

智能传感器在测控系统中的误差补偿研究

柳聪豪

驻马店市产品质量检验检测中心 河南 驻马店 463000

摘要: 智能传感器是测控系统的感知核心,其测量精度直接决定系统性能。受内部机理限制与外部环境干扰,传感器运行中易产生各类误差。本文聚焦智能传感器误差补偿技术,首先解析其内涵与测控系统架构,系统分类误差来源;其次探讨传统硬件与软件补偿方法的原理及局限,重点研究基于机器学习的智能补偿策略,涵盖误差建模、特征提取、算法优化等环节;最后提出多传感器融合补偿方案。研究表明,机器学习可有效处理非线性与时变误差,多传感器融合通过冗余信息实现相互校准,二者结合为提升传感器精度提供新路径,为复杂工况下高精度应用提供理论支撑。

关键词: 智能传感器;测控系统;误差补偿;机器学习;多传感器融合

引言:测控系统是智能制造、航空航天、智慧城市等领域的技术基石,其核心功能是通过精确感知实现有效控制。智能传感器作为系统的“感知末梢”,负责将物理量转化为可处理的电信号,其测量精度直接影响系统可靠性。近年来,机器学习技术凭借其强大的非线性建模能力,为误差动态补偿提供了新方向;多传感器融合策略则通过信息互补与冗余校准,进一步提升了测量鲁棒性。本文系统梳理智能传感器误差补偿技术,探讨机器学习与多传感器融合的应用潜力。

1 智能传感器与测控系统概述

1.1 智能传感器的定义

智能传感器是具备信息处理能力的新型传感器,它将敏感元件与微处理器结合,拥有自感知、自诊断、自补偿、自校准及通信交互等智能化功能。与传统传感器仅做信号转换不同,它集成多种单元,能对原始测量数据初步处理、误差校正等。发展上,从分立元件集成到片上系统集成,正朝低功耗等方向深入。功能层次上,不仅能基础测量,还能预测自身状态、调整参数、协同测量。其智能化特性适应复杂测控场景,也为软件误差补偿提供了操作平台。

1.2 测控系统的基本架构

测控系统由传感器、信号调理电路等部分组成,基本功能是测量被测对象状态参数并控制。从信息流动看,呈分层架构:感知层获取物理量信息;传输层传送信息;处理层处理数据提取特征;应用层生成指令驱动执行机构。测量精度向后端传递,前端传感器偏差可能导致控制失效。现代测控系统呈分布式,多个传感器节点协同工作形成大规模网络。系统复杂度提升,对传感器测量一致性和长期稳定性要求更高^[1]。

1.3 智能传感器在测控系统中的角色

智能传感器在测控系统里是感知中枢与技术基座,作为感知中枢,它是系统获取外部信息的唯一途径,测量质量决定系统对物理世界认知的准确性,如精密制造和结构健康监测中,传感器误差会带来严重后果。作为技术基座,其智能化水平影响系统功能边界,自补偿和通信能力可减轻后端压力、支撑高级功能。从系统集成看,它将传统测控系统分散功能下沉至传感器端,实现功能分布式部署,使系统架构更简洁、响应更快,推动测控系统向边缘智能模式演进。

2 智能传感器误差来源与分类

2.1 内部误差

内部误差主要因传感器自身结构、材料特性及制造工艺的固有局限而产生。敏感元件非线性特性是常见内部误差源,多数物理敏感元件输入输出关系并非理想直线,量程两端常呈饱和或弯曲特征。温度漂移也较为显著,敏感材料的关键参数随温度改变,使零点输出与灵敏度偏移。制造工艺不一致会导致同一批次传感器存在离散性,性能参数有差异。时漂与老化效应同样不可忽视,长期运行中敏感材料物理化学变化,性能参数缓慢退化。此外,封装应力、引线电阻、内部噪声等也影响测量精度。内部误差具规律性和可重复性,为建模补偿提供可能,但不同误差因素相互耦合,综合影响复杂,增加了补偿难度。

2.2 外部误差

外部误差由传感器使用环境和工作条件引发,具有不确定性和时变性。温度影响常见,环境温度偏离标定温度时,传感器内部机械结构、电子元件、敏感材料特性变化,共同影响测量结果。工业现场电磁干扰突出,

设备产生的电磁辐射耦合进传感器信号链路, 叠加在真实信号上。机械振动与冲击干扰敏感元件稳定状态, 对惯性传感器影响大。供电电压波动改变内部电路工作点, 影响放大倍数与偏置电压。安装误差也不容小觑, 安装位置、角度偏差及接触不良会引入额外误差。化学环境中, 腐蚀性气体等会侵蚀敏感元件表面, 改变响应特性。外部误差变化规律难预知且与内部误差交织, 要求补偿方法具备自适应能力。

2.3 误差分类

依据不同维度对误差进行分类, 有助于选择合适的补偿策略。按照误差性质划分, 可分为系统误差与随机误差。系统误差在相同条件下具有确定规律, 来源于传感器结构原理、制造缺陷或固定环境因素, 可通过建模与校准加以消除。随机误差呈现无规则波动, 来源于热噪声、散粒噪声、量化误差等, 难以精确预测, 通常采用滤波方法抑制。按照误差变化速度划分, 可分为静态误差与动态误差。静态误差指输入量为恒定或缓慢变化时传感器输出与真值的偏差, 主要表现为非线性、迟滞、重复性等指标^[2]。动态误差指输入快速变化时传感器由于惯性、阻尼等特性导致输出无法及时跟踪输入的偏差, 反映为幅值衰减与相位滞后。按照误差依赖因素划分, 可分为与输入量相关的误差、与时间相关的误差、与环境因素相关的误差。与输入量相关的误差表现为非线性的输入输出关系; 与时间相关的误差表现为长期稳定性或周期性漂移; 与环境因素相关的误差表现为温度、湿度、电磁场等环境参数的函数。科学分类是精准补偿的前提。

3 智能传感器误差补偿技术

3.1 传统误差补偿方法

3.1.1 硬件补偿

硬件补偿通过在传感器信号链路中引入补偿元件来抵消误差影响。温度补偿是最典型的硬件补偿应用, 常用的方法包括在敏感元件附近布置热敏电阻或热电偶, 将温度信号引入补偿电路, 通过差分结构消除共模温度漂移。在应变式传感器中, 采用四个应变片组成全桥结构, 利用相邻桥臂的温度系数相互抵消, 实现自补偿。电桥调零电路通过可调电阻修正零点偏移, 增益调节电路通过可编程放大器校正灵敏度偏差。屏蔽与滤波电路用于抑制电磁干扰, 金属屏蔽壳隔离外界电场, 滤波网络滤除高频噪声成分。硬件补偿的优势在于响应速度快、不占用处理器资源, 适用于实时性要求高的场景。但其局限性也十分明显: 补偿电路增加硬件成本与空间占用, 设计完成后灵活性差, 难以应对多维耦合误差和

时变特性; 模拟元件的自身漂移还会引入新的误差源。随着数字处理技术发展, 硬件补偿在现代智能传感器中逐渐让位于软件补偿, 但在特定要求低功耗、高可靠性的应用场景中仍有不可替代的地位。

3.1.2 软件补偿

软件补偿利用微处理器的计算能力对传感器原始输出进行后处理, 以实现误差校正。查表法是最基础的软件补偿方式, 预先通过标定实验获取不同输入条件下的误差数据存入非易失存储器, 实际测量时通过查表与插值得到补偿值。该方法原理简单、计算量小, 适用于单调变化的误差场景, 但存储空间随标定点数增加而快速增长, 无法完全连续覆盖全量程。多项式拟合法将误差建模为输入量与环境参数的幂函数组合, 采用最小二乘法确定拟合系数, 补偿时直接代入公式计算。该方法数据压缩效率高, 但阶数过高时容易产生龙格现象, 在量程边界处出现剧烈振荡。插值法在标定点之间采用线性、抛物线或样条插值, 在存储量与补偿精度之间取得折中。软件补偿相比硬件补偿具有灵活性高、成本低、易于升级等优势, 能够实现较复杂的非线性校正^[3]。然而, 传统软件补偿方法本质上是基于预先标定的开环修正, 当传感器特性随时间老化或因未建模因素变化时, 补偿效果会逐渐退化, 难以满足长期稳定运行需求。

3.2 基于机器学习的智能补偿方法

3.2.1 误差建模与特征提取

机器学习方法用于误差补偿的核心在于从数据中自动学习误差规律, 而非依赖人工设定数学模型。误差建模的第一步是数据采集, 在可控实验条件下覆盖传感器全量程以及可能遭遇的各种环境变化, 同步记录传感器输出与参考真值, 构建包含输入量、环境参数、输出误差的训练样本集。特征提取是决定模型性能的关键环节, 需要从原始测量数据中提取与误差相关的有效特征。对于温度漂移补偿, 温度值和温度变化率是必要特征; 对于非线性补偿, 输入量的高阶项可以增强模型表达能力; 对于动态误差补偿, 历史时刻的测量值能够反映系统状态演变。在多维误差耦合场景下, 特征工程还需要考虑交叉项的影响。特征提取的质量直接影响模型的收敛速度和泛化能力, 优秀的特征能够降低模型复杂度、减少训练样本需求。智能传感器的嵌入式资源有限, 特征维度的选择需要在补偿精度与计算开销之间权衡。随着深度学习技术发展, 部分研究开始探索自动特征提取方法, 通过卷积或循环神经网络结构直接从原始时序数据中提取深层次特征。

3.2.2 常用算法

适用于智能传感器误差补偿的机器学习算法种类丰富,各有特点。反向传播神经网络因其结构简单、非线性逼近能力强而获得广泛应用,通过输入层接收传感器输出与环境参数,隐含层进行非线性变换,输出层给出补偿后测量值,训练过程依据误差反向传播调整连接权重。径向基函数网络采用局部响应机制,训练速度优于反向传播网络,尤其适合存在局部非线性特征的误差场景。支持向量机回归基于结构风险最小化原则,在小样本条件下表现出良好的泛化能力,适合标定成本高昂的传感器应用。极限学习机随机初始化输入层权重与隐含层偏置,仅需计算输出层权重,训练效率极高,适合资源受限的嵌入式实现。长短期记忆网络专门处理时间序列数据,能够捕捉误差的动态演化规律,对时漂补偿和动态误差补偿具有独特优势。模糊逻辑系统利用隶属度函数描述误差的不确定性,将专家经验与数据学习相结合,可解释性强。在实际应用中,算法选择需要综合考虑传感器类型、误差特性、硬件资源、实时性要求等多重因素。

3.2.3 模型训练与优化

模型训练与优化是将误差补偿算法从理论转化为有效应用的关键环节。训练过程需要遵循严格的数据划分原则,将采集的样本数据随机分为训练集、验证集和测试集,分别用于模型参数学习、超参数调优和最终性能评估。训练集的规模直接影响模型的泛化能力,样本量不足时容易发生过拟合,样本量过大则可能包含冗余信息。正则化技术通过在损失函数中引入权重衰减项抑制模型复杂度,降低过拟合风险。交叉验证方法充分利用有限数据资源,通过多次训练与验证的平均结果评估模型稳定性。超参数优化包括网络层数、神经元数量、学习率、正则化系数等,通常采用网格搜索、随机搜索或贝叶斯优化策略。模型剪枝与量化是面向嵌入式部署的重要优化手段,通过移除冗余连接、压缩权重精度,在保持补偿精度的前提下大幅降低存储与计算需求。增量学习技术使模型具备在线更新能力,传感器长期运行中持续积累新数据,在不遗忘已有知识的前提下微调模型参数,适应传感器时变特性。经过充分训练与优化的补偿模型能够在智能传感器微控制器上实时运行,实现嵌入式智能补偿^[4]。

3.3 多传感器融合补偿策略

多传感器融合补偿策略利用多个传感器之间的协同

关系进一步提升测量精度与可靠性。其理论基础在于不同传感器的误差特性往往不相关,通过融合处理可以使误差相互抵消。按照融合层次划分,融合补偿可分为数据级融合、特征级融合和决策级融合。数据级融合直接在原始测量数据层面进行加权平均或卡尔曼滤波,简单易行但要求各传感器观测同一物理量且具有可比性。特征级融合从各传感器数据中提取误差特征,建立统一的误差模型进行补偿。决策级融合对各传感器独立补偿后的结果进行综合评判,适用于异构传感器协同工作的场景。卡尔曼滤波是融合补偿的重要工具,通过系统状态方程和观测方程递归估计真实值,能够有效融合历史信息与当前测量,同时给出估计的不确定性。当多个传感器量程重叠但精度不同时,可采用加权融合策略,依据各传感器实时估计的方差动态分配权重,使融合结果偏向于当前更可靠的传感器。对于测量维度互补的传感器组合,如加速度计与陀螺仪的融合,利用两者误差特性的差异实现相互校正。多传感器融合不仅提升精度,还增强了系统的容错能力,当某个传感器失效或受强干扰时,系统仍能依靠其他传感器维持基本功能,这一特性在航空航天、自动驾驶等安全关键领域尤为重要。

结束语

智能传感器测量精度关乎测控系统性能,误差补偿研究兼具理论与工程价值。本文梳理基础概念,剖析误差内外成因并分类,指出传统补偿方法存在灵活性不足等局限;机器学习补偿通过数据建模逼近复杂误差,特征提取、算法优化是关键;多传感器融合利用冗余信息提升精度。未来需探索轻量化嵌入式算法、在线自适应补偿及跨工况迁移学习,推动智能传感与人工智能深度融合,引领测控系统向高精度、强鲁棒性方向演进。

参考文献

- [1]刘龙兵,李迎鑫,李彩霞,等.可编程智能测控系统在石化工业中的应用研究[J].现代工业经济和信息化,2023,13(6):110-113,117.
- [2]杨洪佳.测控技术与仪器在实践中的应用研究[J].科技与创新,2022,(06):132-134+138.
- [3]黄美益.基于深度学习算法的图像传感器误差自动校正研究[J].自动化技术与应用,2023,42(5):8-11.
- [4]展一贤.智能传感器在机械设备状态监测中的应用探讨[J].仪器仪表用户,2026,33(2):111-113.