

文章编号 1004-924X(2025)23-3702-12

融合BO-CNN-BiLSTM的压电式六维力/力矩 传感器非线性解耦

褚宏博¹, 王桂从^{1,2}, 高嘉龙¹, 李映君^{1,2*}

(1. 济南大学机械工程学院, 山东 济南 250022;

2. 山东省传感器技术与高精度衡器重点实验室, 山东 济南 250004)

摘要:针对压电式六维力/力矩传感器存在由维间耦合导致的传感器测力性能下降的问题,提出一种融合贝叶斯优化(Bayesian Optimization, BO)、卷积神经网络(Convolutional Neural Network, CNN)与双向长短期记忆网络(Bi-directional Long and Short-term Memory Network, BiLSTM)的集成解耦算法(BO-CNN-BiLSTM)。该算法首先通过CNN增强对六维力信号的空间耦合特征提取能力,再利用BiLSTM双向时序的建模能力,动态捕获载荷的跨维度时域依赖关系,并引入BO实现超参数自适应全局寻优,有效克服传统解耦方法在实时性、泛化性及物理一致性方面的缺陷。与此同时,BO-CNN-BiLSTM算法消除了传统解耦方法中的人工调整参数经验依赖,实现了传感器非线性特性的自适应建模。实验结果表明,该架构使六维力/力矩传感器输出结果的最大I类耦合误差、最大II类耦合误差分别为0.87%和0.52%。BO-CNN-BiLSTM解耦算法能有效减少六维力传感器的维间耦合,提高传感器的测量精度,为人形机器人的拟人化运动控制和环境交互提供了高可靠性力感知保障。

关键词:六维力传感器;静态解耦;贝叶斯优化;卷积双向长短期记忆网络

中图分类号:TP183;TP212.9 **文献标识码:**A

doi:10.37188/OPE.20253323.3702

CSTR:32169.14.OPE.20253323.3702

Decoupling of piezoelectric six-dimensional force sensors incorporating BO-CNN-BiLSTM

CHU Hongbo¹, WANG Guicong^{1,2}, GAO Jialong¹, LI Yingjun^{1,2*}

(1. School of Mechanical Engineering, University of Jinan, Jinan 250022, China;

2. Shandong Provincial Key Laboratory of Sensor Technology and High Precision Weighing
Instruments, Jinan 250004, China)

* Corresponding author, E-mail: me_liyj@ujn.edu.cn

Abstract: To address the degradation of force measurement performance caused by interdimensional coupling in piezoelectric six-dimensional force/torque sensors, an integrated decoupling algorithm (BO-CNN-BiLSTM) combining Bayesian optimization (BO), convolutional neural networks (CNN), and bidirectional long short-term memory networks (BiLSTM) is proposed. In this algorithm, CNN is first employed to enhance the extraction of spatial coupling features from six-dimensional force signals. BiLSTM

收稿日期:2025-06-30; **修订日期:**2025-07-18.

基金项目:山东省自然科学基金资助项目(No. ZR2023ME109);山东省科技型中小企业创新能力提升工程资助项目(No. 2024TSGC0912);济南市“新高校20条”科研带头人工作资助项目(No. 202228116)

is then utilized to exploit bidirectional temporal modeling capabilities and dynamically capture cross-dimensional time-domain dependencies of the loads. Subsequently, BO is introduced to achieve adaptive global optimization of hyperparameters. In this way, the limitations of traditional decoupling methods in terms of real-time performance, generalization ability, and physical consistency are effectively overcome. The proposed BO-CNN-BiLSTM algorithm eliminates the empirical dependence on manually tuned parameters in conventional approaches and enables adaptive modeling of the nonlinear characteristics of sensors. Experimental results demonstrate that the maximum nonlinear error and cross-coupling error of the six-dimensional force/torque sensor outputs are 0.87% and 0.52%, respectively. The BO-CNN-BiLSTM decoupling algorithm effectively reduces both intra-dimensional and interdimensional coupling in six-dimensional force sensors, significantly improving measurement accuracy and providing important support for anthropomorphic motion control and environmental interaction in humanoid robots.

Key words: six-dimensional force sensors; static decoupling; Bayesian optimization; CNN-BiLSTM

1 引 言

作为高端装备与智能系统实现高精度力感知的核心器件^[1],压电式六维力/力矩传感器(以下简称六维力传感器)在大型工业机器人^[2]、航空航天装备^[3]等领域已彰显其不可替代性^[4]。人形机器人的双足行走等复杂行为的协同实现对传感器精度提出了更高要求^[5]。

六维力传感器的维间耦合是制约测量精度的核心问题^[6]。20世纪70年代以来,针对该问题及传感器体积、灵敏度等局限,国内外研究人员对六维力传感器的解耦方法进行了深入研究。解耦方法分为硬件与软件两类,硬件解耦因设计复杂、成本高且难以兼顾低耦合与结构简洁性,工业应用受限;软件解耦凭借灵活性与高效性成为主流。软件解耦分为线性解耦和非线性解耦两类,线性解耦因依赖系统线性假设而受限,非线性解耦因适应复杂系统成为主流。

为提高六维力传感器精度,研究人员提出了多种非线性解耦算法。李映君^[7]等提出了一种基于径向基函数(Radial Basis Function, RBF)神经网络的解耦算法,通过优化设计,使得最大I类误差与II类误差分别降低至1.29%和1.56%,有效提升了传感器的测量精度。亓振广^[8]等提出基于长短期记忆神经网络(Long and Short-term Memory Network, LSTM)的解耦算法,显著提高了传感器测量精度,然而,该方法存在结构敏感性,其性能受神经元数量影响显著,需要耗费

较多时间进行参数调优。陈伟^[9]等采用改进的XGBoost机器学习网络对力信号进行解耦,此算法虽能有效降低耦合误差,在测试中获得的决定系数 R^2 达到0.9418,但相比其他方法,精度提升空间仍然存在。王志军^[10]等提出了基于多项式拟合的解耦方法,与传统线性解耦算法相比,其最大耦合误差减少了8.914%,线性度误差降低到最大2.98%,充分体现了多项式拟合在解耦领域的优势,但在高精度解耦方面还有不足。徐家琪^[11]等设计了一种结合天牛须算法的改进型极限学习机,该方法通过优化隐含层节点参数来最小化损失函数,但同样面临需要人工确定最优网络结构的问题。现有算法不但在参数调优过程耗时且依赖人工经验,而且难以兼具解耦精度和调整参数效率^[12]。

本文提出了BO-CNN-BiLSTM解耦算法,通过贝叶斯优化(Bayesian Optimization, BO)自动调参的卷积神经网络(Convolutional Neural Network, CNN)与双向长短期记忆网络协同架构,显著提升了六维力传感器的解耦精度,无需人工逐次调整参数。卷积神经网络通过局部感知与权值共享机制,高效提取六维力传感器晶组间的空间耦合特征,精准解析四点支撑结构下多维力信号的非线性映射关系,克服了传统解耦方法对物理模型先验知识的依赖。双向LSTM利用正向与反向双路时序建模,同步捕捉载荷的历史累积效应与未来演化趋势,显著提升对电荷泄漏、冲击响应等时变耦合效应的

补偿能力,可以获得更高的传感器解耦精度。通过高斯过程代理模型与采集函数协同搜索,实现超参数的全局自适应寻优,将解耦模型的调参周期从人工试错的长周期缩短至几秒,且确保模型在复杂工况下的泛化性和稳定性。

2 测量原理与耦合分析

2.1 标定实验与评价指标

对六维力传感器信号解耦的精确标定是其实现工程应用的基础,核心在于通过系统化的载荷实验建立输入力/力矩与输出信号间的映射模型,并基于评价指标量化解耦性能。

2.1.1 标定实验

本文采用课题组自研的四点支撑式压电式六维力传感器作为待测传感器^[13]。课题组自研的六维力传感器静态标定台作为载荷加载装置,如图 1 所示。




图 1 传感器静态标定实验系统

Fig. 1 Experimental system for static calibration of sensors

标定系统硬件包含:六维力传感器静态标定台、标准传感器(量程为 50 kN,灵敏度为 $(2.0 \pm 0.005) \text{ mV/V}$)、传感器样机、数据采集卡(JY-61902B 型,上海简仪科技有限公司)、电荷放大器(YE5850 型,江苏联能电子技术有限公司)及计算机终端等。

2.1.2 性能评价指标

传感器性能通过两类误差系统评价:I类误差表征目标方向测量精度,定义为单维满量程(F_s)加载时,该方向实测值与真实值的最大相对误差;II类误差量化维间耦合串扰,定义为仅方向 A 施加 F_s 力时,非目标方向 B 的测量值与 B 方向 F_s 的相对百分比误差。二者集成于解耦误差矩

阵 E_{AB} 可以表示为:

$$E_{AB} = \begin{bmatrix} E_{11} & E_{12} & E_{13} & E_{14} & E_{15} & E_{16} \\ E_{21} & E_{22} & E_{23} & E_{24} & E_{25} & E_{26} \\ E_{31} & E_{32} & E_{33} & E_{34} & E_{35} & E_{36} \\ E_{41} & E_{42} & E_{43} & E_{44} & E_{45} & E_{46} \\ E_{51} & E_{52} & E_{53} & E_{54} & E_{55} & E_{56} \\ E_{61} & E_{62} & E_{63} & E_{64} & E_{65} & E_{66} \end{bmatrix}, \quad (1)$$

其中:A,B分别为矩阵的行数和列数, $A=1\sim 6$, $B=1\sim 6$ 。 $A=1\sim 3$ 对应于在 X 轴、Y 轴、Z 轴方向施加力,此时 $B=1\sim 6$ 分别为得到的力和力矩在三个方向的力和力矩误差; $A=4\sim 6$ 对应于 X 轴、Y 轴、Z 轴方向施加力矩,此时 $B=1\sim 6$ 分别为得到的误差。由此可知,当 $A=B$ 时,矩阵的对角线表示传感器的 I 类误差;当 $A \neq B$ 时,表示传感器的 II 类误差,矩阵内元素的值即为耦合误差。该体系从直接测量精度与维间解耦能力双维度构建传感器性能量化基准。

2.2 耦合误差分析

六维力传感器产生耦合误差的因素主要有结构性耦合和误差性耦合两种^[14]。其中,结构性耦合源于传感器机械设计的物理约束,表现为多维载荷在刚性环体上的应力场叠加效应。其核心机制在于四点支撑环的力学特性:当外力作用于某一维度时,环体变形将引发其他维度的寄生输出。典型耦合形式包括力对力耦合影响,横向力(如 F_x)加载时,支撑环非对称变形导致轴向晶组受附加弯矩,产生干扰输出;力对力矩耦合,横向加载时通过支点偏心传递,形成绕 Y 轴的扭矩分力;力矩对力矩耦合,扭转力矩(如 M_x)诱发环体扭变,使剪切晶片承受面内附加力。此类耦合由环体刚度分布、晶组正交角度及支点应力集中效应共同决定,凸显结构设计对解耦精度的根本性约束。

误差性耦合由工艺偏差和信号链非线性导致,表现为时变、非线性的附加串扰,主要包含:石英晶片压电系数 d_{11}/d_{14} 的批次差异导致输出电荷比例失衡所引发的误差波动。螺栓预紧力不均使晶组初始应力分布畸变,造成零位偏移与非正交耦合;电荷放大器积分漂移导致信号零点偏移;传感器负载受力面微变形改变力传递路径。

目前,主要采取的解耦算法是对传感器的输出进行补偿解耦。对传感器进行解耦,就是对传感器的误差性耦合采取补偿计算的方式降低维间耦合。以输入向量 F 代表传感器所受输入力值向量可以表示为:

$$F = [F_x, F_y, F_z, M_x, M_y, M_z]^T. \quad (2)$$

以输出向量 U 代表传感器的输出信号向量

可以表示为:

$$U = [UF_x, UF_y, UF_z, UM_x, UM_y, UM_z]^T. \quad (3)$$

由传感器标定实验得到的施加载荷值 F 与输出力值 U 的部分测试数据得到六维力测力性能关系曲线,如图 2 所示。通过各维的测力性能曲线,能够反映出传感器在解耦前各维施加载荷值与输出力值之间的对应关系。

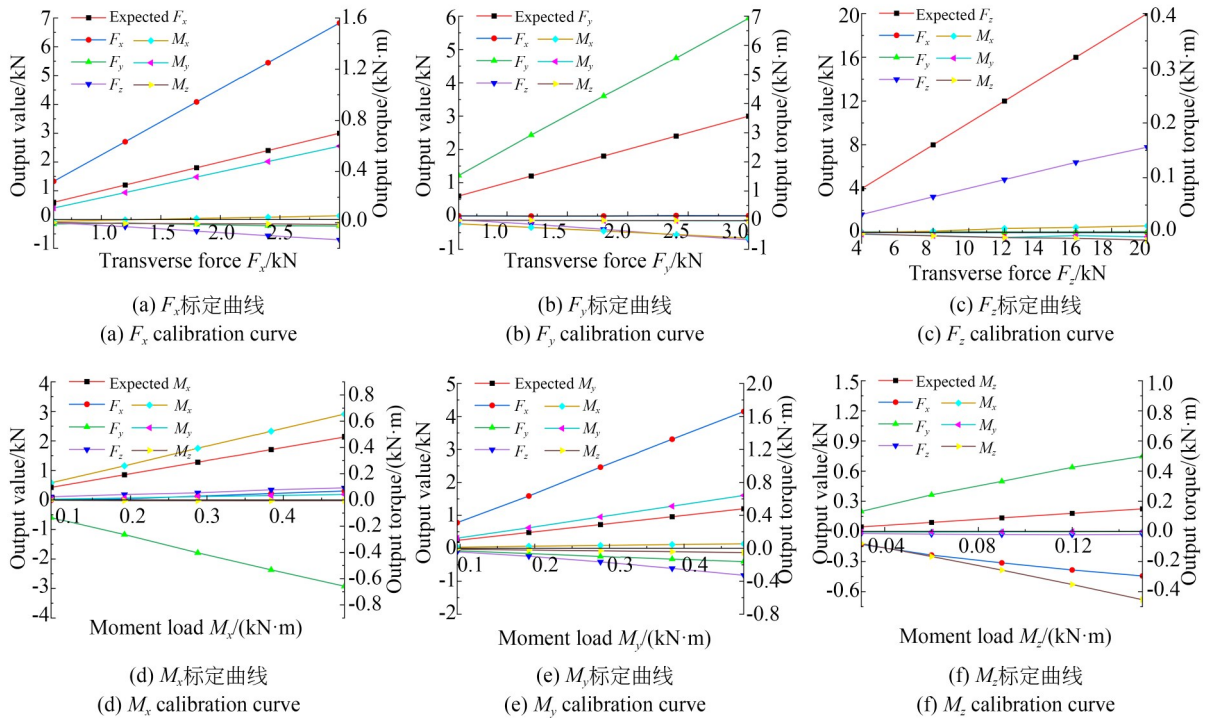


图 2 解耦前压电式六维力传感器测力性能曲线

Fig. 2 Force measurement performance curves of piezoelectric six-dimensional force sensors before decoupling

从图 2 可以看出,当施加各维力载荷时,其输出力值与实际期望值相差较大。此外,当施加某一单维力载荷时,其余各维力均有大小不等的力值输出,耦合影响较大,因此需要对测力性能进行解耦。

3 基于 BO-CNN-BiLSTM 的六维力信号解耦模型

3.1 卷积算法基本原理

卷积神经网络(Convolutional Neural Network, CNN)作为一种高效特征提取工具,具备高度的

容错性与稳定性。自 1980 年福岛引入 CNN 原型发展而来^[15],LeCun 提出的 LeNet-5 首次实现反向传播训练,奠定了现代 CNN 基础^[16]。其核心优势在于局部感知与权值共享机制,通过离散卷积操作构建映射卷积层架构,如图 3 所示。




图 3 卷积神经网络典型架构

Fig. 3 Typical architecture of the CNN

CONV 是 CNN 的核心部分,其主要功能是提取数据中的关键信息,并传递到网络的下一层。卷积核以预设步长在输入数值上滑动,确保完整遍历输入域。卷积操作后,需要经过激活函数来获取输出数据的非线性特征,并增强模型的特征表示。修正线性单元(Corrected Linear Unit, ELU)是一种非饱和的非线性激活函数,在卷积神经网络模型中广泛应用。ELU 在负值区域具有非零梯度,避免神经元“死亡”,具有快速收敛和简单梯度的优点。ELU 函数可表示为:

$$ELU(x) = \begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases} \quad (4)$$

CONV 采用高维特征映射以充分提取信号特征(低维易引发过拟合),并引入最大池化层在压缩参数的同时保留六维力信号的局部显著特征(如冲击峰值),有效抑制了背景噪声干扰,增强了空间耦合解析能力。

3.2 基于 BiLSTM 神经网络的基本原理

C_t 期记忆网络(LSTM)是一种改进的循环神经网络(Recurrent Neural Network, RNN)^[17]。通过门控机制解决长期依赖与梯度消失问题,适用于六维力传感器等时序信号处理。其核心在于引入三重门控单元(遗忘门、输入门、输出门)与细胞状态(长期记忆载体),LSTM 的整体结构如图 4 所示。

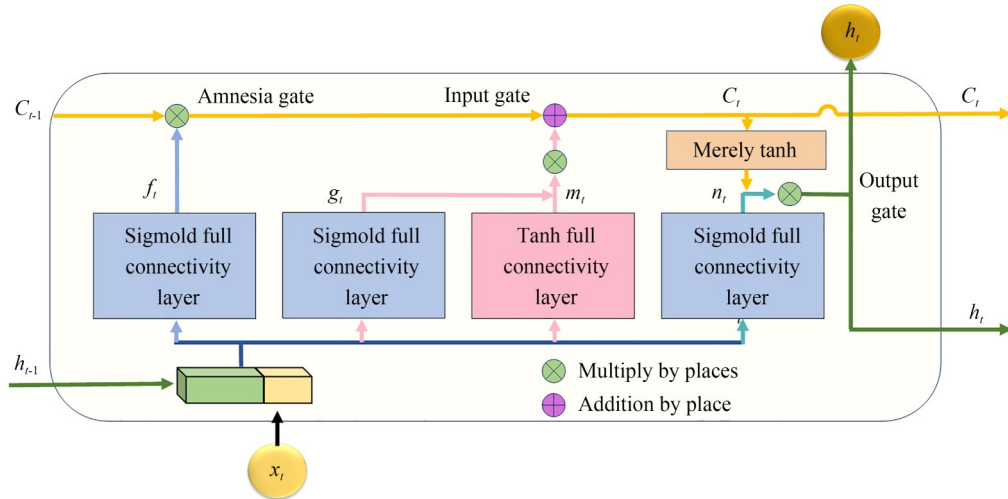


图 4 长短期记忆神经网络结构模型

Fig. 4 Structural modeling of neural networks for LSTM

上一时刻的状态是否保留到当前单元状态由遗忘门控制。遗忘门过滤记忆内容并决定存储的数据是否保留。其计算过程可表示为:

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f), \quad (5)$$

其中: f_t 是遗忘门的输出; σ 是激活函数, 选择为输出为 0~1 的 Sigmoid 函数, 用于表示门的开启程度; W_{xf} 是当前输入与遗忘门之间的权重矩阵; x_t 是当前输入状态; W_{hf} 是历史输出与遗忘门之间的权重矩阵; h_{t-1} 是前一时刻的输出状态; b_f 是遗忘门的偏置项。

输入门用于更新单元状态, 判断单元是否能记住新信息。前一刻的状态和当前输入信息被送入激活函数, 以获得 0 到 1 之间的输出值, 该输

出决定了信息的更新。0 表示不重要, 1 表示重要。前一刻的状态和前一步的当前输入信息也经过 tanh 函数处理。信息在 -1 和 1 之间压缩, 以获得候选单元状态。输入门的输出可表示为:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i), \quad (6)$$

其中: W_{xi} 是输入与输入门之间的权重矩阵, W_{hi} 是历史输出与输入门之间的权重矩阵, b_i 是输入门的偏置项。候选单元状态 \hat{c}_t 可表示为:

$$\hat{c}_t = \tan h(W_{xc}x_t + W_{hc}h_{t-1} + b_c), \quad (7)$$

其中, W_{xc} 是输入与单元状态之间的权重矩阵, W_{hc} 是历史输出与单元状态之间的权重矩阵, b_c 是单元状态的偏置项, 使用 tanh 函数调整值的大小。

当前单元状态 C_t 由两部分组成,一部分是通过将遗忘门的输出与上一时刻的单元状态相乘确定的信息保留,另一部分则是通过将输入门的输出与当前候选状态相乘增加的信息。单元状态表示为:

$$C_t = f_t C_{t-1} + i_t \hat{c}_t. \quad (8)$$

机组状态输出表示为:

$$h_t = o_t \tan h(C_t). \quad (9)$$

压电式六维力传感器的静态耦合效应存在显著时序残留特性,其输出受历史电荷分布与电路响应滞后的双向影响,BiLSTM 通过融合前向与反向 LSTM 层,可实现对传感器信号双向依赖关系的完备建模,有效解析静态载荷下维间耦合的时域传递机制^[16]。BiLSTM 的整体结构如图 5 所示。

3.3 CNN-BiLSTM 模型基本定理

CNN 使用卷积核来提取六维力传感器信号输入数据的空间耦合特性,而 BiLSTM 则在提取过程中加入了记忆单元和门控控制的思想。BiLSTM 模型能够全面学习输入数据序列前后数据之间的依赖特征,从而获得时间相关性。因此,将 CNN 与 BiLSTM 的特征级融合构建联合解耦框架,可有效克服传统

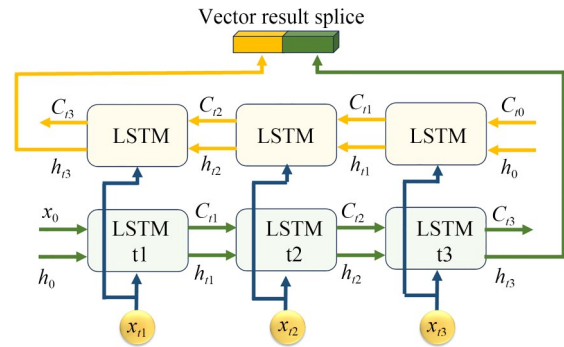


图 5 双向长期记忆网络结构模型

Fig. 5 Structural modeling of neural networks for BiLSTM

CNN 时序解析不足的缺陷,显著提升维间串扰抑制能力。

在 CNN-BiLSTM 信号解耦模型中,CNN 负责提取输入数据的空间特征并降低数据维度,BiLSTM 负责挖掘隐藏的时间规律特征,其记忆细胞状态设计适配静态时序模式识别。CNN-BiLSTM 信号解耦模型的网络结构如图 6 所示。该模型主要由传感器输出力信号输入层、CNN 卷积层、池化层、BiLSTM 层、分类层和输出层组成。

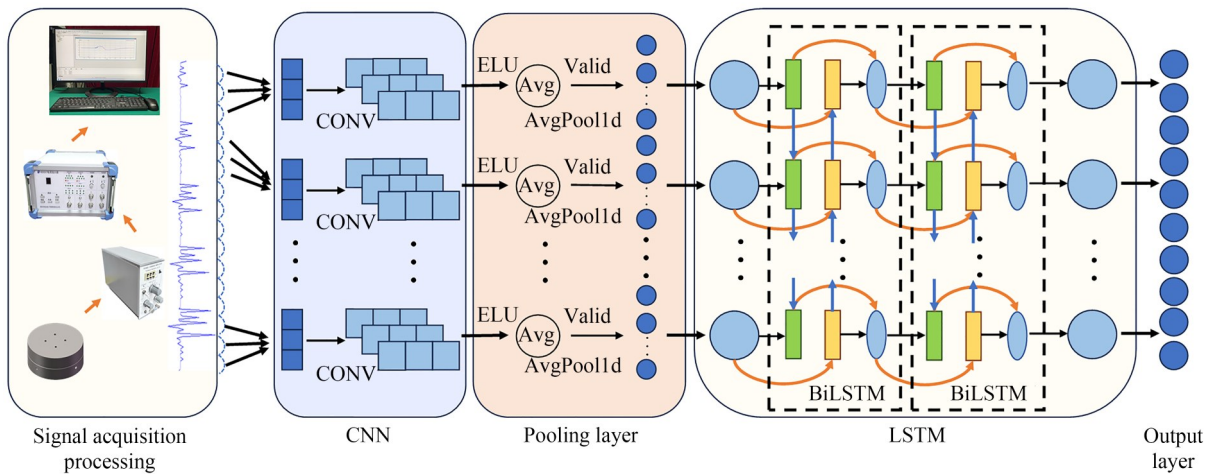


图 6 卷积长短期记忆神经网络模型网络结构

Fig. 6 Structural modeling of neural networks for CNN-BiLSTM

3.4 基于 BO-CNN-BiLSTM 解耦

3.4.1 贝叶斯优化算法

CNN-BiLSTM 模型在六维力传感器解耦中存在 BiLSTM 单元数和学习率等构成超参数高

维搜索空间,传统梯度调节超参数因维度耦合效应及局部最优陷阱,难以实现多参数协同优化的问题^[18]。因此,需要引入智能优化算法实现全局最优参数搜索。贝叶斯优化算法(BO 算法)基于

贝叶斯定理,具有高维非凸空间的全局寻优能力,能实现多超参数寻最优组合^[19]。BO算法可使用概率代理模型来拟合目标函数,先验分布结构与观测模型利用拟合函数解析后验分布,选择期望改进最大的候选点,通过最大化历史信息增益实现评估次数压缩。

本文概率代理模型选用非参数化模型高斯过程函数(Gaussian Process, GP),其核心优势在于通过获取函数灵活拟合复杂非线性模式,并完整量化预测不确定性。该模型直接在函数空间构建概率分布,无需预设模型形式,尤其适合小样本精确建模。

GP由协方差函数 k 和均值函数 m 组成。在GP中,有限数量的随机变量满足联合高斯分布。

$$\alpha_i(x, D_{1:i}) = \begin{cases} (v^* - \mu(x))\varphi\left(\frac{v^* - \mu_i(x)}{\sigma_i(x)}\right) + \sigma_i(x)\varphi\left(\frac{v^* - \mu_i(x)}{\sigma_i(x)}\right), \sigma_i(x) > 0 \\ 0, \sigma_i(x) = 0 \end{cases}, \quad (12)$$

其中: v^* 是当前最优函数值, φ 是标准正态分布概率密度函数。

3.4.2 BO-CNN-BiLSTM基本模型

BO算法用于解决CNN-BiLSTM模型超参数优化的问题。数据集80%用于训练模型,20%用于测试。BO-CNN-BiLSTM回归模型的框架如图7所示。

在CNN-BiLSTM回归模型构建中,确定需要优化的超参数组合并设置待优化超参数的搜索空间,包括LSTM单元、学习率和L2正则化系数。对超参数执行贝叶斯优化算法,使用高斯过程作为概率代理模型来建模目标函数。计算当前超参数组合下的模型评估函数值后,算法基于高斯过

将高斯过程和边际似然分布联合,表示为:

$$\begin{bmatrix} y \\ f_* \end{bmatrix} \sim N\left(0, \begin{bmatrix} \sum + \sigma^2 I & K_s \\ K_s^T & K_{**} \end{bmatrix}\right), \quad (10)$$

其中: f_* 是预测函数的值, $K_s^T = \{k(x_1, X^*), k(x_2, X^*), \dots, k(x_i, X^*)\}$, X^* 表示预测输入。

预测分布可表示为:

$$\text{cov}(f_*) = K_{**} - K_s^T \left[\sum + \sigma^2 I \right]^{-1} K_s. \quad (11)$$

在BO算法中,获取函数的作用是选择下一个最可能的候选点,以评估模型的最佳性能。后验分布构建基于观测数据集 $D_{1:i}$ 获得。此外,通过最大化来指导后续评估点 x_{i+1} 。具体公式可以表示为:

程模型和获取函数选择下一组超参数进行新一轮训练,直至达到最大迭代次数50。模型使用Adam优化器,带有学习率衰减(Learning Rate Decay, LRD)和梯度裁剪(StepLR),在贝叶斯优化阶段(超参数搜索阶段),训练数据加载器的每次迭代所使用的样本数量(batch size)设置为6。

CNN-BiLSTM信号解耦模型采用七层网络架构,包含输入层、CNN卷积层、最大池化、两个BiLSTM层、全连接层以及Softmax分类层。如表1所示,模型对3个关键超参数设定了优化范围,通过迭代搜索直至达到最大迭代次数,最终选择评估函数值最小(RMSE最低)的超参数组合作为最优组合。

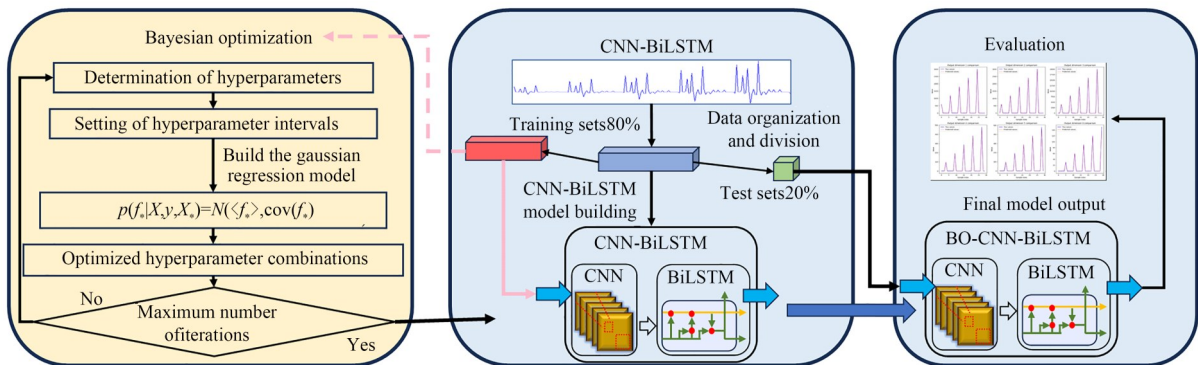


图7 基于贝叶斯优化的卷积长短期记忆神经网络模型的网络结构

Fig. 7 Network structure of Bayesian optimization-based neural network model for CNN-BiLSTM

表 1 CNN-BiLSTM 超参数的区间设置

Tab. 1 Interval setting of CNN-BiLSTM hyperparameters

超参数	优化范围
初始学习率	$[10^{-4} \sim 10^{-2}]$
正则化系数	$[10^{-5} \sim 10^{-1}]$
BiLSTM 第二层神经元数量	$[32 \sim 256]$

在确定最优超参数组合后,模型经过 1 000 次完整训练,训练过程中持续记录损失值,并在 80% 测试集上通过计算各输出维度的均方误差 (Root Mean Square Error, RMSE) 和决定系数 (R^2) 进行性能评估,同时通过可视化手段对比预测值与真实值来验证模型的有效性。该架构中, CNN 的卷积核有助于捕获丰富的特征信息,而 BiLSTM 层的引入则显著提升了模型对时序特征的建模能力,最终通过 Softmax 层实现精准分类。

图 8 展示了优化搜索过程中目标值的变化。BO 算法根据之前的观察结果,在超参数空间中评估新的候选点。对于 CNN-BiLSTM 模型的超参数搜索,经过 20 次迭代后,目标值在第 4 次迭代时完成收敛,模型经过 6 次迭代完成收敛,实现搜索效率较传统方法提升 3.5 倍。这一组最优解

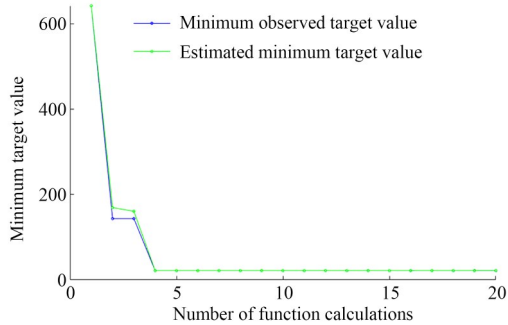


图 8 BO 算法优化搜索过程

Fig. 8 Process of BO algorithm for optimized search

包含了最佳的超参数组合,具体为初始学习率为 2.23×10^{-3} ,正则化因子为 3.7349×10^{-4} ,以及 BiLSTM 第二层的单元数量为 63。

BO 算法为模型超参数的选择提供了一种高效、可靠的方法,避免了手动调整超参数导致的时间损失和模型不稳定问题,从而显著提高了模型的准确性和泛化能力。采用上述设置完成 CNN-BiLSTM 解耦算法的训练,训练误差性能曲线如图 9 所示。




图 9 CNN-BiLSTM 模型训练误差性能曲线

Fig. 9 Error performance curves for CNN-BiLSTM model training

4 实验结果分析

4.1 BO-CNN-BiLSTM 解耦算法解耦结果分析

采用 BO-CNN-BiLSTM 神经网络解耦算法对传感器进行多维非线性优化,得到解耦后的结果如图 10 所示。通过分析各向独立加载时的输出响应曲线可以发现,经过解耦处理的力/力矩信号展现出优异的线性特征。通过对 20% 测试组解耦得到数据的最大 I 类和 II 类误差,计算得到对 BO-CNN-BiLSTM 解耦算法的百分比耦合矩阵 $E_{BO-CNN-BiLSTM}$,可表示为:

$$E_{BO-CNN-BiLSTM} = \begin{bmatrix} 0.2645 & 0.2226 & 0.4308 & 0.0881 & 0.0769 & 0.0037 \\ 0.1759 & 0.1671 & 0.3932 & 0.0630 & 0.1023 & 0.0076 \\ 0.0350 & 0.0115 & 0.5686 & 0.0088 & 0.0087 & 0.0011 \\ 0.2471 & 0.5170 & 0.4207 & 0.8747 & 0.1523 & 0.0073 \\ 0.1213 & 0.3234 & 0.2277 & 0.0930 & 0.3230 & 0.0039 \\ 0.1753 & 0.2843 & 0.4890 & 0.1988 & 0.0934 & 0.2689 \end{bmatrix} \quad (13)$$

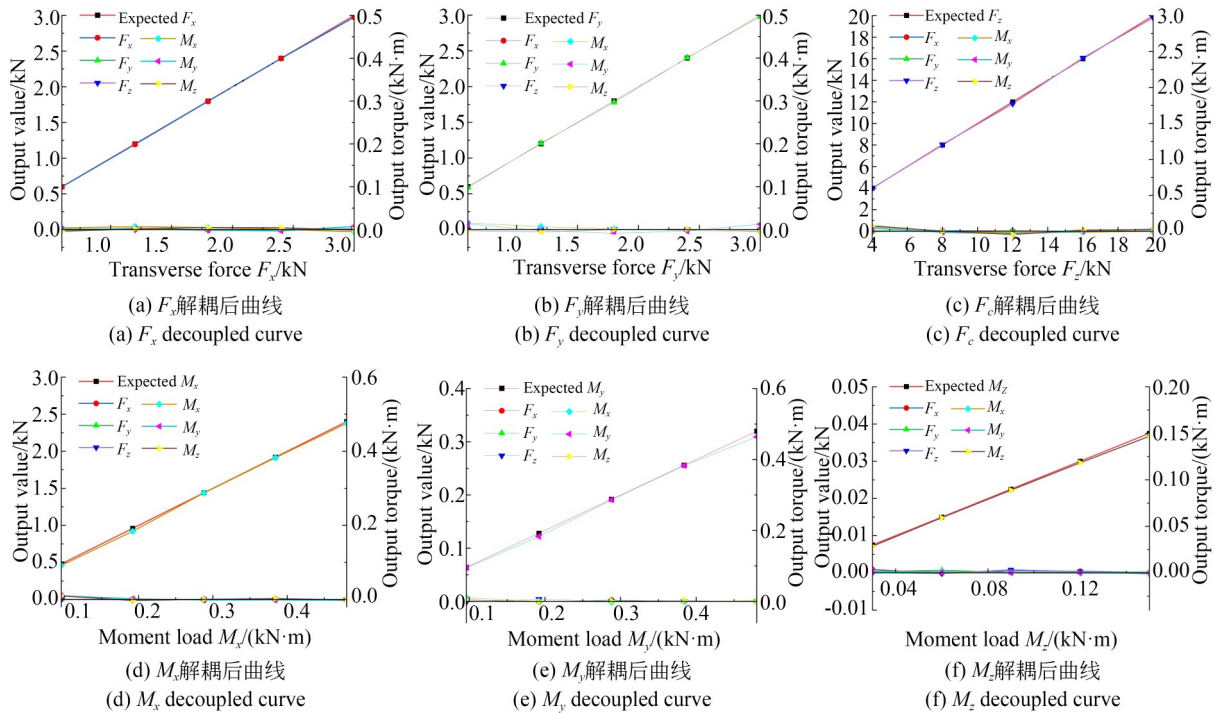


图 10 解耦后压电式六维力传感器测力性能曲线

Fig. 10 Force measurement performance curves of decoupled piezoelectric six-dimensional force sensors

在单一方向施加载荷工况下,非目标方向的输出信号幅值显著降低,这一现象充分证明了该算法对维间耦合效应的抑制效果。模型解耦的目标变量方差占总方差的比例 R^2 最小值在 M_x 方向,在该方向的方差为0.999 1,模型解耦的总方差的比例 R^2 均大于0.99。实验数据表明,BO-CNN-BiLSTM架构通过贝叶斯优化自动调参的CNN特征提取层与BiLSTM时序建模层的协同作用不仅大幅提升了六维力测量的精度,而且有效增强了系统的可靠性,验证了深度学习在解决复杂非线性耦合问题方面的优势,也为高精度多

维力测量提供了新的技术路径。其中,CNN网络负责捕捉传感器的空间耦合特征,而BiLSTM网络则精准建模信号的时序依赖关系,二者的结合通过贝叶斯优化实现了性能最优化。

4.2 实验结果对比

为验证长短期记忆神经网络解耦算法的解耦性能,基于标定实验数据,选取CNN解耦算法和CNN-LSTM解耦算法进行比较分析。表2给出了采用3种解耦算法时,得到六维力传感器百分比耦合矩阵形式的I类误差和II类误差对比。由表2可见,采用CNN线性解耦方法时,解耦效

表 2 三种解耦算法的误差对比

Tab. 2 Error comparison of three decoupling algorithms

算法	力和力矩	各向误差/%					
		F_x	F_y	F_z	M_x	M_y	M_z
CNN	F_x	3.36	0.46	3.60	0.13	0.02	0.01
	F_y	0.64	0.35	7.49	0.52	0.02	0.04
	F_z	0.02	0.22	0.93	0.06	0.04	0.00
	M_x	2.73	0.82	3.11	9.12	3.97	0.27
	M_y	0.74	0.78	21.77	0.53	7.73	0.27
	M_z	2.27	1.30	6.24	1.91	0.17	4.26

续表 2 3种解耦算法的各向误差

Tab. 2 Error comparison of three decoupling algorithms

算法	力和力矩	各向误差/%					
		F_x	F_y	F_z	M_x	M_y	M_z
CNN-LSTM	F_x	0.20	0.28	2.33	0.07	0.18	0.01
	F_y	0.04	0.25	0.65	0.16	0.17	0.01
	F_z	0.01	0.09	3.93	0.01	0.04	0.01
	M_x	0.73	1.62	0.83	3.17	0.19	0.09
	M_y	0.68	1.30	0.77	1.12	1.80	0.05
	M_z	0.40	1.29	1.23	1.06	0.26	0.67
BO-CNN-BiLSTM	F_x	0.26	0.22	0.43	0.09	0.08	0.00
	F_y	0.18	0.17	0.39	0.06	0.10	0.01
	F_z	0.04	0.01	0.57	0.01	0.01	0.00
	M_x	0.25	0.52	0.42	0.87	0.15	0.01
	M_y	0.12	0.32	0.23	0.09	0.32	0.01
	M_z	0.18	0.28	0.49	0.20	0.09	0.27

果较差,解耦后的最大I类和II类误差分别为9.12%,7.48%。采用CNN-LSTM神经网络非线性解耦后的最大I类和II类误差分别为3.93%,1.62%。采用基于贝叶斯优化的CNN-BiLSTM神经网络的解耦算法对六维力传感器进行解耦后,传感器的最大I类和II类误差分别为0.87%,0.52%。

表 3 多种解耦算法的误差对比

Tab. 3 Error comparison of multiple decoupling algorithms

解耦算法	最大 I 类误差	最大 II 类误差
CNN	9.12%	7.48%
CNN-LSTM	3.93%	1.62%
BO-CNN-BiLSTM	0.87%	0.52%
GA-MLP	1.78%	2.01%
RBF	1.57%	1.66%

实验结果表明,基于贝叶斯优化的CNN-BiLSTM神经网络的六维力传感器解耦算法效果理想,满足传感器在使用中两类误差均低于2%的要求,显著提升了六维力传感器的测量精度和性能。

5 结 论

本文提出了一种融合BO-CNN-BiLSTM的压电式六维力/力矩传感器非线性解耦方法,解决了四支点六维力传感器的维间耦合误差较大,算法解耦效率不高,难以进行多参数协同优化且容易陷入局部最优解等问题。实验结果表明,BO-CNN-BiLSTM模型解耦的目标变量方差占总方差的比例 $R^2 \geq 0.99$,在全量程静态载荷下,该算法使传感器最大I类和II类误差分别为0.87%,0.52%。相较于传统解耦方法及CNN-LSTM,精度得到大幅提升,满足了传感器在使用中两类误差均低于2%的要求,显著提升了六维力传感器的测量精度和性能。该方法为人形机器人的双足动态行走等多自由度协同运动提供了高精度的多维力感知技术支撑。

作者贡献声明:

褚宏博:算法的提出及设计,实验数据分析,论文构思和撰写;

王桂从:论文审核与编辑写作;

高嘉龙:数据整理与分析;

李映君:研究框架的论证优化,实验方案的设计完善,方法学改进。

参考文献:

- [1] 曹会彬, 葛运建, 孙玉香, 等. 六维力/力矩传感器研究发展综述[J]. 测控技术, 2020, 39(5): 15-20, 58.
CAO H B, GE Y J, SUN Y X, *et al.* Review on research and development of six-axis force/torque sensor [J]. *Measurement & Control Technology*, 2020, 39(5): 15-20, 58. (in Chinese)
- [2] 李睿智, 陈悦敏, 闫纪红. 面向轨迹动态感知与自主决策的工业机器人数字孪生建模方法研究[J]. 机械工程学报, 2025, 61(7): 269-283.
LI R ZH, CHEN Y M, YAN J H. Digital twin modeling method for industrial robots with dynamic trajectory sensing and autonomous decision-making [J]. *Journal of Mechanical Engineering*, 2025, 61(7): 269-283. (in Chinese)
- [3] 郝帅, 马铁林, 王一, 等. 传感器飞机核心关键技术进展与应用[J]. 航空学报, 2023, 44(6): 027034.
HAO SH, MA T L, WANG Y, *et al.* Progress and application of key technologies of SensorCraft [J]. *Acta Aeronautica et Astronautica Sinica*, 2023, 44(6): 027034. (in Chinese)
- [4] DE A PORTO V G B, MELO D C, MAXIMO M R O A, *et al.* Imitation learning of a model predictive controller for real-time humanoid robot walking [J]. *Engineering Applications of Artificial Intelligence*, 2025, 143: 109919.
- [5] 徐凯, 陈愚, 刘莉, 等. 基于六维力/力矩传感器和关节力矩的仿人机器人步态补偿算法[J]. 机器人, 2006, 28(2): 213-218.
XU K, CHEN K, LIU L, *et al.* Walking gait compensation algorithm for humanoid robots based on universal force-moment sensors and joint torques [J]. *Robot*, 2006, 28(2): 213-218. (in Chinese)
- [6] 姚起宏, 王奉阳, 黄伟, 等. 一种新型电容式六维力/力矩传感器设计及解耦分析[J]. 装备制造技术, 2022(1): 11-14.
YAO Q H, WANG F Y, HUANG W, *et al.* Design and decoupling analysis of a new capacitive six-axis force/torque sensor [J]. *Equipment Manufacturing Technology*, 2022(1): 11-14. (in Chinese)
- [7] 李映君, 韩彬彬, 王桂从, 等. 基于径向基函数神经网络的压电式六维力传感器解耦算法[J]. 光学精密工程, 2017, 25(5): 1266-1271.
LI Y J, HAN B B, WANG G C, *et al.* Decoupling algorithms for piezoelectric six-dimensional force sensor based on RBF neural network [J]. *Opt. Precision Eng.*, 2017, 25(5): 1266-1271. (in Chinese)
- [8] 元振广, 王桂从, 褚宏博, 等. 采用长短期记忆神经网络的压电式六维力/力矩传感器解耦算法[J]. 西安交通大学学报, 2025, 59(4): 158-170.
QI ZH G, WANG G C, CHU H B, *et al.* Decoupling algorithm of piezoelectric six-dimensional force/torque sensor using long short-term memory neural network [J]. *Journal of Xi'an Jiaotong University*, 2025, 59(4): 158-170. (in Chinese)
- [9] 陈伟, 张晓, 袁栋, 等. 农田耕整载荷六维力传感器结构优化与解耦研究[J]. 农业机械学报, 2024, 55(2): 28-35, 89.
CHEN W, ZHANG X, YUAN D, *et al.* Structural optimization and decoupling of six dimensional force sensor for farmland tillage load [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(2): 28-35, 89. (in Chinese)
- [10] 王志军, 张小涛, 李梦祥. 基于多项式拟合的六维力传感器解耦算法研究[J]. 工程设计学报, 2023, 30(5): 571-578.
WANG ZH J, ZHANG X T, LI M X. Research on decoupling algorithm of six-dimensional force sensor based on polynomial fitting [J]. *Chinese Journal of Engineering Design*, 2023, 30(5): 571-578. (in Chinese)
- [11] 徐家琪, 伍万能, 孙炜, 等. 优化极限学习机算法及其在力信息解耦中的应用[J]. 传感技术学报, 2019, 32(10): 1487-1492.
XU J Q, WU W N, SUN W, *et al.* Optimized extreme learning machines and their application in decoupling of multi-component force information [J]. *Chinese Journal of Sensors and Actuators*, 2019, 32(10): 1487-1492. (in Chinese)
- [12] 戴裕强, 王鹏, 张昌明, 等. 基于堆叠学习的六维力传感器解耦方法研究[J]. 仪表技术与传感器, 2025(3): 20-24.
DAI Y Q, WANG P, ZHANG CH M, *et al.* Research on decoupling method of six-axis force sensor based on stacking learning [J]. *Instrument Technique and Sensor*, 2025(3): 20-24. (in Chinese)
- [13] 韩彬彬. 压电式六维力/力矩传感器非线性解耦算法的研究[D]. 济南: 济南大学, 2017.
HAN B B. *Research on Nonlinear Decoupling Algorithm of Piezoelectric Six-Dimensional Force/*

- Torque Sensor* [D]. Jinan: University of Jinan, 2017. (in Chinese)
- [14] 李盼, 杨睿, 任宗金, 等. 全动舵面载荷测量的压电天平设计与误差分析[J]. 哈尔滨工业大学学报, 2018, 50(1): 181-185.
- LIP, YANG R, REN Z J, *et al.* Design and error analysis of a piezoelectric balance for the measurement of aerodynamic loads on an all-movable rudder [J]. *Journal of Harbin Institute of Technology*, 2018, 50(1): 181-185. (in Chinese)
- [15] YAO G L, LEI T, ZHONG J D. A review of convolutional-neural-network-based action recognition [J]. *Pattern Recognition Letters*, 2019, 118: 14-22.
- [16] 周俊宇, 赵艳明. 卷积神经网络在图像分类和目标检测应用综述[J]. 计算机工程与应用, 2017, 53(13): 34-41.
- ZHOU J Y, ZHAO Y M. Application of convolution neural network in image classification and object detection [J]. *Computer Engineering and Applications*, 2017, 53(13): 34-41. (in Chinese)
- [17] 付玲, 余玲娟, 颜镀镭, 等. 基于内嵌物理信息与注意力机制 Bi LSTM 神经网络的臂架系统疲劳损伤预测模型[J]. 机械工程学报, 2024, 60(13): 205-215.
- FU L, SHE L J, YAN D L, *et al.* Fatigue damage prediction framework of the boom system based on embedded physical information and attention mechanism BiLSTM neural network [J]. *Journal of Mechanical Engineering*, 2024, 60(13): 205-215. (in Chinese)
- [18] 李勇, 赵宇明. 基于贝叶斯优化算法和长短期记忆网络的 PM_{2.5} 浓度预测[J]. 流体测量与控制, 2023, 4(6): 14-17, 21.
- LI Y, ZHAO Y M. PM_{2.5} concentration prediction based on Bayesian optimization algorithm and LSTM [J]. *Fluid Measurement & Control*, 2023, 4(6): 14-17, 21. (in Chinese)
- [19] 张梦蝶, 章华, 苏一丹. 进化贝叶斯优化的核极限学习机分类器[J]. 计算机工程与设计, 2022, 43(2): 399-405.
- ZHANG M D, QIN H, SU Y D. Kernel extreme learning machine classifier based on evolutionary Bayesian optimization [J]. *Computer Engineering and Design*, 2022, 43(2): 399-405. (in Chinese)

作者简介:



褚宏博(2000—),男,山东潍坊人,硕士研究生,2023年于济南大学获得学士学位,主要从事多维力传感器方向的研究。E-mail:731902719@qq.com

通讯作者:



李映君(1982—),男,山东烟台人,2004年于山东科技大学获得学士学位,2007年于沈阳理工大学获得硕士学位,2010年于大连理工大学获得博士学位,主要从事传感器与执行器测控技术、工业机器人技术、智能化仪器仪表技术等领域的研究。E-mail:me_liyj@ujn.edu.cn