

doi: 10.11823/j.issn.1674-5795.2025.03.06

法布里-珀罗游标光谱信号的深度学习解调

王桢¹, 赵起超², 王昊琦¹, 邵志强³, 肖爽¹, 刘彬^{1*}

(1. 哈尔滨工程大学, 黑龙江 哈尔滨 150001; 2. 上海机电工程研究所, 上海 201109;

3. 中国电子科技集团公司第四十九所, 黑龙江 哈尔滨 150028)

摘要: 为提升法布里-珀罗(Fabry-Pérot, F-P)传感器游标光谱信号解调的准确性, 提出基于深度学习的光谱数据直接解调方法。首先对光谱数据进行预处理, 将复杂的游标光谱信息转化为卷积神经网络(Convolutional Neural Network, CNN)可以处理的数据格式, 然后采用深度学习模型对预处理后的完整光谱数据进行训练和测试, 并利用卷积神经网络对光谱数据进行特征提取和分类, 最终实现待测信号的准确解调。使用灵敏度为112.5 nm/MPa的双腔法布里-珀罗传感器采集光谱数据, 并开展信号解调实验, 结果表明: CNN模型对未知光谱进行10折(fold)交叉验证的平均准确率为92.49%, 均方根误差 R_{RMSE} (Root Mean Square Error, RMSE)为0.039 2 MPa, 相对误差的平均值为3.31%; 卷积神经网络-长短期记忆(Convolutional Neural Network-Long Short Term Memory, CNN-LSTM)模型对未知光谱进行10折交叉验证的平均准确率为96.98%, R_{RMSE} 为0.039 0 MPa, 相对误差的平均值为3.28%。基于CNN-LSTM模型的方法仅通过解调256个采样点的数据就实现了较高准确度, 具有便捷、高效的优点, 为推动光谱信号解调领域发展提供了有效的技术途径, 为开发智能光学传感系统提供了重要参考。

关键词: 光纤传感器; 法布里-珀罗干涉仪; 光谱解调; 深度学习; 游标效应

中图分类号: TB96; O433; TP183 **文献标志码:** A **文章编号:** 1674-5795(2025)03-0070-08

Deep learning-based demodulation of Fabry-Pérot vernier spectral signals

WANG Hui¹, ZHAO Qichao², WANG Haoqi¹, SHAO Zhiqiang³, XIAO Shuang¹, LIU Bin^{1*}

(1. Harbin Engineering University, Harbin 150001, China;

2. Shanghai Institute of Mechanical and Electrical Engineering, Shanghai 201109, China;

3. China Electronics Technology Group Corporation 49th Research Institute, Harbin 150028, China)

Abstract: To enhance the demodulation accuracy of vernier spectral signals in Fabry-Pérot (F-P) sensors, this study proposes a direct deep learning-based demodulation method for spectral data. The method involves preprocessing spectral data to convert complex vernier spectral information into formats compatible with Convolutional Neural Network (CNN), followed by training and testing deep learning models on the processed full-spectrum data. The CNN architecture was employed for feature extraction and classification of spectral data, enabling accurate demodulation of target signals. Experimental validation was conducted utilizing spectral data collected from a dual-cavity F-P sensor with 112.5 nm/MPa sensitivity. The results demonstrate that the CNN model achieved an average accuracy of 92.49% with 10-fold cross-validation,

收稿日期: 2025-02-17; **修回日期:** 2025-04-10

基金项目: 国家自然科学基金项目(52001096, 62201170); 黑龙江自然科学基金项目(LH2023F028); 中央高校基本科研业务费项目(3072024LJ0806)

引用格式: 王桢, 赵起超, 王昊琦, 等. 法布里-珀罗游标光谱信号的深度学习解调[J]. 计测技术, 2025, 45(3): 70-77.

Citation: WANG H, ZHAO Q C, WANG H Q, et al. Deep learning-based demodulation of Fabry-Pérot vernier spectral signals[J]. Metrology & Measurement Technology, 2025, 45(3): 70-77.



accompanied by a Root Mean Square Error (RMSE) of 0.039 2 MPa and a mean relative error of 3.31%. The hybrid Convolutional Neural Network-Long Short Term Memory (CNN-LSTM) model exhibited superior performance with an average accuracy of 96.98%, an RMSE of 0.039 0 MPa, and a mean relative error of 3.28%. Notably, the CNN-LSTM approach attained high precision using only 256 sampled data points, demonstrating remarkable efficiency. This method provides an effective technical pathway for advancing spectral signal demodulation technology, offering significant reference value for developing intelligent optical sensing systems.

Key words: optical fiber sensor; Fabry-Pérot interferometer; spectral demodulation; deep learning; vernier effect

0 引言

光学传感器技术因其非接触、高精度和抗电磁干扰等优势,已成为现代测量技术的重要组成部分。法布里-珀罗传感器是一种典型的光学传感器,具有体积小、灵敏度高、抗电磁干扰能力强等优点,在温度、压力、应变等多参量检测中展现出显著优势^[1-3],已广泛应用于医疗、气体检测、水声探测等领域^[4-9]。F-P传感器的核心结构由膜片和光纤端面构成,当外界压力作用于膜片时,膜片发生形变,导致反射光谱发生变化,根据反射光谱的变化测量微小物理量。通过串联2个初始腔长略有不同的F-P传感器,可以产生游标效应,通过叠加2个周期性信号的差异,能够提升传感器对微小物理量的测量灵敏度。

传统的游标光谱解调方法主要包括相关法和相位法。相关法通过计算待测光谱与预设参考腔长模板的互相关函数,以相关系数最大值确定绝对腔长^[10]。该方法的优势在于有效解决了光程差之间的串扰效应,但需遍历大范围参考腔长,计算复杂度高;此外,当光源光谱带宽不足或腔长过短时,互相关函数主峰误判风险显著增加,可能导致解调失效。相位法通过提取反射光谱相位信息解算绝对腔长,避免了光源强度扰动对解调结果产生影响的问题^[11]。相位法包括傅里叶变换法、单峰法、双峰法等。傅里叶变换法的理论精度可达纳米级,但需进行全光谱采样,且解算耗时较长,难以满足动态测量需求。单峰法的解调范围受限于自由光谱区,仅适用于窄腔长变化场景。双峰法兼顾速度与绝对解调能力,但该方法的峰值定位误差会通过杠杆效应放大^[12]。尽管这些方法在一定程度上提升了传感器的性能,但处理复杂光谱时仍然存在局限性。研究更高效、更

具鲁棒性的光谱解调方法对于提升F-P传感器的实用性至关重要。

近年来,深度学习方法因其在处理复杂数据和提取高级特征方面的强大能力,在光谱信号处理领域获得了越来越多的应用。2023年,ZHU C等人首次提出并证明了机器学习可用于解调基于光学游标效应的光纤传感器信号,验证了数据驱动方法的可行性^[13]。2024年,MEI Y等人提出了具有LSTM层增强的CNN,利用其解调基于双级联萨格纳克干涉的游标效应增强型压力传感器的信号,结果的 R_{RMSE} 为 3.68×10^{-3} MPa,但需设置512个采样点,硬件成本较高^[14]。

为提升F-P传感器游标光谱信号解调的准确性,本文提出基于深度学习的光谱数据解调方法,利用卷积神经网络进行光谱数据的特征提取和分类,实现对待测信号的直接解调。使用灵敏度为 112.5 nm/MPa ^[15]的双腔F-P传感器实现256个采样点的光谱数据采集,利用CNN模型和CNN-LSTM模型开展光谱信号解调实验,并进行10折交叉验证,对上述方法的应用效果进行评判。

1 传感器及系统设计

1.1 F-P游标传感

F-P游标传感基于F-P干涉仪和游标效应的结合,能够实现对微小位移或折射率变化的高精度测量^[16-19]。F-P干涉仪由2块平行的高反射率镜片构成,光在镜片间多次反射形成干涉。干涉条件为

$$2nd\cos\theta = m\lambda \quad (1)$$

式中: n 为介质折射率, d 为镜片间距, θ 为入射角, m 为干涉级次, λ 为波长。当 d 或 n 变化时,干涉条纹会移动。忽略由衍射、散射、错位等引起的损耗,对于 N 个级联F-P腔中的第 i 个F-P腔,第一面镜和第二面镜分别称为第 i 面镜和第 $i+1$ 面

镜, 可得到以下数学关系

$$E_{i+1}^+ = E_i^+ t_i e^{-i\theta_i} + E_{i+1}^- r_i \quad (2)$$

$$E_i^- = -r_i E_i^+ + t_i E_{i+1}^- e^{i\theta_i} \quad (3)$$

式中: E_i^+ 和 E_i^- 分别为第 i 面镜的入射和反射电场振幅; E_{i+1}^+ 和 E_{i+1}^- 分别为第 $i+1$ 面镜的入射和反射电场振幅; r_i 和 t_i 分别为第 i 面镜的振幅反射和透射

$$\begin{pmatrix} E_1^+ \\ E_1^- \end{pmatrix} = \frac{1}{t_1 t_2 \cdots t_{N-1}} \begin{bmatrix} e^{-i\theta_1} & -r_1 e^{i\theta_1} \\ -r_1 e^{-i\theta_1} & e^{i\theta_1} \end{bmatrix} \times \begin{bmatrix} e^{-i\theta_2} & -r_2 e^{i\theta_2} \\ -r_2 e^{-i\theta_2} & e^{i\theta_2} \end{bmatrix} \times \cdots \times \begin{bmatrix} e^{-i\theta_{N-1}} & -r_{N-1} e^{i\theta_{N-1}} \\ -r_{N-1} e^{-i\theta_{N-1}} & e^{i\theta_{N-1}} \end{bmatrix} \begin{pmatrix} E_N^+ \\ E_N^- \end{pmatrix} \quad (5)$$

式(5)可化简为

$$\begin{pmatrix} E_1^+ \\ E_1^- \end{pmatrix} = \frac{1}{t_1 t_2 \cdots t_{N-1}} \begin{bmatrix} A & B \\ C & D \end{bmatrix} \begin{pmatrix} E_{N+1}^+ \\ E_{N+1}^- \end{pmatrix} \quad (6)$$

式中: A 、 B 、 C 、 D 均为系数。

F-P游标传感器结构如图1所示。只考虑2个F-P腔级联时, 归一化后的反射谱 $R(\lambda)$ 为^[20]

$$R(\lambda) = R_1 + A^2 + B^2 + 2\sqrt{R_1} B \cos[2(\phi_1 + \phi_2)] + 2\sqrt{R_1} A \cos(2\phi_1) + 2AB \cos(2\phi_2) \quad (7)$$

式中: R_1 为光纤端面的反射率; ϕ_1 为光在硅腔内传输导致的相移, $\phi_1 = 2\pi L_1 / \lambda$; ϕ_2 为光在空气腔内传输导致的相移, $\phi_2 = 2\pi n L_2 / \lambda$ 。 A 和 B 的计算公式为

$$A = (1 - \alpha_1)(1 - R_1)(1 - \gamma_1) \sqrt{R_2} \quad (8)$$

$$B = (1 - \alpha_1)(1 - \alpha_2)(1 - \gamma_1)(1 - R_1)(1 - R_2) \sqrt{R_3} \quad (9)$$

式中: α_1 为光纤端面传输损耗, α_2 为膜片表面传输损耗, γ_1 为光纤端面损耗因子, R_2 为膜片表面的反射率, R_3 为右侧端面的反射率。




图1 F-P游标传感器结构

Fig.1 The structure of Fabry-Pérot vernier sensor

系数; θ_i 为相位长度, $\theta_i = 2\pi L_i / \lambda$; L_i 为第 i 面镜和第 $i+1$ 面镜的距离。

计算得到

$$\begin{pmatrix} E_i^+ \\ E_i^- \end{pmatrix} = \frac{1}{t_i} \begin{bmatrix} e^{-i\theta_i} & -r_i e^{i\theta_i} \\ -r_i e^{-i\theta_i} & e^{i\theta_i} \end{bmatrix} \begin{pmatrix} E_{i+1}^+ \\ E_{i+1}^- \end{pmatrix} \quad (4)$$

对于 N 个级联 F-P 腔, 可以推导得到

1.2 实验设置

实验设备连接如图2所示。实验系统包括光源、光谱仪、环形器、F-P传感器、高精度压力计等部分。宽带光源提供光信号; 光谱仪的波长范围为 1 525 ~ 1 565 nm, 采样点为 256 个, 最高采样速率为 32 kHz; 环形器引导光至传感器, 并将传感器反射光传导至光谱仪; 压力传感器安装于高精度压力计的压力腔内。




图2 实验设备连接示意图

Fig.2 Schematic diagram of experimental equipment connection

2 实验可行性分析

2.1 数据集与光谱关系

为获取训练所需的光谱-压力数据集, 搭建了光纤压力传感实验平台, 并在 $(25 \pm 1)^\circ\text{C}$ 环境下开展循环加载实验。实验压力范围设定为 0 ~ 1 MPa, 以 0.1 MPa 为步长, 依次执行升压与降压过程, 确保涵盖整个工作区间内的压力响应。在每个压力节点达到稳态后, 采集 1 525 ~ 1 565 nm 波段内的高分辨力反射光谱, 采集持续时间为 60 s。所获取的光谱数据经均匀采样与预处理, 统一转换为长度为 256 的归一化光谱向量。每一条光谱曲线均标注其对应的真实压力值, 构成监督学习所需的输入-输出对。在多个完整的加载、卸载循环中重复执行数据采集过程, 最终形成包含数千组光谱-压力样本的数据集。

2.2 数据集可用性验证

随着压力增大, 光谱包络波谷向长波长方向线性漂移, 如图3所示。通过对原始光谱进行波长排序、平滑处理及基于波峰检测与插值的包络提取, 可精准定位波谷位置。进一步分析谐振波谷中心波

长发现, 压力在0~1 MPa内变化时, 总波长漂移量达112.5 nm。采用最小二乘法对波谷与压力关系进行线性拟合, 得到相关系数 $R^2 = 0.994$ 。谐振波谷波长随压力的变化关系如图4所示, 二者具有良好的线性关系, 实验结果与理论预期具有一致性。




图3 光谱漂移
Fig.3 Spectral drift

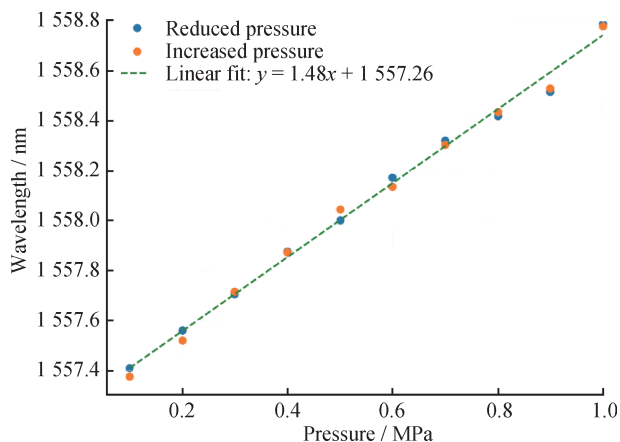


图4 谐振波谷波长随压力的变化关系
Fig.4 The relationship between the wavelength of the resonant wave trough and pressure changes

2.3 模型构建必要性分析

F-P传感器反射光谱网格表面如图5所示。静态压力下的光谱数据本质上是一维连续信号, 具有波长相邻点强相关性。压力变化会导致吸收峰、

基线漂移等光谱微小变化, 导致光谱在特定波长区间发生微小形变。由于压力变化微小, 难以直接通过光谱区分差异, 故利用卷积神经网络对光谱数据进行直接解调。1×8卷积核通过滑动窗口,




图5 F-P传感器反射光谱网格表面图
Fig.5 Reflectance spectra mesh surface plot of F-P sensor

覆盖约3%波长范围，可敏感提取局部梯度、峰值等关键特征。卷积核权重可映射为对特定波长区间的“虚拟传感器”，与光电探测器的物理响应特性具有拓扑一致性。通过步长为1的卷积操作，确保每个数据点均作为卷积核中心被处理，避免了传统大步长卷积导致的信息截断问题。

3 解调模型构建与训练分析

3.1 解调模型构建

选取CNN、LSTM构建解调模型。CNN具有局部特征提取能力，能够通过一维卷积核捕捉光谱

中谐振波谷的形态特征，避免了传统包络提取法对全局平滑度的依赖问题。LSTM具有时序建模优势，针对压力循环加载过程中光谱的动态演化特性，LSTM层可构建光谱序列的长期依赖关系，增强模型对连续压力变化的适应能力。

3.2 实验环境及评价指标

实验配置如表1所示。选择 R_{RMSE} 作为模型检测的评价指标，计算公式为

$$R_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (p_i - \hat{p}_i)^2} \quad (10)$$

式中： p_i 为设定压力， \hat{p}_i 为预测压力。

表1 实验配置
Tab.1 Experimental configuration

CPU	显卡	操作系统	开发平台	开发框架	可视化平台
Intel® Xeon® w9-3495X 1.90 GHz	NVIDIA GeForce RTX 4090	Win10	Pycharm	Pytorch	Tensorboard

3.3 解调模型流程

搭建的压力解调模型如图6所示，其中，蓝色为输入光谱点，黄色与绿色为不同卷积核提取的通道特征，浅蓝色为展平后的向量节点，灰色为预测结果节点。输入为长度为256的一维归一化光谱数据，首先由4个卷积模块提取局部与全局特征，每个模块包括卷积层、批量归一化、ReLU激活与最大池化操作，卷积核大小为 1×8 ，

步长为1，确保保留完整光谱信息。卷积输出通道数逐层增加，尺寸分别为 16×124 、 64×60 、 256×28 和 512×13 。然后，通过Adaptive Avgpool层将特征压缩为一维向量，结合全连接层进行回归预测。

为进一步提取谱间的潜在依赖关系，引入LSTM结构对卷积特征进行序列建模，其输出经展平后与全连接层连接，最终输出单一压力值。

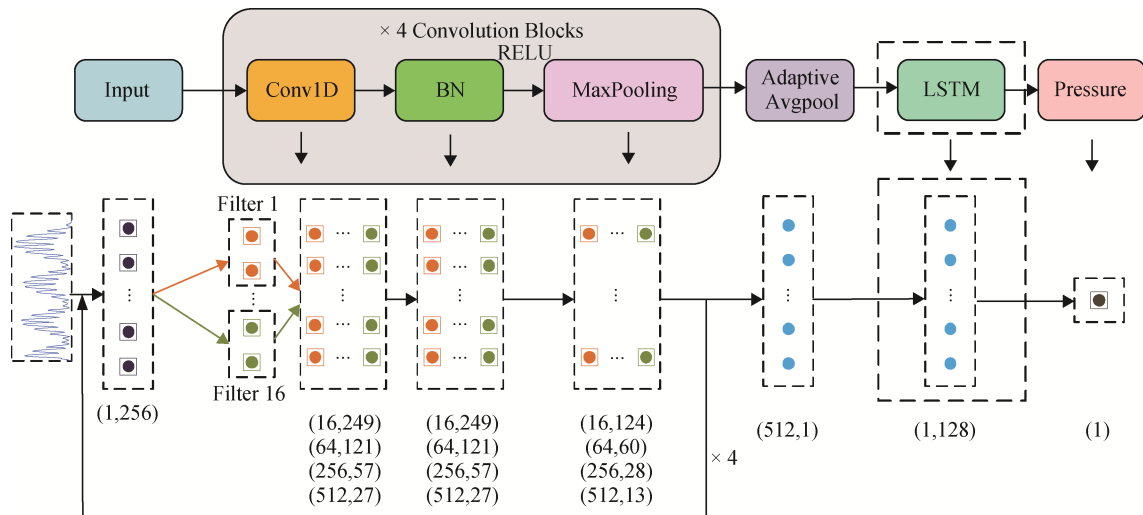


图6 压力解调模型搭建

Fig.6 Construction of the pressure demodulation model


3.4 CNN训练结果分析

取10 000组数据作为训练集,进行10折交叉验证。随机选取未经训练的4 000个样本作为测试集。添加早停机制,当连续15个训练轮数(epoch)验证 R_{RMSE} 没有提升时,自动停止训练。10折交叉验证结果如表2所示,损失可视化如图7所示。分析表2和图7可知:每折模型总系训练 R_{RMSE} 趋势相同,初始的损失均在1.45附近,然后训练损失逐渐下降直至早停。将升压过程即未经训练过的测试集数据4 000条样本输入训练好的模型中,测试得到平均准确率92.53%。改变最终输出函数,直接得到解调压力值,选取全局最优训练模型进行测试,得到 R_{RMSE} 为0.039 2 MPa;相对误差的平均值为3.31%,CNN应用于测试集时的解调性能如图8所示。


表2 压力解调模型10折交叉验证结果

Tab.2 The results of 10-fold cross-validation for the pressure demodulation model

折数	训练损失	训练准确率/%	验证损失	验证准确率/%
1	1.558 1	99.68	1.554 3	99.90
2	1.547 4	99.98	1.546 8	100.00
3	1.562 1	99.24	1.563 9	98.80
4	1.640 2	90.69	1.640 0	90.80
5	1.694 2	89.90	1.689 1	90.30
6	1.636 2	90.86	1.636 5	90.90
7	1.549 2	99.99	1.548 2	100.00
8	1.632 7	90.91	1.632 7	90.90
9	1.813 2	72.71	1.812 2	72.70
10	1.634 4	90.89	1.633 6	91.00
平均	1.626 8	92.49	1.625 7	92.53




(a) 训练损失可视化
(a) Visualization of training results




(b) 分析早停训练轮数
(b) Early-stopping epochs per fold

图7 损失可视化

Fig.7 Loss visualization



(a) 测试结果
(a) Test result



(b) 局部放大结果
(b) Results of local amplification

图8 CNN应用于测试集时的解调性能

Fig.8 Demodulation performance of CNN algorithm in test set

3.5 CNN-LSTM训练结果分析

压力解调模型实验结果对比如表3所示。

表3 压力解调模型实验结果对比

Tab.3 Comparison of experimental results of pressure demodulation models

模型	训练损失	训练准确率/%	验证损失	验证准确率/%
CNN	1.626 8	92.49	1.625 7	92.53
CNN-LSTM	1.682 8	96.98	1.679 7	96.97

由表3中可知，CNN-LSTM模型在分类任务中表现出色，其准确率和泛化能力均优于CNN模型，平均准确率达到96.98%。改变最终输出函数，直接得到解调压力值，结果表明：CNN-LSTM模型的 R_{RMSE} 为0.039 0 MPa；相对误差的平均值为3.28%。尽管CNN-LSTM模型的损失值略高于CNN模型，但在追求高准确率的应用场景中，损失值的略微增加是可以接受的。

利用验证数据集对2个模型进行训练后，得到的测试数据集结果如图9所示。

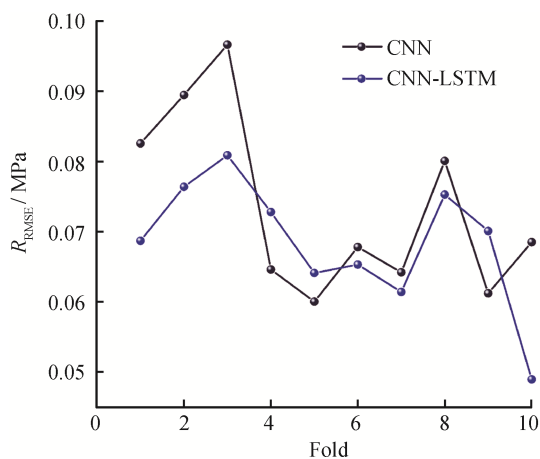


图9 CNN与CNN-LSTM测试结果对比

Fig.9 Comparison of CNN and CNN-LSTM test results

CNN模型的 R_{RMSE} 波动较大，在Fold为0~2时出现显著峰值。CNN模型的整体测试表现不够稳定，不同轮次间误差变化范围较宽。CNN-LSTM模型的 R_{RMSE} 整体波动较小，表现更为稳定。在多数轮次中，CNN-LSTM模型的 R_{RMSE} 低于CNN模型，这表明CNN-LSTM模型的预测精度更高。

4 结论

提出了基于深度学习的光谱数据直接解调方法，该方法不需要进行传统的腔长计算步骤，实现了静态压力值的端到端预测。采用10折交叉验证策略对未知光谱数据进行模型评估，结果表明：基础CNN模型的平均准确率为92.49%，其 R_{RMSE} 为0.039 2 MPa，相对误差均值为3.31%；CNN-LSTM模型的平均准确率为96.98%， R_{RMSE} 为0.039 0 MPa，相对误差均值为3.28%，满足工业级压力传感器的精度要求，可应用于油气管道监测、航空液压系统监控等工业场景中。基于CNN-LSTM模型的方法仅通过分析256个采样点的数据就实现了较高精度的光谱信号解调，显著降低了光谱分析仪的硬件配置门槛，为开发微型化、低功耗、小成本光纤传感系统提供了新思路。

参考文献

- [1] 李文豪, 贾平岗, 王军, 等. 基于硅MEMS技术的高灵敏度微型光纤法布里-珀罗压力传感器[J]. 光子学报, 2024, 53(5): 149-157.
LI W H, JIA P G, WANG J, et al. High sensitivity micro fiber Fabry-Perot pressure sensor based on silicon MEMS technology [J]. Acta Photonica Sinica, 2024, 53 (5) : 149-157. (in Chinese)
- [2] 孙萌萌, 葛益娴, 沈令闻, 等. 基于电弧放电优化的光纤法珀湿度传感器[J]. 光子学报, 2022, 42(10): 28-35.
SUN M M, GE Y X, SHEN L W, et al. Optical fiber Fabry-Perot humidity sensor based on arc discharge optimization [J]. Acta Optica Sinica, 2022, 42(10): 28-35. (in Chinese)
- [3] 盛天宇, 李健, 李鸿昌, 等. 光纤法珀式SiC耐高温压力传感器的制造与测试[J]. 中国机械工程, 2022, 33(15): 1803-1809.
SHENG T Y, LI J, LI H C, et al. Fabrication and measurement of SiC fiber-optic Fabry-Perot pressure sensors for high-temperature applications [J]. China Mechanical Engineering, 2022, 33(15): 1803-1809. (in Chinese)
- [4] CHEN L, TIAN J, WU Q, et al. Hybrid Fabry-Perot interferometer: polymer-induced microcavity for temperature and gas pressure measurement[J]. Optics Communications, 2024, 563. DOI: 10.1016/j.optcom.2024.130578.
- [5] PEREZ-HERRERA R A, BRAVO M, LEANDRO D, et al. Multiparameter sensor based on a multi-interferometric

- serial configuration for temperature and strain measurements [J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2021, 27(6): 1-4.
- [6] LIU H J, PENG N, MENG W, et al. Optical fiber temperature sensing probe based on F-P cavity for human body temperature monitoring [J]. *IEEE Sensors Journal*, 2024, 24(10): 16188-16195.
- [7] HOU L T, LI Y, LIU Y, et al. High-integration optical fiber sensor with Vernier effect based on spatial beam splitting [J]. *Optics & Laser Technology*, 2024, 171. DOI: 10.1016/j.optlastec.2023.110415.
- [8] ZHAO X, REN X, BAI J, et al. Enhanced high-temperature gas pressure sensor based on a fiber optic Fabry-Pérot interferometer probe [J]. *Journal of Lightwave Technology*, 2025, 43(2): 977-982.
- [9] ZHU C, ZHENG H, MA L, et al. Advances in fiber-optic extrinsic Fabry - Perot interferometric physical and mechanical sensors: a review [J]. *IEEE Sensors Journal*, 2023, 23(7): 6406-6426.
- [10] ZUO G, HU H, LI S, et al. Iterative normalized cross-correlation method for absolute optical path difference demodulation of dual interferometers [J]. *Optics Express*, 2021, 29(11): 16595-16610.
- [11] 刘嘉静, 涂子维, 周次明, 等. 基于最小二乘法的光纤法布里-珀罗传感器相位校正解调算法 [J]. *光子学报*, 2019, 48(9): 81-86.
LIU J J, TU Z W, ZHOU C M, et al. Algorithm of phase correction based on least square estimation for optical fiber Fabry-Perot sensor [J]. *Acta Photonica Sinica*, 2019, 48(9): 81-86. (in Chinese)
- [12] 王婷婷, 柯炜, 王秀婷. 基于并联游标效应的MZ光纤应变传感器增敏解调系统 [J]. *光通信技术*, 2024, 48(1): 13-17.
WANG T T, KE W, WANG X T, et al. Sensitization and demodulation system of MZ optical fiber strain sensor based on parallel vernier effect [J]. *Optical Communication Technology*, 2024, 48(1): 13-17. (in Chinese)
- [13] ZHU C, ALSALMAN O, NAKU W. Machine learning for a vernier-effect-based optical fiber sensor [J]. *Optics Letters*, 2023, 48(9): 2488-2491.
- [14] MEI Y, XIA T, CAI H, et al. Deep learning improved spectral demodulation of interferometry vernier effect for pressure sensing [J]. *Journal of Lightwave Technology*, 2024, 42(1): 430-440.
- [15] YANG Y, GENG D, CHEN H, et al. Low SNR multimirror Fabry - Perot pressure sensor optic spectrum signal analysis and demodulation via SVM-KNN regressors [J]. *Applied Optics*, 2024, 63(6): 16-23.
- [16] 王东平, 王伟, 张军英, 等. 光纤法布里-珀罗传感器双峰-干涉级次定位联合解调算法 [J]. *光子学报*, 2022, 42(16): 213-219.
WANG D P, WANG W, ZHANG J Y, et al. Peak-to-peak and interference-order positioning joint demodulation algorithm for fiber-optic Fabry-Perot sensors [J]. *Acta Optica Sinica*, 2022, 42(16): 213-219. (in Chinese)
- [17] GOMES A D, BARTELT H, FRAZÃO O. Optical vernier effect: recent advances and developments [J]. *Laser & Photonics Reviews*, 2021, 15(7). DOI: 10.1002/lpor.202000588.
- [18] HU C, LIU C, JIANG C, et al. Highly sensitive gas pressure sensor utilizing the harmonic vernier effect in parallel FPIs with femtosecond laser processing [J]. *Optical Fiber Technology*, 2024, 82. DOI: 10.1016/j.yofte.2023.103592.
- [19] ZHANG T, HAN Q, MA Q, et al. Intensity demodulation of optical vernier-effect: an intelligent algorithm approach [J]. *IEEE Sensors Journal*, 2024, 24(7): 10084-10090.
- [20] NAKU W, HUANG J, ZHU C. Optical fiber sensors based on advanced vernier effect: a review [J]. *IEEE Sensors Journal*, 2024, 24(9): 13758-13772.
- [21] YANG Y, XU B, LIU Y M, et al. Sensitivity-enhanced temperature sensor with fiber optic Fabry-Perot interferometer based on vernier effect [J]. *Acta Physica Sinica*, 2017, 66(9). DOI: 10.7498/aps.66.094205.

(本文编辑: 刘圣晨)



第一作者: 王桢(2002—), 女, 硕士研究生, 主要研究方向为深度学习及光谱信号解调分析。



通信作者: 刘彬(1987—), 男, 副教授, 主要研究方向为MEMS光纤传感技术。