

基于深度学习补偿的容栅传感器非线性误差校正方法研究

杨广禄

(桂林市晶瑞传感技术有限公司, 广西 桂林 541004)

摘要 容栅传感是量具行业核心支撑技术, 具备非接触测量、低功耗、低成本、高稳定性等突出优势, 在精密加工与检测领域发挥关键作用。深化该技术研究, 既能推动测量精度、响应速度等核心性能提升, 也能为其在智能制造、消费电子等新兴领域的创新应用筑牢基础, 助力产业升级与消费场景拓展。目前该技术虽已发展成熟, 但受测量精度限制, 在高端测量领域的应用拓展遭遇明显瓶颈。基于此, 本文提出一种基于 CBB-LTM 深度学习的容栅传感器非线性误差校正方法。该方法系统解析误差来源并构建误差数据库, 设计融合时序分析与特征提取的混合校正模型。经理论仿真与试验验证, 该方法可有效抑制非线性误差, 显著提升传感器测量精度, 完全满足工程实际应用需求。

关键词 容栅传感器; 非线性误差; 深度学习; CBB-LTM 模型; 误差校正技术

中图分类号: TP212

文献标志码: A

DOI: 10.3969/j.issn.2097-3365.2026.19.004

0 引言

容栅传感技术是一种非接触测量计数, 其技术原理为电容耦合原理, 具备结构简单、分辨率高、抗干扰性强的优势, 广泛应用于量具测量与精密检测领域, 测量精度为其核心性能指标。在实际工况下, 栅极边缘效应、寄生电容、温度漂移及加工偏差会产生非线性误差, 大幅降低测量精度。针对该问题的补救方案有多项式拟合、线性插值、硬件补偿等, 但是上述方案难以适配多误差耦合场景。还有一种具有一定拟合能力的 BP 神经网络补偿方案, 但其特征提取能力弱, 无法提取准确的误差细节。

国内外针对容栅传感器精度提升已开展大量研究: 国外依托工业积累, 聚焦材料稳定性与栅极蚀刻工艺优化; 国内兼顾工艺升级, 同时依托算力开展最小二乘法、神经网络、遗忘滤波等算法补偿。但现有研究均聚焦趋于线性的或非线性耦合项较少的情况下做了理想模型的设计, 在复杂的非线性补偿领域始终是一片空白; 传统方法高精度补偿能力不足, 深度学习模型结构单一, 未兼顾多特征耦合与时序问题, 泛化能力不足^[1]。

本文提出了适配容栅传感器的 CBB-LTM 混合深度学习校正模型, 为解决单一模型精度不足的问题, 构建了融合实测与仿真数据的多因素耦合数据集, 旨在

大大提升模型泛化能力, 且通过仿真与实验验证该方法的有效性。本文主要通过对接容栅传感器误差产生来源进行研究, 结合容栅传感器误差产生理论, 将二者结合在一起进行了耦合数据集搭建, 完成了 CBB-LTM 模型设计、仿真及实验验证三个环节, 形成了完备的验证流程。本研究的核心创新点是提出了 CBB-LTM 混合模型, 将 CBB 特征值和 LTM 时序进行融合适配多误差场景, 在保证精度的前提下降低复杂度、提升实用性。

1 容栅传感器非线性误差机理分析

1.1 非线性误差核心来源

容栅传感器因其理论原理和制造工艺等原因, 其主要误差来源于以下几个方面: 一是由栅极边缘效应引起极板边缘电容畸变、电场耦合不均匀造成非线性误差, 由寄生电容干扰破坏差动电容平衡造成零点漂移、幅值失衡等造成理论误差, 还有栅极尺寸加工误差, 平面度、翘曲变形误差, 电极镀膜与基材误差等传感器自身误差; 二是动定栅安装间隙不均匀造成电容灵敏度波动导致温漂敏感加剧, 还有安装偏心和机械回程空程等装配误差; 三是温度改变介质介电常数, 导致机体热胀冷缩、电极尺寸形变等产生零点漂移, 湿度、油污、粉尘等改变传感器表面等效电阻, 使漏电流增大造成输出偏移, 电磁干扰造成信号耦合产生

作者简介: 杨广禄 (1992-), 男, 本科, 工程师, 研究方向: 容栅传感技术算法及应用。

随机误差；四是电路及信号采集造成的误差，如激励源相位不纯、频率漂移破坏差动调节平衡，运放失调、采样串扰引入直流偏置与高频噪声，解调算法存在理论误差等。从工程实践数据可以看出，在不进行补偿时， $0\ \mu\text{m} \sim 80\ \mu\text{m}$ 测量范围内最大非线性误差达 $10\ \mu\text{m}$ ，温漂误差增量为 $0.15\ \mu\text{m}/^\circ\text{C}$ [2]。

1.2 误差机理与传统方法局限性

容栅传感器非线性误差是多误差共同耦合的结果，具有复杂的非线性与时序相关性。在传统方法中，多项式拟合及线性插值仅能应对简单误差且需要大量数据做补偿依据。例如：线性插补方式需要对传感器进行全量程补偿前数据测量，然后将测量数据与标准数据做对比做出补偿查询表，其中补偿步进值的选取直接决定补偿效果的好坏，不但占用生产时间，还占用芯片内存，更不能满足大量程传感器工程实现要求，无法解决多因素构成的复杂精度问题。例如：由传感器本身加工及环境温度变化共同作用造成的非线性误差，若使用线性插补方案进行补偿，则只能补偿在某一温度范围内的制造误差，而当温度变化时则无法进行全温区适配，若需进行全温区补偿则需结合制造误差一起将温区分成不同区间进行逐个补偿，这种补偿方案会造成工作内容翻倍导致效率严重低下。此外，还有一种叫做 BP 神经网络特征提取的补偿方式，该方式则存在提取效率低、难以捕捉误差时序与耦合特性的问题。实测数据表明，多项式拟合校正后最大误差 $0.58\ \mu\text{m}$ ，BP 神经网络校正后最大误差 $0.32\ \mu\text{m}$ ，均无法满足高端场景 $\pm 0.1\ \mu\text{m}$ 的精度要求 [3]。

2 深度学习校正模型设计

2.1 模型总体设计

结合容栅传感器的误差耦合特性与时序特征，设计出基于输入层、特征提取层、时序耦合层、融合层与输出层的 CBB-LTM 混合深度学习校正模型，该模型不但能够实现静态误差补偿，还能实现动态时序误差的协同补偿。各层具体描述如下：

输入层采用归一化处理，将位移测量值、温度、湿度三个因素转换为 $0 \sim 1$ 区间的数据来消除量纲影响提升模型训练收敛速度，其中测量位移值在 $0\ \mu\text{m} \sim 100\ \mu\text{m}$ 范围内取值，温度在 $-10\ ^\circ\text{C} \sim 60\ ^\circ\text{C}$ 范围内取值，湿度在 $40\% \text{ RH} \sim 80\% \text{ RH}$ 范围内取值。

特征提取层采用 2 层 CBB 结构实现，第一层是用于提取边缘效应及寄生电容等静态误差特征的卷积层，其特征为卷积核大小 3×3 ，数量 32，步长 1，填充方式为 same；第二层是数据核大小为 2×2 ，步长为 2 的缓冲层，该层主要用于配合第一层来抑制过拟合保留

核心误差特征，避免无用数据对结果产生冲击 [4]。

时序耦合层则采用 1 层 LTM 结构将 CBB 提取的静态特征作为输入传输到该层，该层共设置 64 个隐藏层神经元，同时还配有遗忘门、输入门及输出门控制单元，该单元不但能够捕捉温度漂移和动态位移等时序误差的演化规律，还能解决静态模型无法适配动态误差的缺陷。

融合层采用全连接层方案将 CBB 静态特征与 LTM 时序特征进行加权融合（权重分别为 0.6 和 0.4），然后通过 ReLU 激活函数进一步将数据进行融合，该方式不但能增强特征表达能力，还能避免特征冗余，提高输出数据的准确性。

输出层则由线性激活函数实现，可输出包含误差补偿量和校正后位移值的二维结果。

2.2 数据集构建与预处理

基于上述模型构建的融合实测与仿真数据的多因素耦合误差数据集，不但能够确保数据的全面性与真实性，而且还能为后续模型训练提供可靠支撑。首先采用量程为 $0\ \mu\text{m} \sim 100\ \mu\text{m}$ 、分辨率为 $0.01\ \mu\text{m}$ 的容栅传感器，精度等级为 $\pm 0.05\ \mu\text{m}$ 的精密位移台及温湿度箱采集 1 000 组实验数据；其次采用 MATLAB 搭建起容栅传感器误差仿真平台，通过构建模拟边缘效应、寄生电容、加工偏差的仿真模块模拟出共同的耦合影响。此外，再补充 200 组 $-10\ ^\circ\text{C}$ 、 $60\ ^\circ\text{C}$ 极端温度及 $80\% \text{ RH}$ 极端湿度下的极端工况数据用于弥补实测数据极端工况覆盖不足的缺陷。

数据集预处理步骤分为以下四个方面：一是数据清洗，采用 3σ 准则剔除 12 组异常数据，避免异常值影响模型训练精度；二是利用归一化处理方式，采用 min-max 归一化方法，将所有数据映射至 $0 \sim 1$ 区间，该方式不但能够消除量纲差异，还能加速模型收敛；三是通过添加随机噪声、时序平移等方式实现数据增强，将总测量数据集扩充至 2 400 组以避免模型过拟合；四是通过对动态位移数据进行时序对齐处理，确保 LTM 输入数据的时序一致来提升时序误差建模精度；五是数据集按 7:2:1 比例划分为训练集（1 680 组）、验证集（480 组）及测试集（240 组）三个集合，综合实现对误差的补偿 [5]。

2.3 模型训练与优化

本文采用 TensorFlow/Keras 框架进行模型训练，首先，选用均方误差 MSE 为损失函数以衡量模型输出与真实值的偏差；其次，选用学习率为 0.001、迭代次数 100 次、批次大小 32、动量系数 0.9、权重衰减系数 0.001 的 Adam 优化器，该优化器的主要作用是避免模型

过拟合与训练震荡；再次，为抑制过拟合，在CBB层与LTM层之间再添加一层dropout正则化层，dropout系数设置为0.3用于随机丢弃30%的神经元，减少特征冗余与过拟合风险；最后，配合patience=10的早停策略，当验证集MSE连续10次不下降时则停止训练，以保存最优模型参数。实测中，当观察到模型训练集损失值逐步下降且验证集损失值趋于稳定时，验证集中MSE值为0.0018，决定系数 R^2 为0.9982，该数值表明模型拟合效果能够精准捕捉误差特征^[6]。

3 仿真与实验验证

3.1 仿真验证

基于MATLAB/Simulink搭建仿真平台，导入误差机理模型与CBB-LTM混合模型，仿真数据如表1所示。

表1 不同校正方法仿真效果对比表（单位： μm ）

校正方法	单一误差场景 （最大误差）	耦合误差场景 （最大误差）	动态误差场景 （最大误差）	MSE	R^2
多项式拟合	0.56	0.89	0.95	0.0126	0.0972
BP神经网络	0.31	0.45	0.52	0.0048	0.989
CBB-LTM混合模型	0.08	0.15	0.18	0.0017	0.998

（注：测试集300组数据统计结果。）

表2 不同校正方法实验效果对比表（单位： μm ）

校正方法	最大测量误差	平均测量误差	测量精度	实时响应时间
未校正	1.20	0.78	$\pm 1.2 \mu\text{m}$	—
多项式拟合	0.58	0.32	$\pm 0.6 \mu\text{m}$	5 ms
BP神经网络	0.32	0.18	$\pm 0.3 \mu\text{m}$	12 ms
CBB-LTM混合模型	0.09	0.05	$\pm 0.1 \mu\text{m}$	8 ms

（注：常温25℃、湿度60%RH，50组实测数据统计。）

校正后测量精度达到 $\pm 0.1 \mu\text{m}$ ，相比未校正精度提升了60%，而响应时间小于10ms，满足应用需求。

4 结束语

针对容栅传感器精度难以提升的问题，本文提出校正模型充分发挥了CBB与LTM的优势，主要将传感器误差产生的原理及规律进行捕捉，其推理型补偿方案对传感器精度补偿相较传统方案效果明显，同时兼顾了工程实现难度，在工程实现与精度提升之间达到平衡。虽然该方案可以有效提升容栅传感器非线性误差补偿效果，但是该模型仍然存在不足，无法解决极端环境下的精度补偿问题，未来将持续对模型进行优化，探索新一代混合测试模型，解决在极端环境下的精度校准问题，将校准方案推广至高端精密测量领域，为容栅传感器进一步发展提供有力保障。

仿真结果表明，该模型在校正精度、MSE与 R^2 上均优于传统方法，多误差耦合场景下精度较多项式拟合提升83.1%、较BP神经网络提升66.7%，泛化能力良好。

3.2 实验验证

搭建包括容栅传感器（ $0 \mu\text{m} \sim 80 \mu\text{m}$ ，分辨率为 $0.01 \mu\text{m}$ ）、精密位移台（ $\pm 0.05 \mu\text{m}$ ）、温湿度箱等的试验平台，构建基于Python的分析模型实现数据实时采集与校正。实验数据如表2所示。

通过实验结果可以看出，在 $-10^\circ\text{C} \sim 60^\circ\text{C}$ 范围内，本模型温漂系数 $0.001 \mu\text{m}/^\circ\text{C}$ ，与校准之前数据对比，该模型温漂降低了93.3%；与BP神经网络补偿后数据对比，该模型降低了66.7%。综合来看，本模型

参考文献：

- [1] 王赛飞. 容栅位移传感器技术研究及其应用量具开发[D]. 西安: 西安理工大学, 2023.
- [2] 苏自煜, 顾崇林, 郝一旭, 等. 基于容栅技术与改进LSTM的电梯制动器间隙监测预警方法[J]. 现代电子技术, 2026, 49(06): 77-82, 88.
- [3] 马世东. 多反射极相位补偿型容栅传感器位移测量方法及实验研究[D]. 西安: 西安理工大学, 2024.
- [4] 侯贤琴, 徐光学, 乔小强, 等. 基于TCN-LSTM-CMA自编码器的无监督异常检测[J]. 计算机技术与发展, 2026(08): 139-153.
- [5] 郭甜甜, 赵海, 葛辛, 等. 基于容栅技术的位移数据处理专用芯片设计[J]. 空天预警研究学报, 2025, 39(04): 299-303.
- [6] 孔萌萌. 高分辨率电容位移传感器及其应用研究[D]. 合肥: 中国科学技术大学, 2024.