



基于卷积神经网络的混叠光谱解调方法

刘瀚霖 辛璟焘 庄炜 夏嘉斌 祝连庆

Demodulation method of overlapping spectrum based on convolutional neural network

Liu Hanlin, Xin Jingtao, Zhuang Wei, Xia Jiabin, Zhu Lianqing

在线阅读 View online: <https://doi.org/10.3788/IRLA20210419>

您可能感兴趣的其他文章

Articles you may be interested in

基于深度谱卷积神经网络的高效视觉目标跟踪算法

Efficient visual target tracking algorithm based on deep spectral convolutional neural networks

红外与激光工程. 2018, 47(6): 626005 <https://doi.org/10.3788/IRLA201847.0626005>

基于卷积神经网络的反无人机系统图像识别方法

Image recognition method of anti UAV system based on convolutional neural network

红外与激光工程. 2020, 49(7): 20200154 <https://doi.org/10.3788/IRLA20200154>

采用卷积神经网络的红外和可见光图像块匹配

Infrared-visible image patches matching via convolutional neural networks

红外与激光工程. 2021, 50(5): 20200364 <https://doi.org/10.3788/IRLA20200364>

基于3D卷积神经网络的PolSAR图像精细分类

Fine classification of polarimetric SAR images based on 3D convolutional neural network

红外与激光工程. 2018, 47(7): 703001 <https://doi.org/10.3788/IRLA201847.0703001>

流场测速中基于深度卷积神经网络的光学畸变校正技术

Aberration correction for flow velocity measurements using deep convolutional neural networks

红外与激光工程. 2020, 49(10): 20200267 <https://doi.org/10.3788/IRLA20200267>

基于全光衍射深度神经网络的矿物拉曼光谱识别方法

Raman mineral recognition method based on all-optical diffraction deep neural network

红外与激光工程. 2020, 49(10): 20200221 <https://doi.org/10.3788/IRLA20200221>

基于卷积神经网络的混叠光谱解调方法

刘瀚霖^{1,2}, 辛璟焘^{1,2}, 庄 炜^{1,2*}, 夏嘉斌³, 祝连庆^{1,2}

1. 北京信息科技大学 光电测试技术与仪器教育部重点实验室, 北京 100192;
2. 北京信息科技大学 光纤传感与系统北京实验室, 北京 100016;
3. 合肥工业大学 仪器科学与光电工程学院, 安徽 合肥 230009)

摘 要: 研究了一种基于深度学习的光纤光栅混叠 FBG 光谱解调方法。利用卷积神经网络(Convolutional Neural Networks, CNN)模型处理混叠光谱非线性序列模型问题,通过一维卷积神经网络预测识别混叠光谱中心波长,并搭建了并联结构的混叠光谱数据自动采集实验系统,验证了混叠光谱的中心波长高精度解调。实验分析了训练样本、迭代次数对训练时间、测试时间、解调精度的影响,并对训练完成后的模型进行了解调时间测试。分别与其他解调算法进行了解调精度和测试时间对比,同时对同一组光谱数据使用解调模型算法及最高点寻峰算法进行中心波长值的对比并进行误差分析。实验结果表明:解调模型均方根误差结果为 0.082 58 pm,使用 Intel(R) Core(TM) i7-8550U CPU (Central Processing Unit) 的解调计算时间为 0.338 s。研究结果表明:采用卷积神经网络模型对于混叠光谱中心波长解调结果的准确性具有合理性,与其他算法相比,文中的解调算法在解调精度和时间上具有优势,模型大小在 400 kB 以下,所需算力较小,可部署在小型嵌入式设备中,在大规模机载传感网络、结构健康监测中有良好的应用前景。

关键词: 光纤光栅; 混叠光谱; 光谱数据采集系统; 卷积神经网络

中图分类号: TN253 **文献标志码:** A **DOI:** 10.3788/IRLA20210419

Demodulation method of overlapping spectrum based on convolutional neural network

Liu Hanlin^{1,2}, Xin Jingtao^{1,2}, Zhuang Wei^{1,2*}, Xia Jiabin³, Zhu Lianqing^{1,2}

1. Key Laboratory of the Ministry of Education for Optoelectronic Measurement Technology and Instrument, Beijing University of Information Technology, Beijing 100192, China;
2. Beijing Laboratory of Optical Fiber Sensing and Systems, Beijing Information Science & Technology University, Beijing 100016, China;
3. School of Instrument Science and Opto-electronics Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: An FBG spectral demodulation method based on deep learning was studied. The Convolutional Neural Networks(CNN) model was used to deal with the nonlinear sequence model of the overlapping spectrum, and the central wavelength of the overlapping spectrum was predicted and identified through a one-dimensional convolutional neural network. And a parallel structure of the overlapping spectrum data automatic acquisition

收稿日期:2021-12-25; 修订日期:2022-02-25

基金项目:国家自然科学基金(51535002, 61903042);北京市自然科学基金(4212048);高等学校学科创新引智计划(D17021);北京信息科技大学师资补充与支持计划(5029011103)

作者简介:刘瀚霖,男,硕士生,主要从事光纤传感与光电器件方面的研究。

导师简介:辛璟焘,男,副教授,博士,主要从事光纤传感、光纤激光器方面的研究。

通讯作者:庄炜,男,博士后,主要从事光纤传感、解调方面的研究。

experimental system was built to verify the high-precision demodulation of the center wavelength of the overlapping spectrum. The experiment analyzes the effects of training samples and epoch times on training time, testing time, and demodulation accuracy, and tests the computational demodulation time of the model after training. The demodulation accuracy and test time were compared with other demodulation algorithms. At the same time, the demodulation model algorithm and the peak finding algorithm at the highest point were used to compare the center wavelength value and analyze the error for the same set of spectral data. The experimental results show that the root means square error of the demodulation model is 0.082 58 pm, and the demodulation calculation time is 30.886 ms, which is used Intel(R) Core (TM) i7-8550U CPU. The research results show that the convolutional neural network model is reasonable for the accuracy of the central wavelength demodulation results of the overlapping spectrum. Compared with other algorithms, the demodulation algorithm in this article has advantages in demodulation accuracy and time. The model size is less than 400 kB, and the required computing power is small. It can be deployed in small embedded devices. It has good application prospects in large-scale airborne sensor networks and structural health monitoring.

Key words: fiber grating; overlapped spectrum; spectrum data acquisition system; convolutional neural networks

0 引言

光纤光栅传感器在航空航天、道路桥梁、石油电力、安全监测等诸多领域具有重要的应用^[1]。2008年, NASA^[2]利用光纤光栅传感器测量系统对 Ikhana 无人飞机机翼形状进行了测试, 每个机翼布置了 1440 个传感器。在大规模航空航天飞行器的结构检测中, 需要在飞行器表面布置大量光纤光栅传感器, 因此需要大量的解调任务。采用传统的寻峰算法解调 FBG 中心波长时, 单一通道上复用的 FBG 数目受到带宽的限制。单纯增加传感器数目, 相邻 FBG 的光谱会产生混叠, 无法用常规寻峰算法精确解调。因此, 研究混叠光谱解调算法可很好的解决解调通道有限和解调容量大之间的矛盾, 为大容量机载传感网络解调技术提供技术支持。

随着现代信息技术的发展, 人们发现可以借鉴数学工具为研究光谱信号的重叠峰分离提供新的思路^[3]。基于小波理论在混叠光谱解析中的应用也取得了许多进展。2019年, 海军工程大学 Peng Ding 等^[4]提出了一种基于连续小波变换 (CWT) 的多峰 FBG 反射谱分割方法。选择合适尺度的一阶高斯或墨西哥帽小波基函数进行连续小波变换。利用处理后的信号中的极值点对原始信号进行分割。模拟了无重叠峰和有噪声、部分重叠峰和有噪声两种情况下的多峰 FBG 谱。

神经网络对非线性信号有良好的逼近能力。2014年, Jing Chen 等^[5]出了一种基于最小二乘支持向量回归的光栅传感网络 (LS-SVR) 解调算法, 中心波长解调均方根误差 (RMS) 为 3.955 pm, 计算解调时间为 0.073 6 s。

近年来, 深度学习模型的应用领域越来越广泛。将深度学习模型部署在混叠光纤光栅光谱解调算法中会有更高的准确率, 并取得更好的效果。2019年, Jiang H 等^[6]提出了一种基于长短期记忆 (LSTM) 网络的光纤布拉格光栅 (FBG) 传感器网络波长检测方法。中心波长解调均方根误差 (RMS) 为 0.674 pm, 计算解调时间为 0.073 6 s。2020年, 江灏等^[7]针对光纤布拉格光栅 (FBG) 传感网络中重叠光谱的中心波长解调问题, 提出一种基于门控循环单元 (GRU) 网络的波长检测方法, RMS 为 0.8325 pm。Yibeltal Chanie Manie 等^[8]提出了基于强度波分复用 (IWDM) 的自修复光纤光栅传感器网络的深度学习算法, 也提出了一种门控循环单元 (GRU) 深度学习算法, 提升了一些解调精度。RMS 为 0.067 pm, 解调计算时间 0.342 s。使用深度学习技术解调混叠光谱的中心波长的技术已经取得一些进展, 面对实际工程需要, 特别在算力有限的情况下, 解调精度和速度很难满足应用需求。开展兼顾精度和速度的混叠光谱解调技术具有重要的研究价值。

混叠光谱的解调是一种非线性回归问题, CNN

之后将数据进行保存,包含波长和强度信息。图 2 为混叠光谱数据采集上位机程序框图。程序开始运行

之后,首先确定光通道的开启情况,并获得光开关的指令,与此同时进行光谱仪的初始化。

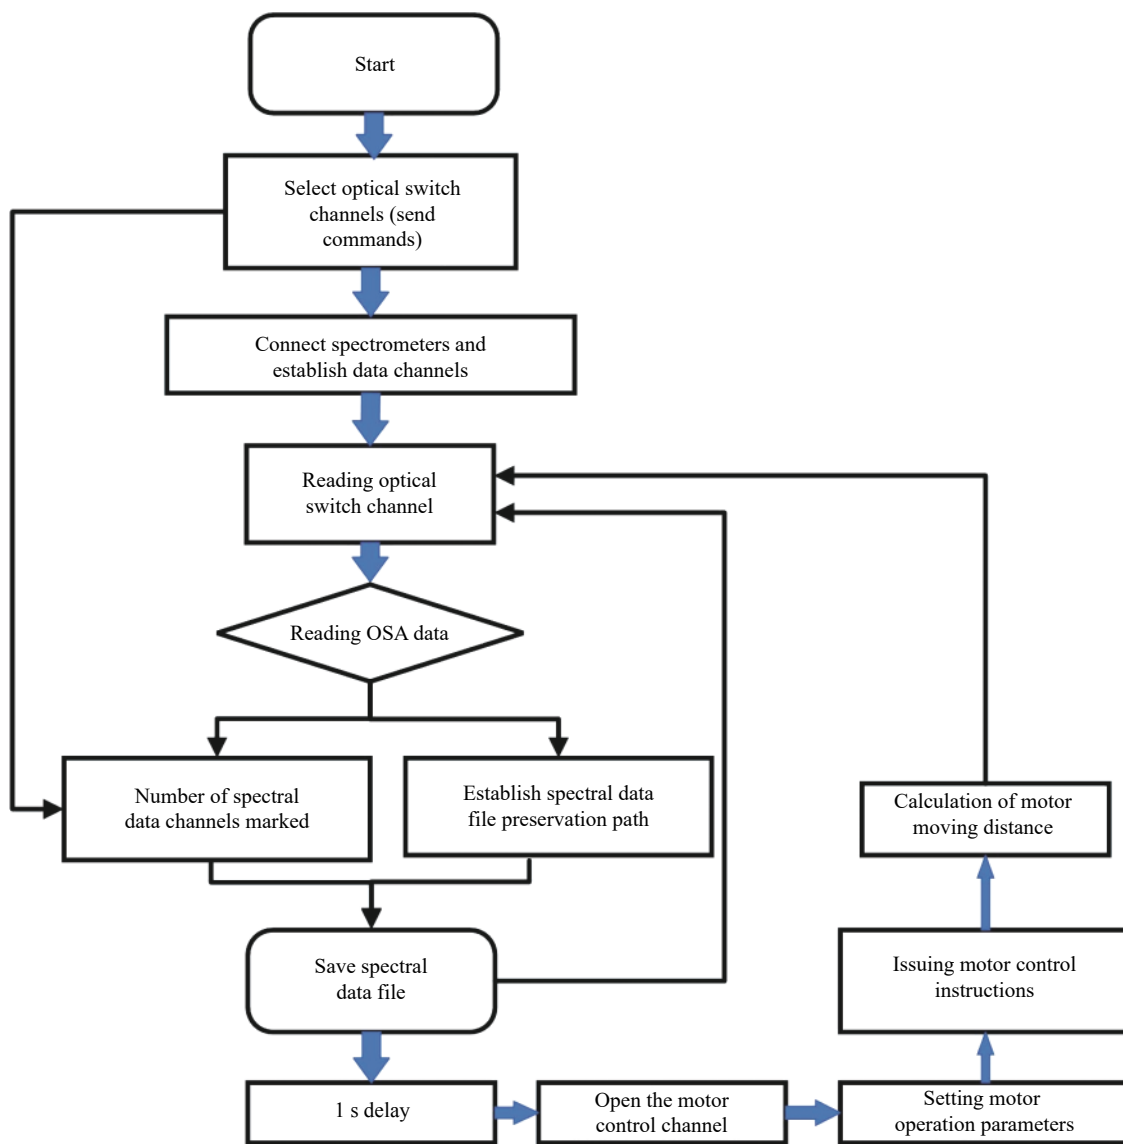


图 2 混叠光谱数据采集上位机程序框图

Fig.2 Program block diagram of the upper computer of the aliasing spectrum data acquisition

随后进入参数设置,包括波长范围设置,反射率,分辨率,采样点,采样间隔设置,可输出包含横纵坐标的光谱数据。设置好路径之后,写入文件,即可保存文件。之后就可进入到电机控制环节,首先设置上升距离,系数,脉冲数,步进方向指令等参数,发送指令就可以完成电机上升。上位机显示界面可分别显示,当前正在扫描保存的光谱,两个原始光谱及混叠光谱的形状。波长范围可调整,以适应中心波长不同的光纤光栅光谱数据采集。数据保存完成后,进入电机控

制部分,使用步进电机及控制系统以 0.005 mm 的步长上升,控制端前面板可实时显示移动距离,运行状态,停止运行的距离高度。图 3(a)~图 3(e) 为上位机显示界面中光谱由完全分离到逐渐重叠,再到完全重叠,之后恢复完全分离情况的示意图。数据采集系统的带宽范围是 1532~1540 nm,对 2 001 个点进行采样。在采集过程中,为获得更多数据,在一次步进电机行程结束之后,改变步进距离,多次进行采集。当电机上升并到达预定距离之后,采集完成,采集系统

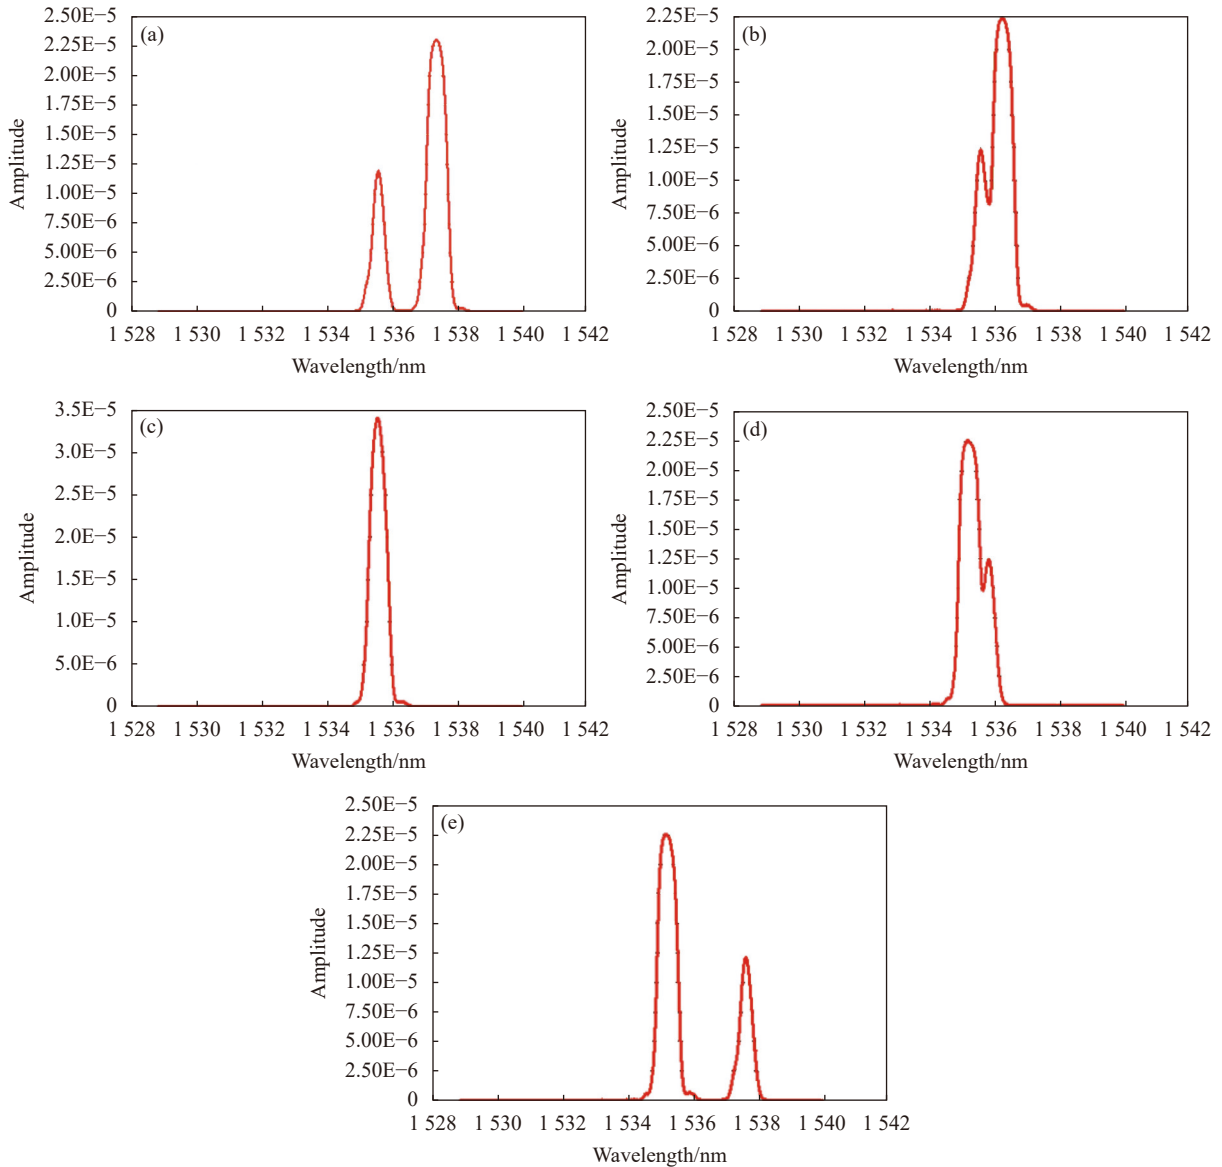


图 3 上位机显示界面中光谱的重叠过程

Fig.3 Overlap process of the spectrum in the display interface of the host computer

会自动停止运行,光谱数据包含通道信息,横坐标为波长值,纵坐标为光谱强度,以文本型文件保存,便于之后进行模型的调用及数据预处理工作。

2 混叠光谱解调模型的构建

2.1 解调模型算法的建立

混叠光谱的解调是一种非线性回归问题,文中提出的 CNN 模型能够处理混叠光谱非线性序列模型问题。CNN 是近年来深度学习应用于计算机视觉领域的重要部分,也逐渐在自然语言处理、信号分析等领域中使用。文中提出了一种 CNN 深度学习算法,用

于解决大型光纤光栅传感器并联传感网络中混叠光谱不可准确识别出中心波长的问题, CNN 可以通过反射光谱序列的特征,学习和识别在不同混叠情况下的光谱特征。在文中提出的 CNN 模型中,对输入的长序列光谱数据的特征提取可由卷积层自动完成,因此,将光谱数据转换成一维 (1D) 数据,提升了检测效率,获得了更高的解调精度。在 CNN 模型训练完成后,可以从 FBG 重叠谱中解调出每个 FBG 的中心波长。在混叠光谱解调算法构建之前,首先要进行数据的预处理,归一化可以有效降低损失函数,由于特征向量中不同特征的取值相差较大,会导致目标函数变

形。这样在进行梯度下降的时候,梯度的方向就会偏离最小值的方向,会导致训练时间过长。归一化后加快了梯度下降求最优解的速度。

首先,需要训练一个可复用的光纤光栅对波长检测模型。对于网络训练,测试样本是从 OSA (optical spectrum analyzer) 中收集到的光谱数据,一组数据采集 2001 个像素点,共采集 11 000 组数据。训练前,频谱归一化为 0~1,光谱序列数据设为以模型输入,通过 CNN 学习的特征学习输出向量 FBG1 和 FBG2 光谱的中心波长。CNN 网络在 TensorFlow 深度学习框架中实现。迭代数 epoch 被设定为 1 000,学习率为 0.1。

在深度学习框架中搭建好模型结构之后,将归一化完成之后的光谱数据进行训练,训练的 CPU 为 Intel Core i7-8550 U CPU,训练完成之后的 CNN 模型可进行波长检测训练。经过良好训练的 CNN 模型可以直接应用于在线检测。经过训练的模型,不需要高水平配置的计算机,便可以达到的毫秒级响应,同时也可以方便地移植到嵌入式系统。

程序部分包括数据加载部分,模型训练部分,混叠光谱模型解调结果输出部分。数据加载部分首先将数据顺序打乱,并划分训练集和测试集。

之后进行神经网络的搭建,首先设置三层卷积层三层池化层,激活函数为 ReLu 函数。由于输出结果为两个数值,因此在这里设置两个分支,再分别进行一层卷积层和池化层,之后设置一个输出层,为全连接层,激活函数为 sigmoid 函数。之后设置损失函数,以均方根误差和平均值误差代表。训练时使用 Adam 随机优化算法,该算法提升了计算效率,减小了噪声和稀疏性。最后将模型保存。图 4 为该卷积神经网络模型的结构示意图。该设计提出的一维卷积神经网络模型文件可保存为 pb(protocol, buffer) 格式文件,是一种表示神经网络模型结构的二进制文件,大小总计在 400 kB 以下,所需设备算力较小。在大规模结构健康检测的应用中,测量精度高、测点范围分布广、数量大。需实现大容量光纤光栅混叠光谱实时解调。因此,模型大小应进行控制,而同样的长短期记忆模型 (LSTM),门控循环单元 (GRU) 等网络模型的大小为 4.78 MB, 2.1 MB,模型所占内存更大,对设备




图 4 一维卷积神经网络结构示意图

Fig.4 Schematic diagram of 1D convolutional neural network structure

的算力需求比 CNN 模型更多。因此,基于一维卷积神经网络的混叠光谱解调模型具有优势。

2.2 模型测试和评估

在模型找到最优解之前,CNN 算法进行了若干次训练,在模型训练部分主函数程序,经过 1 000 次模型迭代训练,损失函数结果接近最优值。使用均方根误差 (RMS) 和平均值误差 (MAE) 来评估光纤光栅传感器混叠光谱测量信号的误差指标。RMS 可计算为:

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

式中: n 表示样本数量; y_i 为当前误差值; \bar{y} 为误差平均值。为了验证 CNN 模型的有效性,进一步评价模型的性能,将该方法与极限学习机 (ELM)、最小二乘支持向量回归 (LS-SVR) 和粒子群优化 (PSO)、LSTM, GRU 等算法^[5-6,8,10-11]进行了比较,通过 RMS、MAE 来评估模型的预测性能。MAE 可计算为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}| \quad (2)$$

式中: n 表示样本数量; y_i 为当前误差值; \bar{y} 为误差平均值。传感器网络参数与实验环境参数保持一致。与

以往的机器学习算法相比,卷积神经网络具有更高的准确度,优于 ELM 和 LS-SVR。LSTM(长短期记忆网络),GRU(门控循环单元)等算法更适合波长序列特征,能够学习 FBG 光谱间的高阶表示和长期相关性。CNN 深度网络结构的使用增强了学习能力,擅长对光谱形状的特征学习,是一种良好的寻峰算法,可以获得较高的寻峰检测精度。将 CNN 的性能与其他算法进行比较,以评价其性能,如表 1 所示,表中也给出了各种算法模型的解调计算时间,文中提出算

法的解调计算时间明显低于其他算法。为更好的评价模型的性能,将模型的一些具体参数(数据样本量、迭代次数)进行调整,观测其损失函数的变化。从图 5 可以看出,批次大小在 100、1000 次迭代次数下,随着训练样本和测试样本的增加,训练的时间普遍在 200 s 以上,测试时间逐步增加。图 6 为模型训练的损失函数下降情况,训练集和测试集的损失函数为 RMS(均方根误差),结果基本保持一致,在迭代次数达到 400 以上趋于平稳。

表 1 不同算法之间的比较

Tab.1 Comparison between different algorithms

Algorithm	RMS/pm	Computational time/s	Data source
ELM	0.918	0.200	Ref.[8]
LS-SVR	3.955	0.0736	Ref.[7]
PSO-SA	<5.000	--	Ref.[10]
LSTM	0.674	0.574	Ref.[8]
CNN	0.0826	0.338	This work




图 5 不同训练样本下的 CNN 训练时间和测试时间

Fig.5 CNN training time and test time under different training samples

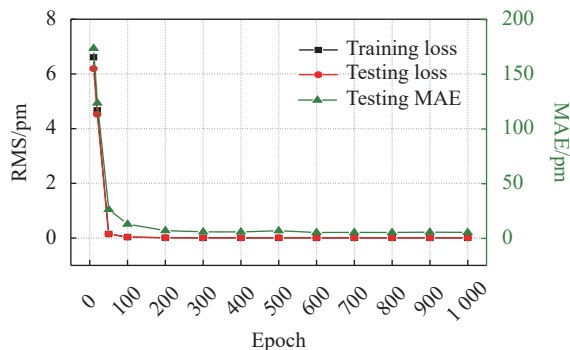


图 6 不同迭代次数下的 RMS、MAE 误差

Fig.6 RMS and MAE error under different epoch times

2.3 实验结果与分析

模型在训练完成之后进行保存,可进行混叠光谱的快速解调。混叠光谱解调算法模型在训练集的均方根误差为 0.0867 pm,在测试集上的均方根误差为 0.0826 pm,结果优于同级别设备或解调算法。图 7(a)~(d) 为光谱不同混叠程度解调模型解调结果,可以看出在往左右各方向混叠时的情况。图 7(a)和图 7(c) 为两光谱部分重叠的情况,图 7(a)中显示的两个 FBG 的中心波长差值为 0.697 nm,根据光谱形状,仍然可分辨出两个峰值,此时的模型解调精度均方根误差以达到 0.05 pm 以下。图 7(c)中的 FBG1 和 FBG2 的中心波长的中心波长差值为-0.391 nm,和图 7(a)的情况相比,两 FBG 之间的距离更近,由此可以看出两个 FBG 左右交换位置后,模型解调出的中心波长值和 FBG 仍然有良好的匹配性。图 7(b)中,FBG1 和 FBG2 的中心波长差值为 1.004 nm,可以明显地区分出两个峰值,图 7(d)为两个光纤光栅光谱完全重叠的情况,可以看出该解调算法有着良好的解调结果。对于这四种情况的 RMS 为 0.0322、0.0319、0.0148、0.0301 pm。在 8000 个样本数据中,RMS 达到 0.050 pm,有 92.1% 样本的均方根误差在 0.1 pm 以下。样本数

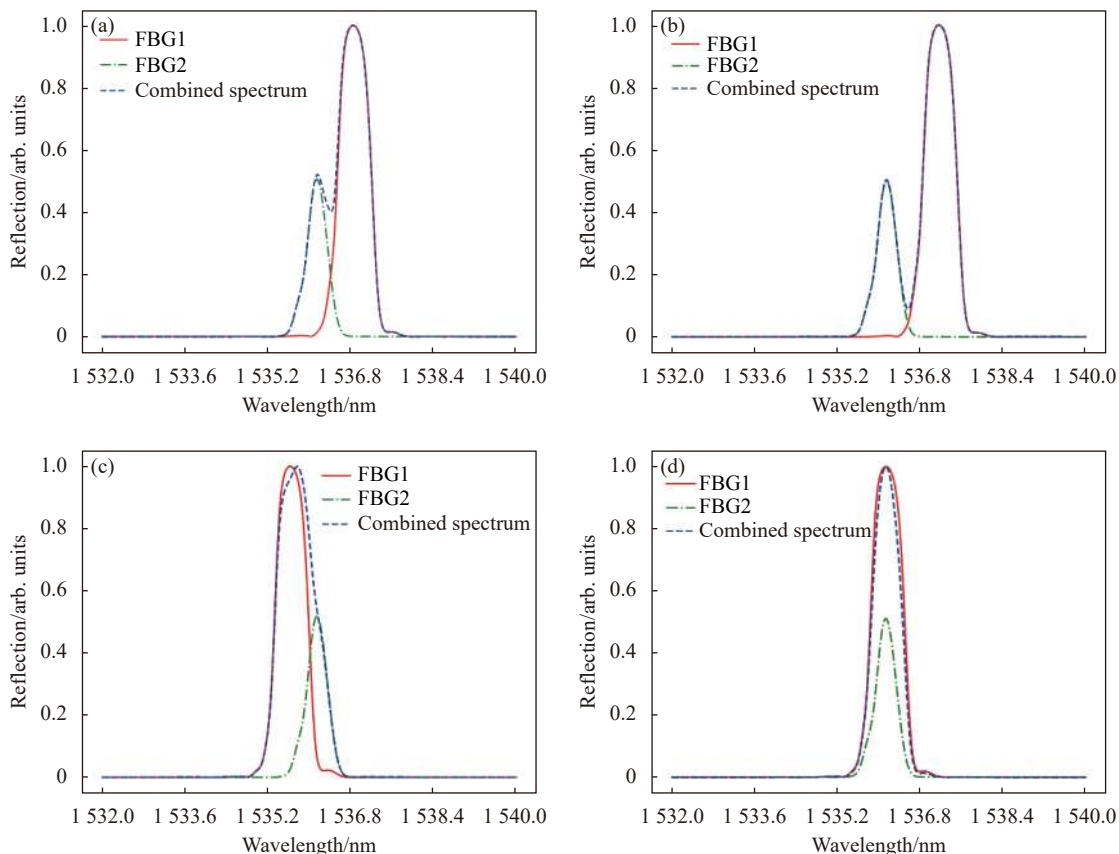


图 7 不同混叠程度下光谱的解调结果

Fig.7 Spectral demodulation results under different degrees of aliasing

据包含了不同混叠程度的光谱数据,以及未混叠下的光谱数据,解调结果并无明显差别,如表 2 所示。因此,进一步地验证了该混叠光谱解调模型的准确度和适应性。

表 2 不同混叠程度的解调结果

Tab.2 Demodulation results with different degrees of aliasing

Case	FBG1/nm	FBG2/nm	$\Delta\lambda$ /nm	RMS/pm
a	1536.8488	1536.1514	0.6974	0.0322
b	1537.1559	1536.1521	1.0038	0.0319
c	1535.7527	1536.1434	-0.3907	0.0148
d	1536.1317	1536.1549	-0.0232	0.0301

3 结论

文中设计了新的混叠光谱解调方法,在数据采集方面,设计了一种混叠光谱数据采集装置,包括应变传递梁实验装置、增加了应变的范围,在此基础上通

过光开关的切换,可同时构造出混叠光谱,以及其对应的单个光谱。各光谱数据可通过上位机自动采集,形成深度学习神经网络模型的训练集和测试集。之后搭建一个适合的深度神经网络模型,通过实验调整其超参数,以得到合适的解调结果。实验结果表明,该模型的均方根解调误差高达 0.082 6 pm、解调时间为 0.338 s、并且具有高精度、高重复性的特点。模型文件可部署在小型嵌入式设备中,在大规模机载传感网络,结构健康监测中有良好的应用价值。

参考文献:

[1] Xu G Q, Xiong D Y. Applications of fiber Bragg grating sensing technology in engineering [J]. *Chinese Optics*, 2013, 6(3): 306-317. (in Chinese)

[2] Wang W J, Xue J F, Zhang M J. Application progress and prospect of optical fiber sensor in aircraft structural health monitoring [J]. *Aeronautical Science & Technology*, 2020, 31(7): 95-101.

[3] Tao W L, Liu Y, Wang X P, et al. Implementation of

- overlapping peak separation algorithm for absorption spectra by fractal dimension analysis in time-frequency domain [J]. *Spectroscopy and Spectral Analysis*, 2017, 37(12): 3664-3669. (in Chinese)
- [4] Ding P, Huang J, Tang J. Multi-peak FBG reflection spectrum segmentation based on continuous wavelet transformation [J]. *Optical Fiber Technology*, 2019, 50: 250-255.
- [5] Chen J, Jiang H, Liu T, et al. Wavelength detection in FBG sensor networks using least squares support vector regression [J]. *Journal of Optics*, 2014, 16(4): 045402.
- [6] Jiang H, Zeng Q, Chen J, et al. Wavelength detection of model-sharing fiber Bragg grating sensor networks using long short-term memory neural network [J]. *Optics Express*, 2019, 27(15): 20583.
- [7] Jiang H, Wang Y G, Chen J, et al. Wavelength detection of overlapping spectra in FBG sensor network based on gated recurrent unit network [J]. *Acta Optica Sinica*, 2020, 40(7): 0706001. (in Chinese)
- [8] Manie Y C, Peng P C, Shiu R K, et al. Enhancement of the multiplexing capacity and measurement accuracy of FBG sensor system using IWDM technique and deep learning algorithm [J]. *Journal of Lightwave Technology*, 2020, 38(6): 1589-1603.
- [9] Yan H, Yu M, Xia J, et al. Diverse region-based cnn for tongue squamous cell carcinoma classification with Raman spectroscopy [J]. *IEEE Access*, 2020, 8: 127313.
- [10] Qi Y, Li C, Jiang P, et al. Research on demodulation of FBGs sensor network based on PSO-SA algorithm [J]. *Optik*, 2018, 164: 647-653.
- [11] Jiang H, Chen J, Liu T. Wavelength detection in spectrally overlapped FBG sensor network using extreme learning machine [J]. *IEEE Photonics Technology Letters*, 2014, 26(20): 2031-2034.