

第二届人工智能与粒子加速器研讨会

基于时空对比融合的粒子加速器异常检测方法

CSNS漂移管直线加速器应用验证

报告人：何泳成

中国科学院高能物理研究所

2025-12

研究成果来自：Yang Z, Zhou R C, He Y C*, Long J Y*, Fang L, Li C. Anomaly detection of particle accelerators using spatial-temporal contrastive fusion of multi-sensor time series[J]. Reliability Engineering & System Safety, 2026, 267(Part B): 111940. <https://doi.org/10.1016/j.ress.2025.111940>

报告内容

一. 研究背景

二. 相关研究现状

三. 时空对比融合 (STCF) 框架设计

四. 实验验证

五. 结论与展望



报告内容

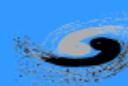
一. 研究背景

二. 相关研究现状

三. 时空对比融合 (STCF) 框架设计

四. 实验验证

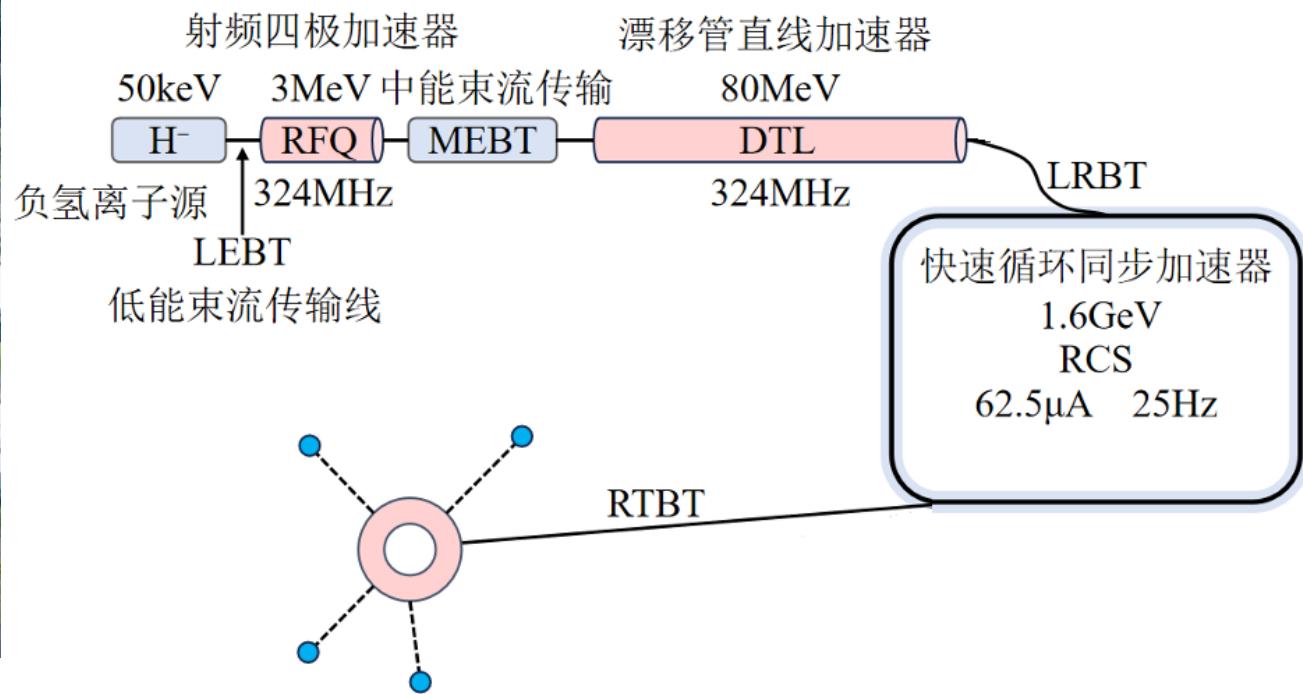
五. 结论与展望



大型粒子加速器是探索微观世界的“超级显微镜”



能量1.6Gev、功率500kW（二期），主要用于产生中子束



- 需长期稳定运行，异常会导致实验失败、设备损坏甚至安全风险
- 应用案例：CSNS漂移管直线加速器（DTL），负责将3MeV负氢离子加速至80MeV



现有异常检测痛点

- 数据层面：多传感器采集的高维时序数据时空耦合紧密，传统方法难以解耦
- 技术层面：现有方法要么时空融合不充分，要么依赖高质量标注数据，而加速器异常样本稀缺
- 工程层面：加速器结构复杂，故障模式多样，包括机械误差、电场误差等，通用方法适配性差

研究目标

- **核心目标：**解决时空信息融合不足、依赖标注数据的问题，实现更精准异常检测
- ✓ 提出时空对比融合 (Spatial-Temporal Contrastive Fusion, STCF) 框架，协同时序与空间特征
- ✓ 仅需正常数据训练，避免异常标注依赖
- ✓ 基于CSNS实际数据验证



报告内容

一. 研究背景

二. 相关研究现状

三. 时空对比融合 (STCF) 框架设计

四. 实验验证

五. 结论与展望

异常检测技术分类

技术类别	典型方法	核心优势	针对粒子加速器场景局限性
传统方法	主成分分析 (PCA)	原理简单、计算开销低	难以处理高维时空数据，无法捕捉加速器多传感器耦合关系
	局部异常因子 (LOF)	无需假设数据分布	对高维数据敏感，异常检测精度低，不适应加速器动态工况
深度学习方法	时序建模 (LSTM、Transformer)	擅长捕捉长时依赖，适配时序演化	忽视传感器间空间关联，无法识别多传感器协同异常
	时空建模 (图神经网络 GDN)	尝试融合时空特征	依赖复杂结构学习，对加速器传感器布局依赖性强，泛化能力弱
	对比学习 (通用框架)	自监督学习，减少标注依赖	缺乏针对加速器数据的时空协同设计，未适配束流/真空等数据特性



现有方法局限性

- 时空分离：未充分融合多传感器的时序动态与空间依赖
- 标注依赖：监督学习需大量异常标注，无监督方法泛化能力弱
- 场景适配：针对通用数据设计，未适配加速器数据的强耦合特性

报告内容

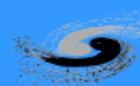
一. 研究背景

二. 相关研究现状

三. 时空对比融合 (STCF) 框架设计

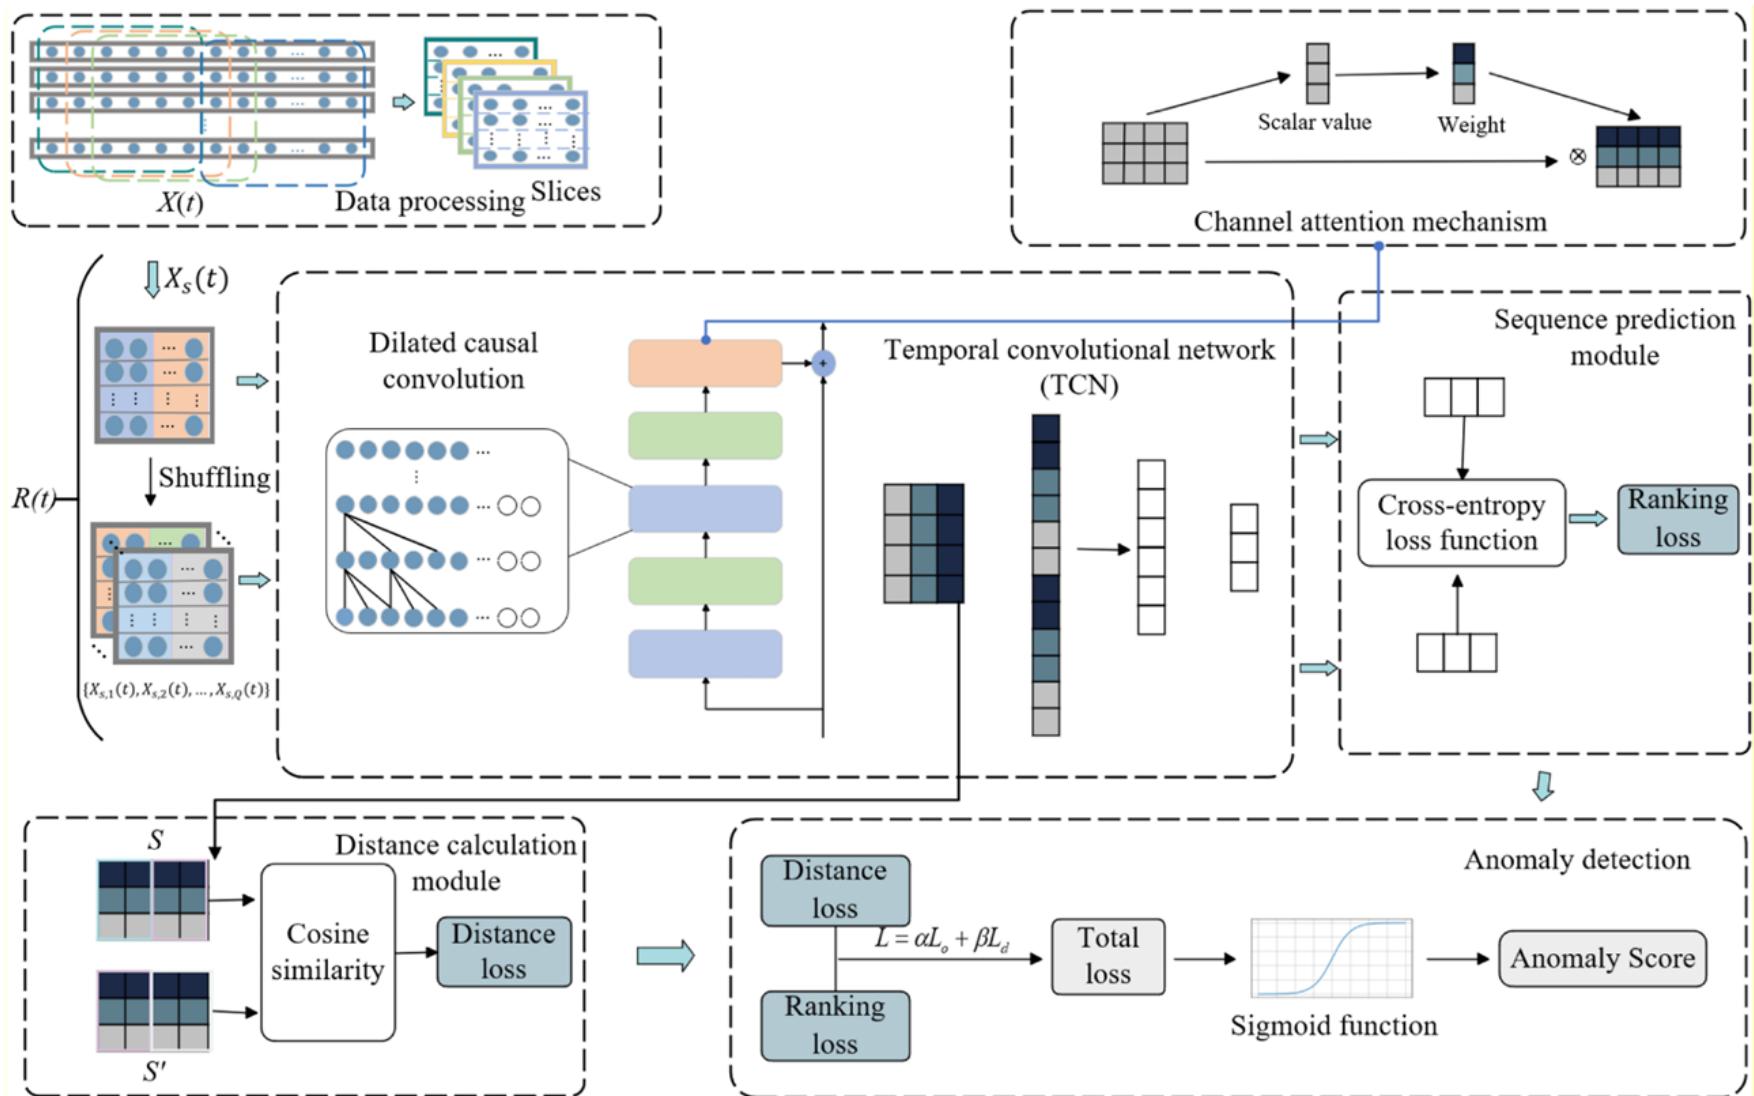
四. 实验验证

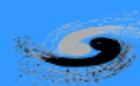
五. 结论与展望



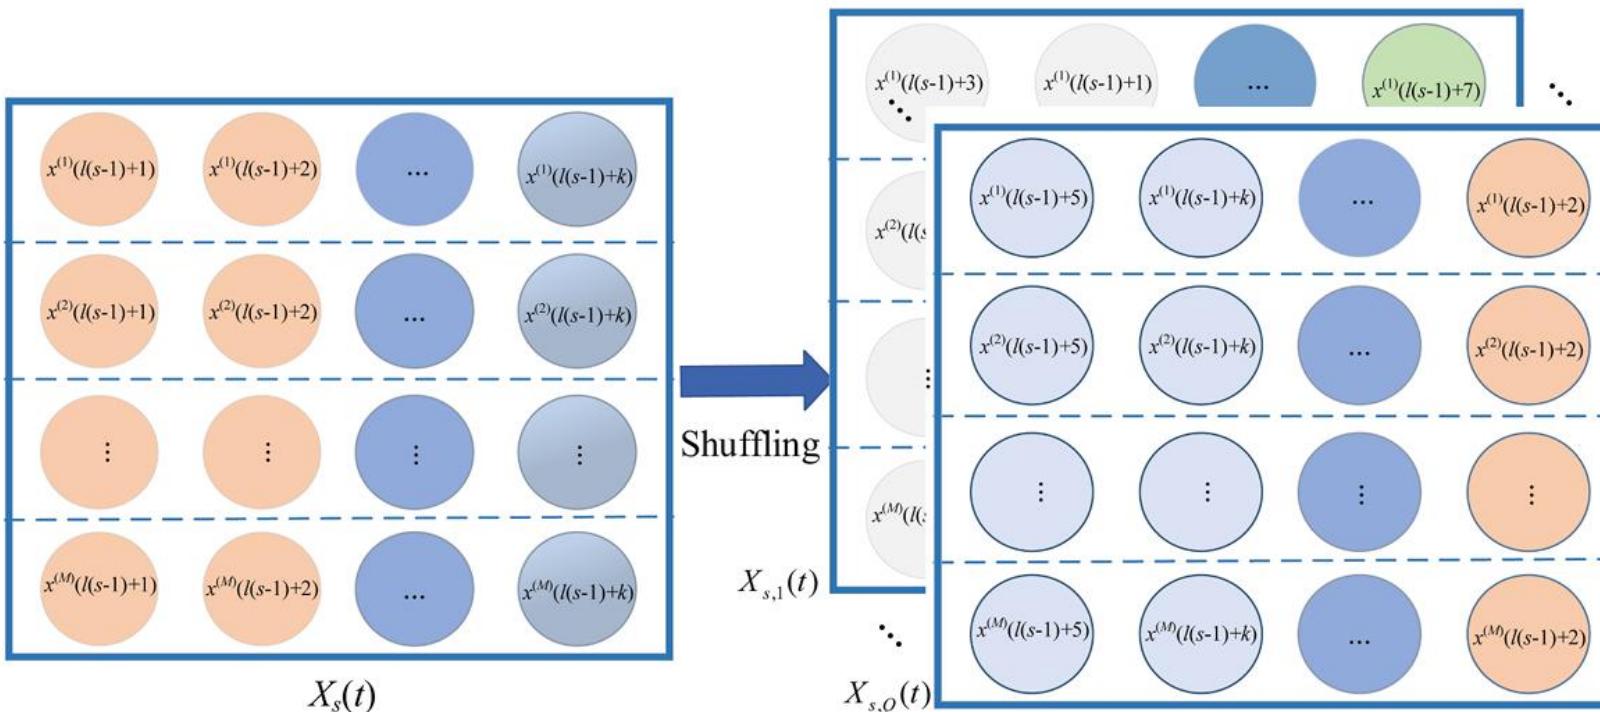
时空对比融合 (STCF) 整体框架设计

- **核心逻辑：**仅用正常数据训练，充分融合时空特征
- **核心流程：**数据预处理与增强→时序特征提取→空间特征强化→时空对比融合→异常判定





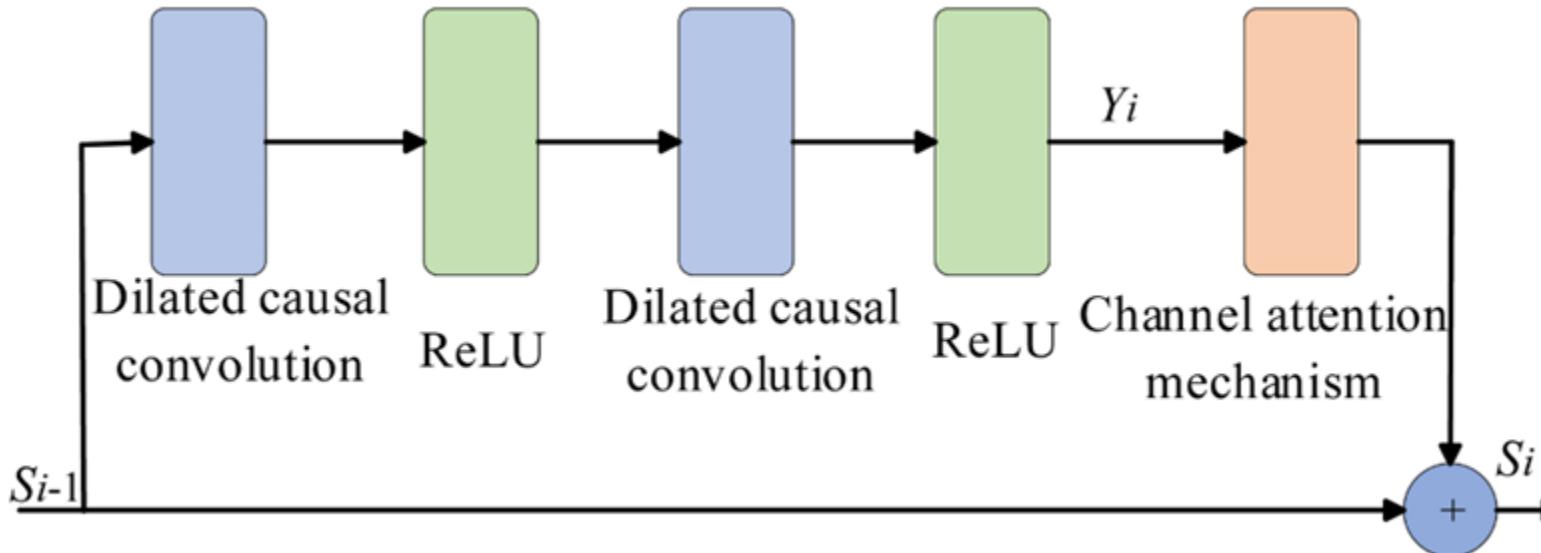
数据预处理与增强



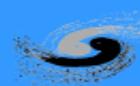
- M 个传感器的时间序列 $X(t) = \{x^{(1)}(t), x^{(2)}(t), \dots, x^{(m)}(t), \dots, x^{(M)}(t)\}$
- 滑动窗口切片：按窗口大小为 k 、步长为 l 分割时序数据（ $X_s(t)$ 为第 s 片段）
- 子序列打乱：将每个切片均分后随机重排，生成乱序子序列 $\{X_{s,1}(t), X_{s,2}(t), \dots, X_{s,Q}(t)\}$
- 数据集构建：整合原始切片与乱序子序列，形成训练数据 $R(t) = \{X_s(t), X_{s,1}(t), X_{s,2}(t), \dots, X_{s,Q}(t)\}$



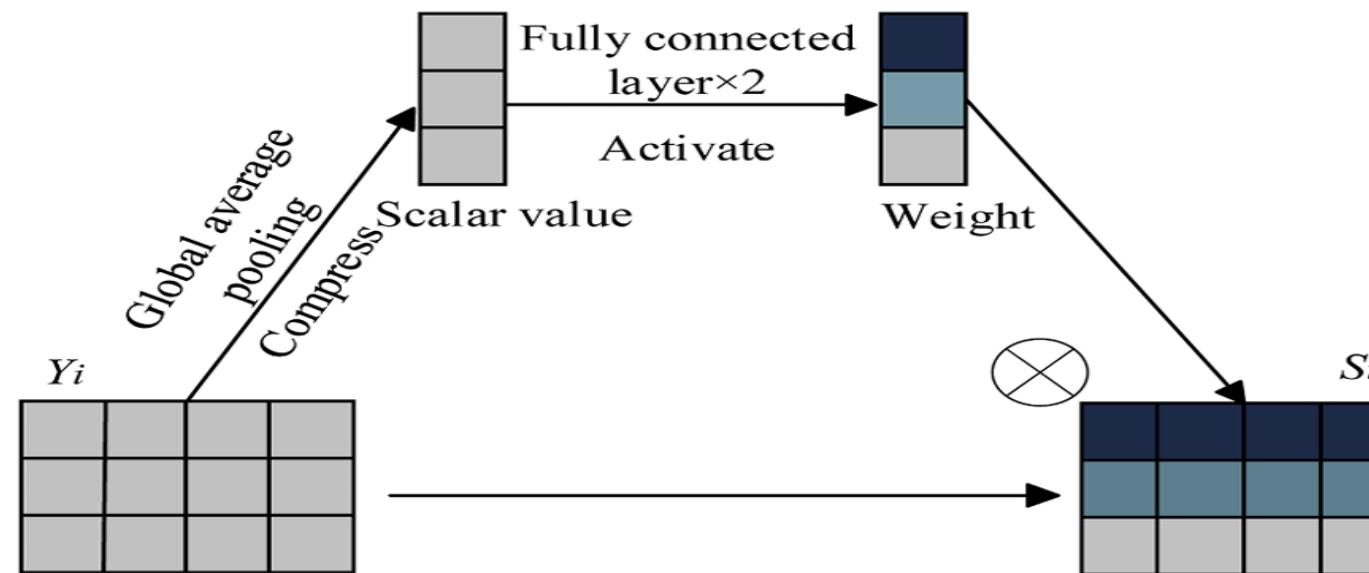
时序特征提取



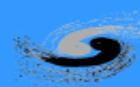
- **核心组件：扩张因果卷积网络** $Y_1 = \sum_{j=0}^{u-1} w_j R_{(t-j)d}$ (u 是卷积核的大小， W_j 代表卷积核， $R_{(t-j)d}$ 表示过去的输入， d 则表示膨胀率。)
- **因果卷积：**仅依赖历史数据，避免信息泄露
- **扩张卷积：**扩大感受野为 $(t-1) \cdot d + 1$ 个时间点，捕捉长时依赖
- **残差连接：**避免深层网络中的梯度消失问题，提升深层特征提取能力



空间特征强化

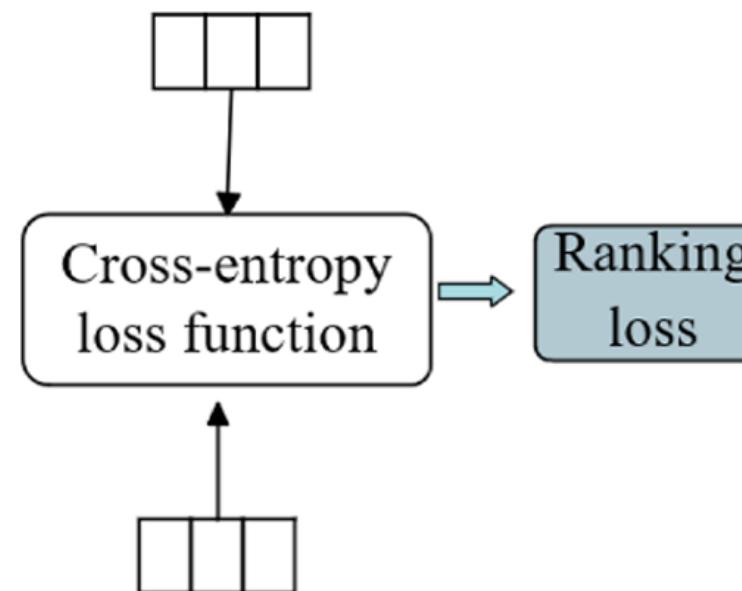


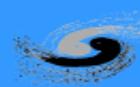
- 设计目的：引入通道注意力机制，强化空间特征区分度，抑制冗余信息
- 压缩：全局平均池化获取通道全局信息 $z_i^{(c)} = \frac{1}{H} \sum_{t=1}^H Y_i^{(c)}$ (c 是通道数, H 是时间步数)
- 激励：通过全连接层与激活函数生成通道权重 $s_i^{(c)} = \sigma(W_2 \cdot \text{ReLU}(W_1 \cdot z_i^{(c)}))$ (W_1 和 W_2 为两个线性变换矩阵, σ 为Sigmoid函数)
- 加权：输入特征的每个通道将按对应的注意力权重缩放，突出关键特征 $S_i^{(c)} = s_i^{(c)} \cdot z_i^{(c)}$



时空对比融合策略

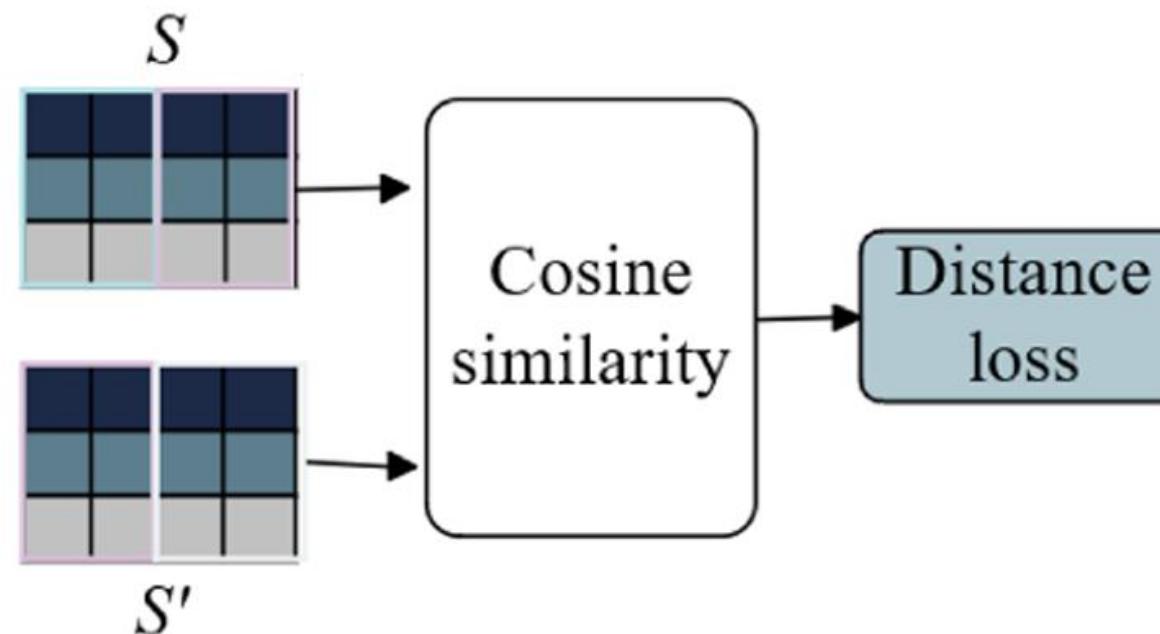
- 时序对比：排序损失
$$L_o = \sum_{i=1}^C P \log \left(\frac{P}{\frac{1}{2}(P + P_b)} \right) + \sum_{i=1}^C P_b \log \left(\frac{P_b}{\frac{1}{2}(P + P_b)} \right)$$
- 核心逻辑：预测子序列原始顺序，量化时序偏差
- 损失计算：使用Jensen-Shannon散度衡量预测分布 P 与真实分布 P_b 间的差异





时空对比融合策略

- 空间对比：距离损失 $L_d = \frac{1}{n} \sum_{i=1}^n (D - D_m)^2$
- 核心逻辑：计算原始与增强样本的特征相似度，量化空间分布差异
- 损失计算：使用分布特征余弦距离 D 和嵌入特征余弦距离 D_m 间的均方误差来衡量距离差异

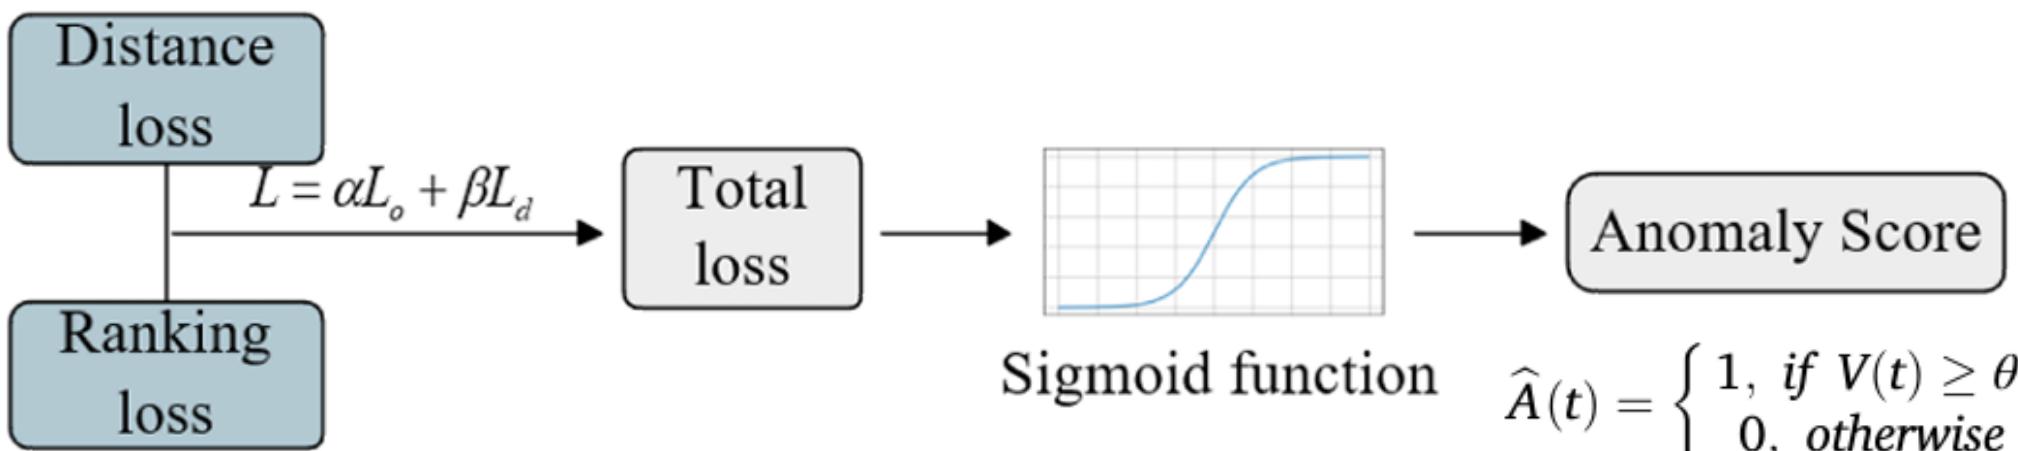




异常判定

- 加权融合策略: $L = \alpha L_o + \beta L_d$ ($\alpha L_o = \beta L_d$, $\alpha + \beta = 1$)
- 综合异常分数: $V = \sigma(L)$, Sigmoid函数归一化至 [0,1]
- 阈值优化: 遍历候选阈值, 基于 F1 分数确定最优阈值 θ'
- 当异常分数 \geq 阈值时判定为异常

$$P = \frac{TP}{TP + FP}, R = \frac{TP}{TP + FN}, \text{ and } F1 = \frac{2PR}{P + R}$$



异常检测流程

1. 数据预处理与增强：采集多传感器数据，生成切片与乱序子序列
2. 时序特征提取：通过时序卷积提取时序特征 Y_i
3. 空间特征强化：引入通道注意力机制生成时空特征 S_i
4. 时空对比融合：计算排序损失与距离损失，生成总损失 L
5. 异常判定：计算异常分数 V ，与最优阈值 θ' 对比，输出检测结果

报告内容

一. 研究背景

二. 相关研究现状

三. 时空对比融合 (STCF) 框架设计

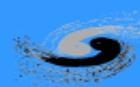
四. 实验验证

五. 结论与展望

实验数据配置

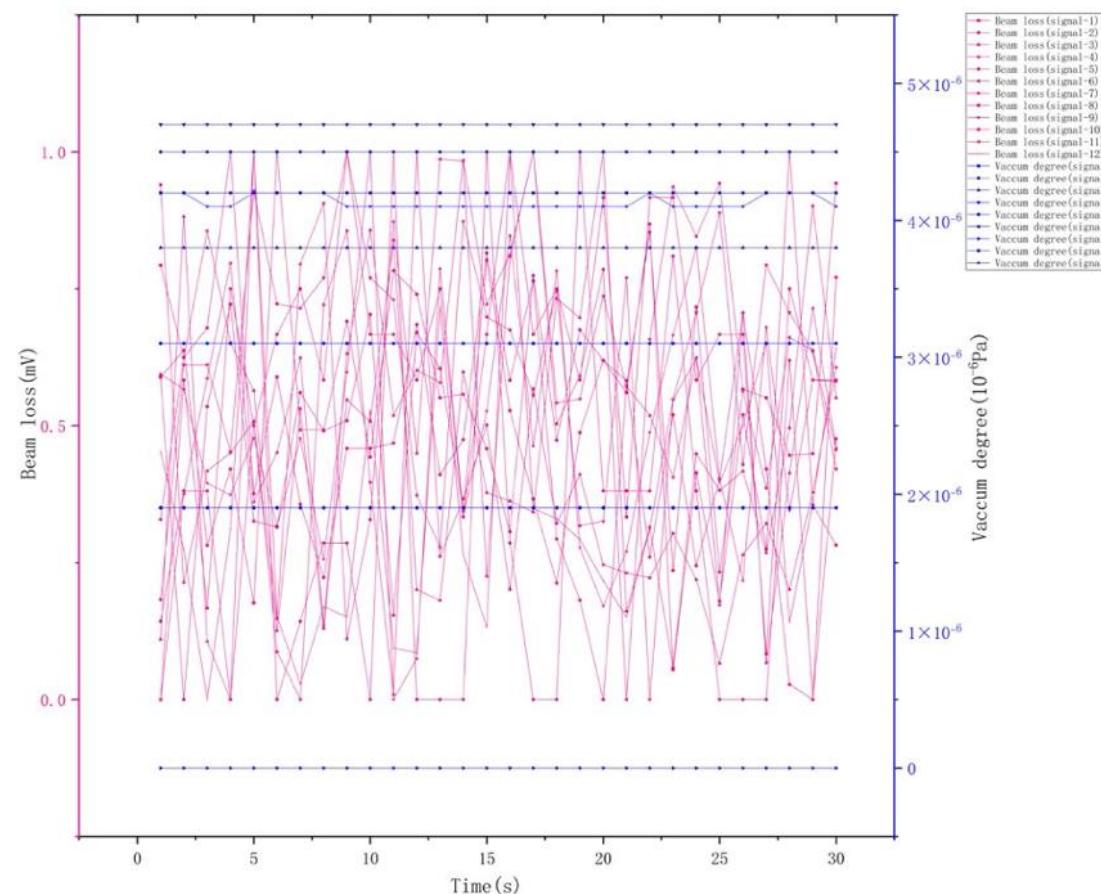
- 数据来源：CSNS DTL 2021年实际运行数据
- 数据规模：21个传感器（12个束流损失+9个真空传感器），采样频率1Hz
- 数据集划分：1月前7天正常数据为训练集，3、4、5、7、11、12月数据为测试集（异常率1.36%-8.87%）

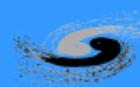
Month	Data Volume	Number of Signals	Anomaly Rate
January	2678,400	21	1.78 %
March	2678,400	21	7.13 %
April	2592,000	21	7.42 %
May	2678,400	21	8.87 %
July	1339,200	21	3.93 %
November	2592,000	21	5.47 %
December	2678,400	21	1.36 %



实验数据处理

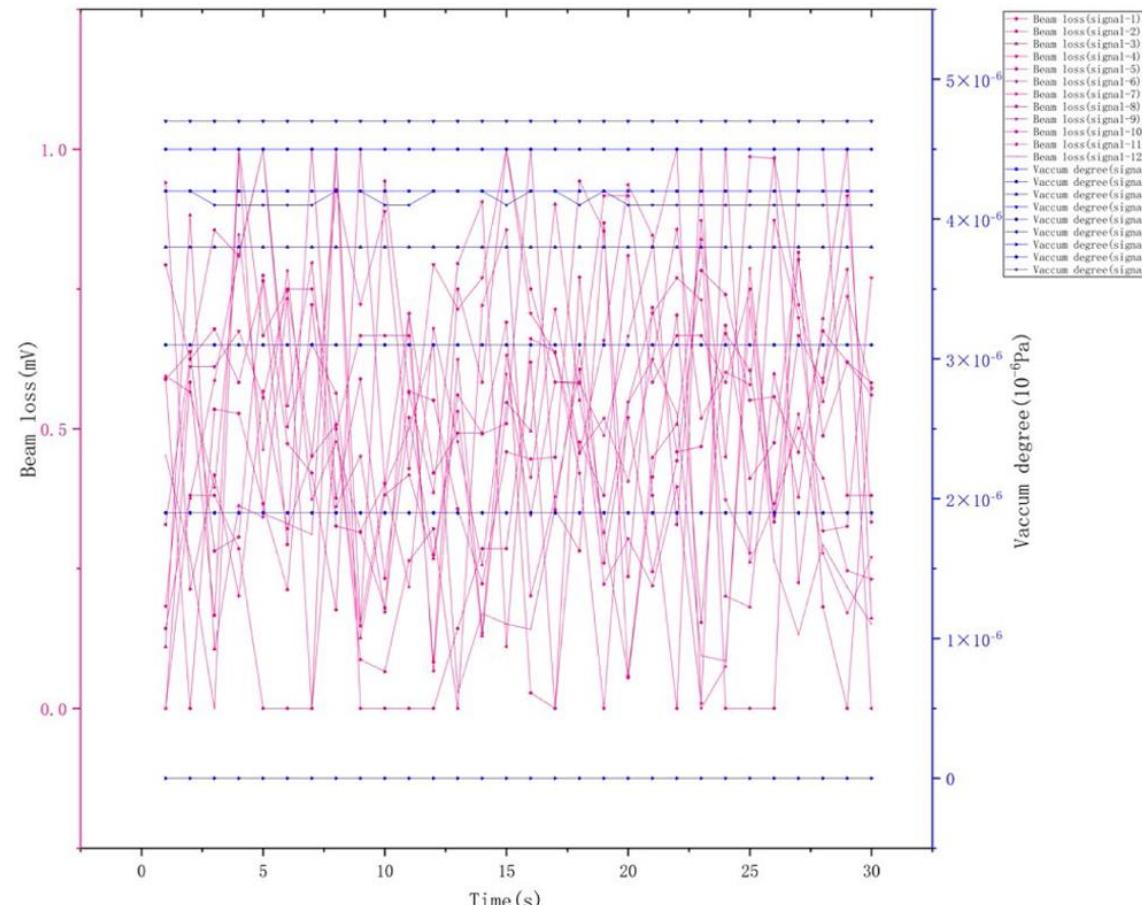
➤ 传感器时序数据被用长度为30秒的滑动窗口进行切片，滑动步长为3秒，得到切片的序列

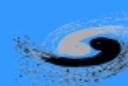




实验数据处理

- 切片的序列被存储并10等分后随机打乱顺序，以生成人工异常序列，对于每个切片序列，会生成5个乱序的后续序列





实验模型参数

➤ 实验使用的时空对比融合 (STCF) 网络结构

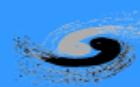
Block	Layer	Output shape
Data preprocessing	Input	(32, 5, 30, 21)
	Reshape	(32, 21, 150)
Residual block 1	Dilated causal conv1 + ReLU	(32, 256, 152)
	Dilated causal conv2 + ReLU	(32, 256, 154)
	Channel attention mechanism	(32, 256, 154)
Residual block 2	Dilated causal conv1 + ReLU	(32, 256, 154)
	Dilated causal conv2 + ReLU	(32, 256, 158)
	Channel attention mechanism	(32, 256, 158)
Residual block 3	Dilated causal conv1 + ReLU	(32, 256, 158)
	Dilated causal conv2 + ReLU	(32, 256, 166)
	Channel attention mechanism	(32, 256, 166)
Residual block 4	Dilated causal conv1 + ReLU	(32, 256, 166)
	Dilated causal conv2 + ReLU	(32, 256, 182)
	Channel attention mechanism	(32, 256, 182)
Residual block 5	Dilated causal conv1 + ReLU	(32, 256, 182)
	Dilated causal conv2 + ReLU	(32, 256, 214)
	Channel attention mechanism	(32, 256, 214)
Residual block 6	Dilated causal conv1 + ReLU	(32, 256, 214)
	Dilated causal conv2 + ReLU	(32, 256, 278)
	Channel attention mechanism	(32, 256, 278)
Pooling	Global Avg Pool	(32, 256)
FC Layer	Fully Connected	(32, 5)

➤ 学习率=0.001, 批量大小=32, 训练迭代次数=50

核心结果

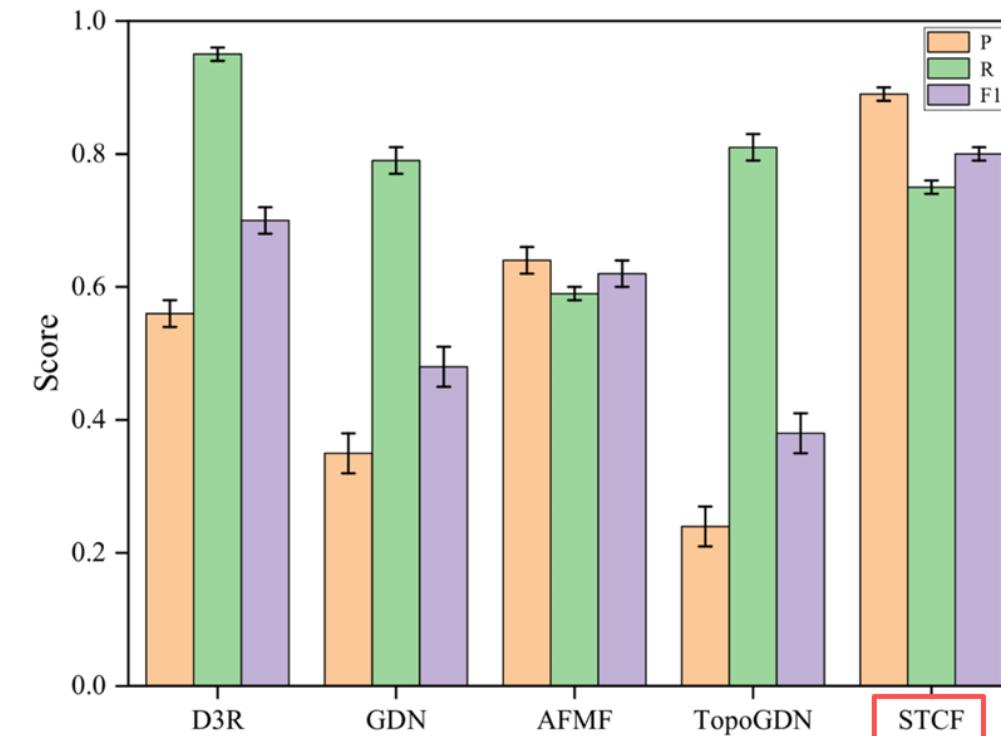
- 整体性能：平均精确率0.89、召回率0.75、F1分数0.80
- 月度表现：5月性能最优（P=0.97、R=0.89、F1=0.92），7月性能略低（异常模式过于复杂而难以被识别）

Month	March	April	May	July	November	December	Mean
P	0.93	0.79	0.97	0.86	0.93	0.86	0.89
R	0.85	0.66	0.89	0.49	0.89	0.70	0.75
F1	0.89	0.72	0.92	0.62	0.91	0.77	0.80



不同方法对比分析

- 对比方法：D³R、GDN、AFMF、TopoGDN等主流异常检测模型
- STCF优势：F1分数优于其他对比方法，时空融合效果显著
- STCF不足：计算时间比其它方法更长



Model	Average test time for data of 1 s
D3R	0.0008864s
GDN	0.0005668s
AFMF	0.0005111s
TopoGDN	0.001090s
STCF	0.001175s



消融实验分析

- 实验设计：验证时序卷积、通道注意力的作用（基于2021年3月数据）
- 消融实验1：时序卷积替换为Transformer，F1分数降至0.87
- 消融实验2：移除通道注意力，F1分数降至0.86
- 消融实验3：通道注意力替换为多头注意力，F1分数降至0.87
- 结论：各组件协同作用，时序卷积与通道注意力是保障性能的关键

Method	STCF	Ablation-1	Ablation-2	Ablation-3
P	0.93	0.87	0.81	0.91
R	0.85	0.88	0.91	0.85
F1	0.89	0.87	0.86	0.87

报告内容

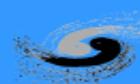
一. 研究背景

二. 相关研究现状

三. 时空对比融合 (STCF) 框架设计

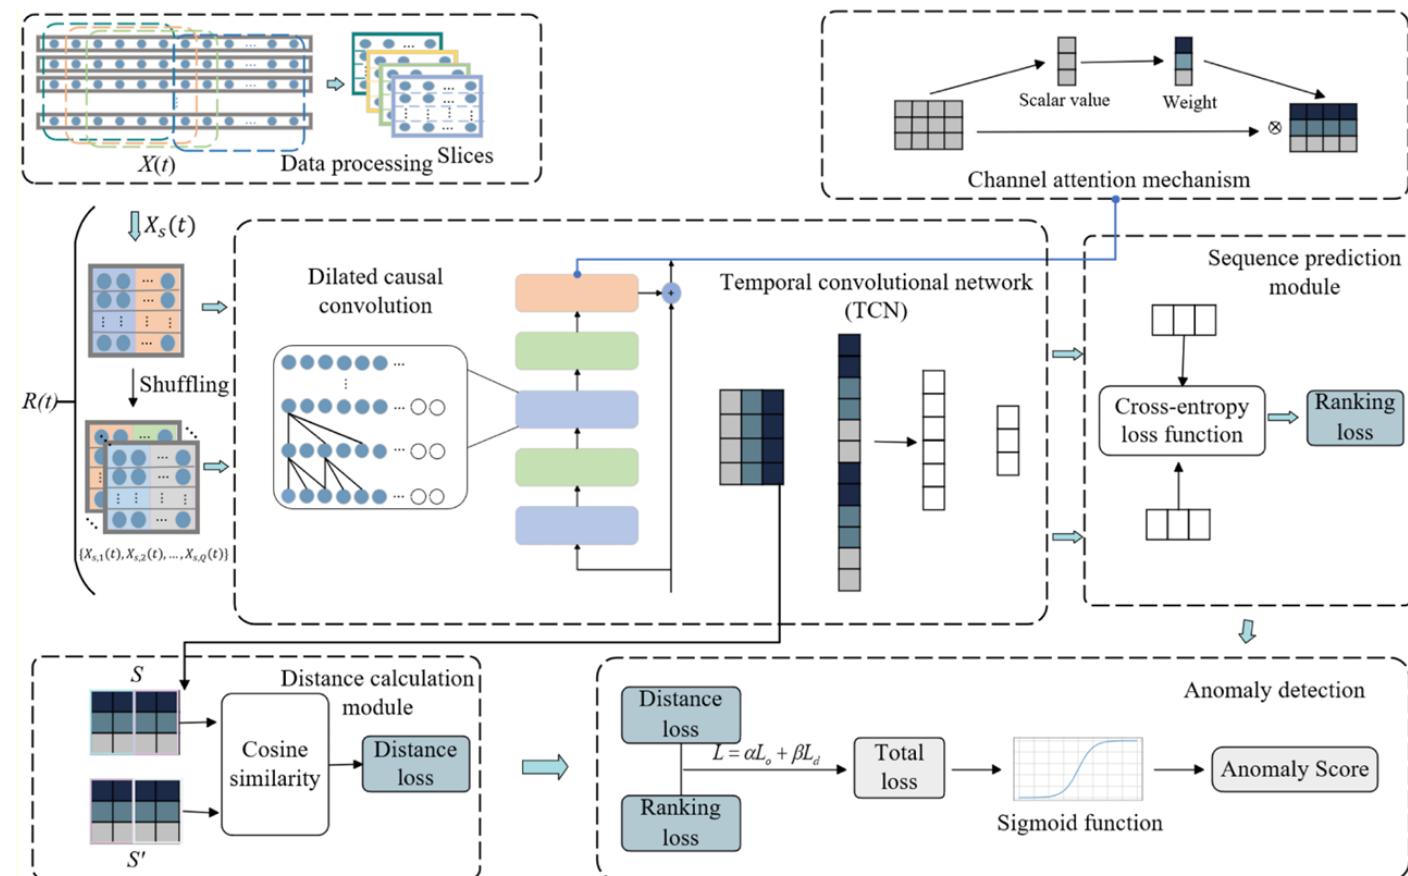
四. 实验验证

五. 结论与展望



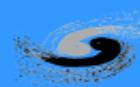
研究结论

- 提出时空对比融合 (STCF) 框架，有效融合时空信息，解决传统方法融合不足的问题
- 仅需正常数据训练，突破异常标注稀缺的瓶颈
- 基于CSNS实际数据验证，平均F1分数达0.80，性能优于主流方法



未来展望

- 通过分析不同故障源对信号的影响，进一步探究时空对比融合（STCF）框架的扩展应用
- 优化模型结构，降低计算复杂度，适配更长时序数据
- 进一步探索将声音、红外、视觉等多模态数据，与现有束流损失、真空度等数据深度融合，构建设备全面感知网络，提升对复杂异常的检测精度



谢谢！