文章编号:1674-7607(2026)10-0001-08 DOI:10.19805/j.cnki.jcspe.2026.250567

多传感器融合技术在锅炉状态监测中的应用

罗 伟, 王增慧, 郑 波, 蔡 伟, 蓝苹瑕
(贵州省习水鼎泰能源开发有限责任公司,贵州遵义 564611)

摘 要: 在复杂环境的锅炉状态监测中,单一传感器往往难以提供全面准确的信息。提出了一种基于多传感器融合的监测方法,通过整合不同类型传感器数据提升系统性能。分析了系统构建原则及卡尔曼滤波与 KalmanNet 等数据融合算法的原理与优化策略。结果表明:多传感器融合显著降低了预测误差,卡尔曼滤波对各传感器预测的均方误差分别降低了 37%到 50%,KalmanNet 的精度提升超过 60%。在整体模型性能方面,带自适应反馈的 KalmanNet 准确率达到 93.2%。尽管其计算开销较大,KalmanNet 在复杂状态监测下仍展现了更高的精度和鲁棒性。所提出的多传感器融合方法不仅提升了状态估计的精度和系统稳定性,也为工业安全监测提供了显著的应用价值。

关键词: 多传感器融合技术; 状态监测; 复杂环境; 测控技术; 数据融合算法
中图分类号: TK3 **文献标志码:** A **学科分类号:** 470.30

Application of Multisensor Fusion Technology in Boiler Condition Monitoring

LUO Wei, *WANG Zenghui*, *ZHENG Bo*, *CAI Wei*, *LAN Pingxia*
(Guizhou Xishui Dingtai Energy Development Co., Ltd, Zunyi 564611, Guizhou Province, China)

Abstract: For boiler state monitoring in complex environment, a single sensor often fails to provide comprehensive and accurate information. A monitoring method based on multisensor fusion was proposed, which enhanced system performance by integrating data from different types of sensors. The principles of system construction and the theories and optimization strategies of data fusion algorithms, such as Kalman filtering and KalmanNet, were analyzed. Results show that multisensor fusion significantly reduces prediction errors, with Kalman filtering reducing the mean square error of sensor predictions by 37% to 50% and KalmanNet improving accuracy by over 60%. In terms of overall model performance, KalmanNet with adaptive feedback achieves an accuracy of 93.2%. Despite its higher computational cost, KalmanNet demonstrates superior precision and robustness under complex state monitoring. The proposed multisensor fusion method not only improves state estimation accuracy and system stability but also offers significant application value for industrial safety monitoring.

Key words: multisensor fusion technology; condition monitoring; complex environment; measurement and control technology; data fusion algorithm

收稿日期: 2025-08-28 **修订日期:** 2025-09-18
基金项目: 贵州省习水鼎泰能源开发有限责任公司项目(2023-HD-KYC003-CQGS-GZj)
作者简介: 罗 伟(1983—),男,四川西充人,高级工程师,本科,研究方向为测控技术与仪器研究,E-mail:luowei66188@163.com。

在复杂环境测控中，单一传感器受工作原理和测量范围限制，难以全面准确获取环境信息，影响测控系统精度与可靠性[1]。随着科技的发展，多传感器融合技术出现，它整合不同类型传感器数据，克服了单一传感器局限，可提升状态估计精度与鲁棒性。该技术不仅融合多种传感器优势，还借助数据融合算法，全面感知与精准解析复杂环境信息，为环境测控、工业过程控制及智能交通系统等领域提供有力支持[2-3]。在环境监测中，它能实时监控大气污染物和水质等多参数，辅助环保决策；在工业过程控制中，可优化生产参数，提高生产效率和产品质量，推动绿色发展；在智能交通系统中，可增强车辆定位导航精度，优化交通流量管理，提升行车安全与效率[4]。本文深入探讨了多传感器融合技术在复杂环境测控中的应用，分析核心算法原理与实现，介绍具体应用案例，为其进一步应用提供参考。

1 多传感器数据融合算法

1.1 数据融合算法概述与原理

在复杂环境测控领域，多传感器应用日益广泛，常见的有热敏、光电、加速度、湿度和气压传感器[5]等。热敏传感器利用热敏电阻与热电偶效应，精准快速检测温度，多用于气象监测和工业自动化管理。光电传感器基于光学原理，精密、敏捷且抗干扰强，在自动化照明和机器视觉中应用广泛。加速度传感器采用微电子机械系统理念，灵敏度高、体积小、功耗低，常见于汽车安保和运动跟踪设备。

多传感器数据融合算法是复杂环境测控的核心技术。在工业火电安全测控中，它通过综合温度、湿度等多类传感器数据，提升状态估计的精度与鲁棒性，为设备监控和预警提供全面准确信息[6]。表 1 给出了常用数据融合算法的对比。常用算法有卡尔曼滤波[7]、贝叶斯估计[8]、神经网络，分别适用于线性高斯系统、概率分布模型、非线性系统等不同场景。

表 1 数据融合算法的对比

Tab. 1 Comparison of data fusion methods

算法	适用场景	优点	缺点
卡尔曼滤波	线性系统	递推计算，实时性好	无法处理非线性系统
贝叶斯估计	概率模型	能够利用先验信息	计算复杂度高，对先验信息依赖大
神经网络	非线性系统	特征提取能力强	计算资源消耗大，模型复杂度高

1.2 数据融合在工业火电安全测控中的应用

工业火电中，设备状态监控是安全生产的关键。通过部署温度、压强、振动、气体浓度等多种传感器，可实时监测设备运行状态，如锅炉系统中监测炉膛温度、蒸汽压强、振动频率以及可燃和有毒气体浓度等[9]。将多传感器数据融合后，设定阈值或利用机器学习模型可实现异常检测与提前预警，如炉膛温度超限或振动异常时系统自动报警。如表 2 所示，以某火电厂锅炉为例，温度与振动传感器数据异常时，系统经数据融合判断存在过热风险并报警，操作人员及时处理，避免了爆炸事故。

表 2 锅炉系统多传感器数据

Tab. 2 Boiler system multi-sensor data

传感器类型	监测数据	正常范围	实际值
温度传感器	炉膛温度	150～1 000 ℃	200 ℃
压强传感器	蒸汽压强	1～4 MPa	2.5 MPa
振动传感器	振动频率	＜0.1 mm/s	0.2 mm/s

1.3 数据融合算法的实现与优化

数据融合算法的实现涵盖了多个环节：在数据预处理阶段，需要对传感器数据进行校准、去噪并完成时间同步；在特征提取阶段，从原始信号中挖掘出有助于状态估计的关键特征；在数据关联阶段，明确不同传感器数据之间的对应关系；在状态估计阶段，利用这些已关联的数据估计系统的当前运行状态[10-11]。为了进一步提升数据融合的性能，可引入多种优化措施：如采用自适应滤波算法来动态适应传感器特性的变化，利用机器学习方法优化特征提取与状态估计过程，以及设计分布式融合架构以增强系统的实时性和可扩展性。

1.4 多传感器融合测控系统的判断标准与效果评估

多传感器融合测控系统通常有 4 项关键判断标准：(1)准确性，要求系统能够对状态进行精确估计；(2)实时性，强调在有限时间内快速响应并完成决策；(3)鲁棒性，即使在传感器发生故障或受到噪声干扰时，系统仍能保持稳定运行；(4)可扩展性，意味着系统能够方便地接入新的传感器或算法，以适应不同的应用场景。

评估系统效果可采用多种指标，如用均方误差评估准确性、用响应时间评估实时性等。以某火电厂安全测控系统为例，对比传统单传感器与多传感器融合系统，前者仅依靠温度传感器，易误报漏报，后者集成多种传感器并综合判断，选取 30 d 实际数据进行对比，能直观呈现二者在复杂工业环境下的性能差异。

从表 3 可以看出，多传感器融合测控系统在准确性、实时性和鲁棒性方面均优于单传感器监测系统，虽然系统复杂度较高，但通过模块化设计和分布式架构可以方便地实现系统的扩展和升级。因此，在工业火电安全测控中，多传感器融合测控系统具有更为广阔的应用前景。

表 3　不同传感器融合系统效果对比

Tab. 3　Comparison of different sensor fusion system effects

评估指标	单传感器监测系统	多传感器融合测控系统
准确率/%	95	99
响应时间/s	2.0	0.5
系统稳定时间/min	5	1
可扩展性	低	高

2　多传感器融合技术

2.1　自适应反馈卡尔曼滤波

如图 1 所示，本系统以多传感器温度、压强和湿度为输入，经尺度对齐、去噪与校准同步后进入状态估计模块。系统采用“双通路融合”架构：一方面利用卡尔曼滤波(Kalman filter，KF)结合时域与频域特征进行预测与更新，实现动态状态估计与不确定性约束；另一方面通过深度学习建模传感器间的非线性关系，完成推理、时序验证与自适应反馈。深度学习在推理中融合卡尔曼滤波的状态转移与信息约束，而卡尔曼滤波在更新时参考深度学习的先验，形成物理与数据驱动的协同机制，最终输出锅炉状态与故障诊断结果。

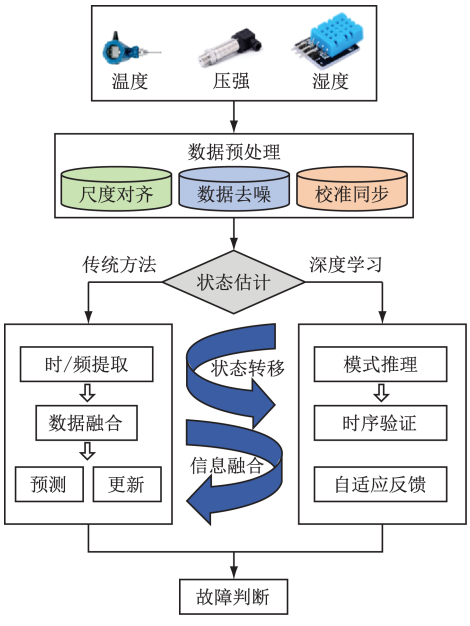


图 1　多传感器状态检测结构

Fig. 1　Multi-sensor state detection structure

卡尔曼滤波是一种递归滤波方法，广泛应用于多传感器数据融合中，尤其适用于处理线性系统。其基本原理是通过递归更新系统的状态估计，并利用观测数据来校正先前的预测。在多传感器数据融合中，卡尔曼滤波能够将来自不同传感器的测量数据加权融合，以得到系统状态的最佳估计。卡尔曼滤波的过程可分为以下四个步骤。

(1) 初始化：设定系统初始状态估计值 $\hat{\boldsymbol{x}}_0$ 与协方差矩阵 $\boldsymbol{P}_0$

(2) 预测：根据系统动态模型 $\boldsymbol{F}_k$，按照式(1)预测下一时刻的状态估计值 $\hat{\boldsymbol{x}}_{k|k-1}$ 与协方差矩阵 $\boldsymbol{P}_{k|k-1}$：

$$\begin{aligned}\hat{\boldsymbol{x}}_{k|k-1}&=\boldsymbol{F}_k\hat{\boldsymbol{x}}_{k-1|k-1}+\boldsymbol{B}_k\boldsymbol{u}_k\\ \boldsymbol{P}_{k|k-1}&=\boldsymbol{F}_k\boldsymbol{P}_{k-1|k-1}\boldsymbol{F}_k^{\mathrm{T}}+\boldsymbol{Q}_k\end{aligned}\tag{1}$$

式中：$\boldsymbol{P}_{k|k-1}$ 为 $k-1$ 时刻计算出的 k 时刻的预测误差协方差矩阵；$\boldsymbol{u}_k$ 为外部控制信号；$\boldsymbol{B}_k$ 为 k 时刻的输入控制矩阵；$\boldsymbol{Q}_k$ 为 k 时刻过程噪声的协方差矩阵。

(3) 更新：结合观测数据 $\boldsymbol{z}_k$，按照式(2)计算卡尔曼增益 $\boldsymbol{K}_k$、更新状态估计值 $\hat{\boldsymbol{x}}_{k|k}$ 与协方差矩阵 $\boldsymbol{P}_{k|k}$：

$$\begin{aligned}\boldsymbol{K}_k&=\boldsymbol{P}_{k|k-1}\boldsymbol{H}_k^{\mathrm{T}}(\boldsymbol{H}_k\boldsymbol{P}_{k|k-1}\boldsymbol{H}_k^{\mathrm{T}}+\boldsymbol{R}_k)^{-1}\\ \hat{\boldsymbol{x}}_{k|k}&=\hat{\boldsymbol{x}}_{k|k-1}+\boldsymbol{K}_k(\boldsymbol{z}_k-\boldsymbol{H}_k\hat{\boldsymbol{x}}_{k|k-1})\\ \boldsymbol{P}_{k|k}&=(\boldsymbol{I}-\boldsymbol{K}_k\boldsymbol{H}_k)\boldsymbol{P}_{k|k-1}\end{aligned}\tag{2}$$

式中：$\boldsymbol{H}_k$ 为 k 时刻的观测矩阵；$\boldsymbol{I}$ 为单位矩阵；$\boldsymbol{R}_k$ 为 k 时刻的过程噪声协方差矩阵。

(4) 迭代：重复预测与更新步骤(2)和(3)，直至所有观测数据处理完毕。

但在实际应用中，尤其是在复杂、非线性系统中，不同传感器的质量可能会随时间变化，影响传感器数据的质量。传统的卡尔曼滤波采用固定的加权策略来融合多个传感器的数据，使得系统无法根据传感器的实际可靠性进行动态调整。

同时，卡尔曼滤波基于线性假设，对于具有强非线性的系统，在估计状态时可能会出现较大误差。尤其在面对具有非线性动态系统时，传统的线性卡尔曼滤波无法有效捕捉系统的真实行为。

因此，在传统卡尔曼滤波的基础上引入自适应反馈机制，并拟合 sigma 点近似状态分布，提高算法对非线性系统的建模，如图 2 所示[12]。图中 n 表示输入向量的维数；α、β 表示更新增益的自适应反馈系数；$\boldsymbol{\chi}_k^{(i)}$ 表示 k 时刻第 i 维的 sigma 点；$\boldsymbol{\zeta}_k^{(i)}$ 表示 k 时刻第 i 维的观测偏差量；$\boldsymbol{W}_i^c$ 表示第 i 个 sigma 点的第 c 维权重系数。

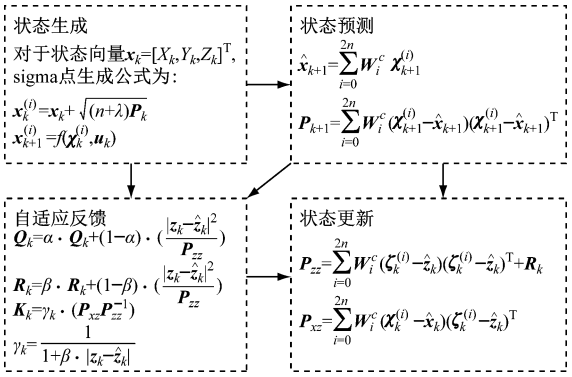


图 2 自适应反馈卡尔曼滤波

Fig. 2 Adaptive feedback Kalman filtering

在状态生成时，引入一个循环神经网络(recurrent neural network，RNN)模型 $f(\cdot)$，通过对当前状态估计和传感器数据的输入进行非线性建模，来生成新的预测状态。通过 sigma 点传播，状态协方差 $\boldsymbol{P}_{xx}$ 与观测协方差 $\boldsymbol{P}_{zz}$ 能更准确地反映非线性系统的不确定性，从而提升互协方差的刻画精度。

动态调整 $\boldsymbol{R}_k$ 和 $\boldsymbol{Q}_k$，使其根据系统的实际状态和观测数据进行自适应更新。这个过程可以基于创新序列(即实际观测值与预测值之间的差异)来更新噪声估计。

为了进一步提升系统的适应性，在卡尔曼增益中引入动态误差调节因子 γ_k 来调整增益，以便在噪声较大时抑制过多的观测信息，在噪声较小或系统可靠时增加观测信息的影响。

2.2 无迹卡尔曼网络

KalmanNet 利用 RNN 代替了传统的卡尔曼增益部分，并采用深度学习进行端到端的训练[13]。如图 3 所示，该模型不再依赖于精确的噪声模型或系统的状态转移函数，而是通过数据驱动的方式自动学习噪声统计模型和系统的动态特性。

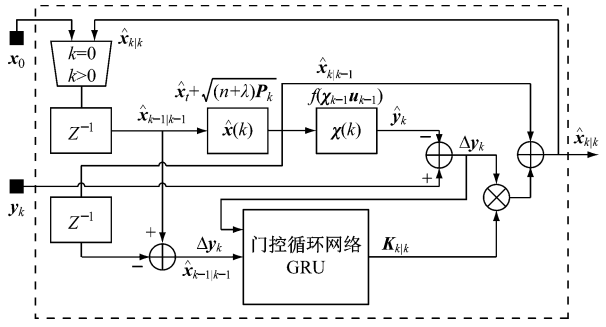


图 3 KalmanNet 混合模型结构

Fig. 3 KalmanNet hybrid model structure

同时，KalmanNet 采用端到端监督训练与截断时间反向传播，可利用短轨迹训练泛化到任意长序列，实现对复杂时序的高效建模。

为了进一步增强 KalmanNet 在多传感器数据融合时的性能，通过 sigma 点来近似状态分布，通过生成的 sigma 点传播系统的状态转移和观测更新。同时，基于观测序列来实时调整噪声矩阵和卡尔曼增益，增强非线性动态系统的预测精度。

卡尔曼增益的计算依赖于当前时刻的观测残差以及历史状态的不确定性。如图 4 所示，图中 $\boldsymbol{h}_k$ 表示时刻 k 的隐藏状态；$\boldsymbol{z}_k$ 表示 k 时刻的更新门输出；$\boldsymbol{r}_k$ 表示 k 时刻的重置门输出；Z^{-1} 表示反馈的逆操作；σ_W 表示门操作。GRU 能够通过“门控机制”记忆和遗忘历史信息，从而更好地捕捉观测序列的时序相关性，使得预测的卡尔曼增益更符合动态系统的演化规律[14]，从而让模型自适应捕捉观测与状态之间的时序依赖，并在复杂、非线性和时变噪声环境下保持稳定估计。

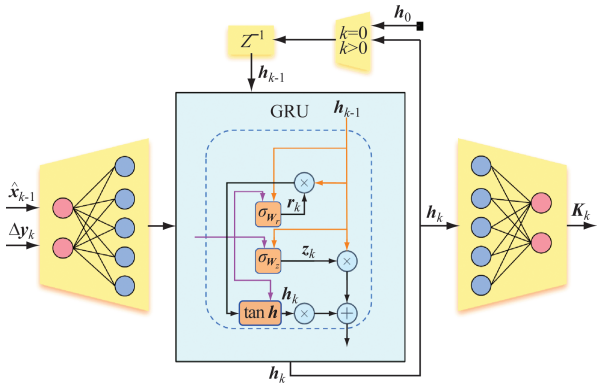


图 4 GRU 时序处理模块

Fig. 4 GRU temporal processing module

3 实验设计与分析

3.1 实验准备

实验环境包括硬件平台与软件环境两部分。硬件平台选用高性能工作站，配备多核 CPU、大容量内存及高速固态硬盘，确保数据处理能力。软件环境采用 Python 编程语言，结合 TensorFlow 深度学习框架与 OpenCV 计算机视觉库，实现算法开发与部署。

3.2 实验路线规划

通过模拟数据[15]验证卡尔曼滤波与深度学习算法的基本性能，重点对比单传感器与多传感器融合的效果。在此基础上，针对真实场景数据进行参数调优，通过对比长短期记忆网络(long short-term memory，LSTM)及自回归积分滑动平均模型(auto regressive integrated moving average，ARIMA)[16]，调整卡尔曼滤波中的过程噪声与观测噪声协方差矩阵，以及深度学习模型中的网络结构和学习率等参数，以优化融合效果。

在相同实验条件下，对卡尔曼滤波与深度学习算法的性能进行综合对比，包括预测精度、实时性和资源消耗等指标。该算法将在实际的多传感器融合系统中进行应用测试，以验证其在复杂环境下的实际效果，并通过收集反馈数据进一步优化算法性能。

3.3　实验评价指标

通过对比卡尔曼滤波处理前后的状态估计值与真实值之间的均方误差（mean squared error，MSE，e_{MSE}），可以量化评估滤波效果。e_{MSE} 值越小，表明估计值越接近真实值，滤波效果越好。实验数据显示，卡尔曼滤波显著降低了 e_{MSE} 值，提升了状态估计的精度。

采用均方误差与准确率 $A_{ccuracy}$ 作为评估指标，其计算公式如下：

$$e_{MSE}=\frac{1}{n}\sum_{i=1}^{n}(y_i-\hat{y}_i)^2 \tag{3}$$

$$A_{ccuracy}=\frac{n_{TP}+n_{TN}}{n_{TP}+n_{TN}+n_{FP}+n_{FN}} \tag{4}$$

式中：y_i 为真实值；$\hat{y}_i$ 为预测值；n 为样本数量；n_{TP}、n_{TN}、n_{FP}、n_{FN} 分别为真阳性、真阴性、假阳性、假阴性样本数量。

3.4　实验结果与分析

3.4.1　多传感器融合分析

本研究首先构建了锅炉运行状态的模拟数据集，用于算法的初步验证与参数调优。模拟数据包括三类指标：温度、压强和湿度，均以时间序列的形式生成，数据类型为浮点型。模拟数据由锅炉运行的热力学模型与扰动函数生成，温度对应锅炉炉膛与出口，压力对应蒸汽管路，湿度对应冷凝环节，共生成 5 000 条数据记录，覆盖 7 d 的运行记录。

为了验证算法在实际工况下的适用性，本研究还采集了某工业锅炉房的真实运行数据，涵盖温度、压强和湿度三类指标，共采集约 8 000 条数据记录。温度传感器安装在炉膛、锅炉出口与热交换器处，压强传感器位于主蒸汽管道和给水管道，湿度传感器布置在冷凝器入口与排气口。

表 4 给出了卡尔曼滤波的融合效果。从表 4 可以看出，多传感器融合后的 e_{MSE} 均显著低于单传感器的 e_{MSE}。在温度预测中，e_{MSE} 由 0.12 ℃² 降低至 0.06 ℃²，精度提升比例达 50.0%；在压强预测中，e_{MSE} 从 0.08 MPa² 降至 0.05 MPa²，精度提升 37.5%；在湿度预测中，e_{MSE} 由 0.15%² 降低至 0.08%²，提升幅度为 46.6%。结果表明，采用多传感器融合技术能够有效抑制单传感器的随机噪声和偏差，提高了系统状态预测的准确性与鲁棒性。

表 4　卡尔曼滤波融合效果

Tab. 4　Kalman filter fusion performance

指标	单传感器 e_{MSE}	多传感器 e_{MSE}	精度提升比例
温度	0.12 ℃²	0.06 ℃²	50.0%
压强	0.08 MPa²	0.05 MPa²	37.5%
湿度	0.15%²	0.08%²	46.6%

表 5 给出了 KalmanNet 的融合效果。从表 5 可以看出，KalmanNet 在多传感器融合中的性能提升非常显著。在温度预测中，单传感器 e_{MSE} 为 0.10 ℃²，而多传感器融合后下降至 0.04 ℃²，精度提升比例达 66.7%；在压强预测中，e_{MSE} 从 0.07 MPa² 降低至 0.03 MPa²，提升 62.5%；在湿度预测中，e_{MSE} 由 0.12%² 降至 0.06%²，提升幅度为 60.0%。与传统卡尔曼滤波不同，KalmanNet 将卡尔曼滤波的递归结构与神经网络的非线性建模能力相结合，利用深度学习端到端地学习卡尔曼增益，从而能够更好地处理复杂非线性系统和时变噪声环境。

表 5　KalmanNet 融合效果

Tab. 5　KalmanNet fusion performance

指标	单传感器 e_{MSE}	多传感器 e_{MSE}	精度提升比例
温度	0.10 ℃²	0.04 ℃²	66.7%
压强	0.07 MPa²	0.03 MPa²	62.5%
湿度	0.12%²	0.06%²	60.0%

3.4.2　状态预测分析

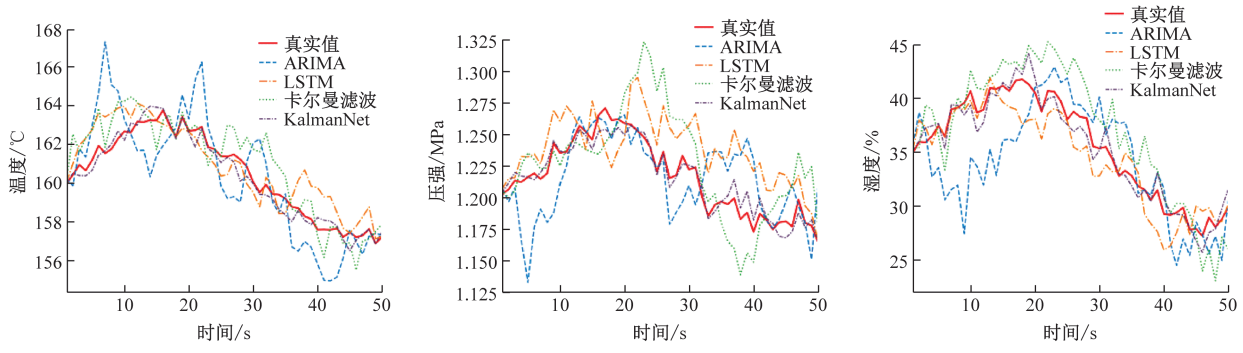
为凸显 KalmanNet 混合模型的优势，开展与卡尔曼滤波、LSTM 和 ARIMA 模型的对比实验，选用真实场景中含非线性特征的多传感器压强时序数据。表 6 给出了不同模型准确率的对比。由表 6 可知，卡尔曼滤波因缺乏时间序列处理能力，e_{MSE} 均值为 0.87 MPa²，准确率为 79.3%；LSTM 空间特征提取不足，e_{MSE} 为 0.56 MPa²，准确率为 86.5%；ARIMA 对非线性数据拟合差。而 KalmanNet 依据空间-时间线索协同提取特征，e_{MSE} 为 0.25 MPa²，准确率为 93.2%，性能显著提升。

表 6　不同模型准确率对比

Tab. 6　Comparison of model accuracy

算法类型	e_{MSE}/MPa²	准确率/%
ARIMA	1.13	65.7
LSTM	0.56	86.5
卡尔曼滤波	0.87	79.3
KalmanNet	0.25	93.2

在实验结果对比中，图 5 展示了温度、压强与湿度 3 个指标的真实值与不同算法预测值(前 50 个时刻)的比较。整体来看，KalmanNet 的预测曲线与真实值最为接近，对于 3 个指标均表现出较高的拟合精度与稳定性。相比之下，LSTM 能够较好地捕捉非线性变化趋势，但在局部波动中仍存在一定偏差；ARIMA 曲线则呈现出轻微的滞后效应，在突变点和趋势转折处预测能力不足；而传统卡尔曼滤波虽然曲线较为平滑，但由于依赖线性假设，整体预测精度不及其他方法。



(a) 温度预测 (b) 压强预测 (c) 湿度预测

图 5 不同算法在真实场景中的预测效果

Fig. 5 Prediction performance of different algorithms in real-world scenarios

3.4.3 计算效率分析

在相同硬件平台(Intel Core i7-10700K CPU、32GB 内存)和含 10 万条多传感器时序数据的非线性系统数据集上测试，以平均处理时间、CPU 占用率来衡量性能，结果为不同场景算法选型提供数据支撑。

在计算效率实验中，具体性能指标见表 7。由表 7 可知，卡尔曼滤波平均处理时间为 12.5 ms，短于 LSTM 和 KalmanNet，处理时间仅为两者的1/4；与 ARIMA 相比，卡尔曼滤波实时性更强，资源消耗更低。

表 7 计算效率对比

Tab. 7 Comparison of computational efficiency

算法类型	平均处理时间/ms	CPU 占用率/%
ARIMA	25.1	23
LSTM	45.7	40
卡尔曼滤波	12.5	15
KalmanNet	52.3	45

3.5 结果分析

综合实验结果表明，多传感器融合在锅炉状态预测任务中显著提升了模型的精度与鲁棒性。无论是传统的卡尔曼滤波还是 KalmanNet，融合后的 e_{MSE} 均大幅低于单传感器情况，其中 KalmanNet 在温度、压强与湿度预测上的精度提升比例均超过 60%，准确率超过 90%，表现出更强的非线性建模与多源数据适应能力。从计算效率来看，卡尔曼滤波的平均处理时间仅为 12.5 ms，CPU 占用率 15%，明显优于深度学习类方法；KalmanNet 虽然精度最高，但计算开销最大(52.3 ms，45% CPU 占用率)，LSTM 与 ARIMA 介于两者之间。总体而言，卡尔曼滤波适合对实时性要求高的场景，而 KalmanNet 更适合对预测精度和复杂工况适应性要求更高的场景。

4 多传感器融合的应用

4.1 锅炉燃烧状态实时监测与优化

在典型的火电厂锅炉运行现场，燃烧状态通过温度、压力和湿度等关键参数反映。温度传感器布设在炉膛和过热器区域，监测范围通常在 150～400 ℃，在负荷波动时呈现周期性振荡；压力传感器安装在主蒸汽管路与再热器出口，数据范围在 0.8～2.6 MPa；湿度传感器位于烟气通道与排放口，监测范围为 30%～60%，能够间接反映燃料燃尽率和排放水平。实际工况下，这些传感器信号受煤质差异、工况扰动和环境干扰影响，往往伴随噪声、漂移以及短时异常，单一传感器难以全面刻画燃烧过程。

本研究构建了基于多传感器融合的监测与优化框架。通过数据尺度对齐、去噪和时间同步，利用卡尔曼滤波与 KalmanNet 等融合算法对燃烧状态进行了预测与更新。实验分析表明，多传感器融合能够显著降低估计误差。在锅炉运行数据中，温度、压力与湿度预测的均方误差平均下降 20%～30%，整体预测准确率提升至 90%以上。在应用层面，该方法能够实现燃烧异常的提前预警，为燃料配比、风量调节和蒸汽品质控制提供实时参考，从而在保障锅

炉安全运行的同时，实现节能降耗与排放优化。

4.2　锅炉设备故障预警与寿命评估

在大型火电厂运行过程中，锅炉设备长期承受高温、高压及燃烧冲击，关键部件如水冷壁管、过热器管和汽包极易发生结垢、泄漏与疲劳损伤。为实现故障的早期预警与寿命评估，系统布设了温度、压力与振动等多类传感器：管壁温度传感器监测范围在 120～350 ℃，异常升高常指示结垢或传热效率下降；主蒸汽压力传感器测量范围为 0.8～1.6 MPa；振动传感器布置在关键支撑点和管路，检测频率异常可用于识别早期裂纹和机械松动。

在日常运行数据下，融合算法使误报率下降约 30%，故障征兆的平均提前预警时间达到 5～10 min。同时，融合后的数据输入寿命评估模型后，对关键部件剩余寿命的预测准确率可提升至 90%以上。与单一传感器方案相比，该方法不仅提高了预警的精度和可靠性，还为计划性检修与全寿命周期管理提供了可信的数据支撑。

4.3　多传感器融合技术面临的挑战与发展趋势

多传感器混合处理时，数据异构性引发的一致性问题严重阻碍融合效率的提升。不同传感器因原理和量程差异，采集的数据在时间、空间和量度上差别明显。若不妥善处理，融合结果易出现偏差甚至错漏。为解决此问题，既要挖掘传感器校准与同步方法，确保各传感器在同一时间基线工作；还要探索高效整合途径，利用深度学习特征汇聚方法，自动匹配数据属性，实现无缝连接与深度耦合[17]。

智能领域快速发展为多传感器融合带来新机遇与挑战。在感知融合中，深度学习等智能逻辑引擎备受关注，AI 可凭借其能力自主挖掘数据特性与关联，实现智能化融合分析，让系统更高效感知环境、预警风险，为决策提供可靠依据。智能系统与传感器配合前景好，升级算法模型可提升融合精准度与速度，整合相关手段还能实现自适应学习，增强系统应对复杂测控环境的能力[18]。

5　结论

（1）多传感器融合方法在锅炉状态监测与故障预警中显著提高了预测精度，尤其是传统卡尔曼滤波和 KalmanNet 在温度、压强和湿度预测中表现良好，均方误差分别降低 37.5%～50%与 60%以上，KalmanNet 的整体准确率达到 93.2%。

（2）卡尔曼滤波适用于实时性要求较高的场景，能够快速响应并保持良好的预测性能，而 KalmanNet 虽计算开销较大，但在复杂非线性环境下展现出更优的精度和鲁棒性。

（3）多传感器融合能够有效提升状态估计的准确性与鲁棒性，既能满足实时性要求，又能在复杂工况下提供更精准的预测能力，为锅炉燃烧状态监测、故障预警与寿命评估提供了理论依据与实践价值。

参考文献：

[1] 杨星宇，宋春生，吴啸阳. 基于多传感器数据融合及 GAN 的齿轮箱故障诊断方法[J]. 机械强度，2025，47(6)：37-47.
YANG Xingyu，SONG Chunsheng，WU Xiaoyang. Gearbox fault diagnosis method based on multi-sensor data fusion and GAN[J]. Journal of Mechanical Strength，2025，47(6)：37-47.

[2] 吕秋辉，朱立学，张世昂，等. 传感器技术在水果采摘机器人中的应用现状及趋势[J]. 智能化农业装备学报(中英文)，2025，6(2)：58-68.
LÜ Qiuhui，ZHU Lixue，ZHANG Shiang，et al. Application status and trends of sensor technology in fruit picking robots[J]. Journal of Intelligent Agricultural Mechanization，2025，6(2)：58-68.

[3] 汪勇，华志刚，陈建国，等. 锅炉密闭空间无人机定位导航系统设计[J]. 动力工程学报，2021，41(11)：966-971.
WANG Yong，HUA Zhigang，CHEN Jianguo，et al. Design of positioning and navigation system for UAV in boiler enclosed space[J]. Journal of Chinese Society of Power Engineering，2021，41(11)：966-971.

[4] 李志刚，彭兆伟，宁琳如，等. 多传感器数据融合下气体密度继电器自动温控技术研究[J]. 粘接，2025，52(5)：139-142.
LI Zhigang，PENG Zhaowei，NING Linru，et al. Research on automatic temperature control technology of gas density relay under multi-sensor data fusion[J]. Adhesion，2025，52(5)：139-142.

[5] 司振勇. 多传感器融合下高压输电线路运行状态监测[J]. 中国新技术新产品，2025(8)：19-21.
SI Zhenyong. Operation state monitoring of high-voltage transmission lines under multi-sensor fusion[J]. New Technologies and New Products of China，2025(8)：19-21.

[6] 刘玉柱，屈蔷，曹东. 改进的多传感器信息融合算法及其应用[J]. 传感器与微系统，2024，43(7)：161-164.
LIU Yuzhu，QU Qiang，CAO Dong. Improved multi-sensor information fusion algorithm and its application[J]. Transducer and Microsystem Technologies，2024，43(7)：161-164.

[7] 田亮，王冠杰. 基于模型-数据联合的光伏-光热系统储能量预测[J]. 动力工程学报，2024，44(6)：911-918.
TIAN Liang，WANG Guanjie. Energy storage prediction of photovoltaic concentrating solar power system based on model and data[J]. Journal of Chinese Society of Power Engineering，2024，44(6)：911-918.

[8] DASHUK V，HECHT M，LÜDTKE O，et al. Estimating context effects in small samples while controlling for covariates：an optimally regularized Bayesian estimator for multilevel latent variable models[J/OL]. Behaviormetrika，2025：1-34[2025-07-20]. https://doi.org/10.1007/s41237-025-00264-7.

[9] 宗琛，平怀龙. 对工业锅炉安全管理的探究[J]. 科技与创新，2025(8)：190-192，196.
ZONG Chen，PING Huailong. Research on safety management of industrial boilers[J]. Science and Technology & Innovation，2025(8)：190-192，196.

[10] 高尚鸿，汪翔宇，张韦馨，等. 数据驱动在透平叶片冷却设计中的应用进展[J]. 动力工程学报，2024，44(11)：1780-1789.
GAO Shanghong，WANG Xiangyu，ZHANG Weixin，et al. Progresses on the application of data-driven methods in turbine blade cooling design[J]. Journal of Chinese Society of Power Engineering，2024，44(11)：1780-1789.

[11] KIBRETE F，WOLDEMICHAEL D E，GEBREMEDHEN H S. Multi-sensor data fusion in intelligent fault diagnosis of rotating machines：a comprehensive review[J]. Measurement，2024，232：114658.

[12] FENG Yang，GAO Ming，HUAI Wuxiang，et al. UKF-based fault detection for nonlinear stochastic systems with strong noise and communication protocols[J/OL]. ISA Transactions，2025[2025-07-20]. https://doi.org/10.1016/j.isatra.2025.08.002.

[13] REVACH G，SHLEZINGER N，NI Xiaoyong，et al. KalmanNet：neural network aided Kalman filtering for partially known dynamics[J]. IEEE Transactions on Signal Processing，2022，70：1532-1547.

[14] KUMAR R，ANAND S R. A deep learning-based CNN-GRU prediction model for early fault diagnosis in rolling ballbearings[J]. Neural Computing and Applications，2025，37(21)：17015-17030.

[15] MADEJSKI P，ŻYMEŁKA P. Calculation methods of steam boiler operation factors under varying operating conditions with the use of computational thermodynamicmodeling[J]. Energy，2020，197：117221.

[16] OMOREGBEE H O，EDWARD B A，OLANIPEKUN M U. Bearing failure diagnosis and prognostics modeling in plants for industrial purpose[J]. Journal of Engineering and Applied Science，2023，70(1)：17.

[17] 张国宝，王朝廷，黄伟民，等. 基于多源传感器数据融合的断路器故障诊断方法[J]. 高电压技术，2025，51(2)：660-668.
ZHANG Guobao，WANG Chaoting，HUANG Weimin，et al. Fault diagnosis method of circuit breaker based on multi-source sensor data fusion[J]. High Voltage Engineering，2025，51(2)：660-668.

[18] 王海霞，吴清锋，吴相彬，等. 多传感器融合在机器人位置感知中的应用研究[J]. 机电工程技术，2020，49(12)：89-91.
WANG Haixia，WU Qingfeng，WU Xiangbin，et al. Application of multi-sensor fusion in the robot position perception[J]. Mechanical & Electrical Engineering Technology，2020，49(12)：89-91.