

DOI: 10.19650/j.cnki.cjsi.J2514588

# 基于 CABiL 融合模型的光纤光栅疲劳 状态智能诊断与早期预警

何健欣<sup>1</sup>, 张钰民<sup>1,2</sup>, 任家庆<sup>1</sup>, 黄齐胜<sup>2</sup>, 祝连庆<sup>1,2</sup>

(1. 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 100016;

2. 北京信息科技大学光纤传感与系统北京实验室 北京 100016)

**摘要:** 光纤布拉格光栅 (FBG) 传感器因其高灵敏度、抗电磁干扰能力和复用特性, 在结构健康监测中得到广泛应用。然而, 在循环载荷作用下, FBG 传感器易发生疲劳退化, 传统诊断方法往往依赖人工特征提取或物理建模, 难以有效捕捉早期微弱的损伤信号。为此, 提出了一种端到端的光谱智能监测模型 CABiL, 旨在解决 FBG 传感器在疲劳退化过程中的早期诊断问题。其核心贡献在于深度融合了卷积神经网络 (CNN)、多头注意力机制 (MHA) 与双向长短期记忆网络 (BiLSTM), 构建了一个自动特征提取与时序建模框架。该模型利用一维 CNN 自动提取光谱数据的局部形态特征, 避免了人工特征选择的依赖; MHA 则增强了模型对微弱损伤早期光谱变化的敏感性, 能够自适应聚焦于光谱中因疲劳引发的细微畸变关键区域; BiLSTM 有效捕捉了光谱数据随加载过程的时序演化规律, 整合了全局依赖与动态信息, 从而提升了对复杂损伤过程的建模能力。此端到端学习框架无需复杂物理建模, 具有较高的推理效率。实验结果表明, CABiL 在 FBG 状态分类中的准确率超过 95%, 各类别的  $F1$  分数均高于 0.93。所提出的光谱智能监测方法为 FBG 传感器的健康管理提供了高可靠、实时的智能诊断方案, 有助于推动结构健康监测向智能化、轻量化方向发展, 具有广阔的工业应用潜力。

**关键词:** 光纤布拉格光栅; 疲劳; 卷积神经网络; 双向长短期记忆网络; 多头注意力机制; 健康监测

**中图分类号:** TH741 TN249 **文献标识码:** A **国家标准学科分类代码:** 460.40

## Intelligent diagnosis and early warning of fiber Bragg grating fatigue status based on the CABiL fusion model

He Jianxin<sup>1</sup>, Zhang Yumin<sup>1,2</sup>, Ren Jiaqing<sup>1</sup>, Huang Qisheng<sup>2</sup>, Zhu Lianqing<sup>1,2</sup>

(1. Key Laboratory of Optoelectronic Measurement Technology and Instrument, Ministry of Education, Beijing University of Information Science and Technology, Beijing 100016, China; 2. Beijing Laboratory of Optical Fiber Sensing and System, Beijing Information Science & Technology University, Beijing 100016, China)

**Abstract:** Fiber Bragg grating (FBG) sensors are widely used in the structural health monitoring due to the high sensitivity, electromagnetic interference resistance, and multiplexing capabilities. However, the FBG sensors are prone to fatigue degradation under the cyclic loading. Traditional diagnostic methods often rely on manual feature extraction or physical modeling, making it difficult to effectively capture the subtle damage signals at the early-stage. Thus this paper proposes an end-to-end spectral intelligence monitoring model named CABiL in order to solve the early diagnosis problem of FBG sensors during the fatigue degradation. The key contribution of CABiL lies in its deep integration of convolutional neural networks (CNN), multi-head attention (MHA) mechanism, and bidirectional long short-term memory networks (BiLSTM), which forms an automatic feature extraction and time-series modeling framework. The model employs a 1D-CNN to automatically extract local morphological features from spectral data by eliminating the need for manual feature selection. MHA enhances the model's sensitivity to early spectral changes caused by subtle damage, allowing it to focus on key regions of spectrum where fatigue-induced distortions occur. BiLSTM effectively captures the temporal evolution patterns of spectral data during the loading process, integrates global dependencies and dynamic information, thus improving the modelling ability of complex damage processes. This end-to-end learning framework does not require complex physical modeling, offering the high inference efficiency. Experimental results show that CABiL achieves the state classification accuracy of over 95% for FBG, which provides the  $F1$

scores above 0.93 for all categories. The proposed spectral intelligence monitoring method provides a highly reliable and real-time intelligent diagnostic solution for the health management of FBG sensors, which also advances the structural health monitoring towards smarter, lightweight systems.

**Keywords:** fiber Bragg grating; fatigue; convolutional neural network; bidirectional long short-term memory; multi-head attention; health monitoring

## 0 引言

光纤布拉格光栅(fiber Bragg grating, FBG)传感器作为新一代智能感知技术的核心器件,因其高灵敏度、有效抗电磁干扰、轻量化设计等优点而被广泛应用,在航空航天工程<sup>[1]</sup>、结构健康监测<sup>[2]</sup>、生物医学工程<sup>[3]</sup>、机械工程<sup>[4]</sup>等领域发挥着重要作用。尽管 FBG 在多领域应用广泛,但在复杂服役环境下,其可靠性问题逐渐显现。特别是表贴封装中使用的高分子聚合物粘接剂在长期受载下容易发生蠕变、老化与脱粘,导致 FBG 与基体间形变传递效率显著下降,引发传感器标定漂移、测量失真<sup>[5]</sup>。因此,开发针对 FBG 自身疲劳状态的有效诊断方法,对保障重大装备的全寿命周期安全运行具有迫切意义。

目前,专门针对 FBG 传感器自身在疲劳载荷下状态的诊断研究相对较少。Ang 等<sup>[6]</sup>基于传统 S-N 法建立应变-寿命曲线,依赖于分级加载-离线断纤,存在样本稀少、工况单一的问题,难以满足 FBG 疲劳状态的实时智能诊断与早期预警需求。Zhou 等<sup>[7-8]</sup>的研究阐明了胶层参数对 FBG 应变传递和光谱失真的影响规律,为理解界面力学-光学耦合行为提供了理论基础。然而,这些研究大多集中于静态载荷条件,缺乏循环载荷下胶层疲劳退化与反射谱动态演化的系统数据,限制了 FBG 疲劳状态的闭环感知能力。虽然已有研究尝试通过光纤网络组监测 FBG 状态<sup>[9]</sup>,但其对单一传感器内部界面劣化的识别敏感度与特异性不足。相比之下,光谱分析方法凭借其实时性强、对微小畸变敏感的优势,能够直接依据反射谱的形态特征如峰值位置、带宽、边模抑制比<sup>[10]</sup>与对称性等实现损伤识别,为 FBG 疲劳状态监测提供了新的技术路径。针对光谱数据,研究者们提出了多种预处理与特征提取方法,例如基于改进经验模态分解(empirical mode decomposition, EMD)的光谱基线校正<sup>[11]</sup>、基于变分模态分解(variational mode decomposition, VMD)融合降噪的光谱寻峰算法<sup>[12]</sup>,这些工作为从原始光谱中提取稳定、有效的特征奠定了基础。舒岳阶等<sup>[13]</sup>从理论上建立了应力疲劳导致的满度误差模型,并以工业仪表精度等级作为传感器极限状态的判据,为本研究确立疲劳状态分级标准提供了重要支撑。Chen 等<sup>[14]</sup>进一步在高温环境中系统探索了 FBG 谱形畸变与疲劳状态的关联规律,为深度学习建模奠定了实验基础。

深度学习技术已在故障诊断领域得到广泛应用,并在传统机械系统中展现出卓越的性能<sup>[15]</sup>。但针对具备高分辨率与复杂谱形特征的 FBG 传感器,面向疲劳识别的模型研究仍相对不足。由于 FBG 反射光谱具有强非线性、多峰干扰及复杂退化模式,其特征分布与时序演化远较传统振动或温度信号更为复杂,对模型的空间特征提取与长程时序建模能力提出了更高要求。在通用机械故障诊断领域,卷积神经网络(convolutional neural network, CNN)凭借强大的局部特征提取优势,已被广泛应用于滚动轴承故障识别<sup>[16]</sup>和冷水机组故障诊断<sup>[17]</sup>等任务中取得良好效果;而长短期记忆网络(long short-term memory, LSTM)因其强大的时序建模能力,在液压机械及其部件的故障检测与诊断中同样表现优异<sup>[18]</sup>。Kumar 等<sup>[19]</sup>基于高斯混合模型提出了针对 FBG 传感信号的自适应特征提取与模式识别方法;Hu 等<sup>[20]</sup>构建了基于多类支持向量机(support vector machine, SVM)的自愈型 FBG 传感网络,实现了光纤节点故障的实时检测与重构;Zhang 等<sup>[21]</sup>进一步提出基于时间序列视觉 Transformer 的旋转机械诊断框架。上述研究表明,基于深度学习的智能诊断正逐渐向多模态融合与自适应特征学习方向发展。

为提升模型性能,研究者们不断探索多种深度结构的融合策略,如结合多步预测与 LSTM 自动编码器的方法实现了对传感器故障的高效检测与分类<sup>[22]</sup>,自适应多变量特征分解与多头注意力机制(multi-head attention mechanism, MHA)的残差卷积网络则在多传感器复杂工况下的故障诊断中展现出强大能力<sup>[23]</sup>。近年来,融合 CNN、注意力机制与双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)的混合模型在处理复杂时序数据中展现出强大性能。Li 等<sup>[24]</sup>验证了其在多工况下识别锂电池状态的鲁棒性;高宇等<sup>[25]</sup>针对遥感卫星在轨测量数据的噪声问题,提出了结合 BiLSTM-CNN 的混合算法,为复杂时序信号的去噪与特征提取提供了有效范例;Zhu 等<sup>[26]</sup>应用于航空发动机寿命预测中,有效建模健康趋势并引入不确定性量化;Yang 等<sup>[27]</sup>在转子电机轴承的故障诊断中实现了超过 99% 的准确率,展示了他们在捕捉局部与全局特征方面的强大表达能力。基于 FBG 的机械手远程操控手套<sup>[28]</sup>验证了复杂 FBG 传感信号实时处理与反馈在嵌入式设备上实现的可行性。

然而,FBG 传感器采集的高分辨率一维反射光谱同时包含局部细微畸变、跨谱段全局依赖以及损伤累积的

非线性演化特征,使得现有深度模型面临3方面局限:1)CNN难以捕获长程依赖;2)LSTM易弱化微弱局部突变;3)一般混合模型缺乏对光谱多尺度特征的协同感知能力。为此,本文提出面向FBG疲劳诊断的CABiL协同感知架构。该模型通过一维CNN提取局部畸变特征,利用MHA建立跨谱段全局关联并动态聚焦关键异常区域,借助BiLSTM完整建模损伤累积的时序动态,并结合级联-并行拓扑与跨层次门控融合设计,在端到端光谱学习框架下实现空间细节、全局关联与时间动态的多尺度协同分析。经验证,模型推理延迟仅29ms,资源占用低,可在嵌入式平台稳定运行,满足工业实时监测需求,为高分辨率FBG光谱的智能分析与健康管理提供了高可靠、可工程化的解决方案。

## 1 理论背景和测量原理

### 1.1 FBG传感器应变原理

FBG传感器的核心原理是利用光纤光栅的布拉格波长对应变和温度变化的敏感性。当应变作用于FBG传感器时,光纤光栅的周期 $\Lambda$ 和光纤的有效折射率 $n$ 会发生变化,从而导致布拉格波长的改变。布拉格波长的计算公式如式(1)所示。

$$\lambda_B = 2n\Lambda \quad (1)$$

应变 $\varepsilon$ 与布拉格波长变化 $\Delta\lambda_B$ 的计算公式如式(2)所示。

$$\Delta\lambda_B = \lambda_B(1 - p_e)\varepsilon \quad (2)$$

其中, $p_e$ 是弹光系数。通过测量反射光布拉格波长的变化,可以精确地确定应变的大小。

### 1.2 FBG健康状态诊断标准

根据中国对工业仪器精度的分类标准<sup>[29]</sup>(共分为16个等级),通常将精度等级为1.0和4.0的工业应用作为参考标准,分别记作I级和IV级。它们对应的最大允许误差分别为测量范围的 $\pm 1.0\%$ 和 $\pm 4.0\%$ 。在本研究中,若光谱的强度衰减或谱宽展宽超过I级误差限,则被视为异常;若超过IV级误差限,则被判定为故障。强度范围 $I_R$ 由光谱数据中的最大强度值 $I_{\max}$ 和最小强度值 $I_{\min}$ 的差值确定,如式(3)所示。

$$I_R = I_{\max} - I_{\min} \quad (3)$$

同样,谱宽范围 $W_R$ 定义如式(4)所示。

$$W_R = W_{\max} - W_{\min} \quad (4)$$

其中, $W_{\max}$ 和 $W_{\min}$ 分别是光谱展宽的最大值和最小值。对于IV级精度标准,强度和谱宽的最大允许误差为测量范围的 $\pm 4.0\%$ ;对于I级,则分别为 $\pm 1.0\%$ 。当强度衰减或谱宽展宽的绝对偏差超过I级误差阈值时,认为传感器处于异常状态;若超过IV级误差阈值,则判定为疲劳故障。上述判定标准确保了FBG传感器性能评估符

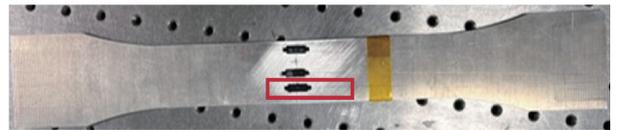
合国家工业精度等级要求,为疲劳状态识别提供了可靠的参考依据。

## 2 实验方案

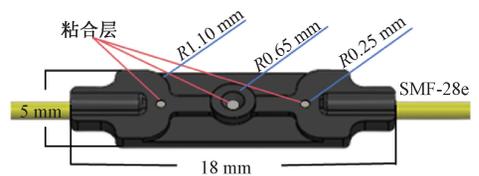
### 2.1 实验设置

本实验旨在加速FBG传感器自身在飞机起落架等关键结构健康监测中所承受的疲劳老化,重点评估其在循环应变反复作用下的响应性能与稳定性。为在实验室内快速诱发传感器本体的疲劳损伤,本文以裸纤FBG为对象,设计高频、高幅值的循环载荷试验,使光栅结构在短时间内经历相当于长期服役的应变循环次数,从而高效揭示其反射谱及机械完整性的退化规律,实现FBG传感器自身疲劳寿命的快速评价。

FBG传感器嵌入于一块7075-T651高强度铝合金样品中,该材料常用于航空航天结构,具备良好的力学性能和抗疲劳特性。为了实现应变从结构体向传感器的有效传递,光纤传感器采用刚性封装方案,以保证应力沿光纤轴线方向充分作用于光栅区域。如图1所示,在封装过程中,选用Corning SMF-28e型裸光纤和尺寸为 $18 \times 5 \times 1$  OSC3200-J热塑性橡胶基片构成传感元件,首先对其进行适度预拉伸处理,以提高应变灵敏性和信噪比。随后,将光纤置于铝合金结构表面,并使用热塑性橡胶材料作为缓冲层,增强光纤与基体之间的顺应性与界面粘接力。同时,采用DG-3S工业级环氧胶粘剂进行封装固定,确保在循环载荷作用下粘结层的长期稳定性与耐疲劳性能。



(a) FBG传感器在金属表面的安装  
(a) Installation of FBG sensors on metal surface



(b) FBG传感器封装结构及尺寸  
(b) Packaging structure and dimensions of FBG sensors

图1 表贴式封装FBG传感器

Fig. 1 Diagram of surface-mount FBG sensor

实验系统如图2(a)所示,实验系统由封装于7075-T651铝合金基体的3个表贴式FBG传感器、多通道光谱解调仪及MTS电液伺服疲劳测试系统组成。铝合金试件横截面尺寸为 $60 \text{ mm} \times 5 \text{ mm}$ ,承受 $0.6 \sim 60 \text{ MPa}$ 的亚疲劳极限应力,该值显著低于材料疲劳阈值 $220 \text{ MPa}$ <sup>[30]</sup>,确

保载荷集中于传感器界面而非基体。如图 2(b) 所示, MTS 系统以 0.3 Hz 正弦波形式施加循环载荷, 模拟机械振动过程。数据采集部分以 1 Hz 的频率实时获取光谱数据, 即每秒记录一条完整的光谱曲线, 用于反映传感器在加载过程中的动态响应。光谱解调分辨率为 20 pm, 主要用于捕捉疲劳载荷作用下的光谱畸变趋势。相比高分辨率解调模式, 该设置可在保证识别精度的同时提升扫描速率与信噪比, 适用于多通道长周期疲劳监测场景。实验维持 25°C 室温环境, 降低热扰动对布拉格波长的影响。此设计精准隔离 FBG 本体疲劳效应, 为捕捉界面劣化引发的光谱畸变提供可控条件。

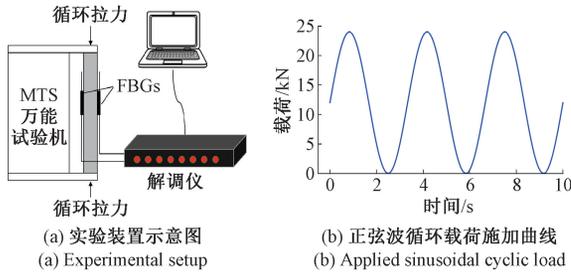


图 2 FBG 传感器疲劳诊断实验

Fig. 2 Fatigue-diagnosis experiment of FBG sensor

实验步骤包括: 首先将封装传感器与铝合金试件在 MTS 系统中轴向对齐安装并连接光谱解调仪; 其次通过预加载消除残余应力并采集光谱; 随后设定正弦载荷参数启动循环测试; 多通道解调仪同步以 1 次/秒频率记录反射光谱; 持续监测直至出现失效特征, 即强度衰减、谱宽展宽或主峰波长异常漂移。

如图 3 所示, 健康状态下, 反射峰较高且谱形对称, 半高宽较窄, 表明栅区结构完整、折射率调制均匀; 疲劳状态下, 主峰高度明显降低、半高宽显著增大, 反映出疲劳累积对光栅结构及光谱特性的影响, 并为智能诊断模型提供了关键输入特征与可靠验证依据。

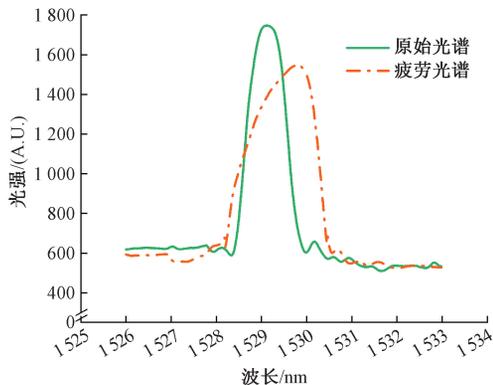


图 3 循环载荷下 FBG 正常光谱与疲劳光谱的对比

Fig. 3 Comparison of normal and fatigue spectra of FBG under cyclic loading

## 2.2 数据处理

本研究通过自编的 LabVIEW 程序自动采集原始光谱数据, 实验过程中, 每个表贴式 FBG 传感器共获取 108 000 条反射光谱曲线。为提升模型训练的稳定性与效率, 首先对原始数据进行了标准化处理, 统一各维度的数值尺度, 并同步进行了光谱基线漂移校正操作。

考虑到测量仪器在长时间解调过程中可能出现的系统性基线漂移现象, 本文在预处理阶段引入了基于无吸光区的基线补偿策略, 选取远离主中心波长、无明显谱峰的平台波段作为参考区域, 对其反射强度波动进行实时监控, 用于补偿主峰强度变化中可能包含的系统干扰成分。该方法确保所提取的谱形变化主要源于 FBG 传感器的疲劳演化过程, 而非环境噪声或仪器误差, 从而显著提升了后续特征提取与模型诊断的准确性与鲁棒性。

在数据增强阶段, 为提升模型的泛化能力并模拟实际应用中可能出现的干扰因素, 采用多种方式对标准化数据进行扰动处理。首先, 对所有样本添加标准差为 0.05 的高斯噪声, 以增强模型对光谱扰动的鲁棒性。其次, 引入时序偏移与振幅缩放操作: 时序偏移通过沿时间轴随机平移数据, 以模拟不同起始采集时刻的观测场景; 振幅缩放通过对光谱幅度施加随机比例变换, 以提升模型对不同信号强度条件下的适应性与鲁棒性。

针对样本类别分布不均的问题, 采用 SMOTE 算法对少数类生成合成样本, 使其在整体样本中的占比从原始的 20% 提升至 40%。为进一步减少数据偏倚, 在训练集与验证集划分过程中采用分层抽样策略, 确保各类别样本分布与原始数据保持一致。同时, 对分布边缘区域的样本实施额外的数据增强, 以提高模型对边界状态的识别能力。

## 3 深度学习模型

模型使用 Keras 和 TensorFlow 2.14.0 框架实现, 运行在一个配备 11 代英特尔酷睿 i7-11700K @ 3.60 GHz 处理器和 NVIDIA GeForce RTX 3060 GPU 的系统上。

### 3.1 CABiL 模型构建

为了更有效地分析 FBG 传感器的光谱时序数据, 本文提出了一种集成一维卷积网络<sup>[31]</sup>、多头注意力机制<sup>[32]</sup>和 BiLSTM<sup>[33]</sup>的融合神经网络架构, 能够同时捕捉局部光谱形态特征、谱间全局依赖关系及其随疲劳加载过程的动态演化特性, 整体结构如图 4 所示, 详细的模型参数配置见表 1。

模型前端采用两级一维卷积模块, 用于提升特征表达能力与非线性建模能力, 并使用相同填充保持时序长度不变。

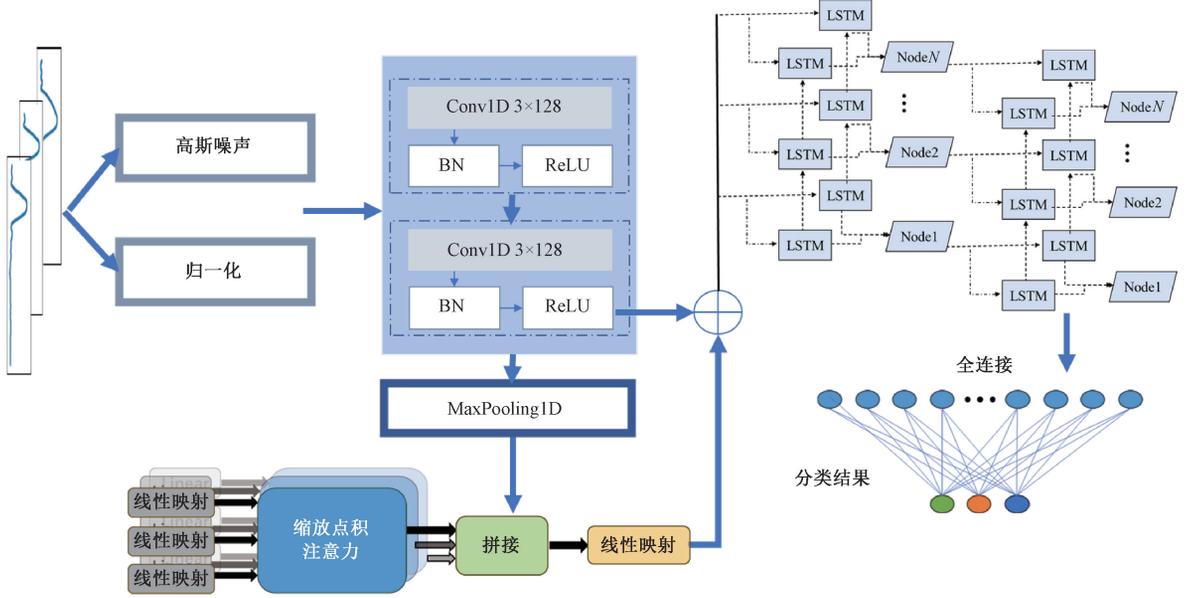


图 4 CABiL 模型的架构  
Fig. 4 Architecture of CABiL model

表 1 CABiL 模型参数配置表

Table 1 Configuration of CABiL model parameters

模块	参数配置
Input Layer	Shape = (10, 65)
Conv Block 1	Filters = 128, Kernel Size = 3
Conv Block 2	Filters = 128, Kernel Size = 3
MHA Module	num_heads = 8, key_dim = 64
Fusion & Norm	Concatenate Conv and MHA
BiLSTM Block	Units = [128, 64]
Dense Layers	Units = [512, 256], Activation = ReLU
Output Layer	Units = 3 (classes), Activation = Softmax

第  $l$  层第  $j$  通道在位置  $i$  的因果卷积输出如式 (5) 所示。

$$y_j^{(l)}[i] = \sum_{k=0}^2 \sum_{c=1}^{128} x_c^{(l-1)}[i+k] \mathbf{w}_{c,j}^{(l)}[k] + \mathbf{b}_j^{(l)} \quad (5)$$

其中,  $\mathbf{w}_{c,j}$  与  $\mathbf{b}_j$  分别为卷积层的权重和偏置。为缓解过拟合风险,引入丢弃率为 15% 的空间随机丢弃机制,在保持结构相关性的同时增强泛化能力。经卷积提取的局部特征随后输入 8 头自注意力模块。该模块通过并行子空间对光谱片段间的长程依赖进行建模,其核心计算如式 (6) 所示。

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right) \mathbf{V} \quad (6)$$

其中,  $\mathbf{Q}, \mathbf{K}, \mathbf{V}$  分别表示查询、键和值矩阵,  $\sqrt{d_k}$  为缩放因子。该机制使模型能自适应关注谱中关键区域,从而增强对微小损伤特征的识别能力。注意力加权输出进

一步传入双向 LSTM 模块,建模光谱随疲劳加载过程的时序演化,其更新机制如式 (7) 所示。

$$\mathbf{h}_t = \overrightarrow{\text{LSTM}}(\mathbf{x}_t, \overrightarrow{\mathbf{h}}_{t-1}) \oplus \overleftarrow{\text{LSTM}}(\mathbf{x}_t, \overleftarrow{\mathbf{h}}_{t+1}) \quad (7)$$

其中,  $\oplus$  表示正反向隐状态的拼接操作,  $\overrightarrow{\text{LSTM}}(\mathbf{x}_t, \overrightarrow{\mathbf{h}}_{t-1})$  与  $\overleftarrow{\text{LSTM}}(\mathbf{x}_t, \overleftarrow{\mathbf{h}}_{t+1})$  分别表示前向与后向 LSTM 的隐藏状态。该结构充分保留了光谱在疲劳加载过程中的时间演化信息。最终,双向时序特征通过全连接层映射至三分类输出空间,并通过 Softmax 函数将每个元素的指数值与所有元素指数值的总和进行比值,确保输出的每个值都在 0 和 1 之间,且所有输出值的总和为 1。计算如式 (8) 所示。

$$\text{Softmax}(\mathbf{z})_i = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (8)$$

其中,  $e^{z_i}$  是输入向量中第  $i$  个元素的指数,它可以任何实数映射到正数,这确保了输出的概率都是正的。

$\sum_{j=1}^n e^{z_j}$  是输入向量中所有元素的指数和。为应对训练数据中类别分布不均的问题,本文在优化过程中引入类别加权的交叉熵损失函数作为主要目标函数,其表达式如式 (9) 所示。

$$\mathcal{L} = - \sum_{c=1}^C \mathbf{w}_c \cdot y_c \log(\hat{y}_c) \quad (9)$$

其中,  $\mathbf{w}_c$  为类别权重因子,  $y_c$  为真实标签,  $\hat{y}_c$  为模型预测的概率分布。针对类别不平衡,模型采取了两方面的优化策略:1) 依据样本数量反比计算每类的权

重,使得在梯度反向传播过程中少数类样本的损失影响更大,从而引导模型更好地学习其特征;2)在损失函数中引入标签平滑机制,设置平滑因子为0.05,有效降低模型对异常或噪声标签的过拟合风险,同时提升对决策边界附近样本的泛化能力。这种双重机制在提升模型鲁棒性的同时,也显著改善了少数类别的识别表现。

### 3.2 训练策略

模型训练采用批量大小为64,以实现计算效率与梯度稳定性的平衡。优化器选用Adam,并引入梯度裁剪机制以防止梯度爆炸。同时,在全网络层中应用 $L_2$ 正则化,正则化系数设置为 $\lambda = 10^{-4}$ ,有效缓解过拟合。空间Dropout也应用于卷积层中,进一步提升对时序噪声的鲁棒性。学习率调度采用动态策略,在训练初期进行线性预热,其变化规律如式(10)所示。

$$\eta_t = \frac{t}{T_{\text{warmup}}} \cdot \eta_{\text{max}} \quad (10)$$

其中, $\eta_t$ 表示在第 $t$ 个训练轮次时使用的实际学习率, $T_{\text{warmup}}$ 为预热阶段的总轮数, $\eta_{\text{max}}$ 为最大学习率。当训练轮次超过预热阶段(即 $t > T_{\text{warmup}}$ )时,学习率进入余弦退火阶段,如式(11)逐步衰减,即:

$$\eta_t = \eta_{\text{min}} + \frac{1}{2}(\eta_{\text{max}} - \eta_{\text{min}}) \left( 1 + \cos\left(\frac{t - T_{\text{warmup}}}{T_{\text{total}} - T_{\text{warmup}}}\pi\right) \right) \quad (11)$$

其中, $\eta_{\text{min}}$ 为最小学习率, $T_{\text{total}}$ 为训练总轮数。该调度策略帮助模型在训练初期快速逃离局部极小点,后期稳态收敛,从而兼顾训练效率与泛化性能。

为防止过拟合并提升泛化能力,训练过程中采用了多项优化策略。每轮训练前对数据进行随机打乱,以降低对训练集顺序的依赖。训练早期采用早停机制:若验证损失连续20个周期内改善不足,则提前终止训练,并自动恢复至验证精度最高的模型权重。此外,当验证性能停滞时,学习率按60%进行阶梯式衰减,确保训练后期仍保持参数微调能力。这些策略共同保障了CABiL模型在FBG状态识别任务中训练过程的稳定性,显著提升了其对故障与异常状态的识别精度与鲁棒性,展现出良好的应用潜力。

## 4 实验结果与分析

本研究在NVIDIA GeForce RTX 3060 GPU上,基于Keras和TensorFlow框架对模型进行了训练。实验数据包含3类样本,在数据预处理中将样本随机打乱后,按6:2:2的比例划分为训练集、验证集和测试集,确保在不同数据子集上的泛化能力得以全面评估。模型训练进行了150个周期,训练结束后,通过计算模型在验证集上的

最终收敛准确率及平均损失,评估模型的性能表现。实验结果为后续模型对比分析提供了重要参考。

### 4.1 预测结果

本文所提出的全光谱FBG训练方法在疲劳状态识别任务中表现出卓越性能。图5混淆矩阵验证了全光谱FBG训练框架的卓越性能。模型在正常、异常与疲劳3类状态下的召回率分别达到96.2%、92.1%和97.7%,对角线元素显著占优,误分类样本稀少且分布集中,表明决策边界清晰、判别能力均衡;与之对应的精确率与 $F1$ 分数亦保持高位,充分体现出CABiL架构在多类别疲劳识别任务中的稳定性与鲁棒性。

真实值	正常	3 422 (96.2%)	128 (3.6%)	6 (0.2%)
	异常	115 (4.1%)	2 616 (92.1%)	108 (3.8%)
	疲劳	4 (0.1%)	58 (2.1%)	2 654 (97.7%)
		正常	异常 预测值	疲劳

图5 FBG传感器疲劳检测混淆矩阵

Fig. 5 Confusion matrix of fatigue detection for FBG sensor

### 4.2 消融实验

图6统评估了CNN(C)、BiLSTM(B)与多头注意力机制(M)在FBG疲劳检测任务中的互补作用。完整CABiL架构在第30轮即收敛,验证精度达到0.956,相比最优子结构双层BiLSTM加注意力的收敛速度提升约25%,并在最终精度上高出4.8%。其中,双层BiLSTM加注意力与双层CNN加双层BiLSTM模型的最高验证精度

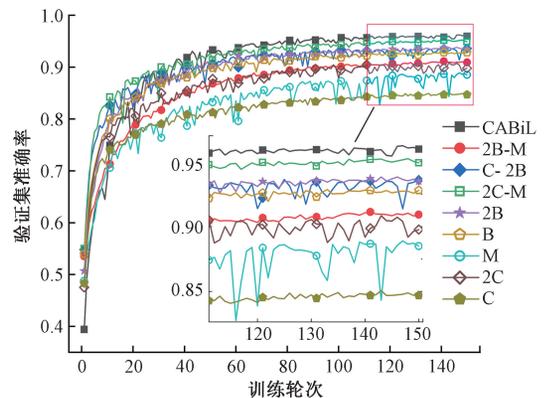


图6 消融实验结果

Fig. 6 Ablation experimental results

分别为 0.91 与 0.90, 较 CABiL 分别下降约 0.046 与 0.056, 验证了卷积层与注意力模块在局部特征提取与全局信息聚焦中的协同增益。进一步剔除 BiLSTM 后, 双层 CNN 加注意力、双层 BiLSTM 与单层 BiLSTM 的精度降至 0.73~0.77, 较 CABiL 平均下降约 22%, 暴露出对时序动态建模能力的严重不足。此外, CABiL 与双层 BiLSTM 加注意力的训练曲线平稳、波动幅度低于 $\pm 0.01$ , 而双层 CNN 加注意力与双层 CNN 模型在训练后期振荡幅度超过 $\pm 0.04$ , 进一步证明了时序建模与注意力机制协同在提升模型泛化稳定性方面的决定性作用。

图 7 定量揭示了 CABiL 各组成模块在 FBG 疲劳状态识别任务中的贡献。完整架构在 3 类状态下的平均精

确率、召回率和  $F1$  分数分别达到 0.962、0.954 和 0.958, 均为唯一在 3 类  $F1$  分数超过 0.95 的方案。相较于 CNN 基线模型平均  $F1$  分数为 0.90, CABiL 整体性能提升 6.4%; 相较 BiLSTM 平均  $F1$  分数为 0.92 和 Multihead 模型平均  $F1$  分数为 0.93, 提升幅度分别为 4.1% 和 2.9%。尤其在识别难度最高的异常类别上, CABiL 的召回率达到 0.93, 较 CNN-BiLSTM 的 0.89 与 CNN-多头注意力的 0.90 分别提升 4.5% 与 3.3%, 显著增强了对早期疲劳光谱微弱漂移的检测灵敏度。此外, CABiL 在 3 类之间的  $F1$  分数极差仅 0.016, 相比 CNN 的 0.036 缩小约 56%, 表明其在复杂状态分布下具备更高的鲁棒性与一致性。

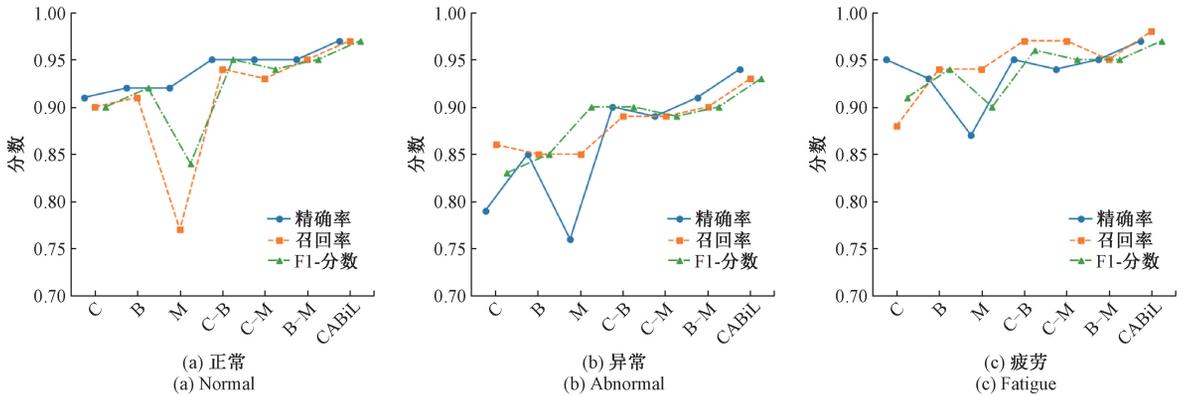


图 7 CABiL 模型在不同类别下的性能评估

Fig. 7 Performance evaluation of the CABiL model under different categories

这一性能优势源于 CABiL 独特的架构设计。模型融合了 CNN 的局部形态特征提取能力、MHA 的全局关键谱段聚焦能力, 以及 BiLSTM 的时序依赖建模能力。该多层次融合机制在保留原始光谱信息完整性的同时, 实现了对疲劳演化过程中微弱但关键特征的捕获, 尤其在早期诊断阶段表现出更高的识别灵敏度与可解释性, 为实际工况下的提前预警与寿命预测提供了可靠支撑。

### 4.3 模型效率评估

如表 2 所示, CABiL 模型在系统资源利用效率与运

行性能方面均表现出显著优势。其单样本平均推理时间为 0.03 s, 与主流轻量化架构相当, 能够满足工业环境对毫秒级响应速度的实时性需求。在资源占用方面, CABiL 通过多模块协同优化与高效计算调度, 实现了性能与开销之间的良好平衡。具体来看, GPU 占用仅增加 2.0%, 远低于 CNN-MHA 架构的 17.5%, 显示出在集成 CNN、MHA 与 BiLSTM 等多种建模单元的情况下仍保持优异的硬件适配性; 内存占用增幅仅 0.9%, 为所有融合模型中最低, 有利于保障长期运行的系统稳定性; CPU 占

表 2 不同模型效率与资源占用对比

Table 2 Efficiency and resource usage comparison of ablated models

模型	训练耗时/min	推理时间/s	CPU 变化率/%	内存变化率/%	GPU 变化率/%	参数量	MFLOPs
CNN	1.29	0.03	-5.2	0.8	0.0	62 339	35.75
BiLSTM	3.71	0.06	1.0	-0.3	0.5	148 739	95.36
MHA	7.20	0.03	-0.3	-1.9	0.0	253 138	23.04
CNN-BiLSTM	3.70	0.04	39.2	7.8	3.0	161 155	25.42
CNN-MHA	2.71	0.03	-44.7	-4.4	17.5	454 403	135.04
BiLSTM-MHA	18.01	0.03	-0.1	-2.3	-1.0	699 846	142.08
CABiL	10.79	0.03	6.4	0.9	2.0	1 174 787	447.99

用增幅控制在 6.4% 以内,显著低于 CNN-BiLSTM 与 CNN-MHA 等对比模型,体现了 CABiL 在资源受限或多任务并发场景下的应用潜力。

为进一步验证 CABiL 在边缘计算环境中的可部署性,本研究还评估了其在典型嵌入式平台上的运行表现。以基于 ARM Cortex-A 系列处理器的光谱解调设备为代表,此类平台通常配置 1~2 GB LPDDR4 内存,采用纯 CPU 架构,整体功耗仅为 3~5 W。实验结果表明,CABiL 的模型参数量约为 1.17 M,推理过程中的内存占用保持在 50 MB 以下,单次推理时间约为 29 ms,各项指标均处于典型嵌入式硬件可承载范围内。这表明 CABiL 能够在低功耗、弱算力的 ARM 嵌入式设备上稳定运行,满足工业现场对实时性与能效比的双重需求。

总体来看,CABiL 在嵌入式系统适配性、模型架构通用性以及工业级实时性能方面均展现出突出的综合优势。其轻量化设计、低内存消耗和高效推理能力,使其特别适用于资源受限的边缘计算设备,如光谱解调仪、嵌入式监测终端等。这些特性使 CABiL 能够满足实时光谱分析、动态信号识别以及设备状态监测等工程场景中的严苛需求,为高分辨率光谱序列的智能解读提供了具有工程可行性的解决方案。

#### 4.4 模型对比

为系统评估 CABiL 模型的综合性能,如表 3 所示,本研究选取支持向量机 SVM、时域卷积网络 (temporal convolutional network, TCN)、门控循环单元 (gated recurrent unit, GRU) 及 Transformer 模型等近年来在时序信号分类领域具有代表性的模型,在相同实验条件下进行了对比分析。

表 3 网络模型的训练和验证结果

Table 3 Training and validation results for network

模型	models (%)			
	准确率	精确率	召回率	F1-分数
SVM <sup>[34]</sup>	72.0	72.0	72.0	72.0
ATCN <sup>[35]</sup>	86.0	86.0	86.0	86.0
GRU <sup>[36]</sup>	92.6	92.0	93.0	93.0
Transformer <sup>[37]</sup>	94.6	94.0	95.0	95.0
<b>CABiL</b>	<b>95.9</b>	<b>96.0</b>	<b>96.0</b>	<b>96.0</b>

如表 3 的实验结果显示,CABiL 模型在准确率、精确率、召回率及 F1 分数这 4 项关键指标上均表现最优,其中准确率达到 0.959,3 项综合评价指标均达到 0.96,较性能次优的 Transformer 模型提升约 1.3%。这一结果验

证了 CABiL 模型通过 CNN 提取局部光谱特征、MHA 建模全局谱段依赖关系,以及 BiLSTM 学习时序演化规律的协同架构优势,表明其能够实现对 FBG 反射光谱退化特征的多尺度精准感知。相较于主流时序分类模型,CABiL 在 FBG 传感器疲劳状态智能诊断任务中展现出更高的识别准确率和更强的模型稳定性。

## 5 结 论

本研究提出基于深度融合架构的 CABiL 模型,以解决 FBG 传感器在循环载荷下易发生疲劳退化、而传统方法难以捕捉早期微弱损伤信号的问题。CABiL 综合 CNN、MHA 与 BiLSTM 的优势,构建了面向原始反射光谱序列的端到端智能分析框架。通过级联—并行拓扑及跨层次门控融合机制,模型能够协同提取光谱的局部形态特征、跨谱段全局依赖关系及损伤时序演化规律,实现对 FBG 疲劳状态的多尺度高精度诊断。

为提升模型稳定性与泛化能力,训练中引入了余弦退火学习率调度、SMOTE 数据平衡、 $L_2$  正则化与标签平滑等策略。实验结果显示,CABiL 在 FBG 传感器正常、异常与故障这 3 类状态识别任务中表现突出,分类准确率超过 95%,各类别平均 F1 分数稳定在 0.93 以上,显著优于 Transformer 等主流模型。尤其在峰值强度衰减、半高宽展宽等疲劳早期微弱畸变的识别上,CABiL 表现出更高的灵敏度与早期预警能力。此外,模型单次推理时间仅 29 ms,资源占用低,可满足工业现场的实时监测与边缘部署需求,为高分辨率光谱序列提供了高效可行的智能诊断方案。

在受控实验条件下,本研究通过单向循环拉伸加载与标准化封装验证了 CABiL 在捕获峰值偏移与半高宽变化等光谱本征特征上的有效性,为复杂工况下的算法迁移奠定了基线。然而实际工程环境更具动态性与多变性,模型的鲁棒性与泛化性仍需提升。未来工作将重点探索:复杂载荷适应性,构建随机载荷谱与多轴应力数据库;多物理场耦合建模,引入温湿度等环境变量或采用域自适应策略;传感器个体差异与小样本场景下的元学习与迁移学习;以及面向边缘设备的模型压缩与协同优化。凭借强大的特征协同感知能力,CABiL 具备扩展潜力,有望发展为适用于复杂工况的高鲁棒性 FBG 智能健康管理,推动结构健康监测向智能化、工程化方向持续演进。

## 参考文献

- [1] 孙广开,李红,吴越,等. 遥感航天器在轨结构微变形光纤监测技术发展综述[J]. 仪器仪表学报,2022,43(12):1-14.

- SUN G K, LI H, WU Y, et al. Review on development of optical fiber monitoring technology for in-orbit micro-deformation of remote sensing spacecraft structures [J]. Chinese Journal of Scientific Instrument, 2022, 43(12): 1-14.
- [ 2 ] YASSIN M H, FARHAT M H, SOLEIMANPOUR R, et al. Fiber Bragg grating (FBG)-based sensors: A review of technology and recent applications in structural health monitoring (SHM) of civil engineering structures [J]. Discover Civil Engineering, 2024, 1(1): 151.
- [ 3 ] ROHAN R, VENKADESHWARAN K, RANJAN P. Recent advancements of fiber Bragg grating sensors in biomedical application: A review [J]. Journal of Optics, 2023, 52(1): 282-293.
- [ 4 ] SATURNO G, CUNHA J, BIAZI-NETO V, et al. FBG-instrumented fdm support structure design guidelines and execution for torque and angular speed measurements in aerospace applications [J]. Measurement, 2025: 118413.
- [ 5 ] 刘明尧, 季冬亮, 肖爽, 等. 胶黏剂黏弹性对粘贴式 FBG 应变传递的影响 [J]. 光学精密工程, 2016, 24(6): 1307-1318.
- LIU M Y, JI D L, XIAO SH, et al. Effect of adhesive viscoelasticity on strain transfer mechanism of bonded FBG [J]. Optics and Precision Engineering, 2016, 24(6): 1307-1318.
- [ 6 ] ANG J, LI H C H, HERSZBERG I. Tensile fatigue properties of fibre Bragg grating optical fibre sensors [J]. International Journal of Fatigue, 2010, 32(4): 762-768.
- [ 7 ] ZHOU J, ZHOU Z, ZHANG D. Study on strain transfer characteristics of fiber Bragg grating sensors [J]. Journal of Intelligent Material Systems and Structures, 2010, 21(11): 1117-1122.
- [ 8 ] WU R J, ZHENG B L, FU K K, et al. Study on strain transfer of embedded fiber Bragg grating sensors [J]. Optical Engineering, 2014, 53(8): 085105.
- [ 9 ] ABDELLI K, GRIESSER H, TROPSCHUG C. A BiLSTM-CNN based multitask learning approach for fiber fault diagnosis [J]. ArXiv preprint arXiv: 2202.08034, 2022.
- [ 10 ] 舒岳阶, 陈伟民, 章鹏, 等. 光纤布拉格光栅器件应力疲劳评价理论研究 [J]. 光子学报, 2013, 42(7): 805-811.
- SHU Y J, CHEN W M, ZHANG P, et al. Investigation on evaluation theory of fiber Bragg grating tensile fatigue property [J]. Acta Photonica Sinica, 2013, 42(7): 805-811.
- [ 11 ] 吕峥, 庄炜, 吴越, 等. 基于改进 EMD 方法的 FBG 传感网络光谱基线校正研究 [J]. 仪器仪表学报, 2022, 43(1): 190-197.
- LYU ZH, ZHUANG W, WU Y, et al. Research on spectral baseline correction of FBG sensing network based on improved EMD method [J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 190-197.
- [ 12 ] 潘红宇, 吕峥, 欧建臻, 等. 基于 VMD 融合降噪的 FBG 光谱寻峰算法 [J]. 仪器仪表学报, 2025, 46(4): 260-269.
- PAN H Y, LYU ZH, OU J ZH, et al. FBG spectrum peak-seeking algorithm based on VMD fusion denoising [J]. Chinese Journal of Scientific Instrument, 2025, 46(4): 260-269.
- [ 13 ] 舒岳阶, 吴俊, 周世良, 等. FBG 应变传感器应力疲劳极限传感寿命评价方法 [J]. 光子学报, 2018, 47(1): 106-111.
- SHU Y J, WU J, ZHOU SH L, et al. Evaluation method of ultimate sensing life for stress fatigued FBG strain sensors [J]. Acta Photonica Sinica, 2018, 47(1): 106-111.
- [ 14 ] CHEN L, LIU P, DING K Q. Research on fatigue failure and life of high-temperature resistant fiber Bragg grating sensors [C]. 4th International Conference on Laser, Optics, and Optoelectronic Technology, 2024: 3040039.
- [ 15 ] LI CH, CHEN J, YANG CH, et al. Convolutional neural network-based transformer fault diagnosis using vibration signals [J]. Sensors, 2023, 23(10): 4781.
- [ 16 ] WANG H W, SUN W L, HE L, et al. Rolling bearing fault diagnosis using multi-sensor data fusion based on 1D-CNN model [J]. Entropy, 2022, 24(4): 573.
- [ 17 ] YAN K, ZHOU X K. Chiller faults detection and diagnosis with sensor network and adaptive 1D CNN [J]. Digital Communications and Networks, 2022, 8(4): 531-539.
- [ 18 ] MALLAK A, FATHI M. Sensor and component fault detection and diagnosis for hydraulic machinery integrating LSTM autoencoder detector and diagnostic

- classifiers[J]. *Sensors*, 2021, 21(2): 433.
- [19] KUMAR S, KM Y, SAGAR D. Developed machine learning algorithm for fiber Bragg grating sensor using Gaussian mixing method[J]. *Discover Sensors*, 2025, 1(1): 1-12.
- [20] HU J H, WANG B Y, DI K J, et al. Self-healing FBG sensor network fault-detection based on a multi-class SVM algorithm[J]. *Optics Express*, 2023, 31(25): 41313-41325.
- [21] ZHANG SH H, ZHOU J H, MA X, et al. TSViT: A time series vision transformer for fault diagnosis of rotating machinery[J]. *Applied Sciences*, 2024, 14(23): 10781.
- [22] HASAN M N, JAN S U, KOO I. Sensor fault detection and classification using multi-step-ahead prediction with a long short-term memory (LSTM) autoencoder[J]. *Applied Sciences*, 2024, 14(3): 7717.
- [23] YAN X AN, YAN W J, XU Y D, et al. Machinery multi-sensor fault diagnosis based on adaptive multivariate feature mode decomposition and multi-attention fusion residual convolutional neural network[J]. *Mechanical Systems and Signal Processing*, 2023, 202: 110664.
- [24] LI Z X, LI L W, CHEN J, et al. A multi-head attention mechanism aided hybrid network for identifying batteries' state of charge[J]. *Energy*, 2024, 286: 129504.
- [25] 高宇, 张旭, 李红, 等. 遥感卫星视轴指向在轨测量数据去噪处理方法与 BiLSTM-CNN 算法实现[J]. *仪器仪表学报*, 2025, 46(6): 330-337.
- GAO Y, ZHANG X, LI H, et al. Denoising processing method for in-orbit line-of-sight pointing measurement data of remote sensing satellite and BiLSTM-CNN algorithm implementation[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(6): 330-337.
- [26] ZHU Y M, LUO Z L, LIU X, et al. Leveraging the hybrid CNN-BiLSTM and multi-head self-attention mechanisms for Aero-engine RUL estimation[C]. 2024 8th International Conference on Electrical, Mechanical and Computer Engineering, 2024: 1014-1019.
- [27] YANG Z ZH, LI W, YUAN F, et al. Hybrid CNN-BiLSTM-MHSA model for accurate fault diagnosis of rotor motor bearings[J]. *Mathematics*, 2025, 13(3): 334.
- [28] 朱云鸿, 张旭, 娄小平, 等. 一种基于光纤光栅传感器的机械手远程操控手套[J]. *仪器仪表学报*, 2024, 45(7): 148-155.
- ZHU Y H, ZHANG X, LOU X P, et al. A remote control glove for manipulator based on fiber Bragg grating sensors[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(7): 148-155.
- [29] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. 工业过程测量和控制用检测仪表和显示仪表精确度等级: GB/T 13283—2008[S]. 北京: 中国标准出版社, 2009.
- General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China, Standardization Administration of the People's Republic of China. Accuracy class of detecting and indicating instruments for industrial-process measurement and control: GB/T 13283—2008 [S]. Beijing: China Standants Press, 2009.
- [30] XIE CH J, SUN T, LI L, et al. Effect of microstructure on fatigue damage accumulation in 7075 aluminum alloy subjected to a single compressive overload[J]. *Metals*, 2024, 14(9): 980.
- [31] KIM Y, KIM Y K. Time-frequency multi-domain 1D convolutional neural network with channel-spatial attention for noise-robust bearing fault diagnosis[J]. *Sensors*, 2023, 23(23): 9311.
- [32] LI ZH R, ZHAO Y M, ZHANG X H, et al. Word embedding factor based multi-head attention[J]. *Artificial Intelligence Review*, 2025, 58(4): 115.
- [33] ZHANG P, HU SH H, XIAO Y, et al. Application of stacked bidirectional LSTM neural networks in reservoir porosity prediction[J]. *Scientific Reports*, 2025, 15(1): 39333.
- [34] KUSTIANA W A A, TRILAKSONO B R, RIYANSAH M, et al. Bridge damage detection with support vector machine in accelerometer-based wireless sensor network[J]. *Journal of Vibration Engineering & Technologies*, 2024, 12: 21-40.
- [35] BAHARANI M, TABKHI H. ATCN: Resource-efficient processing of time series on edge[J]. *ACM Transactions on Embedded Computing Systems*, 2022, 21(5): 3524070.
- [36] LIU SH W, WU M Y, GAO SH H, et al. GRU neural-network-assisted high-refractive-index sensing based on a no-core fiber with a waist-enlarged fusion taper struc-

ture[J]. *Advanced Photonics Nexus*, 2025, 4(4): 046004.

- [37] LI ZH Y, XU P, XING J, et al. SDFormer: A novel transformer neural network for structural damage identification by segmenting the strain field map [J]. *Sensors*, 2022, 22(6): 2358.

### 作者简介



**何健欣**, 2022 年于珠海科技学院获得学士学位, 现为北京信息科技大学硕士研究生, 主要研究方向为光纤传感器和人工智能。

E-mail: hejianxin@bistu.edu.cn

**He Jianxin** received her B. Sc. degree from Zhuhai College of Science and Technology in 2022. She is currently a master's

student at Beijing Information Science and Technology University. Her main research interests include optical fiber sensors and artificial intelligence.



**张钰民** (通信作者), 2011 年于中科院力学研究所获得博士学位, 现为北京信息科技大学教授。主要研究方向为光纤传感、光纤激光器。

E-mail: yinmin.zhang@gmail.com

**Zhang Yumin** (Corresponding author) received his Ph. D. degree from the Institute of Mechanics, Chinese Academy of Sciences in 2011. He is currently a professor at Beijing Information Science and Technology University. His main research interests include fiber-optic sensing and fiber lasers.