研究论文

DOI：10.11949/0438-1157.20251250

基于动态残差补偿的工业时序数据故障检测模型

吉鲁东[1]，朱春梦[1,2]，柳楠[1]，郭建豪[1]，赵云鹏[1]，石孝刚[1]，蓝兴英[1]

（[1]中国石油大学（北京）重质油全国重点实验室，北京 102249；[2]中国石油大学（北京）人工智能学院，北京 102249）

摘要： 为应对化工过程因动态特性、强非线性与复杂时空耦合导致传统故障检测模型精度低且动态适应性差的难题，提出一种基于动态残差补偿的工业时序数据故障检测模型（dynamic residual compensation-based detection model，DRCDM）。DRCDM利用卷积神经网络-双向长短期记忆网络（CNN-BiLSTM）挖掘时序数据的时空依赖关系并进行初步预测，随后构建包含原始数据统计量、基础模型预测值和历史残差的动态统计量的增强元特征集，再驱动XGBoost对预测偏差实时建模与修正。在田纳西-伊斯曼（TE）过程及某280万吨/年催化裂化（FCC）装置运行数据的实验表明，动态残差补偿能够有效实现偏差的实时修正，显著提升DRCDM故障检测的准确性和可靠性。

关键词： 故障检测；动态残差补偿；时序数据；元特征集；TE过程；FCC

中图分类号： TP 183　　**文献标志码：** A

文章编号： 0438-1157（2026）10-6110-15

Industrial time series data fault detection model based on dynamic residual correction

JI Ludong[1], ZHU Chunmeng[1,2], LIU Nan[1], GUO Jianhao[1], ZHAO Yunpeng[1], SHI Xiaogang[1], LAN Xingying[1]

([1] *State Key Laboratory of Heavy Oil Processing, China University of Petroleum, Beijing* 102249, *China*; [2] *College of Artificial Intelligence, China University of Petroleum, Beijing* 102249, *China*)

Abstract: This paper addresses the challenge that traditional fault detection models fail to simultaneously achieve high precision and dynamic adaptability due to the inherent dynamic characteristics, strong nonlinearity, and complex spatiotemporal coupling of chemical processes. Therefore, we propose a dynamic residual compensation-based detection model for fault detection in industrial time-series data. The proposed DRCDM operates by first capturing the spatio-temporal dependencies within time series data to generate preliminary predictions. Subsequently, it constructs an enhanced meta-feature set that incorporates raw data statistics, predictions from the base model, and dynamic historical residual statistics to drive XGBoost for real-time modeling and correction of prediction deviations. Experiments using operational data from the Tennessee-Eastman (TE) process and a 2.8 million t/a catalytic cracking (FCC) unit demonstrate that dynamic residual compensation can effectively achieve real-time correction of deviations, significantly improving the accuracy and reliability of DRCDM fault detection.

Keywords: fault detection; dynamic residual compensation; time series data; meta-feature set; TE process; FCC

收稿日期： 2025-11-11　　**修回日期：** 2026-01-19

通信作者： 蓝兴英(1977—)，女，博士，教授，lanxy@cup.edu.cn

第一作者： 吉鲁东(2000—)，男，硕士研究生，2024210539@student.cup.edu.cn

基金项目： 国家重点研发计划项目(2024YFE0212400)

引用本文： 吉鲁东, 朱春梦, 柳楠, 郭建豪, 赵云鹏, 石孝刚, 蓝兴英. 基于动态残差补偿的工业时序数据故障检测模型[J]. 化工学报, 2026, 77(10): 6110-6124

Citation: JI Ludong, ZHU Chunmeng, LIU Nan, GUO Jianhao, ZHAO Yunpeng, SHI Xiaogang, LAN Xingying. Industrial time series data fault detection model based on dynamic residual correction[J]. CIESC Journal, 2026, 77(10): 6110-6124

引 言

安全性与可靠性对炼厂智能化的生产和开发起到至关重要的作用。然而，化工过程的非线性、强耦合等特性导致安全事故频发[1]。故障早期容易被噪声、干扰以及正常波动所掩盖，导致传统的检测模型难以从高维数据中精准捕捉异常模式，面临灵敏度不足或误报率过高的双重挑战。若不能及时识别并有效干预，易引发连环反应，造成严重的安全事故，对人员生命与资产安全构成严重威胁[2-3]。因此，迫切需要一种有效的方法，能够保证模型的预测精度与故障检测性能，从而保障化工过程的安全高效运行[4-5]。

随着分布式控制系统（DCS）的密集部署，海量的过程数据得以收集，这为基于数据驱动的故障检测技术提供了坚实基础[6]。传统的数据驱动方法，如主成分分析（PCA）[7]、偏最小二乘法（PLS）[8]和支持向量机（SVM）[9]等，虽具有良好的处理线性数据的能力，但受化工过程慢时变、非线性、强耦合以及分布参数等复杂特性的限制[10]，其特征提取能力有限，难以有效捕获化工过程的深层非线性与动态耦合特性[11-12]。近年来，深度学习（DL）技术因其强大的提取深层非线性特征的能力已成为一种极具潜力的替代方案[13-15]。Zhou等[16]构建了一种基于变量相关分析和CNN的新型模型，以增强判别性特征的提取；许洪光等[17]利用PSO算法优化卷积神经网络（CNN）的参数，提升了故障诊断的准确性与效率；李娜[18]则通过优化LSTM结构，强化了对传感器时序关联的建模，显著提高了故障预测的精度与可靠性。然而，深度学习在故障检测领域的应用仍面临严峻挑战。受催化剂性能下降、设备老化、原料组分波动等慢时变因素的影响，工业过程呈现出显著的动态演化特性。这导致基于历史数据训练的静态模型难以适应实际运行过程，从而产生模型失配问题，此类问题尚未得到完善的解决[19-21]。

为缓解此类模型失配问题，部分学者采用预测与补偿策略。Lu[22]提出了一种基于T-XGBoost的热误差预测与动态补偿策略；魏国家等[23]则在数字孪生框架下，通过深度学习预测轮廓误差并动态补偿。但现有方法多将偏差视为一种静态的、仅与当前输入的静态映射关系，忽视了偏差在时间维度上固有的序列相关性与动态演化规律。实际上，预测偏差不仅是瞬时工况的函数，更是历史偏差模式在时序上的延续。当过程动态特性发生快速变化时，基于静态映射的补偿器往往难以进行精准跟踪，导致补偿效果出现滞后甚至失效[24]。因此，面向工况波动频繁且数据具有强时序依赖性的流程工业故障检测，实现有效补偿的关键在于将偏差视为一个动态过程，而非静态映射。

鉴于上述研究现状，本文提出了一种基于动态残差补偿的故障检测模型（dynamic residual compensation-based detection model，DRCDM）。DRCDM的核心是构建一种包含原始数据的统计信息、基础模型的预测输出以及历史残差的滚动统计量的增强元特征，将传统的误差回归问题重构为基于上下文的时序预测问题，从而使得模型能够更精准地校正基础模型的输出，并自适应地跟踪复杂的过程动态。这使得补偿器能够从高维特征中学习并捕捉残差的动态演化模式，而非拟合一个静态函数。将DRCDM应用于田纳西-伊斯曼（TE）过程和某280万吨/年催化裂化（FCC）炼厂实际运行数据，系统性地验证其在提升预测精度和故障检测性能方面的有效性。通过动态残差补偿框架，改善静态补偿方法在时变工业过程中的性能衰退问题，提升故障检测模型在实际场景中的鲁棒性与可靠性。

1 基于DRCDM的故障检测方法

本节详细介绍DRCDM的网络架构。DRCDM的核心是通过训练一个补偿模块主动学习并修正其过程偏差。本文将CNN、BiLSTM与XGBoost有机地集成到一个预测与补偿框架中，其整体框架如图1所示。该模型由3个核心部分组成：（1）基于CNN-BiLSTM的时空特征提取模块，用于深度挖掘时序数据的时空依赖关系；（2）动态残差补偿模块，通过构建增强元特征集，并驱动XGBoost对基础预测残差进行显式建模，从而学习并补偿偏差；（3）决策逻辑与阈值判别策略，整合基础预测与残差修正得到最终预测，并依据95%控制限及“连续5点超限”序贯决策判据进行故障判决。下文将详细阐述DRCDM的各组成部分。

1.1 时空特征提取

化工过程变量普遍呈现出非线性、强耦合的时空动态特性。为同时捕捉两种特征，本文设计了一个CNN-BiLSTM混合网络作为基础预测模型。首先利用CNN强大的特征提取能力，捕捉化工过程中

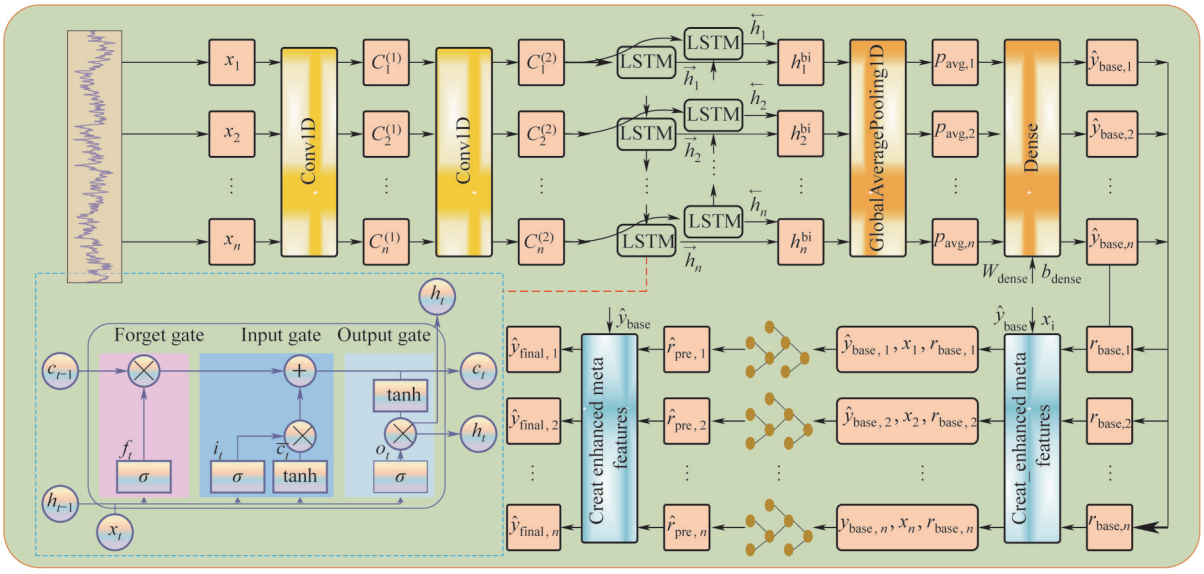

图1 DRCDM架构

Fig.1 DRCDM architecture

变量间的非线性关系，将多变量时间序列转化为一组包含关键状态信息的低维特征序列，再由BiLSTM充分考虑变量间的强耦合特性，并对该特征序列进行深度时序建模。具体的计算流程如下：

输入的时序数据x通过包含了128个滤波器和3个卷积核的Conv1D层，用于从每个时间片段中学习变量间的局部耦合关系和不变模式[25]，输出初步的特征序列$C^{(1)}$，如式(1)所示：

$$C^{(1)} = \text{Dropout}_{0.2}(\text{ReLU}(\text{Conv1D}_{128,k=3}(x))) \tag{1}$$

为捕捉更宏观的组合特征，特征序列$C^{(1)}$被送入包含64个滤波器和3个卷积核的Conv1D层，在特征序列$C^{(1)}$的基础上进行更高层次的抽象与提炼，生成更具信息量的特征序列$C^{(2)}$，如式(2)所示：

$$C^{(2)} = \text{ReLU}(\text{Conv1D}_{64,k=3}(C^{(1)})) \tag{2}$$

经过CNN特征提取的$C^{(2)}$进入一个64个隐藏单元的双向LSTM层。该层通过其特殊的门控机制，从过去和未来的上下文信息同时学习特征序列中的长期时间依赖关系，从而精确捕捉过程的动态演化规律。其前向、后向及最终的隐藏状态序列计算如式(3)~式(5)所示。

前向传播：

$$\vec{h}_t = \text{LSTM}_{\text{fwd},64}(C^{(2)}, \vec{h}_{t-1}) \tag{3}$$

后向传播：

$$\overleftarrow{h}_t = \text{LSTM}_{\text{bwd},64}(C^{(2)}, \overleftarrow{h}_{t+1}) \tag{4}$$

隐藏状态的序列：

$$h_t^{\text{bi}} = [\vec{h}_t; \overleftarrow{h}_t] \tag{5}$$

为降低过拟合风险，BiLSTM输出的隐藏状态序列h_t^{bi}被送入全局平均池化层(global average pooling 1D)。该层沿时间维度对序列进行聚合，将其压缩为一个固定长度的特征向量$\boldsymbol{p}_{\text{avg}}$，该向量被视为对整个时间窗口内过程状态的全局特征表征，如式(6)所示：

$$\boldsymbol{p}_{\text{avg}} = \frac{1}{T}\sum_{t=1}^{T} h_t^{\text{bi}} \tag{6}$$

最后，特征向量$\boldsymbol{p}_{\text{avg}}$通过一个全接连层(dense)，经线性激活后得到基础模型的最终预测值$\hat{y}_{\text{base}}$，如式(7)所示：

$$\hat{y}_{\text{base}} = W_{\text{dense}} p_{\text{avg}} + b_{\text{dense}} \tag{7}$$

1.2 动态残差补偿

动态残差补偿模块通过构建一个能够主动学习并预测动态偏差的高性能补偿器，实现对因过程动态变化而产生的偏差的修正。选用XGBoost作为核心补偿器，主要基于两点考量：(1)XGBoost作为梯度提升决策树(GBDT)的代表，对处理本文的增强元特征集与目标残差空间高度复杂的非线性映射关系具有天然优势，能够在不依赖特征缩放的条件下自动学习特征间的复杂交互效应；(2)XGBoost在算法层面集成强大的正则化策略以抑制过拟合，并通过工程优化实现高效的并行计算，能够有效处理从高维元特征中精准提取复杂模式的任务[26]。基于上述特性，XGBoost成为解码元特征、预测动态偏差的理想选择。该模块具体实现包括以下步骤：

首先，计算基础模型的预测值$\hat{y}_{\text{base}}$与真实值y之间的差异，得到一级残差序列r_{base}。该序列被视为过

程动态中未被基础模型捕获部分的显式表征，蕴含被基础模型忽略的非线性动态信息，如式(8)所示：

$$r_{\text{base}} = y_{\text{true}} - \hat{y}_{\text{base}} \tag{8}$$

为深入揭示偏差的动态成因，设计了增强元特征集M：(1)基础模型预测值$\hat{y}_{\text{base}}$，作为偏差计算的基准；(2)原始数据统计量，即原始输入数据在当前时间窗口内的统计特征stats(X_{seq})，提供偏差产生的环境背景；(3)历史残差的动态统计量，即偏差演化模式，一级残差序列r_{base}在过去L个时间点的滚动统计特征rolling_stats(r_{base})。在元特征构建时，确保t时刻输入仅包含[$t-L$,$t-1$]的历史信息。通过提取历史残差的滚动均值(trend)与滚动标准差(volatility)，将残差序列从一个标量值提升为蕴含时序动态的信号，从而赋予补偿器感知如系统性漂移或瞬时波动等演化模式的能力，如式(9)所示：

$$M = [\hat{y}_{\text{base},t}, \text{stats}(X_{\text{seq},t}), \text{rolling_stats}(r_{\text{base},t-L:t-1})] \tag{9}$$

元特征M与对应的一级残差r_{base}构成训练对，用于训练XGBoost补偿器。在推断阶段，如图2所示，系统维护一个长度为L的FIFO缓存队列用于存储历史残差。每当新的真实值到达，系统实时计算新残差并更新队列，从而动态更新rolling_stats(r_{base})，补偿器可根据新测试样本的元特征预测出对应的残差估计值$\hat{r}_{\text{pre}}$，如式(10)所示：

$$\hat{r}_{pre} = \text{XGBoost}(M) \tag{10}$$

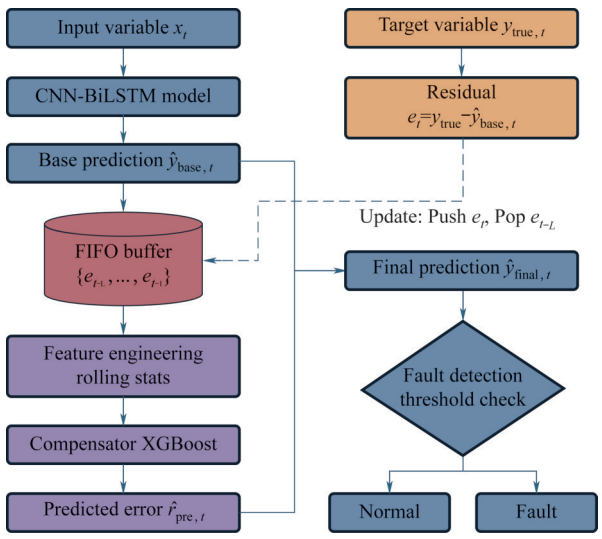

图2 在线更新机制

Fig.2 Online update mechanism

最后，将基础模型的预测值与补偿器预测出的残差修正值相加，得到经过动态修正后的最终预测值$\hat{y}_{\text{final}}$，该值理论上更贴近真实值，如式(11)所示：

$$\hat{y}_{\text{final},t} = \hat{y}_{\text{base},t} + \hat{r}_{\text{pre},t} \tag{11}$$

此机制通过动态刷新的元特征M，使一个固定权重的XGBoost模型能够持续感知过程的最新状态。这相当于为模型嵌入一个轻量级的自适应校准阵列，使其在保持稳定性的同时，获得了对过程慢时变的快速响应能力，从而有效缓解传统静态模型在长周期运行中因概念漂移导致的性能衰退问题。

1.3 决策逻辑与阈值判别策略

决策逻辑与阈值判别策略模块基于动态残差修正后的最终残差序列，采用包含统计阈值和序贯决策判据的策略，实现对系统故障的可靠检测。具体流程如下。

根据残差修正模块得到的最终预测值$\hat{y}_{\text{final}}$与真实值y_{true}计算最终残差序列r_{final}。该序列是评估当前系统状态是否偏离正常运行工况的直接依据，如式(12)所示：

$$r_{\text{final}} = y_{\text{true}} - \hat{y}_{\text{final}} \tag{12}$$

通过设定阈值θ_{res}区分正常波动与潜在异常。利用模型在正常数据的验证集生成的最终残差序列r_{final}，并基于该集合的残差绝对值分布，计算其残差绝对值的95%分位点，并以此作为故障判断的阈值[27]，如式(13)所示：

$$E_t = (|r_{\text{final},t}| > \theta_{\text{res}}) \tag{13}$$

单个数据点的残差绝对值$|r_{\text{final},t}|$超出阈值θ_{res}时，则触发初步报警。为甄别真实故障与随机噪声引起的瞬时扰动，引入一个序贯决策判据[28]。此设计在检测灵敏性与可靠性之间寻求平衡，即通过引入微小且可控的延迟，实现误报率的显著降低。本研究中，设定$k=5$，即只有当连续超过5个采样点的残差绝对值均超出阈值θ_{res}时，系统才确认故障发生，并从第一个超限点视为异常报警，如式(14)所示：

$$F_t = \begin{cases} 1 & \text{if } \sum_{j=t-k+1}^{t} E_j \geqslant k \\ 0 & \text{otherwise} \end{cases} \tag{14}$$

1.4 性能评估指标

本文从预测精度与故障检测能力两个维度对DRCDM的综合性能进行评估。在预测精度方面，采用决定系数(R^2)、均方根误差(RMSE)和平均绝对误差(MAE)三项指标，分别用以衡量模型的拟合优度及预测偏差。三项指标的计算如式(15)~式(17)所示：

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \tag{15}$$

$$\mathrm{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \tag{16}$$

$$\mathrm{MAE} = \frac{1}{n}\sum_{i=1}^{n}\left|y_i - \hat{y}_i\right| \tag{17}$$

式中，n为样本总数；y_i为真实值；$\hat{y}_i$为预测值；$\bar{y}$为真实值的平均值。

将故障检测视为二分类问题，基于混淆矩阵计算故障检测率（FDR）、误报率（FAR）、F1-score、平均检测延迟（ADD）和样本推断时间，如式（18）~式（20）所示：

$$\mathrm{FDR} = \frac{\mathrm{TP}}{\mathrm{TP} + \mathrm{FN}} \tag{18}$$

$$\mathrm{FAR} = \frac{\mathrm{FP}}{\mathrm{FP} + \mathrm{TN}} \tag{19}$$

$$\mathrm{F1} = 2 \times \frac{\frac{\mathrm{TP}}{\mathrm{TP} + \mathrm{FP}} \times \frac{\mathrm{TP}}{\mathrm{TP} + \mathrm{FN}}}{\frac{\mathrm{TP}}{\mathrm{TP} + \mathrm{FP}} + \frac{\mathrm{TP}}{\mathrm{TP} + \mathrm{FN}}} \tag{20}$$

将故障样本视为真，将正常样本视为假。TP为故障样本预测为故障；FP为正常样本预测为故障；FN为故障样本预测为正常；TN为正常样本预测为正常。

2 案例分析

本节使用两个案例来验证DRCDM方法模型的有效性：TE过程和某280万吨/年FCC装置。实验所使用的模型均基于Python语言，硬件配置为Intel(R) core(TM) Ultra 9 285K CPU, 64G RAM，软件环境基于Python 3.13，核心框架为TensorFlow 2.10与XGBoost 2.02。

2.1 DRCDM参数设置

DRCDM的详细参数设置见表1。原始数据输入模型前，采用时序滑窗对数据进行组织，将历史T=30个时间步的特征序列作为基础模型的输入。在基础模型的CNN层中，采用修正线性单元（ReLU）作为激活函数，以利用其计算高效及缓解梯度消失的优势。而在BiLSTM层中，则采用标准的双曲正切函数（tanh）。为抑制过拟合，在第一个Conv1D层和BiLSTM层后均设置了Dropout层，其丢弃率设定为0.2。针对模型的预测任务，选用均方差（MSE）作为损失函数，因其对较大预测误差具有更强的惩罚作用。基础模型采用Adam优化器进行训练，初始学习率设置为0.0005。在基础模型的训练阶段，为防止过拟合，引入早停机制，即在总计100个轮次的训练中，设置了当连续20个轮次内训练未得到改善时，训练将自动终止，并保存性能最佳的模型权重。

表1 模型参数设置

Table 1 Parameters of DRCDM

Model	Parameter
CNN	(Conv1D) Filter=128, Kernel=3, Activation=Relu
	Dropout=0.2
	(Conv1D) Filter=64, Kernel=3, Activation=Relu
BiLSTM	BiLSTM=64
	Dropout=0.2
XGBoost	N_estimators=[100, 200, 300]
	Max_depth=[3, 5, 7]
	Learning_rate=[0.01, 0.05, 0.1]
	Subsample=[0.8, 1.0]
	Colsample_bytree=[0.8, 1.0]

考虑到基础模型与补偿模型在计算复杂度和数据需求上的差异，采用一种混合的时序交叉验证策略，如图3所示，旨在保证评估严谨性的同时充分利用数据。对于计算成本较高的CNN-BiLSTM模型，采用简单的时序划分。将IDV0数据按时间顺序以8∶2的比例划分为训练集和验证集。其中，前80%的数据用于模型权重的梯度更新；后20%的数据仅用于早停判断及后续故障检测阈值的校准，以防止过拟合。对于动态残差补偿模块的XGBoost补偿器，在训练集内部实施5折时序交叉验证。该过程采用扩展窗口策略，即每一折的训练集随时间逐步扩展，而验证集固定长度且位于当前训练窗口之后。此策略严格遵循时序数据的因果约束，避免未来信息的泄露。通过交叉验证在一个包含多个关键参数的高维空间内进行网格搜索，以在模型复杂度与泛化能力之间取得最优平衡。

2.2 TE过程

2.2.1 TE过程介绍 本节通过TE过程进行实验以验证DRCDM的有效性。该过程由Downs等[29]开发，旨在模拟真实的工业过程，现已被广泛应用于检验故障检测与诊断（FDD）算法[30]。该工艺主要包括反应器、冷凝器、压缩机、分离器和汽提塔5个单元，如图4所示。设置阶跃、随机变化和缓慢漂移等不同类型的28种故障，定义了53个过程变量，包括12个操纵变量、22个连续过程变量和19个成分测量变量。

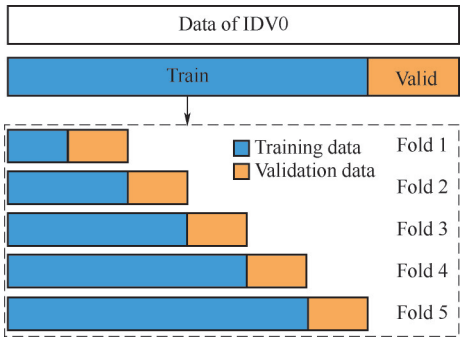

图3 时序交叉策略

Fig.3 Timing cross-validation strategy

实验通过1种正常工况和15种已知故障类型的工况(表2)评估DRCDM的性能,并将重点放在由反应动力学缓慢漂移引发的故障(IDV13)上,因其渐进式积累的特性,使得早期检测极为困难,对模型的灵敏度和鲁棒性提出更高的要求,使其成为验证模型性能的理想案例[31]。

本实验部分所使用数据集采用TE过程的修订版本,可从华盛顿大学控制工程实验室的官方渠道获取(http://depts.washington.edu/control/LARRY/TE/down load. bkp. html)[32]。在MATLAB R2023b Simulink平台对该工艺模态3正常及故障工况进行仿真模拟,并参照Zhang等[13]的研究设置数据采样

表2 TE过程的工艺故障

Table 2 Faults of TE process

故障编号	故障描述	故障类型
IDV1	A和C的进料比变化,B成分不变(流4)	阶跃
IDV2	B成分变化,A和C的进料比不变(流4)	阶跃
IDV3	D的进料温度变化(流2)	阶跃
IDV4	反应器冷却水入口温度变化	阶跃
IDV5	冷凝器冷却水入口温度变化	阶跃
IDV6	A进料损失(流1)	阶跃
IDV7	C存在压力损失-可用性降低(流4)	阶跃
IDV8	A、B、C进料成分变化(流4)	随机变量
IDV9	D的进料温度变化(流2)	随机变量
IDV10	C的进料温度变化(流4)	随机变量
IDV11	反应器冷却水入口温度变化	随机变量
IDV12	冷凝器冷却水入口温度变化	随机变量
IDV13	反应动力学变化	缓慢偏移
IDV14	反应器冷却水阀门	阀黏滞
IDV15	冷凝器冷却水阀门	阀黏滞

时间为每三分钟一次。其中,正常状态运行24 h,收集480个正常样本;而对于故障工况则运行48 h,在第8 h后引入扰动,共收集960个故障样本;IDV6在引入故障后运行一段时间模拟自动停止,详见表3。

2.2.2 基于TE过程的DRCDM性能对比分析 为

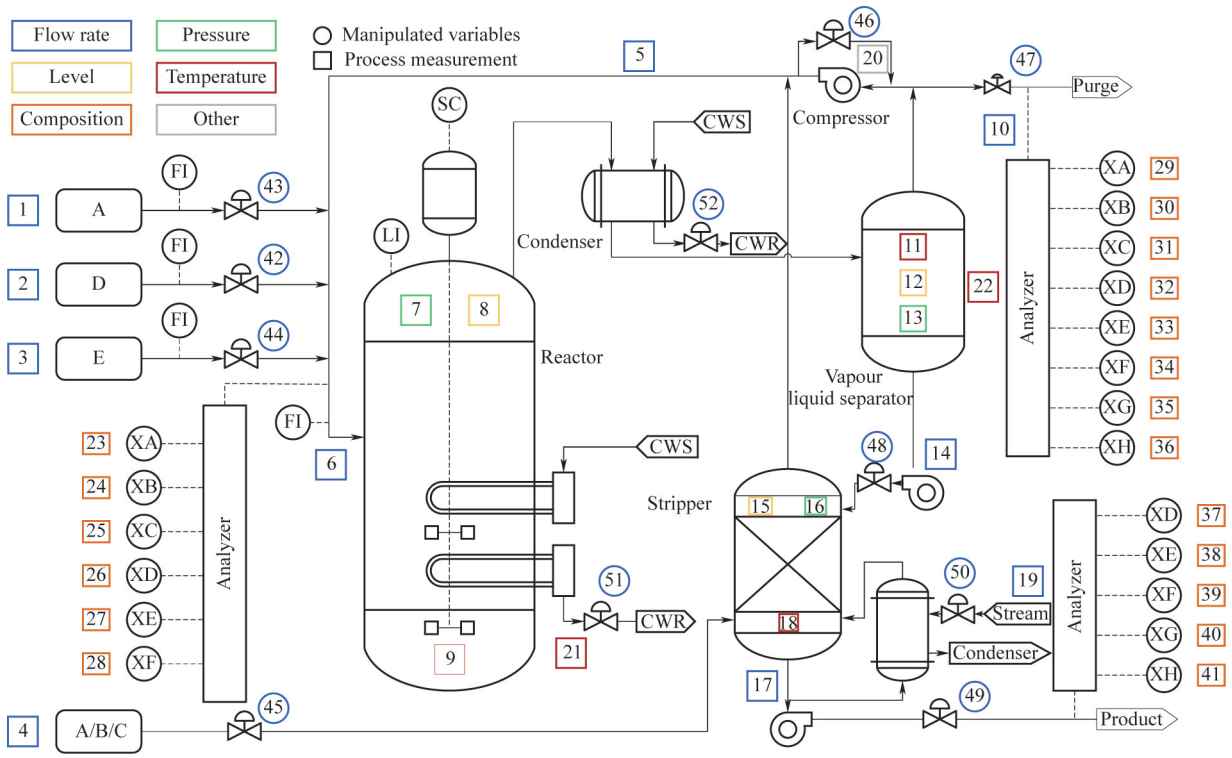

图4 TE工艺流程

Fig.4 The TE process

表3 TE过程仿真数据收集

Table 3 Data of TE process

编号	运行时长/h	样本数量
IDV0(正常)	24.0	480
IDV6	14.1	282
IDV1~5,7~15	48.0	960

全面评估DRCDM的综合性能,本节将从预测精度、变量筛选、阈值无关判别力、类别均衡检测力、实时性及统计稳健性6个维度展开实验。

在预测精度检验中,选取正常工况(IDV0)的过程变量XMEAS(1)作为研究对象,并对比CNN、LSTM、CNN-BiLSTM及其嵌入动态残差补偿模块后的6种模型,详细的实验结果如图5和表4所示。结果表明,CNN-BiLSTM凭借其对时空特征的优越捕获能力,在基础模型中表现极佳,R^2值达到0.88。在此基础上,引入动态残差补偿模型后的模型R^2提升至0.91的同时,RMSE降低11.10%。对于CNN、LSTM模型,在引入该模块后预测精度也呈现显著提升。该结果有力地证实了两个核心论点:(1)先进的深度学习模型在面对复杂工业数据时,其预测中依然存在着不可忽视、可被建模的偏差;(2)本文所设计的动态残差修正模块能够有效地学习并补偿这种偏差,并提升模型的预测精度。动态残差修正模块的有效性为后续利用其构建高精度、低误报的故障检测系统奠定了基础。

表4 6种模型预测性能指标结果

Table 4 The prediction performance indicators results of the six models

Model	R^2	RMSE	MAE
CNN	0.83	0.0021	0.0017
CNN-XGBoost	0.89	0.0016	0.0010
LSTM	0.74	0.0026	0.0020
LSTM-XGBoost	0.87	0.0018	0.0011
CNN-BiLSTM	0.88	0.0018	0.0014
CNN-BiLSTM-XGBoost	0.91	0.0016	0.0010

鉴于故障检测与正常工况预测任务对信息的敏感度不同,筛选出对故障最敏感的过程变量是构建检测模型的关键前提。以IDV13为例,详细展开变量筛选过程。反应动力学的缓慢漂移直接导致反应物消耗速率的降低与放热量的减少,破坏了反应器原有的热力学平衡。系统为维持温度,迫使冷却水出口温度[XMEAS(21)]相应降低。与此同时,串级控制系统为保障关键产品质量,触发汽提塔的蒸汽流量[XMEAS(19)]持续上调。最终,未反应的组分会在下游产品中不断富集,迫使系统通过增加吹扫气体排放[XMEAS(10)]来维持全局的物料平衡。然而,成分浓度测量具有明显的滞后性,因此本研究将XMEAS(10)、XMEAS(19)和XMEAS(21)作为故障检测的候选变量。

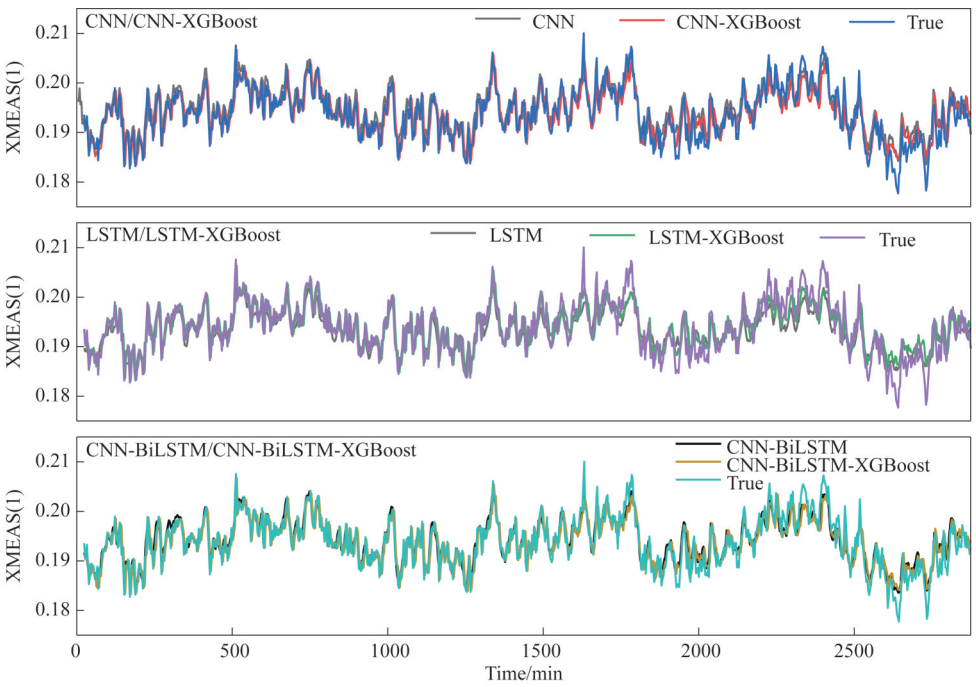

图5 6种模型预测结果

Fig.5 The prediction results of the six models

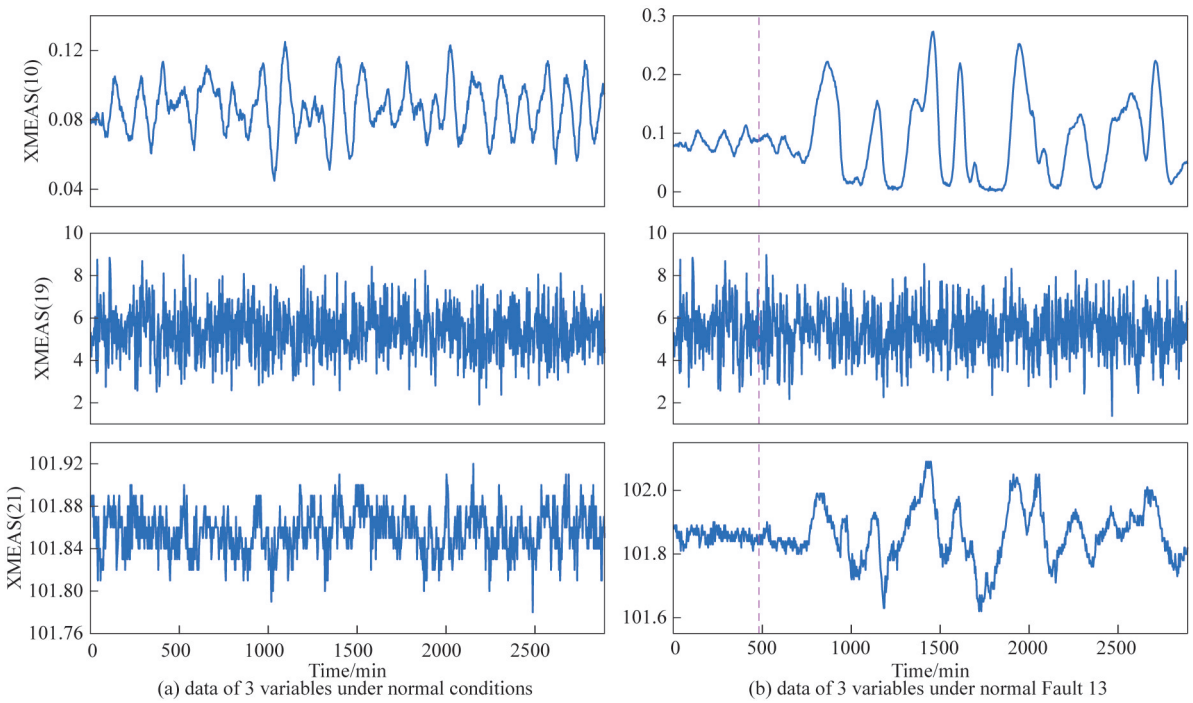

图6 IDV0与IDV13工况下3个变量的动态轨迹

Fig.6 The dynamic trajectories of the three variables under IDV0 and IDV 13 conditions

如图6所示，通过对比故障发生前后候选变量的动态轨迹，XMEAS(10)在故障发生后表现出更清晰的偏离趋势与更高的信噪比，其故障敏感度明显高于XMEAS(19)和XMEAS(21)。同时，采用Kullback-Leibler(KL)散度进一步评估XMEAS(10)、XMEAS(19)、XMEAS(21)及三变量组合对故障特征的表达能力。如图7所示，XMEAS(10)的KL散度分数达9.05，显著高于XMEAS(19)和XMEAS(21)。这源于XMEAS(10)单独承载了IDV13最大的故障信息增益，是故障特征最为集中的载体。对于多变量组合的KL散度为7.73，反而低于XMEAS(10)的单变量得分。这说明引入相关性较弱或噪声较大的控制变量会淹没关键故障信息，从而模糊故障特征，降低模型的判别能力。因此，XMEAS(10)的选择为IDV13的可靠检测提供了坚实基础。

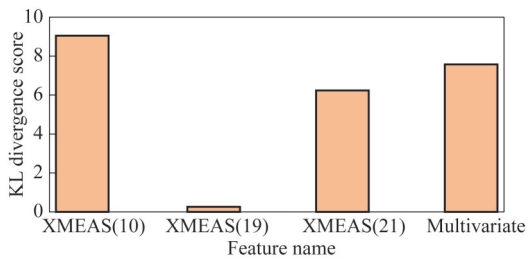

图7 3个变量的概率分布偏移程度

Fig.7 The degree of deviation of probability distribution of the three variables

考虑到单变量与多变量策略可能对模型检测性能存在一定的影响，基于KL散度分析IDV3、IDV9、IDV15的变量概率分布的偏移程度，并进行了检测单变量和多变量检测任务的对比，结果见表5。多变量策略在处理强耦合故障时具有一定的信息优势，但综合评估显示，单变量策略在计算效率与抗干扰鲁棒性方面展现出更具工程应用的潜力。单变量策略平均推断时间为0.0989 ms，而多变量策略普遍增加30%以上，在IDV15中甚至达到0.3546 ms。在IDV3和IDV13中，单变量的检测性能均优于多变量策略，这表明盲目增加变量维度可能会引入无关噪声，削弱故障信号。同时，也兼顾在2.3节中涉及的FCC分馏塔底油浆结焦结垢此类存在明确相关变量的场景。因此，最终选定单变量作为故障检测的核心策略。

为确保在线监测阈值的可靠性，进行阈值估计样本量分析和重采样稳定性检验，旨在明确为达到不同精度要求(以变异系数CV度量)所需的理论最小正常样本数量并验证在足够Bootstrap抽样次数(B=1000)下所得控制限不会因重采样波动而产生显著漂移。实验结果见表6，当前使用的正常样本量为62个，已满足CV ≤ 10%下的理论最小样本量要求。若未来需追求更高精度(如CV ≤ 2%)，则需进一步扩充正常工况样本量至1250以上。此项分

表5 4种故障的单变量和多变量策略检测对比

Table 5 Comparison of univariate and multivariate strategy detection of four faults

故障		F1-score/%	FDR/%	FAR/%	Delay/min	单次推断时间/ms
IDV3	single-variable	69.33	53.06	0	54	0.0998
	multi-variable	56.45	39.33	0	63	0.1393
IDV9	single-variable	56.58	39.45	0	60	0.1022
	multi-variable	62.96	45.94	0	57	0.1373
IDV13	single-variable	95.23	90.89	0	132	0.1027
	multi-variable	94.81	90.14	0	129	0.1375
IDV15	single-variable	27.56	15.98	0	30	0.1036
	multi-variable	49.58	32.96	0	30	0.3546

表6 TE过程的阈值估计样本量分析结果

Table 6 Threshold estimation sample size analysis results for TE process

目标CV水平	理论最小样本量	当前样本量
<10%	50	62
<5%	200	62
<2%	1250	62

析为后续故障检测与模型性能比较提供了样本量基准。

随后，采用B=1000的阈值自举法，通过DRCDM与PCA、KPCA、AE、LSTM-AE及LSTM-VAE方法对比以评估检测延迟对决策阈值不确定性的鲁棒性，并以中位数和四分位距报告结果，以准确反映模型时效性的集中趋势与稳定性，结果如图8所示。DRCDM的统计结果显示其检测延迟为132 min(IQR：0 min)。同时，LSTM-VAE也表现出0 min的四分位距，但LSTM-VAE检测中位数为186 min，显著高于DRCDM。与LSTM-AE相比，DRCDM在取得具有竞争力的故障检测率的同时，还提供了最佳的检测稳定性与可接受的响应延迟。虽然PCA相较于DRCDM在此故障中更早发生异常，但其在检测中出现了更多的漏报。

通过对比在全阈值范围内的受试者工作特征曲线(ROC)及对应的AUC数值，以验证模型在异常扰动下的综合故障判别能力。图9展示了6种模型的ROC曲线及对应的AUC值。结果显示，DRCDM曲线轨迹位于对比模型上方，并且取得了0.9264的最高AUC值，展现出了最优的分类能力。在低FPR区间内，DRCDM的TPR斜率更大，这意味着在极低的误报容忍度下，该模型仍能保持极高的故障检测率。相比之下，重构模型的AUC均低于0.8730，反映出其对微弱故障信号的检测能力不佳。该实验

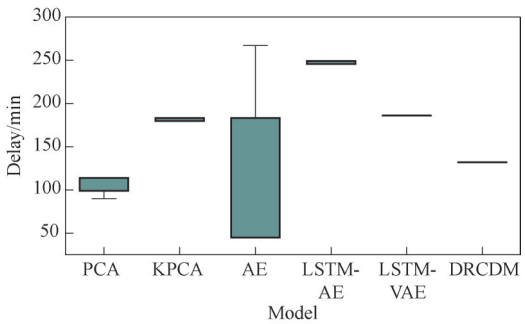

图8 6个模型的IDV13检测延迟分布箱线图

Fig.8 The IDV13 detection delay distribution box plots of the six models

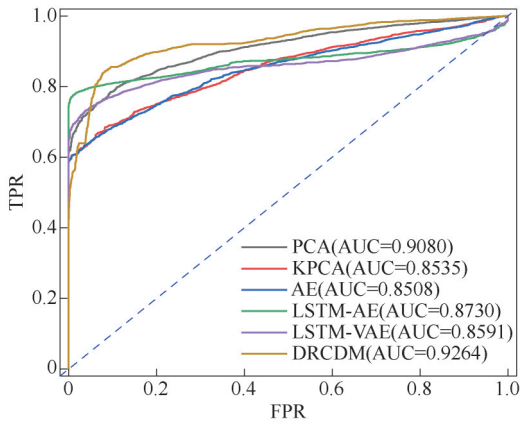

图9 6种模型的ROC/AUC分析

Fig.9 ROC/AUC analysis of the six models

结果证明，DRCDM能够有效地在动态过程中提取特征，从而保证系统低误报率运行的同时，实现故障检测准确性的最大化。

为弥补ROC/AUC在评估固定阈值下评估检测性能的局限性，进一步计算FDR和F1-score来评估DRCDM的均衡检测能力。如图10所示，不同类型故障的检测难度呈现明显差异。对于IDV1、IDV2、IDV6等阶跃或幅值变化明显的故障，所有方法均能在无误报的前提下检测率普遍高于90%，实现精确

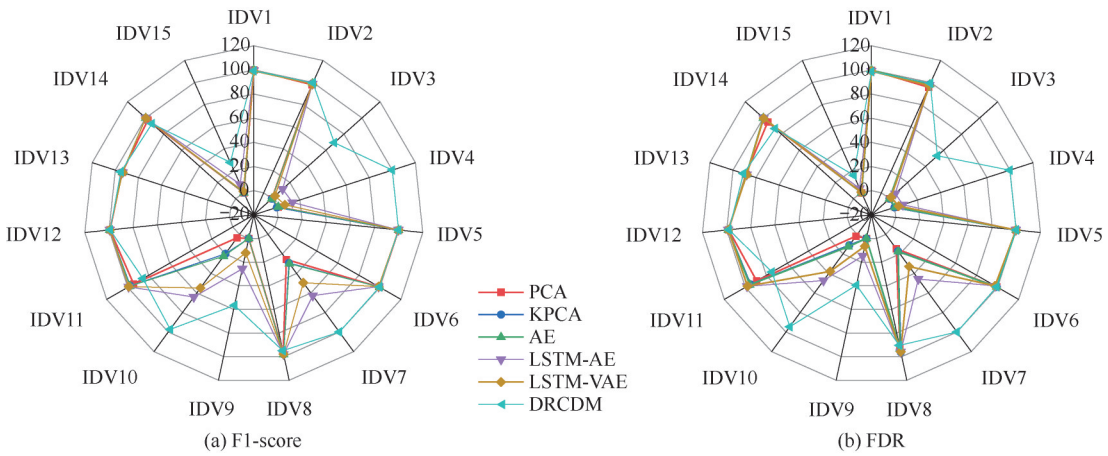

图10 6种模型的TE故障检测结果

Fig.10 The TE fault detection results of the six models

检测。然而,在IDV13的检测中,所有模型的检测性能均有所下降,但DRCDM的检测能力优于其他对比模型。面对IDV3、IDV9、IDV15难以检测的故障时,对比方法几乎全部失效,难以实现可靠报警。相比之下,DRCDM的性能虽有所衰减,但仍保持了可观的检测能力。值得注意的是,在IDV4的检测中,对比模型也近乎全部失效,而DRCDM的FDR仍能保持99.98%。在所有的故障检测中,DRCDM均未出现误报,在保证极低误报的同时,实现了更优的检测性能。

在实际应用中,检测延迟往往对系统安全至关重要,即使检测准确,若响应过慢,异常可能已造成不可逆的危害。为此,进一步测量DRCDM的报警延迟与推理耗时。表7展示了故障的平均检测延迟和单次推断时间。鉴于IDV3、IDV4、IDV9、IDV11等故障在引入瞬间即达到稳态异常水平,过程测量值无渐进式偏离,无法定义具备统计意义的检测延迟,故将其排除。DRCDM以33.6 min的平均检测延迟显著优于所有对比模型。这源于重构模型其平衡效应导致的响应滞后,而DRCDM的动态残差补偿模块利用历史残差序列上下文能够识别偏差的演化趋势,从而在故障早期即可做出判断。DRCDM的推理时间维持在0.0989 ms左右,与基于深度自编码器的LSTM-AE、LSTM-VAE等方法相当,这表明其具备与重构模型相近的在线计算效率。尽管PCA方法在计算速度上占有绝对优势,但其检测性能与延迟表现较差,难以满足高精度工业检测的实际需求。且在多种工况下,DRCDM的推断时间均低于KPCA和AE方法,进一步体现了该方法在计算资源有限场景下的优势。综合来看,DRCDM在保证优异检测性能与极低报警延迟的同时,其在线计算资源消耗亦保持在合理范围内,验证了该方法在准确性、实时性与计算效率方面的综合优势。

表7 6种模型的平均检测延迟与单次推理时间

Table 7 The average detection delay and single inference time of the six models

Model	ADD/min	单次推理时间/ms
PCA	151.8	0.0028
KPCA	96.0	0.0649
AE	96.0	0.0760
LSTM-AE	85.5	0.1148
LSTM-VAE	107.1	0.1077
DRCDM	33.6	0.0989

然而,现场工况漂移、采样波动仍可能影响动态检测性能的稳定性。为此,采用Bootstrap重采样,评估其统计稳健性。通过1000次的重采样模拟,计算F1-score的95%置信区间及P值,结果见表8。DRCDM展现出卓越的故障检测性能,其F1-score的置信区间[89.48, 90.35]显著优于传统统计学方法及复杂深度循环网络模型。值得注意的是,DRCDM的置信下界已超越对比方法的上界,且所有对比模型的P值均为0,这证明了DRCDM的高稳定性与强泛化能力。

2.2.3 基于TE过程的DRCDM动态残差补偿有效性分析 本节通过与无补偿器(CNN-BiLSTM)、线性补偿器(linear compensator)、无历史残差统计(no hist resid)、无静态统计量(no input stat)、无基础预测值(no base pred)、以LightGBM为二级模型的DRCDM(LightGBM)对比评估DRCDM各关键组件的实际贡献,详细结果如图11所示。在易检测的故

表8 基于Bootstrap重采样的6个模型F1-score

Table 8 The F1-score of the six models based on Bootstrap resampling

Model	F1-score 95% CI/%	*P*-value
PCA	71.76[70.96,72.47]	0
KPCA	73.35[72.58,74.06]	0
AE	73.53[72.77,74.24]	0
LSTM-AE	78.66[78.01,79.32]	0
LSTM-VAE	76.36[75.62,77.03]	0
DRCDM	89.94[89.48,90.35]	—

障中，所有模型均表现出优异的检测能力。但在IDV3和IDV9上，无补偿的深度模型完全失效，而引入线性补偿器后性能显著恢复，证明残差补偿架构能有效克服对特定故障的检测局限性。然而，线性补偿器在非线性极强的IDV15上表现有限，而采用非线性补偿器的完整模型性能表现更优，说明复杂工况下需要非线性回归器捕捉高维故障特征。移除历史残差统计使得IDV3检测率下降了23.37%，证明时序动态信息对修正时滞偏差至关重要。而基础预测值与静态统计量的缺失导致IDV15检测性能急剧恶化，表明这些特征为弱信号故障提供了必要的判别基准。值得注意的是，基于XGBoost和LightGBM的两种方案在绝大多数故障上表现相近，进一步证明了模型性能的提升源于动态残差补偿架构，而非依赖于强回归模型。

2.2.4 基于TE过程的DRCDM参数灵敏度分析 为确保研究结论的稳健性，并排除其对经验参数选择的偶然性，本节对滚动窗口长度L、序贯长度k及置信水平CI三个参数进行灵敏度分析。

以IDV13为例，在区间$L\in[3,15]$内测试模型性能，结果如图12所示。此区间的设定考虑到$L=1$或$L=2$时，窗口极短，无法提供足够的样本信息来构建具有统计显著性的二阶矩阵，极易导致元特征受单点噪声干扰而剧烈波动，进而破坏训练的稳定性；$L>15$时，过长的窗口会引入大量陈旧的历史信息，从而埋没当前时刻关键突变信号，导致补偿器响应延迟。滚动窗口的本质是一个回归任务，服务于XGBoost模型，MSE能够直接反映预测误差的变化趋势，故实验采用MSE作为评价指标。通过最小化MSE获得精准的预测误差，实现有效的残差补偿，从而提升最终的故障检测性能。实验表明，随着L的增大，模型的预测精度呈先升后降趋势，在$L=5$时达到最佳预测精度，此时模型既能有效抑制高频噪声，又能最大限度地保持对故障信号的响应灵敏度。因此，本文最终选取滚动窗口大小为$L=5$。

在不同置信水平CI∈{90%,95%,99%}及序贯长度$k\in[1,10]$下进行了全面的灵敏度分析，结果如图13所示。序贯长度k直接决定了噪声抑制与检测灵敏度之间的权衡关系。随着k的增加，误报率呈现衰减趋势，在95%置信水平下，FAR从$k=1$时的6.50%迅速降至$k=5$时的2.00%，并随后趋于稳定。这表明$k=5$能够有效滤除绝大部分由随机波动引起的瞬态干扰。同时，FDR随k增加表现为线性下降，即使在$k=5$时，FDR依然维持在92%以上，且检测延迟控制在约132 min的范围内，未出现数量级的恶化。这说明该设置在保持高检出能力的同时有效控制时滞。在置信水平的选择上，对比曲线显示90%置信水平虽具有最快的响应速度，但伴随6%的误报，而99%置信水平则因过度保守导致

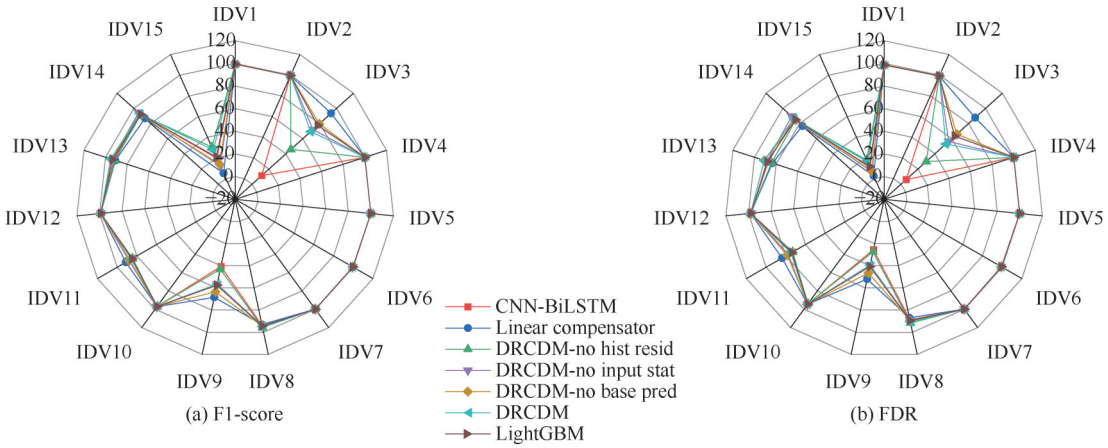

图11 消融实验对比结果

Fig.11 The comparative results of ablation experiments

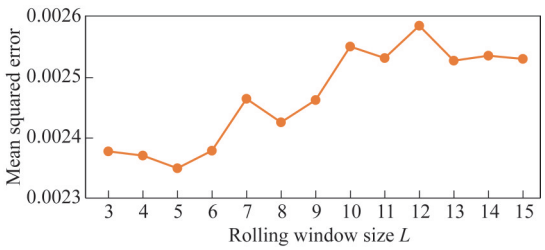

图12 滚动窗口大小对模型预测误差的影响

Fig.12 Influence of rolling window size on model prediction error

FDR跌破90%且检测延迟显著增加。相比之下，95%置信水平在故障检测率、误报率与检测延迟之间取得了极佳平衡，在维持足够故障捕获能力的同时提供了鲁棒的抗噪边界。因此，选取k = 5作为序贯阈值，95%控制限。

2.3 FCC工艺

2.3.1 工艺介绍 FCC作为炼油厂重油轻质化的核心二次加工装置，其运行平稳性直接关系到生产效益与安全水平。该工艺流程错综复杂，异常事故频发，尤其分馏塔底及油浆循环系统，易出现设备结焦、结垢导致管路堵塞，有效地监测油浆线速是判断该异常的重要途径。为此，本节将DRCDM应用于工业FCC运行数据进行测试，实验数据采自某280万吨/年炼厂FCC装置，选取2022年1月的全部历史运行数据构建训练集与验证集，随后选取同年2月的数据作为测试集进行性能评估。该实验旨在严格检验模型在面对真实工业噪声干扰与动态漂移时，能否保持可靠的检测性能，以衡量模型是否具备工程使用价值。

2.3.2 基于FCC工艺的DRCDM性能对比分析 为验证所提阈值生成流程在数据充足场景下的稳态性能，本节在FCC装置上继续开展同尺度的阈值估计样本量与重采样稳定性实验，结果见表9。该大样本工况不仅可一次性达到更高精度(CV ≤ 2%)，更为TE小样本场景提供充足数据基准对比。

相比TE过程中使用的对比基线模型，本节增加了ADWIN自适应基线和增量XGBoost两种方法，结果见表10。不同算法在处理真实工业数据时表现出明显差异。传统统计模型PCA与KPCA的误报率分别高达35.98%和11.86%，这说明浅层模型难以从复杂的工业背景噪声中提取有效特征。而基于深度学习的LSTM-AE亦出现21.99%的高误报率，反映出其在非受控环境下存在严重的过拟合倾向。相比之下，虽然LSTM-VAE利用变分推断使误报率

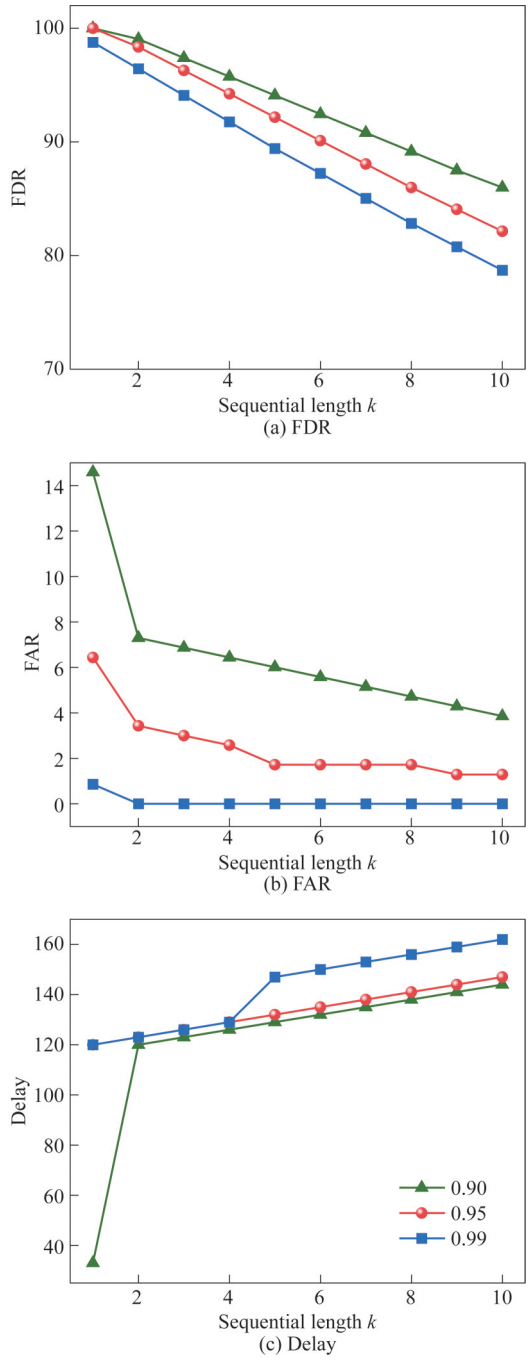

图13 序贯长度k及置信水平CI对FDR、FAR及检测延迟的影响

Fig.13 The effect of sequential length k and confidence level CI on FDR, FAR and detection delay

表9 FCC工艺的阈值估计样本量分析结果

Table 9 Threshold estimation sample size analysis results for FCC process

目标CV水平	理论最小样本量	当前样本量
<10%	30	2097
<5%	120	2097
<2%	747	2097

表10 基于FCC运行数据的模型检测结果

Table 10 The test results based on FCC operation data

Model	FAR/%	单次推理时间/ms
PCA	35.98	0.0004
KPCA	11.86	0.0373
AE	8.84	0.0184
LSTM-AE	21.99	0.1009
LSTM-VAE	3.39	0.0794
DRCDM	1.12	0.0657
ADWIN adaptive baseline	1.95	0.5641
incremental XGBoost	1.76	4.0403

降至3.39%，但DRCDM进一步降至1.12%，甚至优于ADWIN自适应基线，展现出其更强的抗干扰能力。这证明DRCDM能够有效滤除绝大多数非故障性的环境扰动，减少工业现场常见的报警疲劳问题。同时，DRCDM维持了高效率，单次推断仅为0.0657 ms，远快于增量XGBoost。这有力地证实了DRCDM在复杂化工过程中的有效性、鲁棒性及工程推广价值。

3 结 论

本研究提出了一种基于动态残差补偿的工业时序数据故障检测模型，该模型架构的协同优势在TE过程及FCC流程中得到验证，在15种TE过程故障检测任务中，该模型展现出显著优势，AUC达到0.9264，且在IDV3、IDV4、IDV9、IDV13、IDV15这类较难检测的故障中仍保持可观的检测能力，并在无渐进式偏离的故障中以33.6 min的平均检测延迟实现最快报警。基于1000次的Bootstrap重采样统计验证表明，其F1-score 95% CI显著优于对比模型，且在IDV13表现出最佳的稳定性。消融实验证明了该模型检测性能的提升源于动态残差补偿模块，而非依赖于更强的回归模型。参数灵敏性分析确立了滚动窗口L = 5、序贯长度k = 5、95%置信水平的最优组合，实现零误报的前提下保证检测可靠性。在实际FCC工业时序数据应用中，该模型仍能保持极低的误报率(FAR=1.12%)，显著优于其他对比模型。这些结果共同表明，动态残差补偿范式是解决动态化工过程故障检测的一种有效途径。未来的工作将集中于优化堆叠架构以增强实时监控与自适应性，同时探索单变量与多变量检测模式的动态切换以提升场景泛化能力。并在此基础上增加诊断与溯源功能，以构建一个覆盖监测、预警、诊断以及溯源的全流程智能运维系统。

符 号 说 明

B——Bootstrap重采样次数

b_{dense}——全连层偏置向量

$C^{(n)}$——经特征提取后的特征序列

CI——置信水平

E_t——异常计数函数

F_t——故障标记函数

f_t,i_t,o_t——分别为LSTM网络中的遗忘门、输入门和输出门

$\vec{h}_t,\overleftarrow{h}_t,h_t^{\text{bi}}$——分别为前向、后向和最终的隐藏状态序列

K——时序交叉验证折数

k——异常时刻数目

L——滚动统计窗口长度

N——残差序列的时间步长

n——样本总数

$\boldsymbol{p}_{\text{avg}}$——全局平均池化向量

r_{base}——一级残差值

$\hat{r}_{\text{pre}}$——残差修正值

$\text{rolling_stats}(r_{\text{base}})$——滚动统计特征

$\text{stats}(X_{\text{seq}})$——统计特征

T——整个窗口的时间步长

W_{dense}——全连层权重矩阵

y_{true}——真实值

$\bar{y}$——真实值的平均值

$\hat{y}_{\text{base}}$——基础模型的预测值

$\hat{y}_{\text{final}}$——最终预测值

参考文献

[1] Bai Y M, Xiang S Y, Cheng F F, et al. A dynamic-inner LSTM prediction method for key alarm variables forecasting in chemical process[J]. Chinese Journal of Chemical Engineering, 2023, **55**: 266-276.

[2] Xiang S Y, Bai Y M, Zhao J S. Medium-term prediction of key chemical process parameter trend with small data[J]. Chemical Engineering Science, 2022, **249**: 117361.

[3] Jia F, Lei Y G, Guo L, et al. A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines[J]. Neurocomputing, 2018, **272**: 619-628.

[4] 冯子芸, 王治红, 戴一阳. 基于随机森林的不可靠数据化工过程故障诊断方法[J]. 石油学报(石油加工), 2021, **37**(1): 121-129.
Feng Z Y, Wang Z H, Dai Y Y. Random forest based fault diagnosis method for chemical process with unreliable data[J]. Acta Petrolei Sinica (Petroleum Processing Section), 2021, **37**(1): 121-129.

[5] Wang Q L, Han J Q, Chen F, et al. Real-time risk prediction of chemical processes based on attention-based Bi-LSTM[J]. Chinese Journal of Chemical Engineering, 2024, **75**: 131-141.

[6] 杨余, 杨鑫, 王英, 等. 基于mini-1D-CNN模型的TE过程故障诊断[J]. 中国安全科学学报, 2023, **33**(2): 173-178.
Yang Y, Yang X, Wang Y, et al. Research on TE process fault diagnosis based on mini-1D-CNN model[J]. China Safety Science Journal, 2023, **33**(2): 173-178.

[7] 张坤, 肖慧, 徐哈宁, 等. 基于主成分分析和长短期记忆网络的滑坡地表位移监测数据缺失插补算法[J]. 科学技术与工程, 2023, **23**(26): 11129-11135.
Zhang K, Xiao H, Xu H N, et al. Missing interpolation algorithm of landslide surface displacement monitoring data based on principal component analysis and long short term memory network [J]. Science Technology and Engineering, 2023, **23**(26): 11129-11135.

[8] 孔祥玉, 陈雅琳, 罗家宇, 等. 基于偏最小二乘的多特性复杂过程监测方法[J]. 华南理工大学学报(自然科学版), 2022, **50**(6): 100-110.
Kong X Y, Chen Y L, Luo J Y, et al. Multi-feature complex process monitoring method based on partial least squares[J]. Journal of South China University of Technology (Natural Science Edition), 2022, **50**(6): 100-110.

[9] 曹岚, 周成功, 袁斌霞, 等. 基于梯度提升回归树-自训练贝叶斯优化支持向量机的光伏阵列故障诊断方法[J]. 太阳能学报, 2025, **46**(6): 289-297.
Cao L, Zhou C G, Yuan B X, et al. Fault diagnosis methods of photovoltaic arrays based on gradient boosting regression tree-self-training Bayesian optimized support vector machine[J]. Acta Energiae Solaris Sinica, 2025, **46**(6): 289-297.

[10] 严爱军, 王英杰, 王殿辉. Tennessee-Eastman过程的学习型案例推理故障诊断方法[J]. 控制理论与应用, 2017, **34**(9): 1179-1184.
Yan A J, Wang Y J, Wang D H. Fault diagnosis method using learning case-based reasoning for Tennessee-Eastman process[J]. Control Theory & Applications, 2017, **34**(9): 1179-1184.

[11] Perera Y S, Ratnaweera D A A C, Dasanayaka C H, et al. The role of artificial intelligence-driven soft sensors in advanced sustainable process industries: a critical review[J]. Engineering Applications of Artificial Intelligence, 2023, **121**: 105988.

[12] Liu N, Zhu C M, Li Y H, et al. Hybrid deep learning framework with spatiotemporal pattern extraction for decant oil solid content soft sensor development in fluid catalytic cracking units[J]. Petroleum Science, 2025, **22**(7): 3042-3055.

[13] Zhang Z P, Zhao J S. A deep belief network based fault diagnosis model for complex chemical processes[J]. Computers & Chemical Engineering, 2017, **107**: 395-407.

[14] Xu Y Y, Li Y, Wang Y J, et al. Improved few-shot learning method for transformer fault diagnosis based on approximation space and belief functions[J]. Expert Systems with Applications, 2021, **167**: 114105.

[15] Guidotti R, Monreale A, Ruggieri S, et al. A survey of methods for explaining black box models[J]. ACM Computing Surveys, 2019, **51**(5): 1-42.

[16] Zhou Z, Yu H W, Yang L, et al. Fault diagnosis method for chemical processes based on variable correlation-guided convolutional neural networks[J]. The Canadian Journal of Chemical Engineering, 2025, **103**(10): 4874-4889.

[17] 许洪光, 李凤英, 郭茜. 机器学习算法改进及在化工故障诊断中的应用[J]. 粘接, 2022, **49**(5): 85-89, 94.
Xu H G, Li F Y, Guo Q. Improvement of machine learning algorithm and its application in chemical fault diagnosis[J]. Adhesion, 2022, **49**(5): 85-89, 94.

[18] 李娜. 基于改进的LSTM网络的石油化工传感器故障预测研究[J]. 安全、健康和环境, 2025, **25**(6): 40-48.
Li N. Research on fault prediction of petrochemical sensors based on the improved LSTM network[J]. Safety Health & Environment, 2025, **25**(6): 40-48.

[19] Sun L, You F Q. Machine learning and data-driven techniques for the control of smart power generation systems: an uncertainty handling perspective[J]. Engineering, 2021, **7**(9): 1239-1247.

[20] Bayram F, Ahmed B S, Kassler A. From concept drift to model degradation: an overview on performance-aware drift detectors[J]. Knowledge-Based Systems, 2022, **245**: 108632.

[21] Gorinevsky D. Fault isolation in data-driven multivariate process monitoring[J]. IEEE Transactions on Control Systems Technology, 2015, **23**(5): 1840-1852.

[22] Lu C, Fei J Y, Meng X Z, et al. Thermal error prediction and compensation of digital twin laser cutting based on T-XGBoost[J]. Sensors, 2022, **22**(18): 7022.

[23] 魏国家, 赵冠, 赵巍, 等. 数字孪生框架下五轴铣削轮廓误差预测与补偿研究[J]. 机械设计与制造, 2026(1): 362-368,374.
Wei G J, Zhao G, Zhao W, et al. Experimental study on contour error prediction and dynamic compensation method for five-axis milling based on digital twin[J]. Machinery Design & Manufacture, 2026(1): 362-368,374.

[24] Thoma S. Model based compensation of dynamic path deviations in 5-axis machine tools[D]. Zurich: Eidgenössische Technische Hochschule Zürich, 2015.

[25] Li T Y, Hua M, Wu X. A hybrid CNN-LSTM model for forecasting particulate matter ($PM_{2.5}$)[J]. IEEE Access, 2020, **8**: 26933-26940.

[26] 谢世元, 郭志远, 强惠敏, 等. 基于XGBoost算法的船舶目的地预测模型[J]. 计算机工程与设计, 2025, **46**(6): 1766-1771.
Xie S Y, Guo Z Y, Qiang H M, et al. Vessel destination prediction model based on XGBoost algorithm[J]. Computer Engineering and Design, 2025, **46**(6): 1766-1771.

[27] 宋贽, 王晗, 张久军. 网络投诉反馈视角下汽车质量缺陷的动态监测与预警研究[J]. 运筹与管理, 2026, DOI: 10.12005/orms.2026.0060.
Song Z, Wang H, Zhang J J. Dynamic monitoring and early warning research on automobile quality defects from the perspective of online complaint feedback[J]. Operations Research and Management Science, 2026,DOI:10.12005/orms.2026.0060.

[28] 姜旭峰, 陈勇旭, 宋宝宝, 等. 基于油液在线监测数据的海警船状态异常报警策略研究[J/OL]. 润滑与密封, https://link.cnki.net/urlid/44.1260.TH.20250929.2049004.
Jiang X F, Chen Y X, Song B B, et al. Research on abnormal state alarm strategy of coast guard ship based on oil online monitoring

data [J/OL]. Lubrication Engineering, https://link. cnki. net/urlid/44.1260.TH.20250929.2049004.

[29] Downs J J, Vogel E F. A plant-wide industrial process control problem[J]. Computers & Chemical Engineering, 1993, **17**(3): 245-255.

[30] Bai Y M, Zhao J S. A novel transformer-based multi-variable multi-step prediction method for chemical process fault prognosis [J]. Process Safety and Environmental Protection, 2023, **169**: 937-947.

[31] Bi X T, Zhao J S. A novel orthogonal self-attentive variational autoencoder method for interpretable chemical process fault detection and identification[J]. Process Safety and Environmental Protection, 2021, **156**: 581-597.

[32] Bathelt A, Ricker N L, Jelali M. Revision of the Tennessee Eastman process model[J]. IFAC-PapersOnLine, 2015, **48**(8): 309-314.