

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

亓振广¹, 王桂从^{1,2}, 褚宏博¹, 张帅¹, 李映君^{1,2}

(1. 济南大学机械工程学院, 250022, 济南; 2. 山东省传感技术与高精度衡器重点实验室, 250022, 济南)

摘要: 针对压电式六维力/力矩传感器存在的维间耦合导致传感器测力性能下降问题,提出了一种基于长短期记忆神经网络(LSTM)的压电式六维力/力矩传感器解耦算法。首先,通过六维力传感器静态标定实验,获取解耦算法所需的实验数据,并对其进行处理;然后,通过分析传感器维间耦合产生的原因及 LSTM 神经网络解耦原理,构建 LSTM 神经网络解耦模型;最后,采用基于 LSTM 神经网络的解耦算法,对传感器输出的多维非线性特性开展优化,解耦后得到传感器输入、输出之间的映射关系和对应的输出数据,并与径向基函数(RBF)及最小二乘(LS)解耦算法进行对比分析。研究表明:所使用四点支撑式压电六维力传感器的最大重复性误差为 1.55%;采用基于 LSTM 的神经网络算法解耦后,传感器输出结果的最大非线性误差、交叉耦合误差分别为 0.55% 和 0.28%,均小于 RBF 和 LS 算法。LSTM 神经网络解耦算法能有效减少六维力/力矩传感器的维间耦合,提高传感器的测量精度,对航空航天领域的发展具有参考意义。

关键词: 六维力/力矩传感器;压电式;解耦算法;长短期记忆神经网络;维间耦合

中图分类号: TP212.9;TN384 **文献标志码:** A

DOI: 10.7652/xjtuxb202504015 **文章编号:** 0253-987X(2025)04-0158-13

Decoupling Algorithm of Piezoelectric Six-Dimensional Force/Torque Sensor Using Long Short-Term Memory Neural Network

QI Zhenguang¹, WANG Guicong^{1,2}, CHU Hongbo¹, ZHANG Shuai¹, LI Yingjun^{1,2}

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

2. Shandong Key Laboratory of Sensing Technology and High Precision Weighing Instruments, Jinan 250022, China)

Abstract: To address the issue of decreased force measurement performance in piezoelectric six-dimensional force/torque sensors due to inter-dimensional coupling, a decoupling algorithm for piezoelectric six-dimensional force/torque sensors based on long short-term memory neural network (LSTM) is proposed. Firstly, experimental data needed for the decoupling algorithm is obtained through static calibration experiments of the six-dimensional force sensor and processed accordingly. Then, by analyzing the causes of inter-dimensional coupling in sensors and the decoupling principle of the LSTM neural network, an LSTM neural network decoupling model is constructed. Finally, the decoupling algorithm based on the LSTM neural network is used to optimize the multi-dimensional nonlinear characteristics of the sensor output, obtaining the mapping relationship between sensor

inputs and outputs after decoupling, and corresponding output data. A comparative analysis is conducted with radial basis function (RBF) and least squares (LS) decoupling algorithms. The research results show that the maximum repeatability error of the four-point supported piezoelectric six-dimensional force sensor is 1.55%. After utilizing the LSTM-based neural network algorithm for decoupling, the maximum nonlinear error and cross-coupling error of the sensor output results are 0.55% and 0.28% respectively, both lower than those of the RBF and LS algorithms. The LSTM neural network decoupling algorithm effectively reduces inter-dimensional coupling in the six-dimensional force/torque sensor, improving measurement accuracy and holding important implications for the development of the aerospace industry.

Keywords: six-dimensional force/torque sensor; piezoelectric sensor; decoupling algorithm; long short-term memory neural network; interdimensional coupling

自风洞试验问世以来,航空航天技术得到了显著的发展与完善^[1]。风洞试验作为分析和评估飞行器气动弹性特性的关键手段,使得工程师们能够在地上模拟飞行器在真实飞行环境中的受力情况。在飞行器设计阶段,通过气动弹性风洞试验可以验证飞行器的设计强度和性能是否达到要求,并为优化改进提供指导^[2]。风洞试验作为推动航空航天技术进步的重要工具,已成为现代飞行器设计和测试的坚实技术保障。

在风洞试验研究领域中,一直将飞行器模型在不同气流作用下的受力情况作为重点研究内容^[3]。六维力/力矩传感器(以下简称六维力传感器)可在 oxy 直角坐标系下同时检测力 F_x 、 F_y 、 F_z 和力矩 M_x 、 M_y 、 M_z ,并具有感知信息丰富、测量精度高的特点。六维力传感器的应用,使得试验人员能够全面了解包括升力、阻力、侧力及扭矩等风载荷对模型的影响。这些数据对于精确评估气动性能和结构响应至关重要,能够提高设计的可靠性和效率。传感器在使用过程中,由于结构设计、加工制造、安装精度等因素,测量精度会受到较大影响,使某一信号在传输时受到其他信号的干扰,即维间耦合,从而制约传感器在高、精、尖领域的发展和应用。因此,降低或消除传感器的维间耦合是传感器技术发展的关键。

近年来,为了提高传感器在应用过程中的精度,国内外学者提出了多种解耦算法。针对不同类型的传感器,需要选择不同的解耦算法,以寻求传感器的最优性能。目前,对于六维力传感器的解耦算法可分为静态线性解耦和静态非线性解耦。线性解耦算法^[4-7]采用传统的数学方法对输出信号进行修正,要求传感器系统必须是线性的,因此解耦存在一定的局限性和不稳定性。相比之下,非线性解耦算法

通过多函数映射的方式进行解耦,不依赖于传感器的线性特性,能够应用于更复杂的系统,具有更高精度。为此,许多学者针对不同构型的六维力传感器提出了各种非线性解耦算法^[8-13]。李映君等^[14]提出了基于径向基函数(RBF)神经网络的解耦算法,结果表明最大耦合误差为1.56%。孙世政等^[15]提出了一种基于白鲨优化算法的优化极限学习机(WSO-ELM)非线性解耦算法,结果表明:极限学习机具有训练速度快、解耦简单、调参容易等优点,但对输入数据比较敏感以及对神经元数比较依赖的特点会导致结果不稳定,解耦后的最大耦合误差为0.65%。陈伟等^[16]采用改进型XGBoost机器学习网络对力信号进行解耦,结果显示:该算法预测效果较好,能避免陷入局部最优解,且明显优于随机森林模型以及传统多元线性回归模型。董翔等^[17]提出了一种基于改进烟花算法优化极限学习机(IFWA-ELM)的解耦算法,解决了极限学习机对神经元数比较依赖以及对初始参数比较敏感的问题,显著降低了解耦误差。张军等^[18]针对压电式多维力测力仪维间干扰大、制约测量精度的问题,分析了维间干扰对测力仪测量精度的影响,提出了一种基于支持向量回归机(SVR)的非线性解耦算法,并采用混合模拟退火算法(HSA)寻找SVR参数的最优解,结果表明:经过解耦后传感器的维间干扰最大为0.52%,非线性误差最大为0.21%,显著提高了传感器的测量精度。

本文根据长短期记忆(LSTM)神经网络的循环和记忆原理,提出了基于LSTM神经网络的压电六维力传感器解耦算法,并应用于课题组研制的四点支撑式压电六维力传感器研究。

1 传感器检测原理及标定实验

1.1 六维力传感器的测量原理

本文所使用的四点支撑式压电六维力传感器,选用石英晶片为压电材料。由于单片晶体的压电系数较低,为保证传感器具有较高的测量灵敏度,在进行晶组组装时,将两片相同切型的晶片组合为测力晶组,对单维力进行测量^[19]。单维测力晶组结构如图 1(a)所示。将 3 种不同方向的测力晶组用导电胶组合,得到六维力传感器的单元晶组,如图 1(b)所示。




图 1 测力晶组示意图

Fig. 1 Force measuring crystal group diagram

压电六维力传感器的测量原理是基于石英晶体的压电效应。当石英晶片受到外力发生形变时,其内部产生极化现象,会在晶片的相对表面产生等量相反的电荷,且电荷量与外力成正比,这种效应一般称为正压电效应。四点支撑式压电六维力传感器实物如图 2 所示。




图 2 四点支撑式压电六维力/力矩传感器实物图

Fig. 2 Physical picture of four-point support piezoelectric six-dimensional force/torque sensor

同时测量传感器中对称布置的 4 个单元晶组的同向力并进行代数相加,得到三维正交力 F_x 、 F_y 、 F_z 。通过各方向分力及测力晶组的位置关系,得到三维正交力矩 M_x 、 M_y 、 M_z 。晶组产生的电荷信号经过电荷放大器转换成电压信号后,再通过信号调节器转换成数字信号。

根据空间力系统平衡原理,设 F_{ij} 为单个单元晶组的测得力,其中 i 为单维晶组测力方向, $i = x$,

$y, z; j$ 为单元测力晶组编号, $j = 1 \sim 4$ 。定义 a 为空间外力与传感器中心的距离,则三维力 F_x 、 F_y 、 F_z 和三维力矩 M_x 、 M_y 、 M_z 可写为

$$\begin{cases} F_x = F_{x_1} + F_{x_2} + F_{x_3} + F_{x_4} \\ F_y = F_{y_1} + F_{y_2} + F_{y_3} + F_{y_4} \\ F_z = F_{z_1} + F_{z_2} + F_{z_3} + F_{z_4} \\ M_x = a(F_{z_2} - F_{z_4}) \\ M_y = a(F_{z_3} - F_{z_1}) \\ M_z = a(F_{y_1} - F_{y_3} + F_{x_4} - F_{x_2}) \end{cases} \quad (1)$$

1.2 六维力传感器静态标定实验

传感器标定是通过标准传感器来确定待测传感器的准确性和精度的一种校准方式,通过标定实验可以建立待测传感器输入和输出之间的准确关系。同时,传感器的输入力与输出力可作为解耦实验的数据集。

在进行静态标定实验时,采用课题组研制的六维力传感器静态标定台作为载荷施加工具开展实验。待标定传感器由螺栓固定于转接板,转接板由螺栓固定于加载台。进行实验时,通过加载头向传感器施加稳定的力/力矩载荷,如图 3 所示,其中 H 为加载点位置与传感器下平面的高度差。静态标定实验的硬件由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 ± 0.005) mV/V)、传感器样机、简仪科技 JY-61902B 型数据采集卡、江苏联能 YE5850 型电荷放大器以及计算机端组成。标准传感器与加载头通过螺纹连接,标准传感器连接有数值显示器,可获取施加载荷。




图 3 六维力传感器标定实验

Fig. 3 Calibration experiment of six dimensional force sensor

采用等距逐步加载的方法,对传感器:沿 z 方向的加载力 F_z 为 0~20 kN,步长为 4 kN;沿 x 方向的加载力 F_x 为 0~3 kN,步长为 0.6 kN;沿 y 方向的加载力 F_y 为 0~3 kN,步长为 0.6 kN;施加转矩 M_z 为 0~150 N·m,步长为 30 N·m;施加弯矩 M_x 为

0~480 N·m,步长为 96 N·m;施加弯矩 M_y 为 0~150 N·m,步长为 30 N·m。

沿六维力方向依次施加载荷至满量程,共进行 3 次实验,采用重复性误差 R_N 衡量 3 次实验结果的偏离程度,表达式如下

$$R_N = \Delta r_{\max} / F_{\max}$$

(2)

式中: $\Delta r_{\max}$ 为施加相同载荷时 3 次实验结果的最大偏差; $F_{\max}$ 为满量程载荷。

由 3 次实验结果计算可得,重复性误差最大为 1.55%,根据国际标准 ISO 376,力传感器标定重复性误差需小于 2%,因此该传感器符合实验要求。为减少实验误差,取 3 次实验的平均值作为最终实验结果,并采用计算机记录数据。图 4~图 9 为传感器输入载荷与输出载荷之间的标定曲线。

由图 4 可见,当施加轴向力 F_z 时,传感器的各向输出性能均较好,相间干扰较少。




图 4 F_z 标定曲线

Fig. 4 Calibration curve of F_z




图 5 F_x 标定曲线

Fig. 5 Calibration curve of F_x




图 6 F_y 标定曲线

Fig. 6 Calibration curve of F_y




图 7 M_z 标定曲线

Fig. 7 Calibration curve of M_z





图 8 M_x 标定曲线

Fig. 8 Calibration curve of M_x

图 9 M_y 标定曲线Fig. 9 Calibration curve of M_y

由图 5 可见,当沿 x 方向施加力 F_x 时,会产生较大的干扰力矩 M_y 。这是由于在进行传感器标定时,传感器的力学坐标建立在传感器下平面圆心处,与加载位块置会产生高度差 H ,所以在沿此方向加载时,会产生附加力矩 M_y 。

由图 6 可见,沿 y 方向施加力 F_y ,此时干扰力矩 M_x 较大。这同样是因为加载块与晶组位置存在高度差,在沿 y 方向加载时会产生附加力矩 M_x 。

由图 7 可见,当施加转矩 M_z 时,传感器的各向输出性能均较好,相间干扰较少。

由图 8 可见,施加弯矩 M_x 时,亦会产生一部分横向载荷的分力,此时会存在较大的横向力 F_y 干扰。

从图 9 可见,加载弯矩 M_y 时,会产生一部分横向载荷的分力,此时会产生较大的横向力 F_x 干扰。

2 非线性解耦原理及耦合指标的确立

2.1 传感器非线性解耦原理

人工神经网络(ANN)是一种智能学习模型,能够模拟人类大脑神经网络的工作方式,体现了人脑在并行和分布式信息处理方面的能力,从而实现计算机智能化。ANN 能够通过计算和分析数据样本之间的逻辑关系和概率分布,揭示样本的内在联系。

神经网络具备强大的非线性处理能力,能够通过样本之间简单的逻辑对应关系来反应其复杂的映射关系。通过给神经网络提供一定量的实验数据进行训练,可以建立基于训练数据的多维耦合关系,从而实现非线性解耦。本文采用基于 LSTM 神经网络

的解耦算法,结合传感器标定实验,对压电式六维力传感器开展非线性解耦研究。传感器非线性解耦算法原理流程图如图 10 所示。




图 10 传感器非线性解耦算法原理流程图

Fig. 10 Sensor nonlinear decoupling algorithm principle flow chart

2.2 耦合指标的确立

在传感器测量指标的研究中,对测量精度进行评估非常重要。与单维力传感器的耦合误差不同,六维力/力矩传感器耦合误差包括结构性耦合和误差性耦合两种形式^[20]。其中,结构性耦合^[21]主要由标定误差及制造误差引起,无法通过算法将其减小;误差性耦合主要由传感器输出信号时各测量方向之间的干扰误差引起,可以用 I 类误差和 II 类误差来评估传感器误差性耦合的测量精度^[22]。I 类误差表示传感器上施加的与传感器实际测得的力/力矩之间的差值占该方向全量程的比例,又称为静态非线性误差,反映了六维力传感器加载方向测量值与实际加载值之间的偏离程度和 6 个维度的线性度,即组间误差。若 i 表示测力方向,则传感器 I 类误差可表示为

$$\begin{cases} e_{F,i} = |(F_{K,i} - F_{M,i})/F_{Q,i}|, \\ e_{M,i} = |(M_{K,i} - M_{M,i})/M_{Q,i}|, \end{cases} \quad i = x, y, z \quad (3)$$

式中: $e_{F,i}$ 、 $e_{M,i}$ 分别为力和力矩的 I 类误差; $F_{K,i}$ 、 $F_{M,i}$ 、 $M_{K,i}$ 、 $M_{M,i}$ 分别为 i 方向测量得到的和实际施加的力、力矩; $F_{Q,i}$ 、 $M_{Q,i}$ 分别为 i 方向力和力矩的全量程值。

II 类误差表示在某一方向施加力或力矩时,其他方向受到这一方向干扰所产生的附加干扰力/力矩占这一方向全量程的比重。II 类误差又称为静态交叉耦合误差,反应了六维力传感器 6 个维度之间的干扰程度,即组内误差。若 i 、 j 表示测力方向,则 i 对 j 方向产生的 II 类误差可表示为

$$\begin{cases} e_{F,ij} = |F_{ij}/F_{Q,i}|, \\ e_{M,ij} = |M_{ij}/M_{Q,i}|, \end{cases} \quad i = x, y, z, j = x, y, z, i \neq j \quad (4)$$

式中: $e_{F,ij}$ 、 $e_{M,ij}$ 分别为力和力矩的 II 类误差; F_{ij} 、 M_{ij} 分别为 j 方向未施加载荷而 i 方向施加载荷时, j 方向测得的力和力矩。

采用百分比耦合矩阵表示六维力传感器的 I 类误差和 II 类误差,表达式如下

$$\mathbf{E}_{\alpha\beta} = \begin{bmatrix} E_{11} & E_{12} & E_{13} & E_{14} & E_{15} & E_{16} \\ E_{21} & E_{22} & E_{23} & E_{24} & E_{25} & E_{26} \\ E_{31} & E_{32} & E_{33} & E_{34} & E_{35} & E_{36} \\ E_{41} & E_{42} & E_{43} & E_{44} & E_{45} & E_{46} \\ E_{51} & E_{52} & E_{53} & E_{54} & E_{55} & E_{56} \\ E_{61} & E_{62} & E_{63} & E_{64} & E_{65} & E_{66} \end{bmatrix} \quad (5)$$

式中: α 、 β 分别为矩阵的行数和列数, $\alpha = 1 \sim 6$, $\beta = 1 \sim 6$ 。 $\alpha = 1 \sim 3$ 对应于在 x 、 y 、 z 方向施加力, $\alpha = 4 \sim 6$ 对应于在 x 、 y 、 z 方向施加力矩, $\beta = 1 \sim 6$ 分别为得到的力在 x 、 y 、 z 方向的误差和力矩在 x 、 y 、 z 方向的误差。由上可知,当 $\alpha = \beta$ 时,矩阵的对角线表示传感器的 I 类误差;当 $\alpha \neq \beta$ 时,矩阵内元素表示传感器的 II 类误差,即耦合误差。

3 基于 LSTM 神经网络的解耦算法

3.1 循环神经网络基本原理

循环神经网络(RNN)能够捕获和记住上、下文信息,利用上一时刻的信息及当前时刻信息共同计算当前时刻的输出结果,这使得模型能够生成更准确更连贯的输出。LSTM 神经网络一般由输入层、隐含层和输出层组成。实现步骤为:样本从输入层输入,进入隐含层进行处理并输出到输出层;若输出的解耦数据与实际加载力误差过大,则进行前向传播进入下次循环,直至解耦数据与实际加载数据的误差小于预设值后停止。RNN 循环神经网络结构图如图 11 所示,其中 x 为输入层, h 为隐含层, o 为输出层, W 、 U 、 V 分别为输入层、隐含层和输出层的权重矩阵, t 为时间。




图 11 RNN 循环神经网络结构图

Fig. 11 RNN cyclic neural network structure diagram

在 RNN 循环神经网络中,在 $t=1$ s 时,初始化

隐含层时间为 0,初始化输入层、隐含层、输出层权重矩阵,然后对下式进行计算

$$\mathbf{h}_1 = f(\mathbf{U}\mathbf{x}_1 + \mathbf{W}\mathbf{h}_0 + \mathbf{b}'_1) \quad (6)$$

$$\mathbf{o}_1 = g(\mathbf{V}\mathbf{h}_1 + \mathbf{b}''_1) \quad (7)$$

式中: $\mathbf{h}_1$ 、 $\mathbf{o}_1$ 分别为 $t=1$ s 时的隐含层和输出层; f 为隐含层激活函数,通常为 tanh 函数; g 为输出层激活函数,通常为 softmax 函数; $\mathbf{W} = [\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_n]^T$ 、 $\mathbf{U} = [\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_n]^T$ 、 $\mathbf{V} = [\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_n]^T$ 分别为输入层、隐含层和输出层的权重矩阵; n 为权重矩阵的行数,其大小由神经网络的样本数据量与深度决定; $\mathbf{b}'_1$ 、 $\mathbf{b}''_1$ 分别为输入层和输出层神经元的阈值矩阵。

经过时间 t 后,模型的最终预测结果如下

$$\mathbf{y}_t = g(\mathbf{V}\mathbf{h}_t + \mathbf{b}''_t) \quad (8)$$

式中: $\mathbf{y}_t$ 为 t 时刻的输出层,即最终预测结果; $\mathbf{h}_t$ 为 t 时刻的隐含层。

在 RNN 神经网络计算中,各时刻使用的阈值 $\mathbf{b}'_1$ 、 $\mathbf{b}''_1$ 及权重 $\mathbf{U}$ 、 $\mathbf{W}$ 、 $\mathbf{V}$ 均相同,这是 RNN 神经网络循环计算的重要前提。

3.2 LSTM 循环神经网络原理

长短期记忆神经网络是一种特殊的 RNN 网络^[23-24]。传统的 RNN 神经网络在处理长时间依赖时会遇到梯度消失和梯度爆炸的问题^[25],导致层数比较深的权重无法更新,不能继续学习,使得神经网络难以记住和利用长时间跨度的信息。

LSTM 神经网络通过设计 RNN 隐含层中的结构,添加记忆细胞状态机制和门控机制,可以解决传统 RNN 中长时间序列存在的依赖关系以及梯度消失和梯度爆炸问题^[26-28],并有效处理序列中的噪声和其它影响因素。图 12 展示了 LSTM 神经网络结构模型。其中, $\mathbf{C}$ 为细胞状态, $\mathbf{f}_t$ 为遗忘门输出向量, $\mathbf{f}_t \in [0, 1]$, σ 为 sigmoid 函数, $\mathbf{i}_t$ 为输入门输出向量, $\mathbf{i}_t \in [0, 1]$, $\mathbf{C}'_t$ 为新细胞状态, $\mathbf{o}'_t$ 为输出门的输出向量, pointwise 为点乘操作。

LSTM 神经网络的关键在于细胞状态机制,其通过隐含层的门控机制调节信息传递。门控机制包含一个 sigmoid 函数层和一个 pointwise 点乘操作, sigmoid 函数将输入样本数据压缩至 $[0, 1]$ 区间,用于判断信息的重要程度,其中 1 为完全记住,0 为完全忘记。

LSTM 神经网络的门控机制由遗忘门、输入门、输出门组成,因其隐含层中含有 4 个交互层,并以独特的方式进行交互,故每一门都具有独立的权




图 12 LSTM 神经网络结构模型

Fig. 12 LSTM neural network structure model

重和阈值。在信号输入进 LSTM 网络时,第一步就是决定系统要丢弃的信息,此过程由遗忘门进行,如下所示

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (9)$$

式中: W_f 为遗忘门的权重矩阵; h_{t-1} 为前一时间步的输出; x_t 为当前时间步的输入; b_f 为遗忘门的阈值矩阵。

输入门决定哪部分新的信息会被存放在细胞中,其包含两个部分:第一部分为 sigmoid 层,该层决定更新的值,作用效果与遗忘门相同;第二部分为 tanh 层,该层为单元更新层,用于创建新的细胞状态 C'_t 。两部分可分别表示为

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (10)$$

$$C'_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (11)$$

式中: W_i 为输入门权重矩阵; b_i 为输入门的阈值矩阵; W_C 为更新单元的权重矩阵; b_C 为更新单元的阈值矩阵。

完成遗忘门与输入门的计算后,需要进行细胞状态的更新,此时要将遗忘门与输入门的输出信息添加到细胞状态中,即将 C_{t-1} 更新为 C_t , 如下所示

$$C_t = f_t C_{t-1} + i_t C'_t \quad (12)$$

输出门负责决定当前时刻的输出,其组成及原理与输入门一致,输出的最终值为 o_t , 表达式如下

$$o'_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (13)$$

$$o_t = o'_t \tanh C_t \quad (14)$$

式中: W_o 为输出门权重矩阵; b_o 为输出门阈值矩阵。

3.3 LSTM 神经网络解耦模型设计

利用 MATLAB 软件的 LSTM 神经网络工具箱,可以方便地构建 LSTM 神经网络结构基本模

型。本文采用 5 层 LSTM 神经网络,搭建传感器非线性解耦算法模型。

解耦实验所需样本数据集由标定实验获取,实验共得到 5 组标定数据,每组标定数据由一个维度为 6×6 的矩阵组成,包括 36 个数据点(每个加载方向各 6 个),样本数据以组为单位输入解耦算法。将标定数据的 80% 用于训练 LSTM 神经网络解耦算法,20% 用于测试解耦算法的精度。为提升神经网络的训练速度及提高模型的收敛性,利用 MATLAB 中 Mapminmax 函数将实验所需数据进行归一化处理,将样本数调整在 $[-1, 1]$ 之间。这一步不仅提高了计算效率,还有助于提升模型的整体精度和泛化能力,从而确保解耦算法的可靠性。样本归一化公式如下

$$y = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{x_{\max} - x_{\min}} + y_{\min} \quad (15)$$

式中: y 为归一化后的数据; $y_{\max}$ 、 $y_{\min}$ 分别为目标区间的最大值和最小值; x 为待归一化数据; $x_{\max}$ 、 $x_{\min}$ 分别为输入数据的最大值和最小值。

由于 LSTM 神经网络适用于处理时间序列数据,因此需将标定数据进行转换格式。在使用该网络时,可用 MATLAB 中的 Num2cell 函数将六维标定数据转换为单元数组,以适应 LSTM 网络的输入要求。将转换为单元数组标定数据的 6 个力值作为神经网络的输入层数据,将标定加载的 6 个力值作为神经网络的输出层数据。在隐含层中的门控机制使用 sigmoid 函数作为激活函数,在生成更新信息时,使用双曲正切函数 tanh 作为激活函数,然后添加 Relu 函数层对全连接层的输出数据进行非线性激活,最终经全连接层和回归层对数据进行输出。

基于 LSTM 神经网络的非线性解耦算法流程图如图 13 所示。




图 13 基于 LSTM 神经网络的非线性解耦算法流程图
Fig. 13 Flow chart of nonlinear decoupling algorithm based on LSTM neural network

在构建解耦算法模型时,由于模型的不确定性,无法准确获取最佳神经元数进行训练,因此根据经验预设初始隐含层神经元数为 10,每增加 10 个神经元后单独训练网络。隐含层神经元数的最优解由多次训练的结果决定。设置最大迭代次数为 3 000,梯度阈值为 1,初始学习率为 0.05。在训练 2 000 次后降低学习率,将学习率下降因子设置为 0.01,每次迭代重新随机选择 256 个样本进行训练,其他参数为默认值。采用均方根误差 E_{RMSE} 评估隐含层神经元对解耦精度的影响,计算公式如下

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (U_i - U'_i)^2} \tag{16}$$

式中: n 为样本数; U_i 、 U'_i 分别为第 i 个样本的真实值和预测值。

对神经网络进行多次训练,改变隐含层神经元数得到解耦算法的均方根误差,如图 14 所示。由图可见,神经元数的改变对解耦算法影响较大,当神经元数为 50 时,解耦算法的均方根误差最小为 7.7。

采用上述设置完成 LSTM 神经网络解耦算法训练,得到输入层、隐含层和输出层权重矩阵的元素个数分别为 3 600、10 000、600,输入层和输出层阈值矩阵的元素个数分别为 200、12。LSTM 神经网络的训练误差性能曲线如图 15 所示。




图 14 隐含层神经元数对精度的影响
Fig. 14 Comparison of the effect of the number of hidden layer neurons on accuracy




图 15 LSTM 神经网络训练误差性能曲线
Fig. 15 LSTM neural network training error performance curve

3.4 LSTM 解耦算法解耦效果分析

采用 LSTM 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 16~图 21 所示。




图 16 F_z 解耦结果
Fig. 16 Decoupling results of F_z




图 17 F_x 解耦结果

Fig. 17 Decoupling results of F_x




图 18 F_y 解耦结果

Fig. 18 Decoupling results of F_y




图 19 M_z 解耦结果

Fig. 19 Decoupling results of M_z




图 20 M_x 解耦结果

Fig. 20 Decoupling results of M_x




图 21 M_y 解耦结果

Fig. 21 Decoupling results of M_y

从图 16~图 21 可以看出,采用 LSTM 神经网络解耦算法对六维力传感器的输出力进行解耦后,当各向分别施加载荷时,传感器的输出力/力矩曲线显示出良好的测力标准和线性度。此外,当单独施加某一方向的载荷时,其他方向的输出力相对较小,表明传感器的维间耦合效应得到了有效抑制。实验表明:LSTM 神经网络解耦算法显著提高了六维力传感器的解耦性能,使得各个方向上的载荷测量更加精准。该算法不仅提升了测量的准确性和可靠性,还进一步验证了 LSTM 神经网络在处理非线性耦合问题时的强大能力。

3.5 LSTM 解耦算法解耦精度分析

为评估 LSTM 神经网络解耦算法的误差性耦合数值及测量精度,首先,选取 20% 未参与训练的标定样本 U' 进行解耦算法精度测试;然后,将样本 U' 作为输入层数据,经 LSTM 神经网络解耦后得到的输出力矩阵 F'_{LSTM} ;最后,根据神经网络的输入力

$\boldsymbol{F}'$ 和解耦后的输出力 $\boldsymbol{F}'_{\text{LSTM}}$,通过式(2)、式(3) 计算,得到 LSTM 神经网络解耦算法的百分比耦合矩

阵 $\boldsymbol{E}_{\text{LSTM}}$ 。测试样本数据 $\boldsymbol{U}'$ 、输出力矩阵 $\boldsymbol{F}'_{\text{LSTM}}$ 及百分比耦合矩阵 $\boldsymbol{E}_{\text{LSTM}}$ 的具体表达式如下

$$\boldsymbol{U}' = \begin{bmatrix} 6\,825.30 & 8.10 & -22.00 & 303.33 & 4\,150.33 & -443.33 \\ -222.90 & 5\,936.40 & 67.00 & -2\,923.00 & -403.67 & 747.33 \\ -704.10 & -715.20 & 7\,790.00 & 410.00 & -819.33 & -29.00 \\ 54.60 & -616.50 & 12.00 & 654.31 & 54.20 & -0.78 \\ 599.40 & -24.90 & -8.00 & 42.00 & 642.00 & -0.02 \\ -12.90 & -13.50 & -14.00 & -5.10 & -51.84 & -453.21 \end{bmatrix}$$

(17)

$$\boldsymbol{F}'_{\text{LSTM}} = \begin{bmatrix} 2\,991.641\,8 & 0.068\,7 & 0.819\,5 & 2.637\,3 & 3.899\,9 & -0.109\,3 \\ 1.386\,8 & 2\,987.414\,1 & 5.237\,6 & 0.866\,0 & 0.975\,4 & 5.776\,5 \\ -19.997\,4 & 4.228\,4 & 19\,889.842\,0 & 8.820\,3 & 12.594\,5 & 19.869\,8 \\ -0.257\,8 & 0.253\,0 & 0.318\,0 & 478.253\,1 & 0.394\,6 & 0.254\,7 \\ -0.170\,1 & 0.614\,5 & 1.088\,8 & -0.050\,5 & 478.274\,1 & 0.882\,2 \\ -0.167\,7 & 0.044\,9 & 0.129\,8 & 0.067\,0 & 0.094\,6 & 149.474\,9 \end{bmatrix}$$

(18)

$$\boldsymbol{E}_{\text{LSTM}} = \begin{bmatrix} 0.278\,6 & 0.002\,3 & 0.027\,3 & 0.087\,9 & 0.130\,0 & 0.003\,6 \\ 0.046\,2 & 0.419\,5 & 0.028\,9 & 0.030\,0 & 0.032\,5 & 0.192\,5 \\ 0.100\,0 & 0.021\,1 & 0.550\,8 & 0.044\,1 & 0.063\,0 & 0.099\,3 \\ 0.053\,7 & 0.052\,7 & 0.066\,2 & 0.363\,9 & 0.022\,1 & 0.022\,1 \\ 0.035\,4 & 0.128\,0 & 0.226\,8 & 0.010\,5 & 0.359\,6 & 0.183\,8 \\ 0.111\,8 & 0.030\,0 & 0.086\,5 & 0.044\,7 & 0.063\,0 & 0.350\,0 \end{bmatrix}$$

(19)

由式(19)可以看出,经过 LSTM 神经网络解耦后,四点支撑传感器的最大静态非线性误差为 0.55%,发生在采用 F_z 加载时;最大静态交叉耦合误差为 0.23%,发生在采用 M_y 加载时,此时 F_x 的干扰最大。

4 实验结果分析

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 RBF 非线性解耦算法和最小二乘法(LS)线性解耦算法进行比较分析。表 1 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(见式(5))的Ⅰ类误差和Ⅱ类误差对比。3 种解耦算法的最大Ⅰ类误差和Ⅱ类误差对比如图 22 所示。

由图 22 可见,采用 LS 线性解耦方法时,解耦效果较差,解耦后的最大Ⅰ类和Ⅱ类误差分别为 4.26%、3.25%。采用 RBF 神经网络非线性解耦后的最大Ⅰ类和Ⅱ类误差分别为 1.29%、1.53%。采用基于 LSTM 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 0.55%、0.23%。结果表明:基于 LSTM 神经网络的六维力传感器解耦算法效果理想,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。

表 1 3 种解耦算法百分比耦合矩阵形式的误差结果
Table 1 Error results in the form of percentage coupling matrix for three decoupling algorithms

算法	误差/%					
LSTM	0.279	0.002	0.027	0.088	0.130	0.004
	0.046	0.420	0.029	0.029	0.033	0.193
	0.100	0.021	0.551	0.044	0.063	0.099
	0.054	0.053	0.066	0.364	0.022	0.022
	0.035	0.128	0.227	0.011	0.360	0.184
	0.112	0.030	0.087	0.045	0.063	0.350
RBF	0.933	0.113	0.019	0.201	1.533	0.029
	0.453	0.103	0.147	0.166	0.685	0.601
	0.411	0.010	0.109	0.011	0.225	0.556
	0.010	0.067	0.181	0.482	0.046	1.163
	1.001	0.044	0.007	0.012	1.142	0.040
	0.054	0.426	0.227	0.206	0.160	0.088
LS	1.671	2.651	1.356	1.256	0.688	0.189
	0.556	1.865	0.287	2.220	0.627	0.184
	0.370	0.004	2.995	0.052	0.947	0.056
	2.218	0.120	0.255	2.655	1.006	0.362
	0.514	1.346	1.115	0.565	0.652	0.085
	3.255	2.222	0.377	0.478	1.246	4.263




图 22 3 种解耦方法最大误差的对比

Fig. 22 Error comparison of three decoupling methods

5 结 论

为有效提升压电式六维力/力矩传感器的测量精度,降低维间耦合误差,本文基于 LSTM 神经网络开展了传感器非线性解耦算法研究,得到如下主要结论。

(1)基于压电效应分析了四点支撑式压电六维力传感器的测量原理,并结合其标定实验阐述了维间耦合产生的原因,确立了传感器精度测量指标。

(2)分析了传感器非线性解耦的原理,提出基于 LSTM 神经网络的六维力传感器解耦算法,建立了 LSTM 解耦算法模型,并利用 MATLAB 中 Mapminmax 和 Num2cell 函数提升了算法的整体精度和泛化能力。

(3)采用均方根误差为指标,分析对比了不同隐含层神经元数对神经网络精度的影响。结果表明:该指标较好地展示了解耦算法的整体解耦效果,在神经元数为 50 时,均方根误差最小,为 7.7。

(4)基于获取的标定数据分别对 LSTM、RBF 以及 LS 算法进行了训练和验证,对 3 种模型的解耦结果进行了对比。结果显示:经 LSTM 解耦算法解耦后,传感器的最大 I 类和 II 类误差分别降低至 0.55%、0.28%,耦合误差显著减小。

本文研究结果有效降低了传感器非线性测量系统中存在的维间耦合问题,为高精度力传感器的开发以及更精确地进行风洞试验提供了新的解决方案和理论依据。

参考文献:

[1] 唐志共,袁先旭,钱炜祺,等. 高速空气动力学三大手段数据融合研究进展 [J]. 空气动力学学报, 2023, 41(8): 44-58.
TANG Zhigong, YUAN Xianxu, QIAN Weiqi, et al. Research progress on the fusion of data obtained by

high-speed wind tunnels, CFD and model flight [J]. Acta Aerodynamica Sinica, 2023, 41(8): 44-58.

- [2] 周学文,闫华东,吕水燕,等. 高超声速火箭橇气动特性优化与风洞试验 [J]. 西安交通大学学报, 2024, 58(5): 156-166.
ZHOU Xuwen, YAN Huadong, LÜ Shuiyan, et al. Optimization of hypersonic rocket Sled aerodynamic characteristics and wind tunnel tests [J]. Journal of Xi'an Jiaotong University, 2024, 58(5): 156-166.
- [3] 焦林虎,任宗金,张军,等. 六维压电风洞盒式天平研究 [J]. 传感器与微系统, 2024, 43(10): 31-34.
JIAO Linhu, REN Zongjin, ZHANG Jun, et al. Research on six dimensional piezoelectric wind tunnel box balance [J]. Transducer and Microsystem Technologies, 2024, 43(10): 31-34.
- [4] 李荟霖,康雨,赵保华,等. 基于最小二乘的多维力/力矩传感器线性解耦算法研究 [J]. 应用物理, 2024, 14(6): 452-461.
LI Huilin, KANG Yu, ZHAO Baohua, et al. Study of linear decomposition algorithms for multidimensional force/torque sensors based on least squares [J]. Applied Physics, 2024, 14(6): 452-461.
- [5] 彭小武,马国鹭,赵涌,等. 三维力传感器的设计和静态解耦算法研究 [J]. 传感技术学报, 2021, 34(11): 1518-1522.
PENG Xiaowu, MA Guolu, ZHAO Yong, et al. Design of three-dimensional force sensor and research on the static decoupling algorithm [J]. Chinese Journal of Sensors and Actuators, 2021, 34(11): 1518-1522.
- [6] LI Yingjun, WANG Guicong, YANG Xue, et al. Research on static decoupling algorithm for piezoelectric six axis force/torque sensor based on LSSVR fusion algorithm [J]. Mechanical Systems and Signal Processing, 2018, 110: 509-520.
- [7] 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 Zhijun, ZHANG Xiaotao, LI Mengxiang. Research on decoupling algorithm of six-dimensional force sensor based on polynomial fitting [J]. Chinese Journal of Engineering Design, 2023, 30(5): 571-578.
- [8] 石中盘,赵铁石,厉敏,等. 大量程柔性铰六维力传感器静态解耦的研究 [J]. 仪器仪表学报, 2012, 33(5): 1062-1069.
SHI Zhongpan, ZHAO Tieshi, LI Min, et al. Research on static decoupling of large range flexible joint six-axis force sensor [J]. Chinese Journal of Scientific Instrument, 2012, 33(5): 1062-1069.

- [9] 查浩, 费少华, 傅云, 等. 基于 EtherCAT 总线的六维力传感器在线解耦技术 [J]. 浙江大学学报(工学版), 2023, 57(10): 2042-2050.
ZHA Hao, FEI Shaohua, FU Yun, et al. Online decoupling technology of six-dimensional force sensor based on EtherCAT bus [J]. Journal of Zhejiang University (Engineering Science), 2023, 57(10): 2042-2050.
- [10] 徐志成, 关佳希, 周兴林. 基于 ReLU 函数的轮胎接触三向力传感器解耦方法 [J]. 仪表技术与传感器, 2023(4): 77-82.
XU Zhicheng, GUAN Jiashi, ZHOU Xinglin. ReLU function-based decoupling method for tyre path contact three-way force sensors [J]. Instrument Technique and Sensor, 2023(4): 77-82.
- [11] 张家敏, 许德章. 基于蚁群 BP 神经网络算法的六维力传感器解耦研究 [J]. 轻工机械, 2016, 34(1): 1-4, 13.
ZHANG Jiamin, XU Dezhong. Study on decoupling algorithms for six-axis force sensor based on ant algorithm and BP neural network [J]. Light Industry Machinery, 2016, 34(1): 1-4, 13.
- [12] 张军, 王康, 钱敏, 等. 压电矢量力传感器力分量解耦与实验研究 [J]. 仪表技术与传感器, 2016(1): 1-3.
ZHANG Jun, WANG Kang, QIAN Min, et al. Component decoupling of piezoelectric vector force sensor and experiment research [J]. Instrument Technique and Sensor, 2016(1): 1-3.
- [13] LI Yingjun, YANG Cong, WANG Guicong, et al. Research on the parallel load sharing principle of a novel self-decoupled piezoelectric six-dimensional force sensor [J]. ISA Transactions, 2017, 70: 447-457.
- [14] 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 Yingjun, HAN Binbin, WANG Guicong, et al. Decoupling algorithms for piezoelectric six-dimensional force sensor based on RBF neural network [J]. Optics and Precision Engineering, 2017, 25(5): 1266-1271.
- [15] 孙世政, 庞珂, 于竞童, 等. 基于白鲨优化极限学习机的三维力传感器非线性解耦 [J]. 光学精密工程, 2023, 31(18): 2664-2674.
SUN Shizheng, PANG Ke, YU Jingtong, et al. Non-linear decoupling of 3D force sensors based on WSO-ELM [J]. Optics and Precision Engineering, 2023, 31(18): 2664-2674.
- [16] 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 Wei, ZHANG Xiao, YUAN Dong, 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.
- [17] 董翔, 许子健, 曹会彬, 等. 基于 IFWA-ELM 的六维力传感器解耦算法 [J]. 传感技术学报, 2023, 36(12): 1943-1951.
DONG Xiang, XU Zijian, CAO Huibin, et al. Decoupling algorithm of Six-Axis force sensor based on IFWA-ELM [J]. Chinese Journal of Sensors and Actuators, 2023, 36(12): 1943-1951.
- [18] 张军, 蔡佳乐, 王郁赫, 等. 基于 HSA-SVR 的压电式车削测力仪多维力解耦 [J]. 仪表技术与传感器, 2024(6): 26-29.
ZHANG Jun, CAI Jiale, WANG Yuhe, et al. Decoupling for multidimensional force of piezoelectric turning dynamometer based on HSA-SVR [J]. Instrument Technique and Sensor, 2024(6): 26-29.
- [19] LI Yingjun, WANG Guicong, ZHANG Shuai, et al. Design and calibration of spoke piezoelectric six-dimensional force/torque sensor for space manipulator [J]. Chinese Journal of Aeronautics, 2024, 37(1): 218-235.
- [20] 曹会彬, 孙玉香, 刘利民, 等. 多维力传感器耦合分析及解耦方法的研究 [J]. 传感技术学报, 2011, 24(8): 1136-1140.
CAO Huibin, SUN Yuxiang, LIU Limin, et al. Coupling analysis of multi-axis force sensor and research of decoupling method [J]. Chinese Journal of Sensors and Actuators, 2011, 24(8): 1136-1140.
- [21] 赵鹏, 王桂从, 李映君, 等. 组合式自解耦压电薄膜三维力传感器研制 [J]. 西安交通大学学报, 2023, 57(3): 139-149.
ZHAO Peng, WANG Guicong, LI Yingjun, et al. Development of combined self-decoupling piezoelectric thin film three-dimensional force sensor [J]. Journal of Xi'an Jiaotong University, 2023, 57(3): 139-149.
- [22] 马俊青, 宋爱国, 吴涓. 三维力传感器静态解耦算法的研究与应用 [J]. 计量学报, 2011, 32(6): 517-521.
MA Junqing, SONG Aiguo, WU Juan. Research and application of static decoupling for 3-axis wrist force sensor [J]. Acta Metrologica Sinica, 2011, 32(6): 517-521.
- [23] 陈保家, 陈学力, 沈保明, 等. CNN-LSTM 深度神经网络在滚动轴承故障诊断中的应用 [J]. 西安交通大

- 学学报, 2021, 55(6): 28-36.
- CHEN Baojia, CHEN Xueli, SHEN Baoming, et al. An application of convolution neural network and long short-term memory in rolling bearing fault diagnosis [J]. Journal of Xi'an Jiaotong University, 2021, 55(6): 28-36.
- [24] ZHANG Dongxiao, CHEN Yuntian, MENG Jin. Synthetic well logs generation via recurrent neural networks [J]. Petroleum Exploration and Development, 2018, 45(4): 629-639.
- [25] 吴全玉, 刘美君, 范家琪, 等. 遗传算法与修正的自适应矩估计优化循环神经网络的心音分类方法 [J]. 南京理工大学学报, 2024, 48(2): 202-208, 226.
- WU Quanyu, LIU Meijun, FAN Jiaqi, et al. Heart sound classification method combining GA with rectified Adam for RNN optimization [J]. Journal of Nanjing University of Science and Technology, 2024, 48(2): 202-208, 226.
- [26] 刘颖, 杨鹏飞, 张立军, 等. 前馈神经网络和循环神经网络的鲁棒性验证综述 [J]. 软件学报, 2023, 34(7): 3134-3166.
- LIU Ying, YANG Pengfei, ZHANG Lijun, et al. Survey on robustness verification of feedforward neural networks and recurrent neural networks [J]. Journal of Software, 2023, 34(7): 3134-3166.
- [27] LIN Chenxiao, TAN Yidong, WANG Qingxuan. Machine learning-based prediction approach for ranging resolution enhancement of FMCW LiDAR system with LSTM networks [J]. Optics & Laser Technology, 2024, 179: 111299.
- [28] 张译文, 王志恒, 邱睿贤, 等. 利用长短期记忆神经网络的改进 POD-Galerkin 降阶模型及其在流场预测中的应用 [J]. 西安交通大学学报, 2024, 58(2): 12-21.
- ZHANG Yiwen, WANG Zhiheng, QIU Ruixian, et al. Improved POD-Galerkin reduced order model with long short-term memory neural network and its application in flow field prediction [J]. Journal of Xi'an Jiaotong University, 2024, 58(2): 12-21.

(编辑 李慧敏)