kappa^2 - \zeta^2} \quad (8)$$

总光栅结构可表示为:

$$\begin{bmatrix} B(z_k) \\ A(z_k) \end{bmatrix} = T_{kgL} T_{g1} T_{g2} \begin{bmatrix} B(z_1) \\ A(z_1) \end{bmatrix} \quad (9)$$

纯 FBG 反射光谱可表示为:

$$R(\lambda) = \left| \frac{F_{21}}{F_{11}} \right|^2 \quad (10)$$

式中: $F = T_{kgL} T_{g1} T_{g2} = \begin{bmatrix} F_{11} & F_{12} \\ F_{21} & F_{22} \end{bmatrix}$ 为光纤光栅的传输矩阵。

每个模拟原始频谱为纯光纤光栅反射光谱 $R(\lambda)$ 、背景光谱 $B(\lambda)$ 、和噪声光谱 $N(\lambda)$ 的和,如式(11)所示。

$$F(\lambda) = R(\lambda) + B(\lambda) + N(\lambda) \quad (11)$$

式中: λ 为光波的波长。

为了保证纯 FBG 反射光谱 $R(\lambda)$ 的准确性和代表性,考虑到光波在实际 FBG 传感器中的传播,结合光波导的耦合模式理论,本文采用 T 矩阵方法对 FBG 传感器的级联光谱数据进行了模拟。

每个背景谱 $B(\lambda)$ 被随机模拟为多项式分布、指数分布、正弦分布、高斯分布或 s 型分布或这些分布的组合。信号基线比(SBR)在 $0 \sim 50$ 之间随机变化。

$$SBR = 10 \log \frac{R(\lambda)_{\max}}{(B(\lambda)_{\max} - B(\lambda)_{\min})} \quad (12)$$

式中: $R(\lambda)_{\max}$ 是 $R(\lambda)$ 的最大值; $B(\lambda)_{\max}$ 是 $B(\lambda)$ 的最大值; $B(\lambda)_{\min}$ 是 $B(\lambda)$ 的最小值。

将噪声谱 $N(\lambda)$ 建模为散粒噪声、热噪声和读出噪声的总和,得到高斯白噪声模拟信号的信噪比公式为:

$$SNR = 10 \log \frac{R(\lambda)_{\max}}{\sigma_{N(\lambda)}} \quad (13)$$

式中: $\sigma_{N(\lambda)}$ 为高斯白噪声的振幅标准差。

为了验证训练后模型的性能,将数据集建立如表1所示。

表 1 数据集参数
Table 1 Data set parameter

参数类型	$R(\lambda)$	$B(\lambda)$	$N(\lambda)$
光谱参数	光栅个数:3	信噪比:~20~20 dB,	信基比:
	中心波长范围:	每个 5 dB 为一组,	随机信号
	1 525~1 565 nm	共 9 组	0~10 dB
样本参数	光谱数据点	2 000 个数据点	
	样本数量	10 000	

2 基于 DSC-U-Net 模型的光谱去噪算法研究

2.1 模型搭建

本文结合了图像分割中使用的 U-NET 架构^[19-20]和深度可分卷积(DSC)^[21],用于一维光纤光栅光谱分析。图 3 显示了 DSC-U-Net 的网络结构。该网络采用深度可分卷积,减少了传统卷积运算的参数个数和运算成本。同时,对含有噪声的原始频谱进行卷积层网络去噪,预测有效频谱信号。网络结构由编码器网络和解码器组成。编码器将原始频谱作为输入。它从频谱中提取基本特征,以产生信息的多级特征表示,将输入映射到期望的输出。然后,解码器使用编码器提取的信息重构输出,使其具有与输入相同的像素空间。

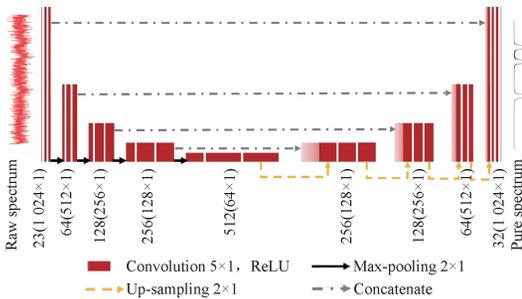


图 3 DSC-U-Net 网络结构

Fig. 3 DSC-U-Net network architecture

在编码器部分,使用深度可分离卷积网络提取频谱特征。它包括 3×1 深度卷积操作和 1×1 点向卷积操作,然后是批归一化和池化大小为 4×1 的最大池化操作。此操作重复 4 次。在编码器的末端,增加了两个相同深度的可分离卷积运算来连接编码器和解码器。在每个下采样步骤之后,用于卷积操作的滤波器数量增加一倍,从而使特征通道的数量增加一倍。

在解码器部分,本文应用了上采样和串联的重复应用,然后是相同的深度可分离卷积操作。首先使用 4×1 转置卷积运算对特征通道进行上采样。然后上采样的特征通道,现在减少了一半,在池化操作之前被编码器的相

应卷积层的输出附加。连接步骤允许网络在编码期间通过池操作检索丢失的信息。经过上采样和拼接后,特征谱通过两个深度可分离的卷积层传播,然后进行批归一化。与编码器类似,这种上采样、串联和卷积操作的顺序操作重复 4 次,在每个阶段将特征通道减半。采用整流线性单元(ReLU)来激活编码器和解码器网络的所有卷积层的输出。在解码器的最后,使用一个没有激活函数的 1×1 卷积层来检索预测输出。

2.2 模型评价指标

为了准确的进行模型去噪能力的比较,通过不同指标定量表征模型去噪能力。利用光谱信噪比提升值(improved SNR)、光谱均方根误差(root mean square error, RMSE)和光谱相似度(curve similarity)这 3 个指标来表征去噪效果。指标计算公式为:

$$SNR_{\text{imp}} = 10 \log \frac{R_{\text{imp}}(\lambda)_{\max}}{\sigma_{N(\lambda)}} \quad (14)$$

式中: $R_{\text{imp}}(\lambda)_{\max}$ 是去噪光谱 $R_{\text{imp}}(\lambda)$ 的最大值; $\sigma_{N(\lambda)}$ 为高斯白噪声的振幅标准差; SNR 为原始光谱信噪比。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (R_i(\lambda) - R'_i(\lambda))^2}{n}} \quad (15)$$

式中: $R_i(\lambda)$ 为纯净光谱的光谱强度; $R'_i(\lambda)$ 为去噪后光谱的光谱强度; n 为光谱长度。

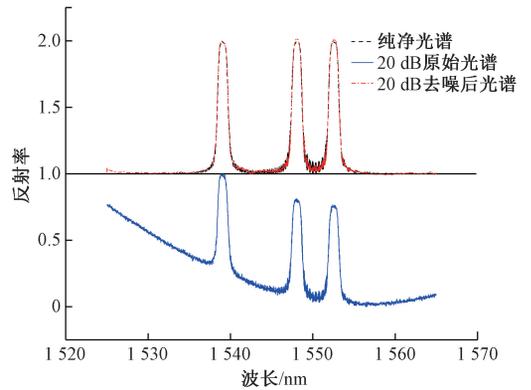
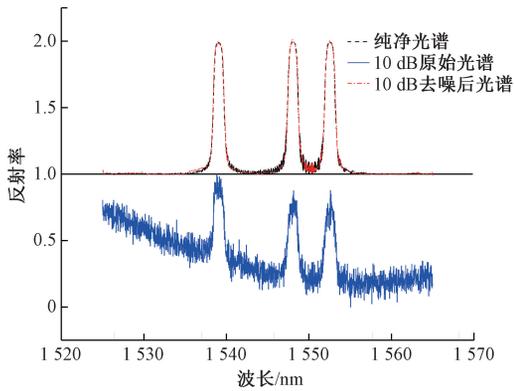
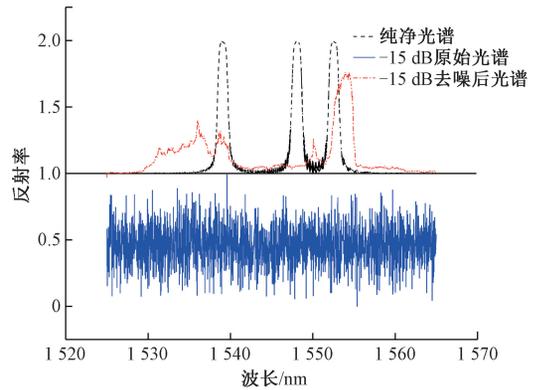
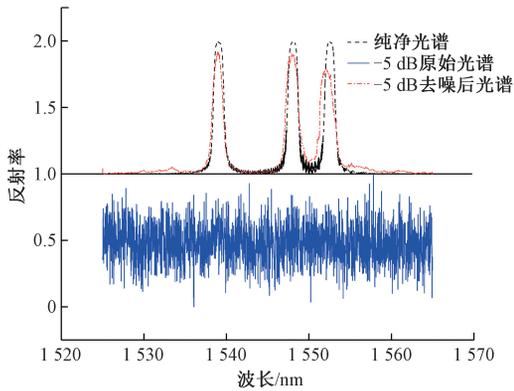
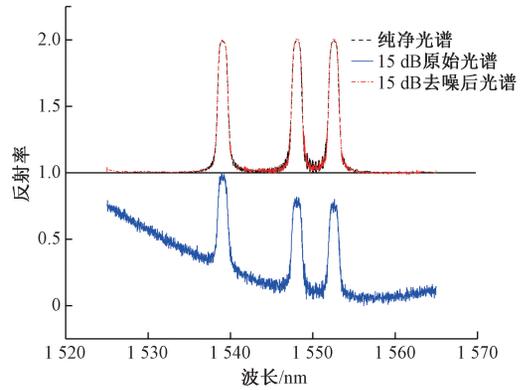
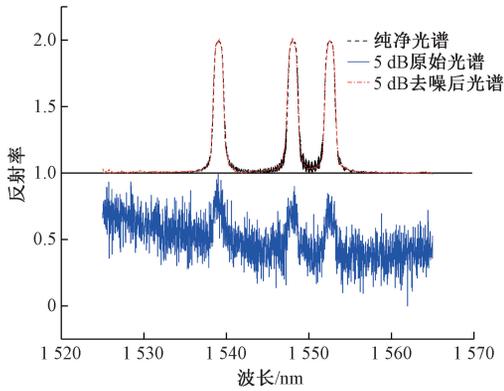
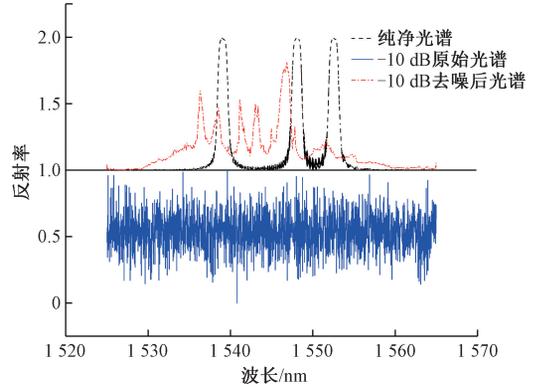
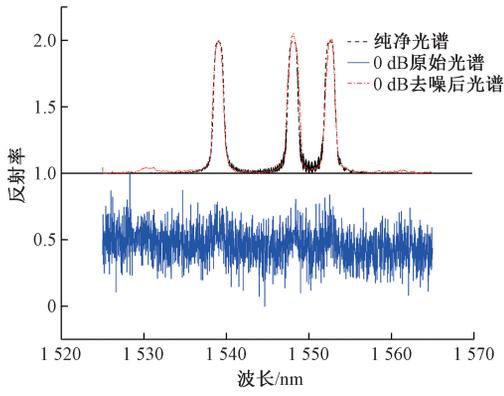
$$\rho = \frac{\text{cov}(R(\lambda), R_{\text{imp}}(\lambda))}{\sigma_{R(\lambda)} \sigma_{R_{\text{imp}}(\lambda)}} \quad (16)$$

式中: $\text{cov}(R(\lambda), R_{\text{imp}}(\lambda))$ 为纯净光谱 $R(\lambda)$ 和去噪后光谱 $R_{\text{imp}}(\lambda)$ 的协方差; $\sigma_{R(\lambda)} \sigma_{R_{\text{imp}}(\lambda)}$ 是 $R(\lambda)$ 与 $R_{\text{imp}}(\lambda)$ 标准差的乘积。

2.3 基于仿真数据集的模型测试结果分析

本文利用仿真数据集进行模型训练与测试,讨论 DSC-U-Net 模型对 FBG 光谱去噪的作用。仿真数据集包含 SNR 为 $-20 \sim 20$ dB 的所有仿真数据,数据集样本总数是 90 000 条,在模型训练过程中,将数据集 80% 的样本作为训练集,10% 作为验证集,剩余 10% 作为测试集。

图 4 展示了模型测试结果,图中实线表示原始光谱,虚线表示纯净光纤光栅反射光谱,点虚线表示经过模型计算的去噪后的光谱,对光谱数据进行了归一化处理,每个光谱幅值高度为 1。为了更加清晰地直观地表示模型去噪作用,将纯净光谱和去噪后的反射光谱绘制在同一基线上,并将基线提高一个单位,与原始光谱基线进行区分。通过图 4 可以直观地得出模型对于信噪比 < -5 dB 原始信号去噪能力有限,效果不佳;从 -5 dB 信噪比的原始信号开始,模型能开始有效还原光谱信号;在 0 dB 信噪比原始光谱中,已经能较好提高光谱信噪比,还原出淹没在噪声信号中的光谱信号。



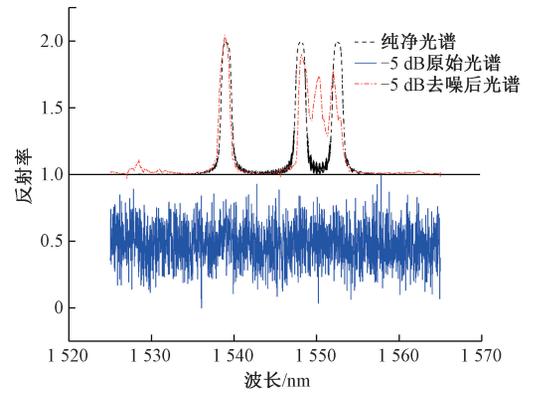
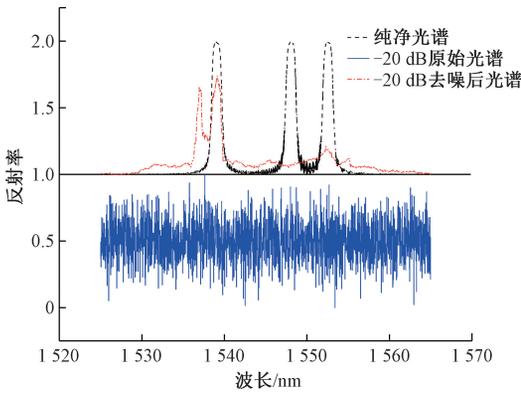
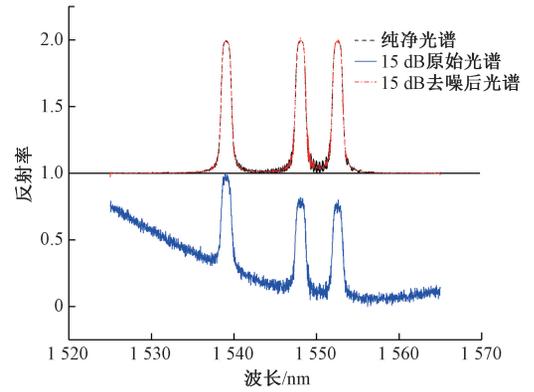
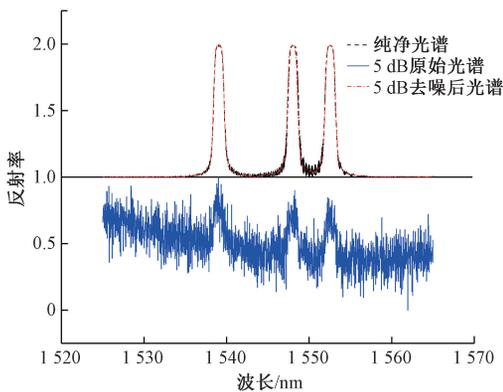
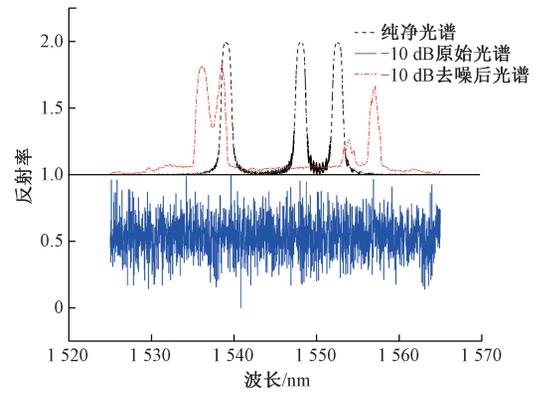
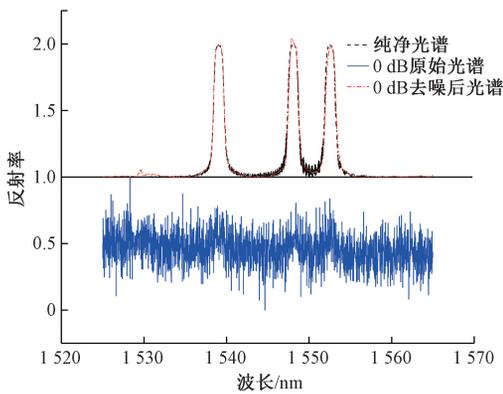
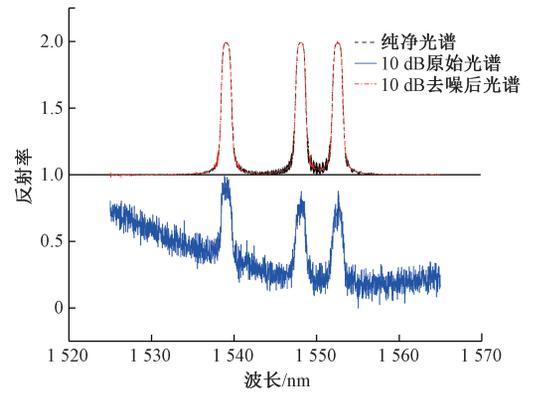


图 4 全部数据集模型测试结果
Fig. 4 Graph of model test results

通过降低模型训练数据量,提高模型训练速度,并且进一步讨论使用不同信噪比样本进行模型训练与模型去噪能力的关系,根据表 1 数据集情况,本文使用 9 种信噪比样本各自进行模型训练与测试,测试结果如图 5 所示。结果展示的测试光谱与前述模型所使用的测试光谱一致。如图 5 所示,单一数据集模型训练结果趋势与全部数据集模型结果大致相同,从 -5 dB 信噪比的原始光谱数据集模型开始能有效去除光谱噪声,提高光谱信噪比,从定性角度分析,-5 dB 信噪比数据集模型的去噪效果不如全部数据集模型,0 dB 信噪比数据集模型的去噪效果与全部数据集模型大致相同。



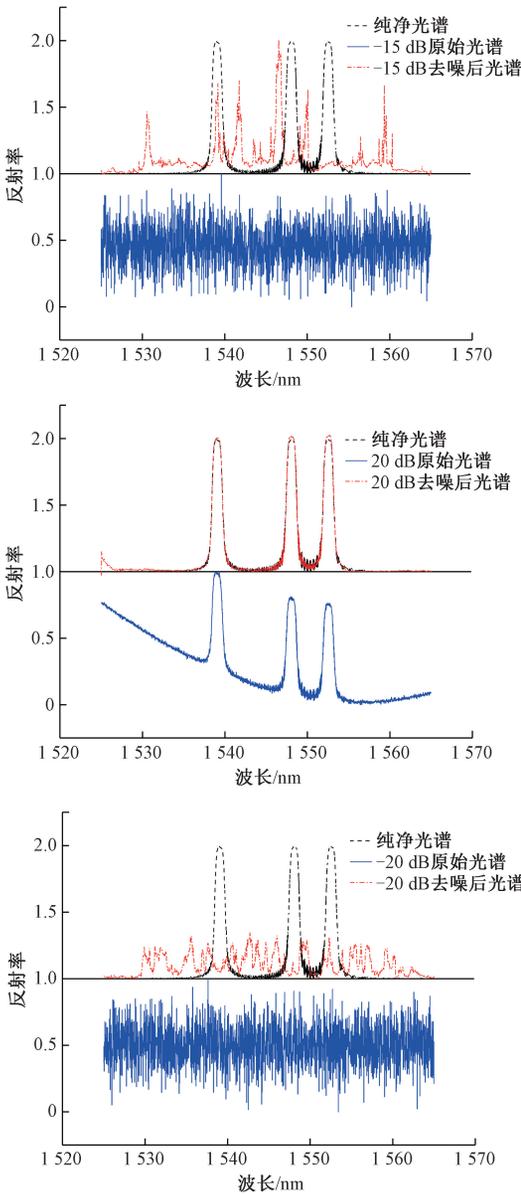


图5 单一数据集模型测试结果

Fig. 5 Single data set model test results

图6是模型去噪效果指标图,3个指标子图中横坐标1~9分别表示信噪比(SNR)为-20、-15、-10、-5、0、5、10、15、20 dB的9种不同数据集训练的模型,10表示全部信噪比数据集训练的模型。为提高模型的泛化能力和稳定性,模型训练过程中使用5折交叉验证方法,每个模型使用相同的测试集进行结果比较。

从光谱信噪比提升值指标能看出,在模型1~9中信噪比提升值首先随着数据集信噪比的增加而增加,在模型5信噪比提升值达到最高,之后信噪比提升值随着数据集信噪比的增加而减少,数据表明使用0 dB数据集训练的模型去噪能力最强,该模型光谱信噪比提升值为13.228 dB。模型10(全部数据集训练的模型)信噪比提

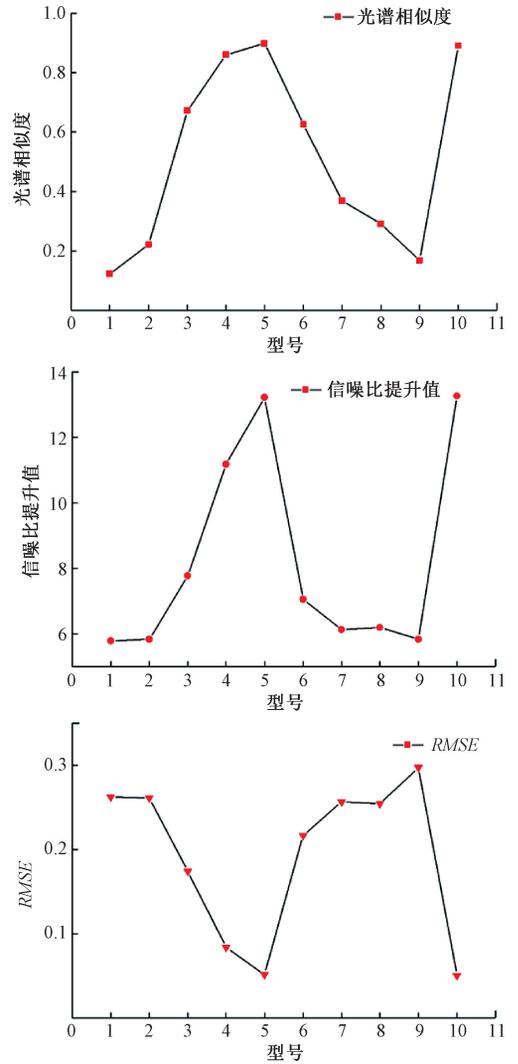


图6 不同训练集训练的模型去噪能力表征

Fig. 6 Representation diagram of denoising ability of model trained by different training sets

升值为13.266 dB,与模型5信噪比提升值近似。模型1~4信噪比提升值变化情况可以得出DSC-U-Net模型能有效去除光谱噪声,还原出纯净光谱,结合图5所展示的光谱形状,对信噪比为-5 dB以下的光谱虽然提升了光谱信噪比,但去噪后光谱仍与纯净光谱相差很多,这一点可以从光谱相似度指标中得到印证。模型6~9信噪比提升值变化情况说明对于信噪比较高的原始光谱DSC-U-Net模型去噪能力有限,这一点是由于高信噪比原始光谱中噪声强度占比较小,因此原始光谱信噪比提升空间有限。

分析光谱相似度首先可以得出模型5和10的表现最好,光谱相似度分别为0.898和0.892。从式(16)可以得出,光谱相似度值越接近1,去噪后光谱与纯净光

谱越相似,表面模型 5 和 10 能有效去除原始光谱的噪声信号。进一步分析光谱相似度与不同信噪比数据集集模型的关系,在模型 1~4 中可以得出,随着数据集信噪比的提升,模型去噪能力逐步提升。通过对模型 6~9 的光谱相似度和信噪比提升值的分析,DSC-U-Net 模型对高信噪比的原始光谱进行去噪时,虽然信噪比有所提升,但是去噪后光谱与纯净光谱相似度不高,通过对图 3 和 4 分析可以得出造成上述现象的主要原因是去噪后光谱与纯净光谱曲线的平滑程度不同,影响了光谱相似度。

从光谱均方根误差角度分析,可以得出模型 1~10 的均方根误差都 <0.3 ,其中模型 5 和 10 均方根误差最小,分别为 0.08 与 0.05。均方根误差与光谱相似度结论一致,两个指标呈负相关,相似度越高,均方根误差越低。

综合上述分析,模型 5 和 10 信噪比提升能力相近,但仍无法准确比较两个模型去噪能力,因此进一步分析两个模型对于不同信噪比光谱测试集提升信噪比的能力,使用去噪后光谱信噪比(SNR)、光谱均方根误差和光谱相似度 3 个指标进行定量分析。

如图 7 所示,在光谱信噪比指标上,使用全部数据训练所得的模型 10 明显优于仅使用信噪比为 0 dB 数据训练所得的模型 5。仅分析模型 5 的光谱去噪后信噪比指标,证明 DSC-U-Net 模型具有一定的推理能力,在训练集只有 0 dB 光谱数据情况下,模型 5 对于不同信噪比的光谱测试数据都能有一定程度的去噪能力,对-20~10 dB 的测试光谱数据去噪后光谱信噪比都有一定程度的提升;对于 15 和 20 dB 的测试光谱数据去噪效果不佳;在对 >0 dB 测试光谱进行去噪测试,去噪后光谱信噪比随着测试数据信噪比的提升而降低,证明了模型推理能力有限,且当被测数据偏离模型训练数据集越远(即信噪比相差越大),模型推理能力越差。结合光谱均方根误差和光谱相似度两个指标,模型 10 测试结果都优于模型 5。在光谱相似度方面两个模型光谱相似度都 >0.9 ,在光谱均方根误差方面两个模型误差都 <0.1 。经过比较,DSC-U-Net 模型在仅使用 0 dB 训练集进行模型训练可以在不降低模型性能情况下,大幅度减少模型的训练时间与训练所需的内存需求。

通过对 DSC-U-Net 模型算法与其他机器学习算法进行比较,来证明该模型算法的优势。其他机器学习去噪算法一般由曲线拟合和曲线平滑两个流程组成,如表 2 所示,选用了偏最小二乘法与 Hanning Window 函数、blackman 窗函数、Savitzky Golay 滤波器相结合的 3 个算法以及多项式拟合与 Savitzky Golay 滤波器相结合的算法进行比较。去噪测试集选用 0 dB 光谱数据集,总结得出,从提升的信噪比,光谱相似度以及均方误差 3 个指标

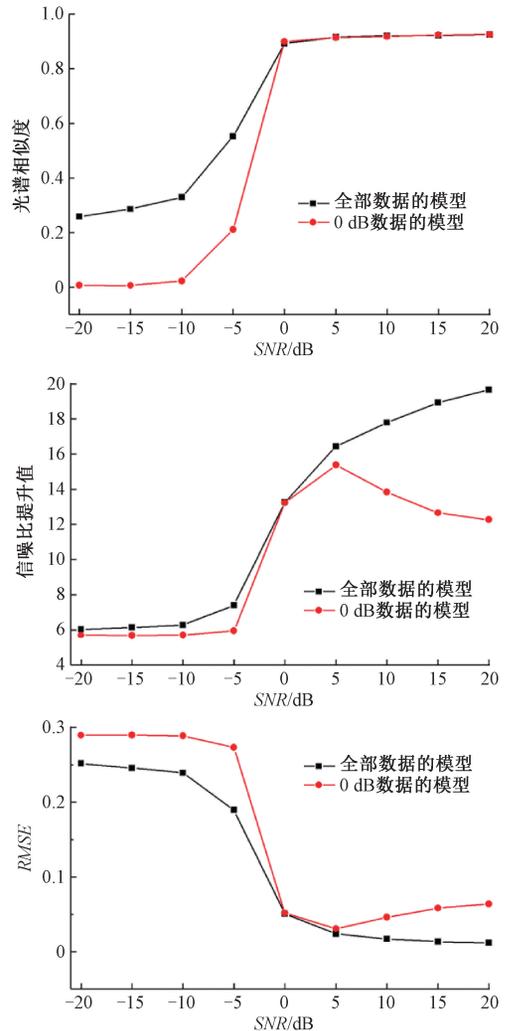


图 7 不同信噪比测试数据集上模型去噪能力表征
Fig. 7 Representation diagram of denoising ability of model on different SNR test data sets

表 2 不同算法去噪效果比较结果
Table 2 Results of comparison of denoising effect of different algorithms

SNR=0 dB	Δ SNR/dB	光谱相似度	MSE
DSC-U-Net	13.266	0.892	0.050
arPLS+hanning	5.478	0.216	0.287
arPLS+blackman	5.446	0.201	0.289
arPLS+SG	5.571	0.284	0.281
Poly+SG	5.399	0.306	0.279

进行比较,DSC-U-Net 模型算法提升信噪比是 13.266,光谱相似度是 0.892,均方误差是 0.050,各项指标都远大于其他机器学习的去噪结果。

为了更直观地表达不同算法对 0 dB 光谱数据去噪的效果,将算法去噪后光谱绘制如图 8 所示,能清晰地看出,DSC-U-Net 模型算法能较好地将 0 dB 光谱数据的噪声信号去除,且去噪后光谱与纯净光谱近似。

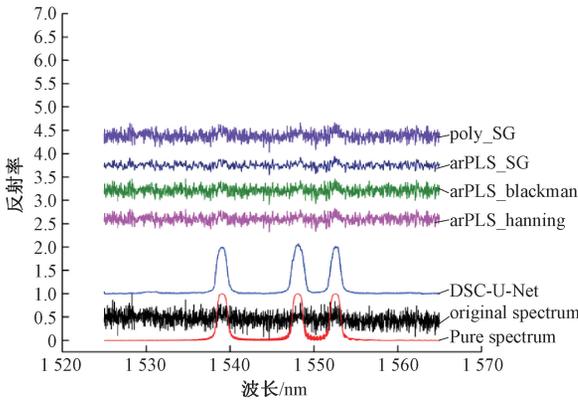


图 8 算法去噪效果比较

Fig. 8 Diagram of algorithm denoising effect comparison diagram

3 实验验证

3.1 实验系统搭建

在 DSC-U-Net 的模型训练中,使用的是仿真数据集进行训练,为了验证 DSC-U-Net 模型算法实际使用时光谱去噪能力,开展数据采集系统搭建工作,使用实验数据进行算法验证。

光纤光栅传感数据采集系统如图 9 所示,光纤光栅传感数据采集系统由带有解调软件的电脑、光纤光栅解调仪和光纤光栅传感器组成。其中光纤光栅解调仪由扫描式激光器、光纤光路和光电二极管等组件构成。



图 9 光纤光栅传感数据采集系统

Fig. 9 Fiber grating sensor data acquisition system

实验过程中,将数据采集系统的光纤传感器放置于恶劣环境中,环境温度变化范围是 $-55^{\circ}\text{C} \sim 150^{\circ}\text{C}$,进行长时间实验,得到的光谱数据作为 DSC-U-Net 模型算法测试集。通常对于深度学习模型使用实验数据进行训练模型训练,再用未被用于训练的测试集进行模型评估,本次实验中,为了探究模型训练优化的可能性,即使用仿真数据进行预训练,可以减少前期模型训练对实验数据的依赖度。使用仿真数据进行模型训练,使用实验数据进行模型测试,来评估模型去噪效果。

3.2 基于实验数据的模型测试验证

光纤光栅传感器通常是由光纤光栅光谱解调出中心波长,再转换为对应的物理参量,如应变、温度、加速度等实现传感功能。因此光谱通过去噪后能有效提高光谱解调的精度是最为关键的,所以选用光谱解调后中心波长的均方根误差 (RMSE) 来对光谱去噪模型 (DSC-U-Net 的模型) 进行评估。解调算法选用了卷积神经网络 (LeNet5) 算法、多层感知机 (multi-layer perceptron, MLP) 算法、高斯拟合 (Gaussian) 算法和连续小波变换 (continuous wavelet transform, CWT) 算法,从表 3 中可得知,光纤光栅传感器光谱在使用 DSC-U-Net 的模型去噪算法后解调精度都有所提升,解调后中心波长均方根误差有所下降,其中去噪算法 DSC-U-Net 和解调算法 MLP 组合对光谱解调精度提升效果最大,误差从 0.297 pm 下降到了 0.023 pm ,精度提升了 92.26%。

表 3 基于不同算法的解调结果数据

Table 3 Demodulation result data based on different algorithms

去噪算法	解调算法	RMSE/pm
	LeNet5	0.126
	MLP	0.297
	Gaussian	0.455
	CWT	0.389
	DSC-U-Net	0.023
DSC-U-Net	LeNet5	0.114
	MLP	0.023
	Gaussian	0.197
	CWT	0.203

图 10 直观地展示了 DSC-U-Net 模型算法对原始光谱去噪后效果,表明使用仿真数据集训练的模型能有效提高实验光谱数据的信噪比。

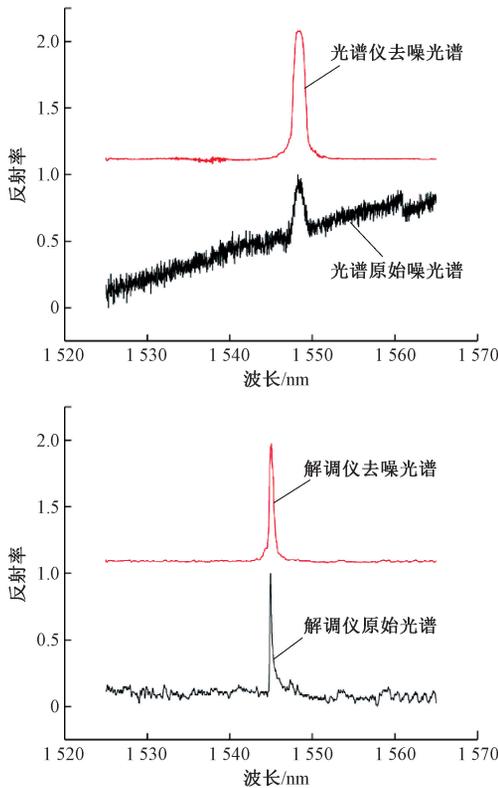


图10 实验数据测试结果

Fig. 10 Experimental data test results

4 结 论

本文基于光纤光栅传感原理,结合传输矩阵理论和深度学习模型开展光纤光栅光谱去噪算法研究。使用仿真数据对DSC-U-Net模型进行训练,验证了模型可以有效提高光谱信噪比,使用光谱信噪比提升值、光谱均方根误差和光谱相似度3个指标定量探究了不同规模的训练集对模型训练与测试结果的影响。

在相同测试集上与其他机器学习算法对比,DSC-U-Net模型去噪效果表现优异,可以将信噪比为0 dB的光谱数据信噪比提升至13.26 dB,去噪后光谱与纯净光谱相似度为0.892。

利用实验数据对模型进行测试,在相同测试集上去噪算法与解调算法组合进行测试,测试结果表明使用DSC-U-Net模型能有效实现光谱去噪功能,对去噪后光谱进行解调能大幅度提升光谱解调精度,解调误差降低了92.26%。同时证明了通过仿真数据集训练的模型能有效应用于实验数据的预测,因此后续可以使用少量实验数据对仿真数据的预训练模型进行微调,以降低对真实数据的依赖,提升训练效率,同时保持高精度。

参考文献

- [1] MASSARONI C, ZALTIERI M, LO PRESTI D, et al. Fiber Bragg grating sensors for cardiorespiratory monitoring: A review[J]. IEEE Sensors Journal, 2020, 21(13): 14069-14080.
- [2] ZHANG J Q, QIAN K, QIU D, et al. FBG strain monitoring data denoising in wind turbine blades based on parameter-optimized variational mode decomposition method [J]. Optical Fiber Technology, 2023, 81: 103527.
- [3] JINACHANDRAN S, RAJAN G. Fiber Bragg grating based acoustic emission measurement system for structural health monitoring applications [J]. Materials, 2021, 14(4): 897.
- [4] LIU ZH CH, ZHANG X, SHAO T P, et al. Heartbeat and respiration monitoring based on FBG sensor network [J]. Optical Fiber Technology, 2023, 81: 103561.
- [5] LIU F, LEI Y, XIE Y, et al. Vehicle identification using deep learning for expressway monitoring based on ultra-weak FBG arrays [J]. Optics Express, 2023, 31(10): 16754-16769.
- [6] HEGDE G, ASOKAN S, HEGDE G. Fiber Bragg grating sensors for aerospace applications: A review [J]. ISSS Journal of Micro and Smart Systems, 2022, 11(1): 257-275.
- [7] CHEN Y H, WU J, LIN D D, et al. Research on dynamic response of vertical displacement of runway pavement slab end under aircraft taxiing using novel FBG sensors [J]. Measurement, 2025, 243: 116296.
- [8] HEGDE G, SUHAS B K, SURENDRANATH V, et al. FBG sensors for low-speed flow analysis [C]. Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2022, 2022, 12046: 363-369.
- [9] CHEN Y, LI Y H, AN W Y, et al. Rolling bearing performance degradation prediction based on FBG signal [J]. IEEE Sensors Journal, 2021, 21(21): 24134-24141.
- [10] JIANG H, LI D, ZHANG X M, et al. Research on denoising method of fiber grating multiplexing network based on LCEEMD-LWT [J]. Optik, 2021, 247: 167997.
- [11] ZHU S, WANG Y L, XU Y F, et al. Asymmetric fiber grating overlapping spectrum demodulation technology based on convolutional network and wavelet transform noise reduction [J]. Optical Fiber Technology, 2025, 90: 104132.
- [12] GOLMOHAMMADI A, HASHEMINEJAD N,

- HERNANDO D, et al. Performance assessment of discrete wavelet transform for de-noising of FBG sensors embedded in asphalt pavement[J]. *Optical Fiber Technology*, 2024, 82: 103596.
- [13] MA J, GONG ZH, YAN CH L, et al. Wavelet denoising analysis on vacuum-process monitoring signals of aerospace vacuum vessel structures [J]. *Measurement Science and Technology*, 2024, 35(12): 126008.
- [14] SONG F R, SUN W, WEI J T, et al. The optimization study of FBG Gaussian fitting peak-detection based on Levenberg-Marquardt algorithm[C]. 2017 Chinese Automation Congress, 2017: 3723-3727.
- [15] CI ĘSZCZYK S, PANAS P, SKORUPSKI K, et al. Fibre Bragg grating wavelength shift demodulation with filtering and enhancement of spectra by simple nonlinear signal processing[J]. *Applied Sciences*, 2025, 15(6): 3384.
- [16] XIN J T, ZHUANG W, LOU X P, et al. High spatial resolution temperature field measurements by apodized short fiber Bragg grating sensors [J]. *Optical Engineering*, 2019, 58(6): 064102.
- [17] YAMADA M, SAKUDA K. Analysis of almost-periodic distributed feedback slab waveguides via a fundamental matrix approach[J]. *Applied Optics*, 1987, 26(16): 3474-3478.
- [18] FERNÁNDEZ-RUIZ M R, CARBALLAR A. Fiber Bragg grating-based optical signal processing: Review and survey[J]. *Applied Sciences*, 2021, 11(17): 8189.
- [19] RONNEBERGER O, FISCHER P, BROX T. U-net; Convolutional networks for biomedical image segmentation[C]. *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2015: 234-241.
- [20] GEBREKIDAN M T, KNIPFER C, BRAEUER A S. Refinement of spectra using a deep neural network: Fully automated removal of noise and background[J]. *Journal*

of Raman Spectroscopy, 2021, 52(3): 723-736.

- [21] CHOLLET F. Xception; Deep learning with depthwise separable convolutions [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1251-1258.

作者简介



夏嘉斌, 2016 年于北京信息科技大学获得学士学位, 2019 年于合肥工业大学获得硕士学位, 2023 年于合肥工业大学获得博士学位, 主要研究方向为光纤传感技术与人工智能算法。

E-mail: xiajiabinxjb@126.com

Xia Jiabin received his B. Sc. degree from Beijing Information Science and Technology University in 2016, and his M. Sc. and Ph. D. degrees both from Hefei University of Technology in 2019 and 2023. His main research interests include fiber optic sensing technology and artificial intelligence algorithms.



祝连庆(通信作者), 1984 年和 1989 年分别于合肥工业大学获得学士学位和硕士学位, 2013 年于哈尔滨工业大学获博士学位, 现为北京信息科技大学教授、博士生导师, 主要研究方向为生物医学仪器、光纤传感与激光器、光电测试仪器与装备。

E-mail: zhulianqing@sina.com

Zhu Lianqing (Corresponding author) received his B. Sc. and M. Sc. degrees both from Hefei University of Technology in 1984 and 1989, respectively, and his Ph. D. degree from Harbin Institute of Technology in 2013. He is currently a professor and doctoral supervisor at Beijing Information Science and Technology University. His main research interests include biomedical instruments, fiber optic sensing and lasers, and optoelectronic testing instruments and equipment.