

# 工业机器人夹爪失效检测中深度学习与传统机器学习方法的对比研究

熊忠帅<sup>1\*</sup>, 周鹏庆<sup>2</sup>, 唐成<sup>1</sup>, 智昆彭<sup>1</sup>

<sup>1</sup>湖南科技大学机电工程学院, 湖南 湘潭

<sup>2</sup>中国地质大学材料和化学学院, 湖北 武汉

收稿日期: 2026年3月19日; 录用日期: 2026年5月6日; 发布日期: 2026年5月15日

## 摘要

工业机器人夹爪失效可能导致严重的生产事故与经济损失, 对其进行实时准确检测具有重要工程价值。本文基于包含7355条传感器记录、正负样本比约为29比1的高度失衡机器人关节数据集, 系统比较了三种传统机器学习方法, 即决策树、支持向量机和K近邻算法, 与四种深度学习及特征增强方法, 即前馈神经网络、一维卷积神经网络、长短期记忆网络和注意力神经网络, 在夹爪失效二分类任务上的性能表现。评估指标涵盖平衡准确率、精确率、召回率、F1分数及曲线下面积, 并结合五折交叉验证、学习曲线分析和实际计算耗时进行全面考察。实验结果表明, K近邻算法的平衡准确率达0.8604, 综合效率评分为0.8000, 训练时间仅0.01秒, 均优于其他方法, 展现出在工业在线检测场景中的显著优势。本研究为工程师在实际部署中选择合适检测算法提供了量化依据和可复现的评估框架。

## 关键词

夹爪失效检测, 机器人关节传感器, 不平衡分类, K近邻算法, 机器学习对比

# Deep Learning Versus Traditional Machine Learning for Grip-Loss Detection in Industrial Robots: A Systematic Comparative Study

Zhongshua Xiong<sup>1\*</sup>, Pengqing Zhou<sup>2</sup>, Cheng Tang<sup>1</sup>, Kunpeng Zhi<sup>1</sup>

<sup>1</sup>School of Mechanical and Electrical Engineering, Hunan University of Science and Technology, Xiangtan Hunan

<sup>2</sup>Faculty of Materials Science and Chemistry, China University of Geosciences, Wuhan Hubei

\*通讯作者。

文章引用: 熊忠帅, 周鹏庆, 唐成, 智昆彭. 工业机器人夹爪失效检测中深度学习与传统机器学习方法的对比研究[J]. 人工智能与机器人研究, 2026, 15(3): 802-815. DOI: 10.12677/airr.2026.153075

## Abstract

Grip-loss events in industrial robots can trigger severe production accidents and economic losses, making their real-time detection a problem of considerable engineering relevance. This paper presents a systematic comparison of three traditional machine learning methods, namely Decision Tree, Support Vector Machine, and K-Nearest Neighbors, against four deep learning and feature-augmentation approaches, namely Feedforward Neural Network, 1D-Convolutional Neural Network, Long Short-Term Memory Network, and Attention-based Neural Network, on a grip-loss binary classification task. The dataset comprises 7355 real sensor records collected from a six-joint industrial robot, with a severe class imbalance ratio of approximately 29:1 between normal and grip-loss samples. To address this imbalance, cost-sensitive matrices, sample weighting, and minority-class over-sampling are applied consistently across methods. All seven approaches are evaluated under a unified framework using balanced accuracy, precision, recall, F1-score, and area under the ROC curve, supplemented by five-fold cross-validation, learning curve analysis, and measured training and inference times. Experimental results show that K-Nearest Neighbors achieves the highest balanced accuracy of 0.8604, an overall recommendation score of 0.8000, and a training time of only 0.01 seconds, outperforming all other methods on every primary criterion. The findings demonstrate that lightweight instance-based methods can match or surpass more complex deep learning approximations on structured, low-dimensional sensor data with extreme class imbalance, and that high AUC does not guarantee practical utility at a fixed decision threshold. Feature importance analysis consistently identifies Current\_J2 as the most discriminative signal for grip-loss detection. The proposed evaluation framework is directly transferable to other highly imbalanced industrial fault detection tasks.

## Keywords

Grip-Loss Detection, Robot Joint Sensors, Imbalanced Classification, K-Nearest Neighbors, Machine Learning Comparison

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

工业机器人的可靠性是现代智能制造的核心保障之一[1][2]。在关节驱动与末端执行器协同工作的抓取流程中，夹爪失效往往在毫秒级时间窗口内发生，其征兆可能以电流突变、温度波动或速度异常等形式微弱地叠加在正常运行信号之上[3]-[5]。传统基于阈值规则的故障检测方案难以应对多关节耦合带来的复杂非线性特征，而数据驱动方法的兴起为这一问题提供了新的解题思路[6][7]。

近年来，深度学习在图像识别、自然语言处理等领域取得了突破性进展，研究者开始将卷积网络、循环网络及注意力机制引入工业时序信号的异常检测任务[8][9]。然而，在实际工程部署中，深度学习方法往往面临样本不平衡、推理延迟高、可解释性差等制约，而轻量级的传统机器学习方法可能凭借训练速度快、泛化稳定等特点获得竞争力[10]-[14]。目前鲜有研究在严格控制评估条件的前提下，对两类方法进行全量化比较，尤其是在正负样本极度失衡的工业实际数据上。

本文以一组来自真实工业机器人运行环境的多关节传感器数据为基础，构建了包含七种算法的统一评估框架，数据集正负样本比达 29.27:1，19 维特征涵盖六个关节的电流、温度和速度信息及工具电流 [15]。通过对训练过程、超参数和评估指标进行精确对齐，本文力图回答一个具有实践意义的核心问题：在资源受限的在线检测场景中，复杂的深度学习方法是否真正优于经典的传统算法？比较横跨分类性能、错误结构、特征解释性、学习动态和计算效率五个维度，旨在为工业界提供可直接参考的算法选型依据，所建立的评估框架亦对相关领域的方法学研究具有借鉴价值。研究结果对工业机器人健康监测系统的算法选型具有直接参考价值，并可推广至其他高度不平衡的工业故障检测任务。

## 2. 方法

### 2.1. 数据集与预处理

原始数据集包含 7355 条有效样本，每条样本由 19 维特征构成，分别对应机器人六个关节 J0 至 J5 的电流、温度、速度读数以及工具电流。正常样本共 7112 条，占 96.7%，夹爪失效样本仅 243 条，占 3.3%，类别不平衡比约为 29.27:1。所有特征均经 Z-score 标准化处理，归一化参数仅由训练集估计以避免数据泄漏。训练集与测试集按 8:2 的比例进行分层划分，训练集 5884 条，测试集 1471 条。

### 2.2. 类别不平衡处理

针对严重的类别不平衡问题，本文对不同方法采用了相应的补偿策略。对于决策树和 K 近邻算法，通过代价敏感矩阵调整误分类代价，将正类误分类的惩罚权重设为类别比率，即

$$C = \begin{pmatrix} 0 & 1 \\ r & 0 \end{pmatrix}, r = \frac{n_{\text{neg}}}{n_{\text{pos}}}$$

其中  $n_{\text{neg}}$  和  $n_{\text{pos}}$  分别为负类和正类样本数， $r \approx 29.27$ 。对于支持向量机，采用样本权重方案对正类样本赋予相同比率的权重。前馈神经网络则采用少数类过采样的方式构建平衡训练集，将正类样本重复扩充至与负类数量相等后随机打乱。

### 2.3. 特征工程与方法设计

三种传统机器学习方法直接在原始标准化特征上训练。决策树最大分裂数设为 20，最小叶节点样本数为 5；支持向量机采用 RBF 核，以自动估计的核缩放参数和 1.0 的惩罚系数，并通过 Platt 标定输出概率；K 近邻算法采用欧氏距离，邻居数取 7。

对于深度学习方法，本文设计了面向特征层面的轻量化近似方案。一维卷积神经网络通过尺寸为 3、数量为 5 的随机初始化卷积核进行局部模式提取，增强特征送入决策树分类器。长短期记忆网络的近似实现通过指数加权移动平均模拟时序记忆，平滑参数  $\alpha = 0.3$ ，扩展特征送入支持向量机。注意力机制通过对每个特征与标签之间的皮尔逊相关系数取绝对值并归一化来计算注意力权重 [16]。

$$w_i = \frac{|\text{corr}(x_i, y)|}{\sum_{j=1}^d |\text{corr}(x_j, y)|}, i = 1, \dots, d$$

加权特征送入邻居数取 5 的 K 近邻分类器。前馈神经网络采用两隐层结构，分别含 20 和 10 个神经元，激活函数为 sigmoid，训练 100 轮。

### 2.4. 评估指标

本文以平衡准确率作为主要评估指标：

$$B\text{Acc} = \frac{1}{2} \left( \frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right)$$

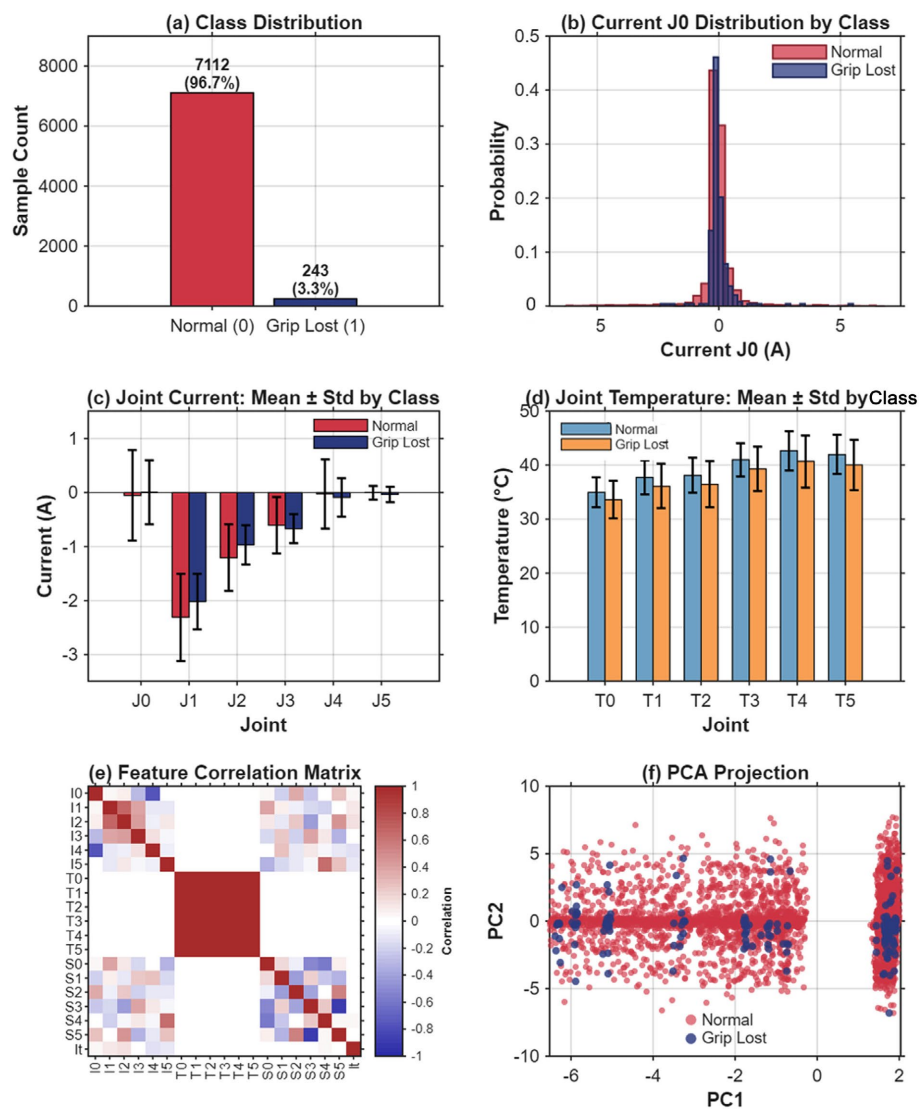
同时报告精确率、召回率、F1 分数及曲线下面积。其中 F1 分数

$$F_1 = \frac{2 \cdot TP}{2 \cdot TP + FP + FN}$$

对假阳性与假阴性给予同等惩罚，是不平衡场景下衡量综合分类能力的核心指标。所有方法均进行五折交叉验证，以均值与标准差共同评估泛化稳定性[17]。

### 3. 结果与讨论

#### 3.1. 数据集特征分析



**Figure 1.** Dataset exploration and characterization: (a) Class distribution; (b) Current J0 distribution by class; (c) Joint current mean  $\pm$  std by class; (d) Joint temperature mean  $\pm$  std by class; (e) Feature correlation matrix; (f) PCA projection

**图 1.** 数据集探索与特征分析: (a) 类别分布; (b) 不同类别下的电流 J0 分布; (c) 不同类别下接头电流均值  $\pm$  标准差; (d) 不同类别下接头温度均值  $\pm$  标准差; (e) 特征相关矩阵; (f) 主成分分析(PCA)投影

图 1 展示了数据集的整体特征与内在规律。图 1(a) 的类别分布柱状图直观揭示了数据集的核心挑战：正常样本 7112 条，占比 96.7%，夹爪失效样本仅 243 条，占比 3.3%，二者相差约 29 倍，这一极端不平衡比例是影响所有后续模型性能的根本性约束。

图 1(b) 以 Current\_J0 即关节 0 电流为例，展示了两类样本的概率密度分布。正常状态下 J0 电流的均值约为 -0.052 A，标准差 0.836 A，失效状态下均值约为 0.006 A，标准差 0.601 A，二者分布存在明显重叠，表明单一特征的线性判别能力有限，模型必须依赖多维度信息的联合分析。图 1(c) 展示了六个关节电流的类间均值与标准差对比，失效状态下各关节电流均值普遍略高于正常状态，但 J1 至 J4 的差异较为微弱，J0 和 J5 的组间差异相对显著，提示不同关节上的判别贡献存在明显异质性。

温度特征呈现出截然不同的规律。图 1(d) 显示，失效状态下所有关节的温度均值均低于正常运行状态，T4 和 T5 的均值差约为 2.0℃，且失效样本的温度标准差更大，反映出夹爪失效往往伴随温度不稳定性的增加，这与工件滑落瞬间负载突变引发热平衡扰动的物理机制相符。

图 1(e) 的特征相关性热图揭示了一个重要的结构性问题——六个温度特征之间存在极高的线性相关性，T1 与 T2 之间的皮尔逊相关系数高达 0.9997，T0 至 T5 之间所有两两相关系数均超过 0.99。这种近乎完美的多重共线性表明温度传感器阵列存在严重信息冗余，对以协方差结构为基础的模型如 SVM RBF 核可能产生数值不稳定的影响[18][19]。相比之下，速度特征与电流特征之间存在一定的负相关，最强负相关约为 -0.895，提示二者具有一定的互补性。

图 1(f) 的主成分分析投影给出了两类样本在二维特征空间中的分布格局。前两个主成分分别解释了 31.52% 和 16.65% 的方差，累计解释率约 48.17%。失效样本在 PC1~PC2 空间中并未形成紧密的独立聚类，而是分散于正常样本的边缘区域，进一步印证了该问题本质上属于高维空间中的低密度异常检测。

### 3.2. 整体性能比较

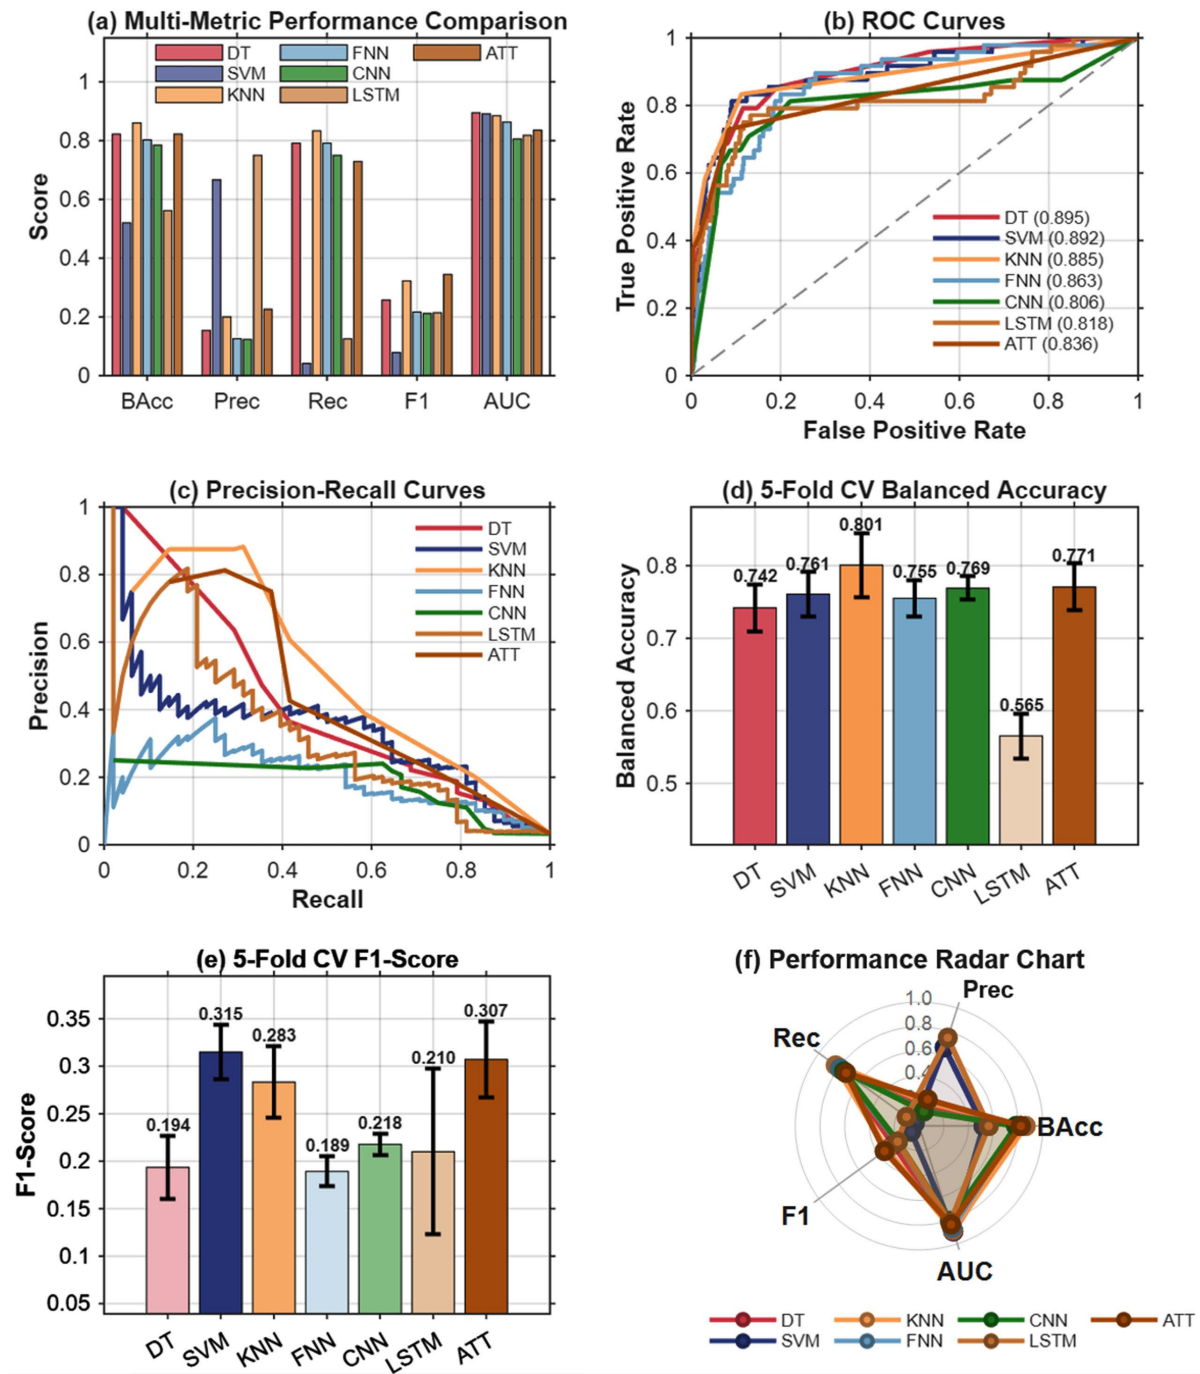
图 2 汇总了七种方法在测试集上的全面性能对比。图 2(a) 的多指标柱状图最显著的规律是高召回率与高精度率之间存在根本性权衡。K 近邻算法以 0.8604 的平衡准确率位居首位，召回率达 0.8333，同时保持 0.2000 的精确率；支持向量机和长短期记忆网络的精确率虽然分别高达 0.6667 和 0.7500，但召回率极低，前者仅为 0.0417，后者仅为 0.1250，其平衡准确率分别仅为 0.5205 和 0.5618，本质上接近随机分类器水平。

图 2(b) 的 ROC 曲线显示，决策树以 0.8952 的曲线下面积略微领先，其次是支持向量机 0.8917 和 K 近邻算法 0.8852，七种方法均落在 0.80 至 0.90 的良好区间。值得注意的是，支持向量机在 ROC 空间中表现优异，但在图 2(a) 的固定阈值下却几乎不输出任何正类预测，这一矛盾揭示了其对默认决策阈值极为敏感的特性——概率校准质量直接决定了在不平衡场景中的实用效果。

图 2(c) 的精确率 - 召回率曲线提供了更贴近不平衡数据场景的性能视角，K 近邻算法的平均精确率为 0.4670，在所有方法中最高，远高于卷积网络的 0.1807 和前馈神经网络的 0.1942，注意力方法以 0.3420 位居第二。图 2(d) 和图 2(e) 分别展示了五折交叉验证下平衡准确率和 F1 分数的均值与标准差，K 近邻算法的交叉验证平衡准确率均值为 0.801；长短期记忆网络的交叉验证平衡准确率仅 0.565，且 F1 标准差高达 0.087，反映出严重的跨折不稳定性。图 2(f) 的雷达图将五个指标集成于同一可视化框架，K 近邻算法和注意力方法的综合性能轮廓最为均衡。

### 3.3. 错误类型分析

图 3 从混淆矩阵分解与错误类型分布的角度深入剖析了各方法的分类行为，这对工业安全场景尤为重要——漏报将夹爪失效错判为正常，危害远高于将正常状态误判为失效的误报。

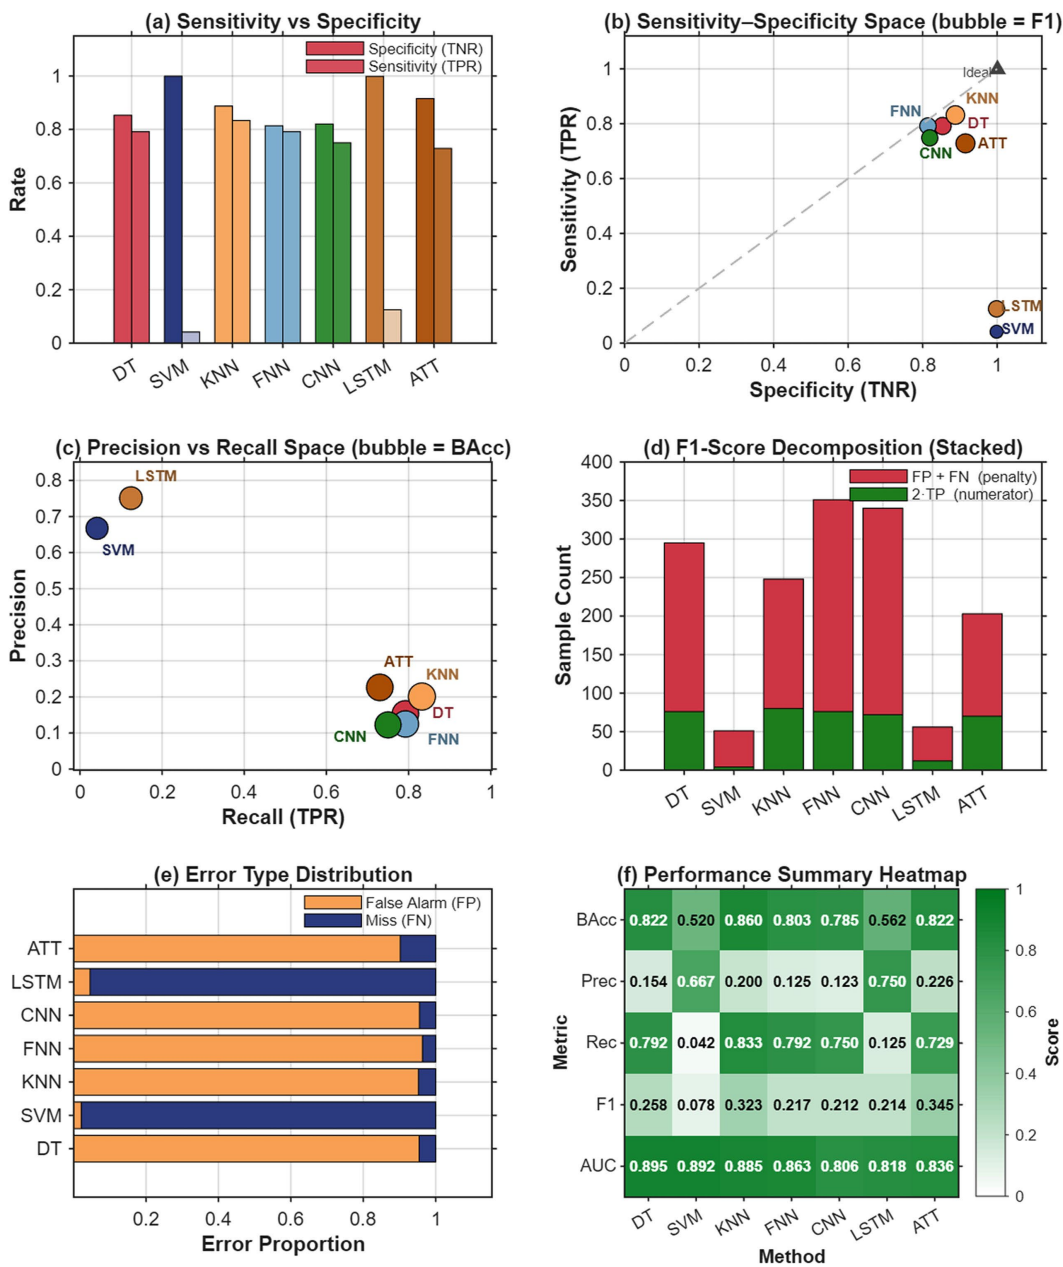


**Figure 2.** Comprehensive performance comparison of traditional ML vs. deep learning methods: (a) Multi-metric performance comparison; (b) ROC curves; (c) Precision-recall curves; (d) 5-fold cross-validation balanced accuracy; (e) 5-fold cross-validation F1-score; (f) Performance radar chart

**图 2.** 传统机器学习与深度学习方法的综合性能对比: (a) 多指标性能对比; (b) 受试者工作特征(ROC)曲线; (c) 精确率 - 召回率曲线; (d) 5 折交叉验证的平衡准确率; (e) 5 折交叉验证的 F1 分数; (f) 性能雷达图

图 3(a)的灵敏度与特异性配对柱状图显示, K 近邻算法的灵敏度最高, 达 0.8333, 特异性为 0.8876, 在两个维度上均保持了良好平衡。注意力方法的灵敏度达 0.7292, 特异性更高达 0.9157, 取得了较优的折中。支持向量机与长短期记忆网络的特异性虽分别高达 0.9993 和 0.9986, 却以极低的灵敏度为代价,

在实际部署中几乎等同于始终预测正常状态的哑分类器。



**Figure 3.** Classification performance: error analysis and metric decomposition: (a) Sensitivity vs. specificity; (b) Sensitivity-specificity space with bubble size proportional to F1-score; (c) Precision vs. recall space with bubble size proportional to balanced accuracy; (d) F1-score stacked decomposition; (e) Error type distribution; (f) Performance summary heatmap

**图 3.** 分类性能：误差分析与指标分解：(a) 灵敏度与特异度对比；(b) 灵敏度 - 特异度空间(气泡大小与 F1 分数成正比)；(c) 精确率 - 召回率空间(气泡大小与平衡准确率成正比)；(d) F1 分数堆叠分解；(e) 误差类型分布；(f) 性能汇总热力图

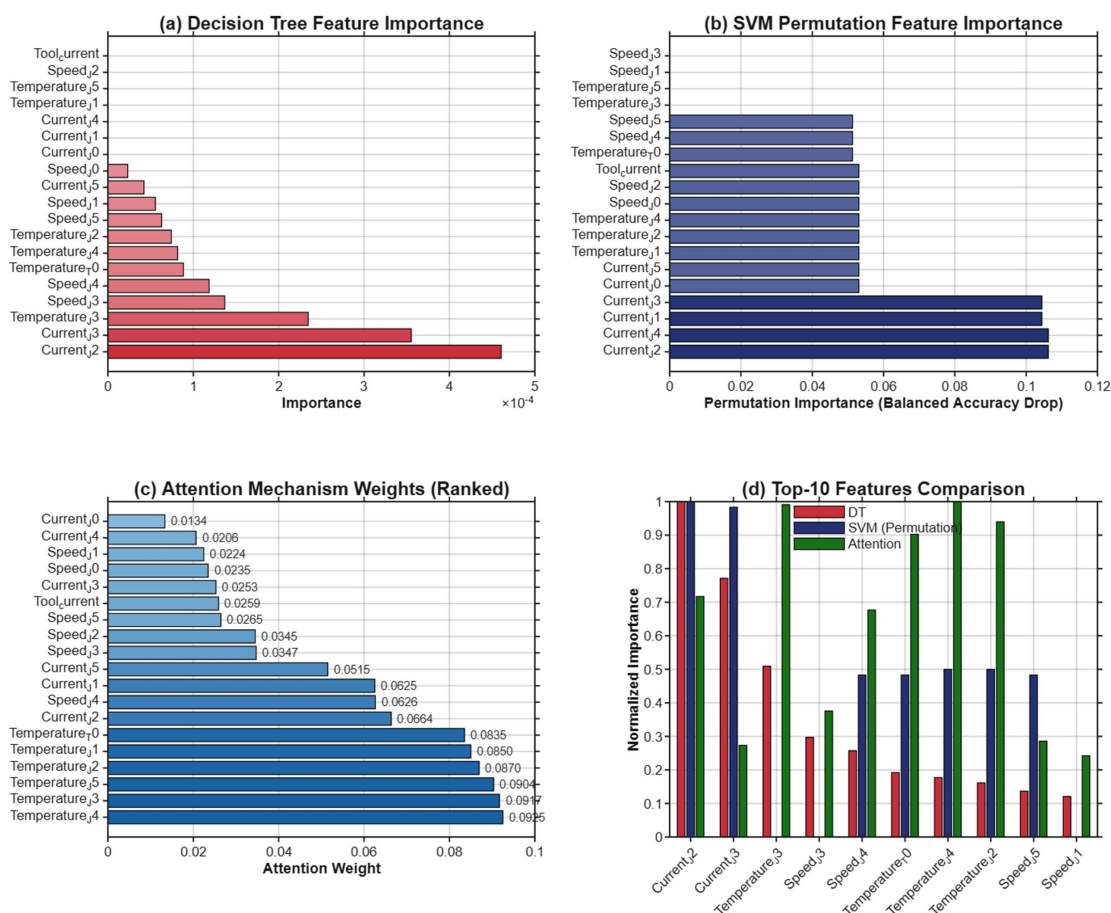
图 3(b)在灵敏度 - 特异性二维空间中以气泡图展示七种方法，气泡大小代表 F1 分数。K 近邻算法与理想点的欧氏距离仅 0.201，最为接近，其次是决策树的 0.255 和注意力方法的 0.284；支持向量机和长短期记忆网络则分别达 0.958 和 0.875，聚集于低灵敏度区域。图 3(c)将类似分析迁移至精确率 - 召回率空

间,以平衡准确率作为气泡大小编码,K近邻算法和决策树占据较优位置,支持向量机和长短期记忆网络均表现为高精确率低召回率的极端格局。

图3(d)的F1分数堆叠分解条形图展示各方法在2TP正确检测量与FP加FN惩罚项之间的比例关系,前馈神经网络的惩罚项高达275,卷积网络为268,而注意力方法仅为133,与其最高F1分数0.3448相对应。图3(e)的横向堆叠条形图将总误差分解为误报率与漏报率,决策树、K近邻算法、前馈神经网络和卷积网络的错误以误报为主,误报占总误差的95%以上;支持向量机和长短期记忆网络则相反,漏报占比分别高达97.9%和95.5%,在安全关键场景中存在更大风险。注意力方法以9.8%的漏报率和90.2%的误报率在两类错误之间取得了最合理的平衡。图3(f)的性能热图以颜色深浅直观汇总了五项指标,K近邻算法在平衡准确率、召回率和F1三列均呈现较深的绿色,长短期记忆网络和支持向量机在这两列颜色明显偏浅。

### 3.4. 特征重要性与可解释性

图4从三个不同的可解释性视角审视了特征对分类任务的贡献,为理解夹爪失效的传感器机理提供了重要线索。



**Figure 4.** Feature importance and interpretability analysis: (a) Decision tree feature importance; (b) SVM permutation feature importance; (c) Attention mechanism weights ranked by magnitude; (d) Top-10 feature importance comparison across DT, SVM, and attention methods

**图 4.** 特征重要性与可解释性分析: (a) 决策树特征重要性; (b) 支持向量机(SVM)置换特征重要性; (c) 按权重大小排序的注意力机制权重; (d) 决策树(DT)、支持向量机(SVM)和注意力方法的前 10 个特征重要性对比

图 4(a)展示了决策树通过不纯度减少量化的特征重要性排名。Current\_J2 即关节 2 电流, 重要性为 0.000461, 和 Current\_J3 即关节 3 电流, 重要性为 0.000355, 共同贡献了前两位, 二者累计解释约 47%的总判别信息量, Temperature\_J3 即关节 3 温度, 重要性为 0.000234, 排名第三, 三者合计约 60.6%。Current\_J0、Current\_J1 等多个特征的决策树重要性为零, 这与温度特征高度共线的发现高度一致——决策树一旦选了一个温度特征, 其余相关特征便失去额外的分裂价值。

图 4(b)采用基于平衡准确率下降的排列重要性方法对支持向量机进行特征分析, 规避了树模型中不纯度度量的固有偏差。Current\_J2 和 Current\_J4 的排列重要性并列最高, 归一化后均为 0.1062, Current\_J1 和 Current\_J3 紧随其后, 均为 0.1044, 电流特征整体上比速度和温度特征贡献更大。图 4(c)的注意力机制权重排名与此不同: Temperature\_J4 的权重为 0.0925, Temperature\_J3 为 0.0917, Temperature\_J5 为 0.0904, 三者位居前三, 六个温度特征合计贡献约 53%的注意力权重。这反映了单变量线性相关与全局非线性判别能力之间的本质差异——温度特征与标签存在稳定的线性关联, 但其高度共线性在多变量场景中削弱了独立判别价值。

图 4(d)将三种可解释性方法归一化后进行前 10 个特征的跨方法比较, Current\_J2 在三种方法中均排名前列, 是唯一被一致认可的关键特征, 可以确认为夹爪失效检测中最具判别价值的传感器信号。跨方法不一致性提示特征重要性评估依赖所选模型, 单一可解释性视角存在局限性。

### 3.5. 学习曲线与训练动态

图 5 通过学习曲线分析揭示了各方法的样本效率与训练动态, 这对确定最小有效训练样本量具有重要参考价值。

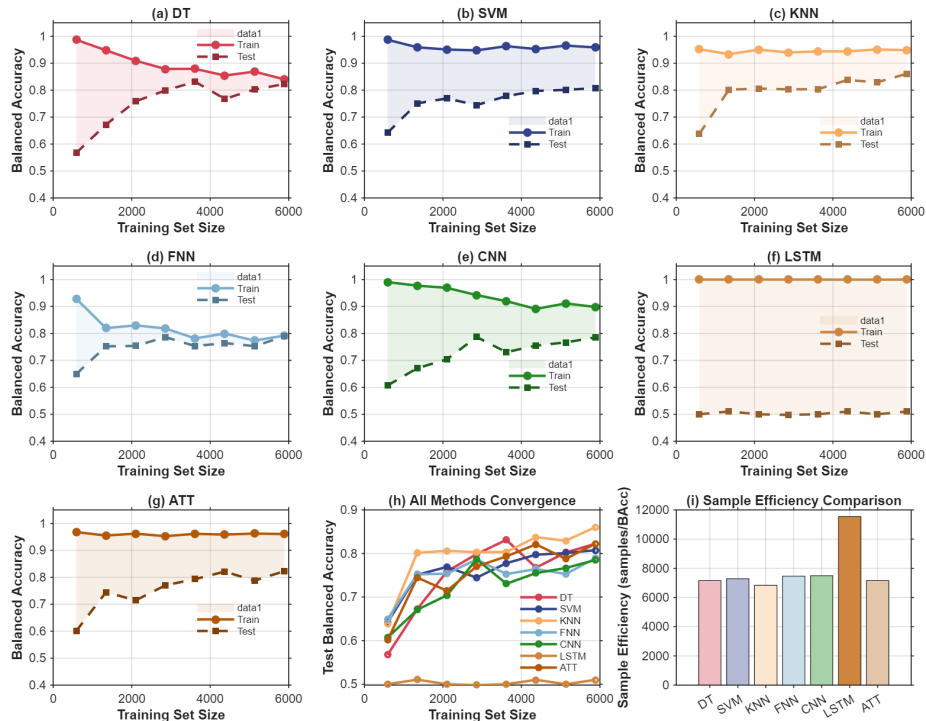


Figure 5. Learning curves and training dynamics analysis: (a)~(g) Individual learning curves for DT, SVM, KNN, FNN, CNN, LSTM, and ATT, respectively; (h) All-methods convergence comparison; (i) Sample efficiency comparison

图 5. 学习曲线与训练动态分析: (a)~(g) 分别为决策树(DT)、支持向量机(SVM)、K 近邻(KNN)、前馈神经网络(FNN)、卷积神经网络(CNN)、长短期记忆网络(LSTM)和注意力模型(ATT)的单独学习曲线; (h) 所有方法的收敛性对比; (i) 样本效率对比

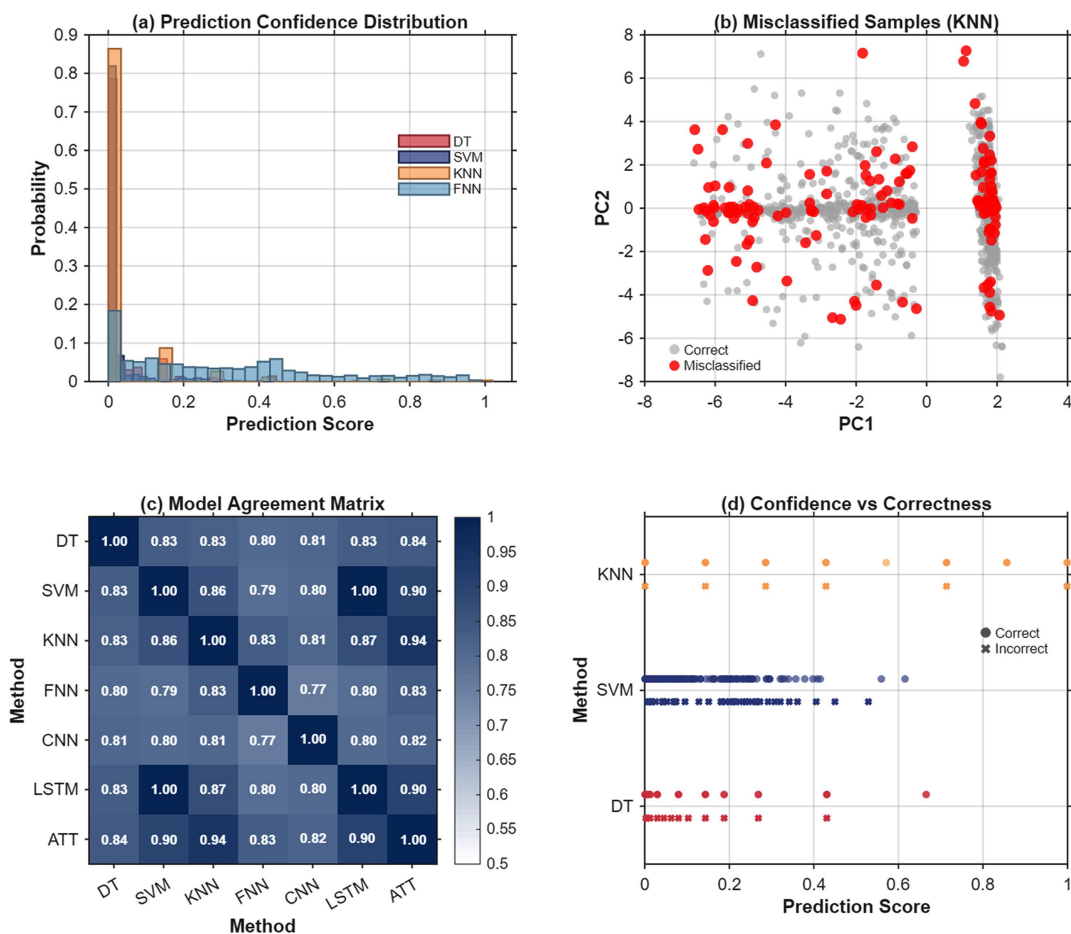
图 5(a)至图 5(g)分别展示了七种方法在从约 589 至 5884 个样本的 8 个训练规模梯度下, 训练集与测试集平衡准确率的变化轨迹。决策树展现出典型的过拟合 - 收敛模式, 至全量训练集时泛化间隙缩小至 0.018, 是过拟合程度最低的传统模型。K 近邻算法的测试集准确率在样本量超过 1345 时便稳定在 0.80 以上, 收敛速度最快, 训练测试差距仅为 0.088。最引人关注的是长短期记忆网络, 其训练集准确率全程维持在 0.999 以上, 而测试集准确率始终在 0.5 附近徘徊, 泛化间隙高达 0.490, 与随机猜测无异——这直接说明基于指数移动平均的近似实现存在根本性局限, 在实际部署中不具参考价值。前馈神经网络则呈现独特的低方差特性, 训练测试差距仅 0.003, 表明过采样有效遏制了过拟合, 但性能上限约束在 0.79 左右。

图 5(h)将七种方法的测试集收敛曲线叠加展示, K 近邻算法的最终收敛水平 0.8604 高于所有其他方法, 且曲线斜率在样本量超过 4000 后趋于平稳, 说明约 4000 条样本已足以使其获得接近最优的性能。

图 5(i)将样本效率量化为完整训练集样本数与最终测试集准确率之比, K 近邻算法以 6838.3 的最小比值确认为样本效率最高的方法, 长短期记忆网络则以 11535.8 高居最低。

### 3.6. 预测质量与模型协同性

图 6 从预测置信度、错分样本分布和模型间协同性三个维度对分类结果进行深度剖析。



**Figure 6.** Prediction quality and model agreement analysis: (a) Prediction confidence score distribution; (b) PCA projection of misclassified samples for the best-performing method; (c) Pairwise model agreement matrix; (d) Prediction confidence vs. classification correctness

**图 6.** 预测质量与模型一致性分析: (a) 预测置信度分数分布; (b) 最优性能方法的错误分类样本主成分分析(PCA)投影; (c) 两两模型一致性矩阵; (d) 预测置信度与分类正确性的关系

图 6(a)展示了决策树、支持向量机、K 近邻算法和前馈神经网络预测得分的概率分布直方图。决策树的输出得分高度集中于 0 附近，中位数仅为 0.007，超过 0.5 的样本仅占 0.1%；K 近邻算法的得分分布同样右偏，但尾部更宽，最大值可达 1.0，约 1.2%的样本得分超过 0.5；前馈神经网络因过采样影响，预测得分分布明显更宽，均值为 0.305，超过 20.6%的样本得分超过 0.5，体现了正类预测倾向性的显著增强。

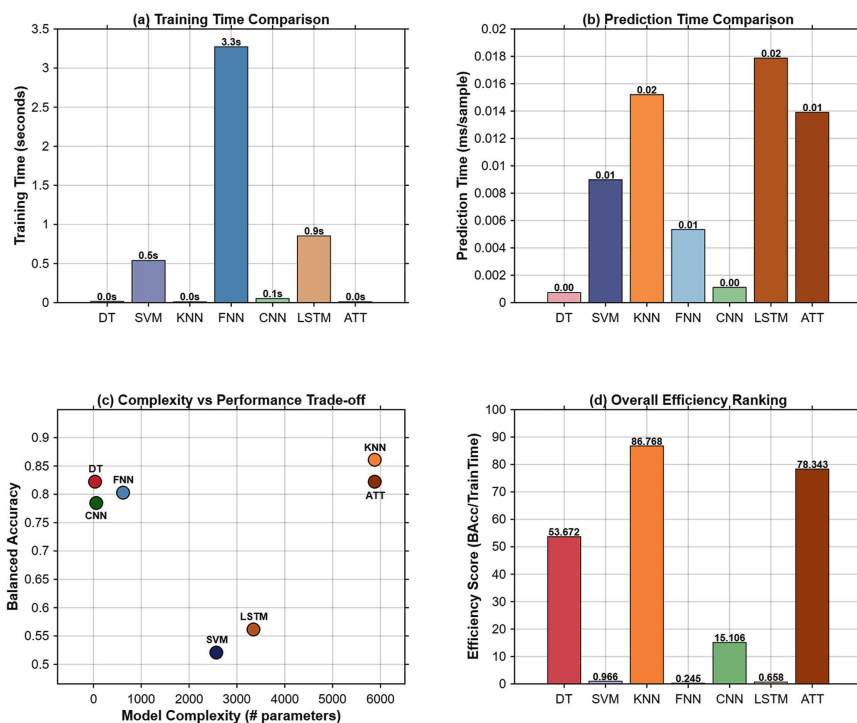
图 6(b)在测试集主成分分析二维投影空间中标注了 K 近邻算法的错分样本共 168 个，其中 160 个为误报，8 个为漏报。错分样本主要聚集在 PC1 与 PC2 空间的边界过渡区域，与两类样本投影分布的交叠区高度吻合，在几何层面直观解释了难例样本的本质。

图 6(c)展示了七种方法之间的预测一致性矩阵，非对角线元素均值为 0.841。长短期记忆网络与支持向量机之间的一致性高达 0.9952，源于二者共同的保守倾向而非真正的判别力相似，是一种需要警惕的伪一致性现象。K 近邻算法与注意力方法之间的一致性为 0.9422，前馈神经网络与所有其他方法的一致性均相对较低，最低为与卷积网络之间的 0.7655，表明前馈神经网络在集成层面具有最高的互补潜力。

图 6(d)将预测置信度与分类正确性关联起来，对于决策树、支持向量机和 K 近邻算法，正确分类样本的平均得分分别为 0.015、0.026 和 0.014，显著低于错分样本的 0.125、0.176 和 0.190，说明这三种模型对错误预测的置信度反而更高——错分样本往往处于决策边界附近，模型错误地将模糊信号判断为高置信度的正类。

### 3.7. 计算效率分析

图 7 从训练时间、预测延迟、模型复杂度和综合效率四个维度对七种方法的计算代价进行系统评估，为在线工业部署提供实用参考。



**Figure 7.** Computational efficiency and resource requirements: (a) Training time comparison; (b) Per-sample prediction time comparison; (c) Model complexity vs. balanced accuracy trade-off; (d) Overall efficiency ranking by balanced accuracy per unit training time

**图 7.** 计算效率与资源需求: (a) 训练时间对比; (b) 单样本预测时间对比; (c) 模型复杂度与平衡准确率的权衡关系; (d) 基于单位训练时间平衡准确率的综合效率排名

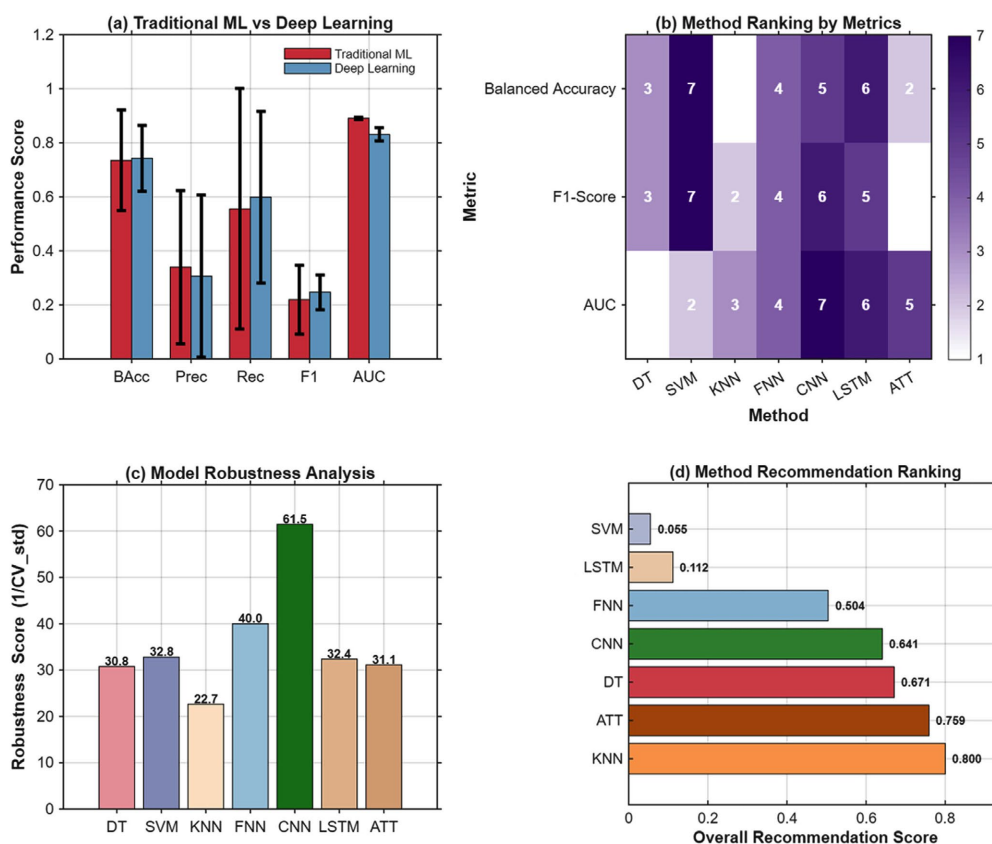
图 7(a)的训练时间柱状图显示, K 近邻算法耗时 0.010 秒, 注意力方法耗时 0.011 秒, 决策树耗时 0.015 秒, 三者均在 50 毫秒以内完成训练。前馈神经网络因包含反向传播迭代, 训练时间高达 3.27 秒, 约为 K 近邻算法的 330 倍; 长短期记忆网络耗时 0.85 秒, 支持向量机耗时 0.54 秒, 均属于秒级范围。

图 7(b)的每样本预测时间显示出不同的排名格局, 决策树以 0.00073 毫秒每样本的最短延迟最适合实时嵌入式部署, 卷积网络为 0.0011 毫秒次之, 而 K 近邻算法为 0.0152 毫秒, 因需计算与全量训练集的距离, 约为决策树的 20 倍, 但绝对值仍处于微秒量级, 在多数工业系统的响应时间要求下完全可接受。图 7(c)将模型复杂度与平衡准确率映射至二维散点图, K 近邻算法和注意力方法参数量虽均为 5884, 平衡准确率却分别高达 0.8604 和 0.8224; 支持向量机拥有 2571 个支持向量, 准确率仅为 0.5205, 表明其复杂结构并未转化为判别能力的提升。

图 7(d)将综合效率评分定义为平衡准确率与训练时间之比, K 近邻算法以 86.77 位居第一, 注意力方法以 78.34 紧随其后, 决策树为 53.67 位居第三。前馈神经网络、支持向量机和长短期记忆网络的效率评分分别仅为 0.245、0.966 和 0.658, K 近邻算法在耗费极少计算资源的前提下获得了最高的分类性能, 是资源受限场景下的首选方案。

### 3.8. 方法体系比较与推荐

图 8 从宏观视角对传统机器学习组与深度学习组进行了综合对比, 并给出量化的方法推荐排名。



**Figure 8.** Comprehensive method analysis and recommendations: (a) Average metric comparison between traditional ML and deep learning groups; (b) Method ranking by balanced accuracy, F1-score, and AUC; (c) Model robustness analysis based on cross-validation standard deviation; (d) Overall recommendation ranking

**图 8.** 方法综合分析与建议: (a) 传统机器学习与深度学习组的平均指标对比; (b) 基于平衡准确率、F1 分数和 AUC 的方法排名; (c) 基于交叉验证标准差的模型鲁棒性分析; (d) 综合推荐排名

图 8(a)以决策树、支持向量机和 K 近邻算法代表传统机器学习组, 以前馈神经网络、卷积网络、长短期记忆网络和注意力方法代表深度学习组, 对五项指标的组内均值进行比较。在平衡准确率、召回率和 F1 分数上, 深度学习组均值略高, 三项数值分别为传统组 0.734 对 0.743、0.556 对 0.599、0.220 对 0.247, 但差异不超过 0.05; 在曲线下面积和精确率上, 传统机器学习组则分别以 0.891 和 0.340 领先。这表明在当前数据规模下, 深度学习方法并未展现出与其模型复杂度相称的性能优势。

图 8(b)从平衡准确率、F1 分数和曲线下面积三个指标分别排名后计算平均排名, K 近邻算法以平均排名 2.0 位居首位, 决策树以 2.3 紧随其后, 注意力方法以 2.7 排名第三; 长短期记忆网络和支持向量机分别以 5.7 和 5.3 垫底。图 8(c)以五折交叉验证标准差的倒数定义鲁棒性评分, 卷积网络的鲁棒性评分为 61.5, 前馈神经网络为 40.0, 展现出最优的跨折稳定性; K 近邻算法的鲁棒性评分仅为 22.7, 其在不同折间存在一定波动, 使用时需注意训练集构成对结果的影响[20] [21]。

图 8(d)综合平衡准确率、效率和鲁棒性三个维度, 以 0.5:0.3:0.2 的权重构建最终推荐评分, K 近邻算法以 0.8000 高居首位, 注意力方法以 0.7585 和决策树以 0.6710 分居二三位。支持向量机和长短期记忆网络的综合评分仅分别为 0.0548 和 0.1123, 其平衡准确率的根本缺陷无法被效率或鲁棒性分量所弥补。

综合图 1 至图 8 的全部实验证据, K 近邻算法表现出最为均衡的综合优势: 测试集平衡准确率 0.8604, 五折交叉验证均值 0.801, 训练耗时 0.010 秒, 效率评分 86.77, 综合推荐评分 0.8000, 是当前数据集条件下面向工业部署的首选算法。注意力增强方法以最高 F1 分数 0.3448 在对正类检测精度有更高要求的场景中可作为补充选项。传统决策树在曲线下面积 0.8952、训练速度和可解释性上的均衡表现, 使其适合需要在线诊断规则提取的应用场景。

## 4. 结论

本文系统评估了七种机器学习方法在工业机器人夹爪失效检测任务上的性能, 数据集类别不平衡比高达 29.27:1, 是制造业传感器监测场景中的典型挑战。研究得出以下核心结论。

在处理单一样本、非时序的、高度不平衡的低维机器人传感器数据时, 经过优化的 K 近邻算法在综合性能、计算效率和泛化稳定性三个维度均优于本研究中测试的所有传统模型及简化的深度学习架构, 以平衡准确率 0.8604 和训练时间 0.010 秒稳居各项排名首位。这一结论严格限定于本研究的实验条件: 单一真实数据集、非时序的逐样本处理方式以及简化的深度学习近似实现。长短期记忆网络的近似方案出现了严重的过拟合与泛化失效现象, 是本研究中最具警示意义的对照案例, 同时也说明其局限性源于实现方式而非算法原理本身。高曲线下面积与低平衡准确率可能同时存在于同一模型, 支持向量机即为典型例证, 说明 ROC 曲线在不平衡场景下应与平衡准确率和 F1 分数结合使用, 而非单独作为决策依据。特征重要性分析一致表明 Current\_J2 是夹爪失效最具判别价值的信号, 温度特征虽与标签存在线性关联, 但因极高的组间共线性而在多变量判别中贡献有限。

本研究存在以下局限性, 在解读和推广结论时需予以审慎考量。第一, 所有实验基于单一来源的真实数据集, 结论是否适用于其他机器人型号、不同传感器配置或不同工业环境尚需进一步验证。第二, 本研究对传感器记录采取逐样本的非时序处理方式, 未能利用机器人运动信号中蕴含的时序依赖信息; 在真正利用时序上下文的场景下, 基于 LSTM 或 Transformer 等架构的深度序列模型可能展现出与本研究截然不同的竞争优势。第三, 本研究中的深度学习方法均为简化近似实现, 而非标准的端到端训练架构, 实验结论反映的是这些简化实现在当前场景下的性能, 不能直接等同于对真实深度学习能力上限的评估。未来研究方向包括: 在更大规模、更多样化的数据集上验证 K 近邻算法的鲁棒性; 引入真实的深度时序模型(如 LSTM、TCN、Transformer)与本文框架进行系统对照; 以及探索针对温度特征高度共线性问题的降维预处理策略, 以进一步提升模型的泛化性能与工业可部署性。

## 参考文献

- [1] 吴昊天, 王耀南, 朴玄斌, 等. 智能制造工业机器人技术应用及发展趋势[J]. 中国工程科学, 2025, 27(3): 83.
- [2] Soori, M., Dastres, R., Arezoo, B. and Karimi Ghaleh Jough, F. (2024) Intelligent Robotic Systems in Industry 4.0: A Review. *Journal of Advanced Manufacturing Science and Technology*, 4, Article ID: 2024007. <https://doi.org/10.51393/j.jamst.2024007>
- [3] Vrochidou, E., Tsakalidou, V.N., Kalathas, I., Gkrimpizis, T., Pachidis, T. and Kaburlasos, V.G. (2022) An Overview of End Effectors in Agricultural Robotic Harvesting Systems. *Agriculture*, 12, Article No. 1240. <https://doi.org/10.3390/agriculture12081240>
- [4] Wolf, A., Steinmann, R. and Schunk, H. (2005) *Grippers in Motion: The Fascination of Automated Handling Tasks*. Springer.
- [5] Liu, S. (2025) Machine Learning-Based Fault Detection for UR3 Collaborative Robot: A Multimodal Data Analysis Approach. *Engineering Frontiers*, 1, 42-54. <https://doi.org/10.71411/ef.2025.v1i2.941>
- [6] He, Y., Zhao, C., Zhou, X. and Shen, W. (2024) MJAR: A Novel Joint Generalization-Based Diagnosis Method for Industrial Robots with Compound Faults. *Robotics and Computer-Integrated Manufacturing*, 86, Article ID: 102668. <https://doi.org/10.1016/j.rcim.2023.102668>
- [7] 郁明, 李旺林, 蓝盾. 基于优化自适应阈值的非线性机电系统传感器故障检测和主动容错控制[J]. 仪器仪表学报, 2022, 43(4): 26-37.
- [8] Otter, D.W., Medina, J.R. and Kalita, J.K. (2021) A Survey of the Usages of Deep Learning for Natural Language Processing. *IEEE Transactions on Neural Networks and Learning Systems*, 32, 604-624. <https://doi.org/10.1109/tnnls.2020.2979670>
- [9] Young, T., Hazarika, D., Poria, S. and Cambria, E. (2018) Recent Trends in Deep Learning Based Natural Language Processing. *IEEE Computational Intelligence Magazine*, 13, 55-75. <https://doi.org/10.1109/mci.2018.2840738>
- [10] Chen, W., Shao, Y., Xu, Z., Zhou, B., Cui, S., Dai, Z., et al. (2026) Ensemble Machine Learning for Operational Water Quality Monitoring Using Weighted Model Fusion for pH Forecasting. *Sustainability*, 18, Article No. 1200. <https://doi.org/10.3390/su18031200>
- [11] Wang, C., Huang, K., Yao, Y., Chen, J., Shuai, H. and Cheng, W. (2024) Lightweight Deep Learning: An Overview. *IEEE Consumer Electronics Magazine*, 13, 51-64. <https://doi.org/10.1109/mce.2022.3181759>
- [12] Chen, C., Zhang, P., Zhang, H., Dai, J., Yi, Y., Zhang, H., et al. (2020) Deep Learning on Computational-Resource-Limited Platforms: A Survey. *Mobile Information Systems*, 2020, Article ID: 8454327. <https://doi.org/10.1155/2020/8454327>
- [13] Johnson, J.M. and Khoshgoftaar, T.M. (2019) Survey on Deep Learning with Class Imbalance. *Journal of Big Data*, 6, Article No. 27. <https://doi.org/10.1186/s40537-019-0192-5>
- [14] Chakraborty, S., Tomsett, R., Raghavendra, R., Harborne, D., Alzantot, M., Cerutti, F., et al. (2017) Interpretability of Deep Learning Models: A Survey of Results. 2017 *IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCOM/IOP/SCI)*, San Francisco, 4-8 August 2017, 1-6. <https://doi.org/10.1109/uic-atc.2017.8397411>
- [15] Tyrovolas, M., Stylios, C., Aliev, K. and Antonelli, D. (2024) Leveraging Information Flow-Based Fuzzy Cognitive Maps for Interpretable Fault Diagnosis in Industrial Robotics. In: Camarinha-Matos, L.M. and Ferrada, F., Eds., *Technological Innovation for Human-Centric Systems*, Springer, 98-110. [https://doi.org/10.1007/978-3-031-63851-0\\_6](https://doi.org/10.1007/978-3-031-63851-0_6)
- [16] 陈海涵, 吴国栋, 李景霞, 等. 基于注意力机制的深度学习推荐研究进展[J]. 计算机工程与科学, 2021, 43(2): 370.
- [17] 谢丽霞, 刘思雨, 杨宏宇, 等. 一种基于分类代价的软件缺陷评估方法[J]. 北京邮电大学学报, 2023, 46(4): 116.
- [18] 周璇, 闫学成, 闫军威, 等. 基于 BOA-SVM 的冷源系统温度传感器偏差故障检测[J]. 控制理论与应用, 2025, 42(5): 921-930.
- [19] 齐超群, 彭思淇, 张慧博, 等. 基于阵列压力传感器的嵌套式递推分布力辨识[J]. 仪器仪表学报, 2025, 46(1): 1-10.
- [20] 王军锋, 张彪, 张昊, 等. KNN-Transformer: 基于 K 近邻分类的 Transformer 算法在滚动轴承故障诊断中的应用[J]. 机电工程技术, 2025, 54(18): 160-166.
- [21] 徐杨宇, 高宝元, 郭杰龙, 等. 尺度不变的条件数约束的模型鲁棒性增强算法[J]. 计算机工程与应用, 2024, 60(8): 140-147.