

# 基于自编码器与动态多元状态估计的核电厂主泵异常检测方法

李飞<sup>1</sup>, 丁宸轲<sup>2\*</sup>, 郑胜<sup>2</sup>, 罗骁域<sup>1</sup>

<sup>1</sup>中核武汉核电运行技术股份有限公司, 核动力仿真技术与控制技术研究中心, 湖北 武汉

<sup>2</sup>三峡大学数理学院, 湖北 宜昌

收稿日期: 2026年5月25日; 录用日期: 2026年6月18日; 发布日期: 2026年6月25日

## 摘要

针对核电厂主泵运行数据具有高维、非线性和动态变化特征, 提出一种融合自编码器与动态多元状态估计的主泵异常检测方法(AutoEncoder-Dynamic Multivariate State Estimation Technique, AE-DMSET)。该方法在动态多元状态估计(Dynamic Multivariate State Estimation Technique, DMSET)方法的基础上, 引入自编码器学习主泵正常运行状态下多变量监测数据之间的非线性特征关系, 并利用重构残差实现异常识别; 同时, 融合孤立森林(Isolation Forest, IF)、局部离群因子(Local Outlier Factor, LOF)和DBSCAN构建联合异常评分机制, 对候选正常样本进行多角度筛选, 并结合时间衰减因子实现记忆矩阵动态更新。基于某核电厂主泵历史运行数据开展实验, 结果表明, AE-DMSET在动态工况下具有更稳定的状态重构能力和更可靠的异常检测性能, 能够在保持较高异常检出能力的同时有效降低误报风险。AE-DMSET方法的精确率、召回率和F1分数分别达到0.978、0.943和0.960, 能够提升核电厂主泵复杂动态工况下异常检测的准确性, 具有一定工程应用价值。

## 关键词

核电厂主泵, 异常检测, 动态多元状态估计, 联合异常评分

# Anomaly Detection Method for Main Pumps in Nuclear Power Plant Based on Autoencoder and Dynamic Multivariate State Estimation

Fei Li<sup>1</sup>, Chenke Ding<sup>2\*</sup>, Sheng Zheng<sup>2</sup>, Xiaoyu Luo<sup>1</sup>

<sup>1</sup>China Nuclear Power Operation Technology Corporation, Ltd., Wuhan Hubei

\*通讯作者。

文章引用: 李飞, 丁宸轲, 郑胜, 罗骁域. 基于自编码器与动态多元状态估计的核电厂主泵异常检测方法[J]. 机械工程与技术, 2026, 15(3): 399-411. DOI: 10.12677/met.2026.153039

## Abstract

To address the high-dimensional, nonlinear, and dynamic characteristics of operational data from nuclear power plant main pumps, an anomaly detection method integrating an Autoencoder with Dynamic Multivariate State Estimation Technique (AE-DMSET) is proposed. Based on the Dynamic Multivariate State Estimation Technique (DMSET), the proposed method introduces an Autoencoder to learn the nonlinear feature relationships among multivariate monitoring data under normal operating conditions, and utilizes reconstruction residuals for anomaly identification. Meanwhile, a joint anomaly scoring mechanism combining Isolation Forest (IF), Local Outlier Factor (LOF), and DBSCAN is constructed to perform multi-perspective screening of candidate normal samples. A time decay factor is further incorporated to realize dynamic updating of the memory matrix. Experiments are conducted using historical operational data from a nuclear power plant main pump. The results demonstrate that AE-DMSET exhibits more stable state reconstruction capability and more reliable anomaly detection performance under dynamic operating conditions, while effectively reducing false alarm risks and maintaining high anomaly detection capability. The proposed AE-DMSET achieves a precision, recall, and F1-score of 0.978, 0.943, and 0.960, respectively, indicating that it can improve the accuracy of anomaly detection for nuclear power plant main pumps under complex dynamic operating conditions and has potential engineering application value.

## Keywords

Nuclear Power Plant Main Pump, Anomaly Detection, Dynamic Multivariate State Estimation Technique, Joint Anomaly Scoring Mechanism

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

反应堆冷却剂泵，简称主泵，是核电厂反应堆冷却剂系统中的关键设备，其主要作用是维持一回路冷却剂循环，保证堆芯热量能够及时带出[1][2]，其运行状态直接关系到核电机组的安全性和稳定性。一旦主泵发生异常，可能导致冷却剂循环能力下降，进而影响反应堆安全裕量[3]。因此，开展主泵运行状态监测与异常检测研究，对于提高核电厂设备可靠性、降低非计划停机风险以及保障机组安全运行具有重要意义[4]。

随着核电厂数字化水平的不断提升，基于数据驱动的监测方法逐渐成为核电设备异常检测的重要技术路线[5]-[7]。多元状态估计方法(Multivariate State Estimation Technique, MSET)是一类典型的数据驱动状态监测方法，近年来已在汽轮发电机振动故障诊断、滚动轴承性能退化评估、齿轮箱轴承温度预测、制粉系统故障诊断以及电站风机故障预警等工业设备状态监测场景中得到应用[8]-[14]。然而，MSET通常采用固定记忆矩阵。当设备运行工况发生变化或数据分布随时间漂移时，固定记忆矩阵难以及时反映系统当前运行状态，容易导致状态估计偏差增大，从而影响异常检测的准确性和稳定性[15]。

针对传统 MSET 记忆矩阵固定、难以适应动态工况的问题, 丁宸轲等[16]提出了动态多元状态估计方法(Dynamic Multivariate State Estimation Technique, DMSET)。该方法采用最近邻方法(Nearest Neighbors, NN) [17]对实时数据进行状态重构, 并通过实际值与重构值之间的残差进行异常判定; 同时, 引入孤立森林(Isolation Forest, IF) [18]对样本异常程度和重要性进行评估, 实现记忆矩阵的动态更新, 使模型能够随实时数据变化不断调整历史样本集合。研究表明 DMSET 能够在一定程度上提升 MSET 对时变工况的适应能力, 为核电厂主泵异常检测提供了一种有效思路[16]。

然而, DMSET 方法在高维、非线性和强动态的主泵运行数据中仍存在局限性。一方面, DMSET 主要依赖最近邻距离度量进行状态重构, 当监测变量维度升高且变量之间存在复杂非线性耦合关系时, 欧氏距离难以充分刻画样本之间的真实相似性, 容易出现邻域匹配失准, 导致重构残差波动增大。另一方面, DMSET 在记忆矩阵更新过程中主要依赖单一孤立森林算法进行样本筛选, 但对局部密度变化、边界样本以及簇状异常的识别能力有限, 在动态工况下可能导致正常过渡样本被误判或异常样本被错误保留, 进一步引发误报或漏报。

为解决上述问题, 本文在 DMSET 基础上提出一种融合自编码器(Autoencoder, AE) [19][20]与动态多元状态估计的主泵异常检测方法(AutoEncoder-Dynamic Multivariate State Estimation Technique, AE-DMSET)。该方法利用自编码器对主泵多变量监测数据进行非线性特征学习, 通过编码-解码结构提取正常运行状态下变量之间的深层关联关系, 并基于重构残差实现异常判定。同时, 融合 IF、局部离群因子(Local Outlier Factor, LOF) [21]和 DBSCAN [22]构建联合异常评分机制, 从全局孤立程度、局部密度偏离程度和密度聚类结构三个角度综合评估样本状态, 以提高候选正常样本筛选的可靠性。在记忆矩阵更新过程中, 结合综合异常评分和时间衰减因子对样本重要性进行评估, 动态替换代表性较低或时效性较弱的历史样本, 使记忆矩阵能够持续反映主泵当前运行状态。

## 2. AE-DMSET 异常检测方法

### 2.1. AE-DMSET 整体框架

针对在高维、非线性和强动态的主泵运行数据中, DMSET 存在的基于最近邻的状态重构能力有限、基于单一 IF 的记忆矩阵更新可靠性不足的局限, 本文提出了如图 1 所示的融合自编码器与动态多元状态估计主泵异常检测方法 AE-DMSET 方法。该方法利用自编码器学习主泵多变量监测数据之间的非线性关联关系, 并通过 IF、局部离群因子(Local Outlier Factor, LOF)和 DBSCAN 构建联合异常评分机制, 以提高记忆矩阵动态更新的鲁棒性。

AE-DMSET 方法的基本思想是: 以动态记忆矩阵作为正常样本库, 利用自编码器构建非线性状态重构模型, 并通过多模型联合异常评分机制筛选高可信度正常样本, 从而实现记忆矩阵的动态更新和主泵异常检测。在状态重构环节, 采用 AE 替代最近邻方法, 以增强模型对高维非线性数据结构的表征能力。在记忆矩阵更新环节, 采用 IF、LOF 和 DBSCAN 联合异常评分机制替代单一 IF 评分, 从全局隔离程度、局部密度偏离程度和密度聚类结构三个角度综合判断样本状态, 提高候选正常样本筛选的可靠性。

如图 1 所示, AE-DMSET 方法首先利用历史正常运行数据构建初始记忆矩阵, 并对数据进行标准化处理。然后, 利用记忆矩阵中的正常样本训练 AE 模型, 使其学习主泵正常运行状态下多变量监测数据之间的非线性关联关系。在线检测阶段, 实时输入样本经 AE 模型重构后, 计算重构残差, 并根据动态阈值判断当前样本是否异常。并采用 IF、LOF 和 DBSCAN 对输入样本进行联合异常评分。当样本残差未超过异常阈值且综合异常评分低于设定阈值时, 该样本被视为候选正常样本。随后, 系统根据综合异常评分和时间衰减因子计算样本重要性, 并动态替换记忆矩阵中代表性较低或时效性较弱的历史样本。最后, 基于更新后的记忆矩阵周期性更新 AE 模型和检测阈值, 使模型持续适应主泵运行状态变化。

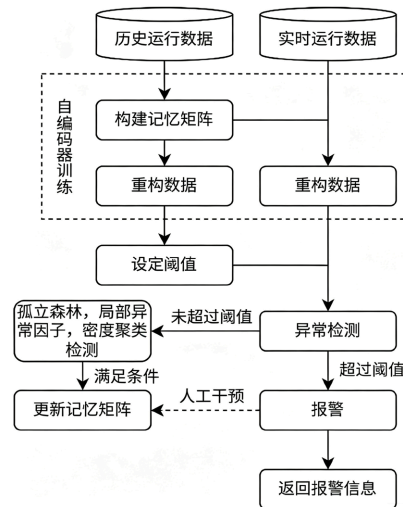


Figure 1. A framework of the AE-DMSET anomaly detection method

图 1. AE-DMSET 异常检测方法整体框架

## 2.2. 自编码器非线性状态重构模型

自编码器(Autoencoder, AE) [19]是一种典型的无监督神经网络模型, 由编码器和解码器两部分组成。编码器将输入数据映射到低维隐空间, 提取数据中的主要特征; 解码器则将隐空间特征映射回原始输入空间, 以实现输入数据的重构。设主泵在时刻 $t$ 的监测状态向量为 $x_t$ , 如公式(1)所示:

$$x_t = [x_t^1, x_t^2, \dots, x_t^n] \in \mathbb{R}^n \quad (1)$$

其中,  $n$  为监测变量数量。AE 编码器将输入样本 $x_t$ 映射为隐变量 $h_t$ , 如公式(2)所示:

$$h_t = f_e(W_e x_t + b_e) \quad (2)$$

式中,  $W_e$  和  $b_e$  分别为编码器的权重矩阵和偏置项,  $f_e$  为编码器激活函数。解码器根据隐变量 $h_t$  重构输入样本, 得到重构向量 $\hat{x}_t$ , 如公式(3)所示:

$$\hat{x}_t = f_d(W_d h_t + b_d) \quad (3)$$

式中,  $W_d$  和  $b_d$  分别为解码器的权重矩阵和偏置项,  $f_d$  为解码器激活函数。AE 模型训练目标是 minimized 输入样本与重构样本之间的均方误差  $MSE$ , 如公式(4)所示:

$$L_{MSE} = \frac{1}{N} \sum_{t=1}^N \|x_t - \hat{x}_t\|_2^2 \quad (4)$$

其中,  $N$  为训练样本数量。

在异常检测阶段, 样本重构残差定义为 $e_t$ , 如公式(5)所示:

$$e_t = \|x_t - \hat{x}_t\|_2^2 \quad (5)$$

当主泵处于正常运行状态时, 输入样本与训练数据分布相近, AE 模型能够较好完成重构, 残差 $e_t$ 较小; 当样本偏离正常运行状态时, AE 难以准确重构该样本, 残差 $e_t$ 增大。因此, 重构残差可作为判断主泵运行状态是否异常的重要依据。

为实现动态工况下的自适应检测, 本文基于记忆矩阵中样本的重构残差动态计算异常判定阈值 $T$ , 如公式(6)所示:

$$T = \mu_e + \kappa\sigma_e \quad (6)$$

式中,  $\mu_e$  和  $\sigma_e$  分别为当前记忆矩阵中正常样本重构残差的均值和标准差,  $\kappa$  为阈值系数。通常可取  $\kappa = 3$ , 对应 3 倍标准差准则。若当前样本满足  $e_t > T$ , 则判定该样本为异常样本; 否则认为该样本未表现出明显异常特征。

### 2.3. 多模型联合异常评分机制

在动态记忆矩阵更新过程中, 若仅依赖 AE 重构残差进行样本筛选, 可能会受到阈值波动和动态工况变化的影响。为提高样本筛选的可靠性, 本文构建由 IF、LOF 和 DBSCAN 组成的联合异常评分机制。其中, IF 适合识别与整体数据分布明显偏离的全局异常样本。LOF 方法通过比较样本与其邻域样本的局部可达密度, 判断样本是否处于局部稀疏区域用于评估样本的局部密度偏离程度, 能够弥补 IF 对局部边界异常识别不足的问题。DBSCAN 方法能够根据样本之间的密度连通关系识别核心点、边界点和噪声点, 用于分析样本的密度聚类结构, 增强模型对簇状异常和孤立噪声点的识别能力。

为统一上述方法的输出, 本文将 IF、LOF 和 DBSCAN 得到的异常度量归一化到  $[0,1]$  区间。设当前样本  $x_t$  对应的三个异常评分分别为  $S_{IF,t}$ 、 $S_{LOF,t}$  和  $S_{DBSCAN,t}$ , 则综合异常评分定义为  $S_t$ , 如公式(7)所示:

$$S_t = w_1 S_{IF,t} + w_2 S_{LOF,t} + w_3 S_{DBSCAN,t} \quad (7)$$

其中,  $w_1$ 、 $w_2$ 、 $w_3$  分别为三种算法的权重, 且满足:  $w_1 + w_2 + w_3 = 1$ 。综合异常评分  $S_t$  越接近 1, 说明样本在多个检测器下均表现出较强异常特征;  $S_t$  越接近 0, 说明样本更可能属于正常运行状态。设联合评分阈值为  $\eta$ , 当样本满足:  $S_t \leq \eta$  时, 认为该样本可作为候选正常样本参与记忆矩阵更新; 当  $S_t > \eta$  时, 则认为该样本异常风险较高。

### 2.4. 动态记忆矩阵更新策略

记忆矩阵是 AE-DMSET 实现动态适应的关键, 在动态工况下, 需要保证记忆矩阵既能够保留具有代表性的历史正常样本, 又能够及时吸收反映当前运行状态的新正常样本。设当前记忆矩阵为  $M_t$ , 如公式(8)所示:

$$M_t = \{x_1, x_2, \dots, x_C\} \quad (8)$$

其中,  $C$  为记忆矩阵容量上限。对于实时输入样本  $x_t$ , AE-DMSET 首先计算其重构残差  $e_t$  和综合异常评分  $S_t$ 。当样本同时满足  $e_t \leq T$  and  $S_t \leq \eta$  时, 将其作为候选正常样本,  $T$  为重构残差异常阈值,  $\eta$  为综合异常评分阈值。候选正常样本进入记忆矩阵前, 需要综合考虑样本异常评分和存储时间, 定义样本重要性为  $I_t$ , 如公式(9)所示:

$$I_t = (1 - S_t) \exp(-\lambda \Delta t_t) \quad (9)$$

式中,  $I_t$  为第  $i$  个样本的重要性;  $S_t$  为该样本的综合异常评分;  $\Delta t_t$  为该样本进入记忆矩阵后的存储时间;  $\lambda$  为时间衰减系数。

由上式可知, 异常评分越高, 样本重要性越低; 存储时间越长, 样本重要性也会随着时间衰减而降低。因此, 该定义能够使记忆矩阵优先保留异常风险低、代表性强且时效性较好的样本。当新的候选正常样本加入后, 若记忆矩阵容量超过上限  $C$ , 则删除重要性  $I_i$  最低的历史样本  $x_{remove}$ , 如公式(10)所示:

$$x_{remove} = \arg \min_{x_i \in M_t} I_i \quad (10)$$

随后, 将新的正常样本加入记忆矩阵, 得到更新后的记忆矩阵  $M_{t+1}$ , 如公式(11)所示:

$$M_{t+1} = M_t - \{x_{remove}\} + \{x_t\} \quad (11)$$

通过上述更新策略，AE-DMSET 能够在固定记忆矩阵容量下动态吸收新的正常运行样本，并剔除代表性较弱的历史样本，使记忆矩阵持续反映主泵当前运行状态。

### 3. 数据与实验

#### 3.1. 实验数据

本文实验数据来源于国内某核电厂主泵历史运行数据，包含主泵运行过程中与电机轴承、绕组、空冷器、推力瓦及泵轴承等温度监测变量，如表 1 所示，共包含 18 个主泵温度测点。为验证所提 AE-DMSET 方法在动态工况下的异常检测性能，本文从主泵历史运行数据中选取训练集和测试集。其中，训练集用于构建初始记忆矩阵并训练 AE 模型，测试集用于比较 AE-DMSET 与 DMSET 在动态数据中的异常检测性能。

**Table 1.** Description of the main pump-related dataset

**表 1.** 主泵相关数据集描述

序号	变量	描述	单位	序号	变量	描述	单位
1	615MT	电机轴承温度	℃	10	634MT	绕组 V 相温度	℃
2	616MT	电机轴承温度	℃	11	611MT	主推力瓦温度	℃
3	630MT	绕组 U 相温度	℃	12	612MT	主推力瓦温度	℃
4	633MT	绕组 U 相温度	℃	13	613MT	泵轴承温度	℃
5	620MT	空冷器出口温度	℃	14	643MT	泵轴承温度	℃
6	621MT	空冷器入口温度	℃	15	623MT	空冷器入口温度	℃
7	635MT	绕组 W 相温度	℃	16	622MT	空冷器入口温度	℃
8	631MT	绕组 V 相温度	℃	17	645MT	副推力瓦温度	℃
9	632MT	绕组 W 相温度	℃	18	644MT	副推力瓦温度	℃

实验数据集的划分如表 2 所示，训练数据对应序号区间为([30,001, 60,000])，共包含 30,000 个时间采样点，采样周期为 1 min。测试数据对应序号区间为([10,001, 14,000])，共包含 4000 个时间采样点，采样周期同样为 1 min。测试数据中包含一段已知异常运行区间，对应序号区间为([13,222, 13,500])，异常点数量为 279 个。

**Table 2.** Partition of the experimental dataset

**表 2.** 实验数据集划分

数据类型	序号区间	样本数量	采样周期	说明
训练集	[30,001, 60,000]	30,000	1 min	用于初始记忆矩阵构建与 AE 模型训练
测试集	[10,001, 14,000]	4000	1 min	用于模型测试与性能评价
异常区间	[13,222, 13,500]	279	1 min	测试集中标注的异常运行区间

图 2 展示选取的主泵温度测点的时序数据以及对应的异常区间，从图中可以看出，温度变量数量较多，能够反映主泵不同部位的运行状态；各温度变量之间存在一定的耦合关系，具有明显的非线性特征；

测试数据中包含动态变化过程，正常状态与异常状态之间并非完全突变，给异常检测模型的适应性和鲁棒性带来挑战。因此，该数据适合用于验证 AE-DMSET 在高维、非线性和动态工况下的异常检测能力。




Figure 2. Time series data of main pump temperature and anomalous data

图 2. 主泵温度时序数据及异常数据

在模型训练与测试前，本文对原始数据进行如下预处理。首先，对不同测点的数据进行时间对齐，确保每个时间采样点均包含完整的 18 维监测变量。对于少量缺失数据，可采用前向填充、线性插值或删除缺失样本的方式处理。其次，为消除不同变量量纲和数值范围差异的影响，对所有变量进行标准化处理。设第  $j$  个变量在时刻  $t$  的原始值为  $x_t^j$ ，标准化后的值为  $\tilde{x}_t^j$ ，则可采用形式如公式(12)所示：

$$\tilde{x}_t^j = \frac{x_t^j - \mu_j}{\sigma_j} \quad (12)$$

式中， $\mu_j$  和  $\sigma_j$  分别表示训练集中第  $j$  个变量的均值和标准差。测试集采用训练集计算得到的均值和标准差进行标准化，以避免测试数据统计信息泄漏到模型训练过程。经过标准化处理后，每个时间点的主泵状态可表示为一个 18 维状态向量作为 DMSET 和 AE-DMSET 的输入。

### 3.2. 评价指标

为定量评价不同方法在主泵异常检测任务中的性能，本文采用精确率(Precision)、召回率(Recall)和  $F_1$  分数( $F_1$ -score)作为评价指标。精确率、召回率和  $F_1$  的定义分别为：

$$Precision = \frac{TP}{TP + FP}, \quad Recall = \frac{TP}{TP + FN}, \quad F_1 = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

精确率反映模型检测出的异常样本中真实异常所占比例，主要用于衡量误报情况；召回率反映真实异常样本被模型识别出的比例，主要用于衡量漏检情况； $F_1$  分数为精确率和召回率的调和平均，能够综合评价模型的异常检测性能。

### 3.3. 对比方法与实验方案

本文的实验目标是验证 AE-DMSET 相对于原始 DMSET 在高维非线性动态数据中的改进效果。对 DMSET 和 AE-DMSET 的主要参数进行统一设置，如表 3 所示。DBSCAN 算法中的邻域半径参数  $\varepsilon$  用于描述样本局部邻域范围，其取值会直接影响密度聚类结果以及异常样本识别能力。为分析  $\varepsilon$  对 AE-DMSET 检测性能的影响，本文在归一化数据条件下，对  $\varepsilon$  参数进行了精细扫描实验。实验范围设置为 0.3~1.0，步长为 0.1，并以异常检测  $F_1$  分数作为评价指标。实验结果表明，当  $\varepsilon = 0.3$  时，模型  $F_1$  分数仅为 0.5789，检测性能明显下降。这主要是由于邻域范围过小，导致大量正常样本无法形成稳定密度簇，从而被误判为噪声点，影响联合异常评分结果。当  $\varepsilon$  从 0.4 增加至 1.0 时，模型  $F_1$  分数始终稳定在 0.7071 附近，说明在该范围内 DBSCAN 对样本局部密度结构的划分基本保持稳定，模型检测性能对  $\varepsilon$  参数变化不再敏感。本文最终选择  $\varepsilon = 0.5$  作为 DBSCAN 的邻域半径参数，既能够保证正常样本形成稳定聚类结构，又能够有效识别离散异常样本。

**Table 3.** Model parameter settings  
**表 3.** 模型参数设置

参数	取值	说明
输入维度	18	主泵温度监测变量数量
记忆矩阵容量	500	动态记忆矩阵最大样本数
AE 网络结构	18-64-32-16-32-64-18	编码器 - 解码器结构
损失函数	MSE	重构误差损失
优化器	Adam	AE 模型优化方法
学习率	0.001	AE 训练学习率
训练轮数	1000	AE 训练迭代次数
IF 树数量	100	孤立森林基学习器数量
LOF 邻居数	12	局部密度估计邻居数量
DBSCAN 参数( $\varepsilon$ )	0.5	邻域半径
联合评分阈值( $\eta$ )	0.5	候选正常样本筛选阈值
残差阈值系数( $\kappa$ )	3	三倍标准差准则

AE 网络结构的设计需要综合考虑特征压缩能力与模型复杂度之间的平衡。由于主泵监测数据包含 18 个温度变量，且变量之间存在较强相关性，因此本文采用逐层压缩的编码结构(18-64-32-16)，使模型能够逐步提取多变量数据中的低维非线性特征。其中，潜在空间用于对正常运行状态进行紧凑表示，选择 16 作为潜在特征维度，以避免过度压缩导致信息丢失，解码器采用对称结构(16-32-64-18)以保证重构稳定性。

LOF 算法中的邻居数用于确定局部密度估计范围, 其取值会影响模型对局部异常和噪声样本的敏感性。为分析不同邻居数对异常检测性能的影响, 本文对该参数进行了实验分析, 取值范围为 3~15, 并以  $F_1$  分数作为评价指标。实验结果表明, 当邻居数较小时, 模型检测性能相对较低。取值为 3 时,  $F_1$  分数仅为 0.4714。这是由于邻域范围过小, 局部密度估计容易受到噪声扰动, 导致异常评分稳定性较差。随着邻居数增加, 模型检测性能逐渐提升。当取值为 12 时, 模型取得最高  $F_1$  分数 0.8388, 说明该参数能够较好平衡局部异常敏感性与密度估计稳定性。当邻居数继续增大时,  $F_1$  分数变化趋于平稳, 并出现轻微下降。这表明过大的邻域范围会削弱 LOF 对局部异常结构的识别能力。综合考虑异常检测性能与参数稳定性, 本文最终选择 12 作为 LOF 算法的邻居数参数。

联合异常评分阈值  $\eta$  用于判定候选样本是否属于正常样本, 其取值会直接影响记忆矩阵更新质量以及异常检测结果。为分析模型对阈值参数的敏感性, 本文在 0.3~0.8 范围内对  $\eta$  进行了实验分析, 并以  $F_1$  分数作为评价指标, 实验结果如图 3 所示。实验结果表明, 当  $\eta$  从 0.3 逐渐增加至 0.8 时, 模型  $F_1$  分数整体保持在较高水平, 变化范围为 0.9495~0.9632, 说明 AE-DMSET 对联合异常评分阈值具有较好的鲁棒性。其中, 当  $\eta=0.4$  时模型取得最高  $F_1$  分数 0.9632; 而本文默认采用的  $\eta=0.5$  对应  $F_1$  分数为 0.9613, 与最优结果差异较小。

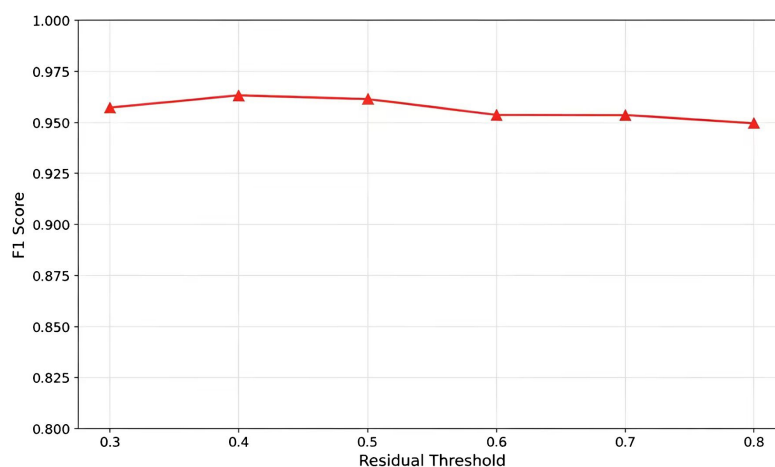
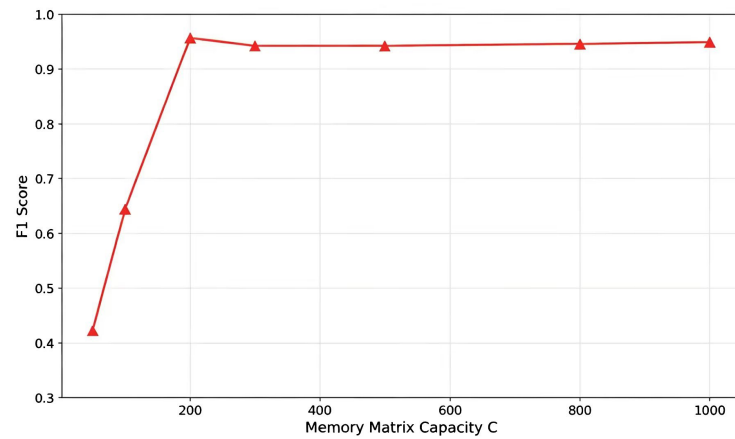


Figure 3. Sensitivity results of the joint anomaly scoring threshold  $\eta$

图 3. 联合异常评分阈值  $\eta$  的敏感性结果

记忆矩阵容量  $C$  决定了模型可保留的历史正常样本数量, 其取值会影响模型对系统运行状态的表征能力以及动态工况适应能力。为分析 AE-DMSET 对记忆矩阵容量参数的敏感性, 本文分别设置不同取值进行实验, 并以  $F_1$  分数作为评价指标, 实验结果如图 4 所示。当记忆矩阵容量较小时, 模型检测性能明显下降。当  $C=50$  时, 模型  $F_1$  分数仅为 0.4229; 当  $C=100$  时,  $F_1$  分数提升至 0.6447。这是由于较小容量下记忆矩阵难以充分覆盖主泵在动态运行过程中不同工况下的正常状态特征, 导致状态重构误差增大, 并进一步影响异常检测准确性。当容量增加至  $C=200$  时, 模型取得最高  $F_1$  分数 0.9567, 说明此时记忆矩阵已经能够较好覆盖主泵在动态工况下的正常运行状态特征。当容量继续增大至 300 以上时, 模型  $F_1$  分数整体保持在 0.94 以上小范围波动, 检测性能趋于稳定。这表明在记忆矩阵达到一定规模后, 继续增加历史样本数量对检测性能提升有限。综合考虑异常检测性能、参数稳定性以及计算复杂度, 本文最终选择  $C=500$  作为记忆矩阵容量, 在保证较高检测性能的同时, 能够保留更多动态工况下的正常运行模式, 从而提升模型对复杂运行状态变化的适应能力与稳定性。

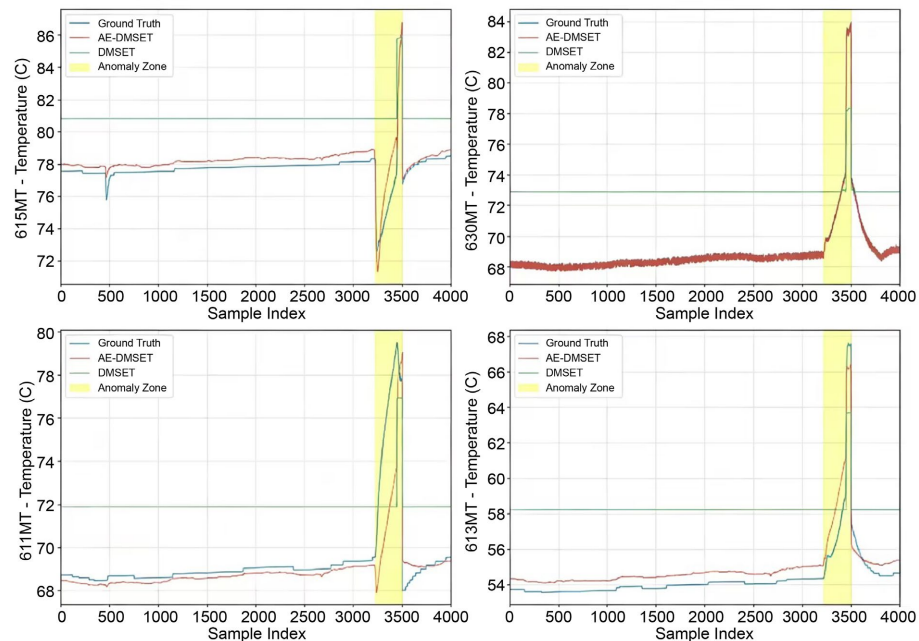


**Figure 4.** Sensitivity results of memory matrix capacity ( $C$ )  
**图 4.** 记忆矩阵容量  $C$  的敏感性结果

## 4. 实验结果与分析

### 4.1. 预测重构结果对比分析

为验证所提 AE-DMSET 方法在主泵动态工况数据中的状态表征能力, 本文首先对 DMSET 与 AE-DMSET 的预测重构结果进行对比分析, 结果如图 5 所示。从图 5 可以看出, 在测试数据的正常动态变化区间内, DMSET 的重构曲线在部分时段与真实值之间偏差较大。这说明在动态工况下, 基于最近邻的局部重构方法容易受到样本邻域匹配变化的影响。相比之下, AE-DMSET 的重构曲线整体上能较好跟踪真实数据变化趋势, 说明自编码器能够有效学习多测点温度变量之间的非线性关联关系, 具有动态工况下的状态重构的稳定性。



**Figure 5.** Comparison of reconstruction results for typical measurement points between DMSET and AE-DMSET

**图 5.** DMSET 与 AE-DMSET 典型测点重构结果对比图

## 4.2. 异常检测结果及分析

异常检测的直接依据是模型重构残差。为进一步比较 DMSET 与 AE-DMSET 在动态工况下的异常响应能力和检测效果, 本文将两种方法的残差变化曲线、异常判定阈值、真实异常区间以及模型检测出的异常点进行了比较。如图 6 所示, 蓝色或绿色曲线表示模型平均重构残差, 红色虚线表示异常判定阈值, 黄色阴影区域表示真实异常区间, 红色散点表示模型判定出的异常样本。

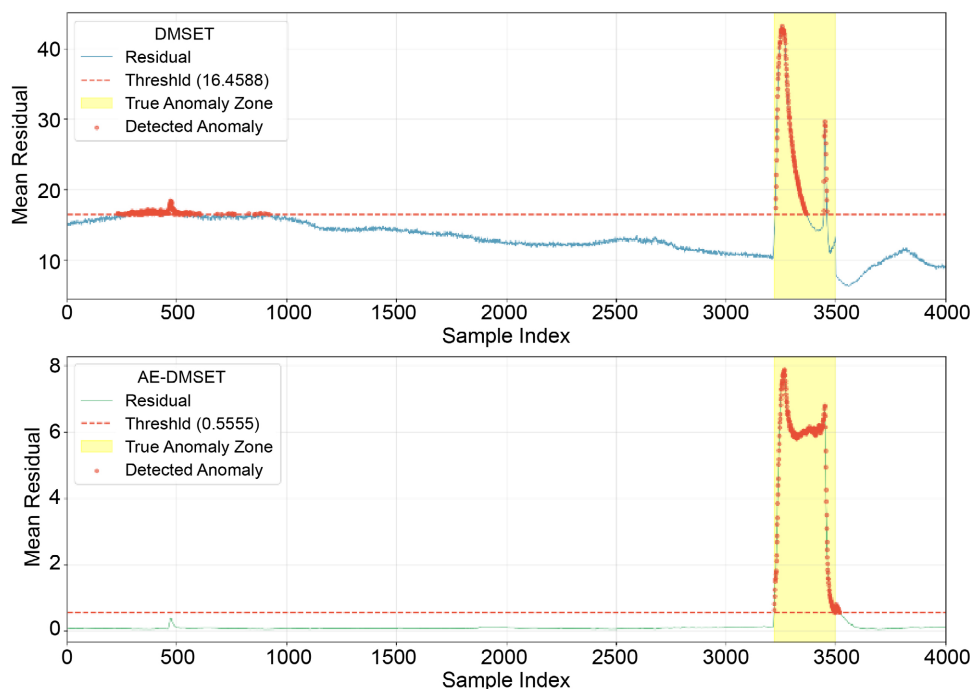


Figure 6. Comparison of residual and anomaly detection results between DMSET and AE-DMSET  
图 6. DMSET 与 AE-DMSET 残差及异常检测结果对比

从图 6 上半部分可以看出, DMSET 在真实异常区间内残差明显升高, 并能够对异常状态产生较强响应, 说明其对异常样本具有较高敏感性。然而, 在真实异常区间之外, DMSET 残差也存在一定波动, 部分正常样本残差超过异常判定阈值并被标记为异常。这表明 DMSET 虽然能够较好覆盖真实异常区间, 但其基于动态记忆矩阵和重构残差的判定方式在正常动态波动区间仍存在一定误报风险。尤其是在主泵运行状态缓慢变化或局部波动较明显时, 正常样本可能因重构误差增大而被误判为异常。相比之下, AE-DMSET 在正常区间内的残差整体保持在较低水平, 残差曲线更加平稳, 且大部分正常样本均低于异常判定阈值。说明 AE 能够有效学习主泵正常运行状态下多测点温度变量之间的非线性关联关系, 从而降低正常动态波动引起的重构误差。在异常区间内, AE-DMSET 残差迅速升高并持续超过阈值, 表明该方法仍能够对异常状态保持较强响应能力。

主泵异常检测结果如表 4 所示, DMSET 检测出 400 个异常点, 其中真实异常点 279 个, 误报点 121 个。其召回率达到 1.000, 说明 DMSET 能够识别全部真实异常样本; 但其精确率仅为 0.7025, 表明大量正常样本被误判为异常。AE-DMSET 共检测出 269 个异常点, 其中真正例为 263 个, 误检 6 个, 漏检 16 个, 对应精确率、召回率和 F1 分数分别为 0.978、0.943 和 0.960。与 DMSET 相比, AE-DMSET 的召回率由 1.000 略降至 0.943, 但精确率由 0.703 显著提高至 0.978, F1 分数由 0.825 提高至 0.960。该结果表明, AE-DMSET 在保持较高异常检出能力的同时, 显著降低了误报数量, 综合性能明显优于 DMSET。

**Table 4.** Comparison of results between AE-DMSET and DMSET algorithms**表 4.** AE-DMSET 与 DMSET 算法的结果对比

	总异常点数	检测出异常点数	TP	FP	FN	精确率	召回率	F1 分数
DMSET	279	400	279	121	0	0.698	1.000	0.822
AE-DMSET	279	269	263	6	16	0.978	0.943	0.960

相比之下, AE-DMSET 的误报点数由 121 个降低至 6 个, 减少了 115 个, 误报数量下降约 95.04%。虽然 AE-DMSET 漏检了 16 个真实异常点, 但其召回率仍保持在 0.943, 说明绝大多数异常样本仍能被有效识别。AE-DMSET 相较于 DMSET 在精确率上提高了 28%; F1 分数提高了 13.5%。虽然召回率降低了 5.7%, 但仍保持在 0.943。说明 AE-DMSET 并非通过提高检测精度来获得性能提升, 而是在异常检出能力和误报控制间取得了平衡。

## 5. 结论

针对核电厂主泵运行数据具有高维、非线性和动态变化等问题, 本文提出了一种融合自编码器与动态多元状态估计的主泵异常检测方法(AE-DMSET)。该方法在 DMSET 动态记忆矩阵更新思想的基础上, 引入自编码器对主泵多测点温度变量之间的非线性关联关系进行学习, 并利用重构残差表征当前运行状态与正常状态之间的偏离程度; 同时, 融合 IF、LOF 和 DBSCAN 构建联合异常评分机制, 从全局孤立程度、局部密度偏离程度和密度聚类结构三个角度综合筛选候选正常样本, 以提高记忆矩阵动态更新的可靠性。

基于某核电厂主泵历史运行数据的实验结果表明, AE-DMSET 能够有效识别动态工况下的异常样本。精确率、召回率和 F1 分数分别达到 0.978、0.943 和 0.960。与原始 DMSET 相比, AE-DMSET 在保持较高异常检出能力的同时, 有效降低了正常动态波动引起的误报, 使异常判定结果更加集中于真实异常区间。具备在复杂动态工况下主泵异常检测的准确性和鲁棒性。为核电厂主泵及类似关键设备的状态监测提供了一种可行的数据驱动方法。该方法尤其适用于监测变量维度较高、变量间存在非线性耦合且运行工况随时间变化的工业设备异常检测场景。

## 参考文献

- [1] 王飞. 主泵轴封水回流温度高原因分析及应对措施[J]. 科技视界, 2017(2): 256+203.
- [2] 赵亮, 宋立, 范瑞波, 等. “华龙一号”与 CPR1000 反应堆主冷却剂泵对比分析[J]. 水泵技术, 2019(1): 1-4+9.
- [3] Wang, X., Lu, Y., Zhu, R., Fu, Q., Chen, Y. and Zhong, W. (2020) Experimental Study on Transient Characteristics of Reactor Coolant Pump under Rotor Seizure Accident. *Annals of Nuclear Energy*, **136**, Article 107039. <https://doi.org/10.1016/j.anucene.2019.107039>
- [4] 侯修群, 蒋庆磊, 包彬彬, 等. 基于相关系数的核电主泵振动异常定位方法研究[J]. 核科学与工程, 2021, 41(5): 920-928.
- [5] 毛伟, 余刃, 陆古兵. 基于 LS-SVM 方法的某核电站主泵故障诊断[J]. 海军工程大学学报, 2012, 24(5): 82-85.
- [6] 许勇, 蔡云泽, 宋林. 基于数据驱动的核电设备状态评估研究综述[J]. 上海交通大学学报, 2022, 56(3): 267-278.
- [7] Wang, Z., Wei, H., Tian, R. and Tan, S. (2025) A Review of Data-Driven Fault Diagnosis Method for Nuclear Power Plant. *Progress in Nuclear Energy*, **186**, 105785. <https://doi.org/10.1016/j.pnucene.2025.105785>
- [8] Gross, K.C., Singer, R.M., Wegerich, S.W., et al. (1997) Application of a Model-Based Fault Detection System to Nuclear Plant Signals. Office of Scientific Technical Information Technical Reports.
- [9] 任梦祎, 焦嵩鸣. 改进型非线性状态估计的制粉系统故障诊断[J]. 热力发电, 2015, 44(12): 87-92+97.
- [10] 杨婷婷, 张蓓, 吕游, 等. 基于 MSET 的电站风机故障预警技术研究[J]. 热能动力工程, 2017, 32(9): 63-68+124.

- 
- [11] 李大中, 常城, 许炳坤. 基于样本优化的风电机组齿轮箱轴承温度预测[J]. 系统仿真学报, 2017, 29(2): 374-380.
- [12] 张龙, 吴荣真, 周建民, 等. 滚动轴承性能退化的时序多元状态估计方法[J]. 振动测试与诊断, 2021, 41(6): 1096-1104+1235-1236.
- [13] 张龙, 刘杨远, 吴荣真, 等. 基于 MSET 重构模型整体优化的轴承性能退化评估方法[J]. 振动与冲击, 2023, 42(16): 251-261.
- [14] 黄杨森, 王勇, 刘云平, 等. 基于多元状态评估和相关分析的振动故障诊断[J]. 振动与冲击, 2024, 43(17): 269-277.
- [15] Guo, P., Infield, D. and Yang, X. (2012) Wind Turbine Generator Condition-Monitoring Using Temperature Trend Analysis. *IEEE Transactions on Sustainable Energy*, **3**, 124-133. <https://doi.org/10.1109/tste.2011.2163430>
- [16] 丁宸轲, 郑胜, 贺俊杰, 等. 基于动态多元状态估计的核电厂主泵异常检测方法[J]. 科学技术与工程, 2025, 25(27): 11614-11621.
- [17] İnkaya, T. (2022) Parameter-Free Surrounding Neighborhood Based Regression Methods. *Expert Systems with Applications*, **199**, Article 116881. <https://doi.org/10.1016/j.eswa.2022.116881>
- [18] Aljohani, T.M. (2026) Markov-Constrained Isolation Forest for Early Detection of Battery Anomalies in Solar-Grid Applications. *Mathematics*, **14**, Article 1192. <https://doi.org/10.3390/math14071192>
- [19] 袁非牛, 章琳, 史劲亭, 等. 自编码神经网络理论及应用综述[J]. 计算机学报, 2019, 42(1): 203-230.
- [20] Shan, L., Liu, Y., Ai, X. and Gao, J. (2025) Research on Fault Sensor Detection and Localization Method Based on Autoencoder. *Annals of Nuclear Energy*, **220**, Article 111546. <https://doi.org/10.1016/j.anucene.2025.111546>
- [21] Abuzaid, A.H. (2020) Identifying Density-Based Local Outliers in Medical Multivariate Circular Data. *Statistics in Medicine*, **39**, 2793-2798. <https://doi.org/10.1002/sim.8576>
- [22] Ram, A., Jalal, S., Jalal, A.S. and Kumar, M. (2010) A Density Based Algorithm for Discovering Density Varied Clusters in Large Spatial Databases. *International Journal of Computer Applications*, **3**, 1-4. <https://doi.org/10.5120/739-1038>