



山东大学
SHANDONG UNIVERSITY

2026年超级陶浆装置研讨会

基于Transformer的STCF DTOF PID算法

李邦辉, 李腾, 黄性涛

山东大学

2026. 07. 02 西安

I. 研究背景

II. 基于CNN的鉴别算法

III. 基于Transformer的鉴别算法

IV. Pion/Kaon表现性能


V. 总结

超级陶粲装置 (STCF) 是中国新一代的正负电子对撞机。

- 质心能量 $2-7 \text{ GeV}$
- 峰值亮度 $0.5 \times 10^{35} \text{ cm}^{-2}\text{s}^{-1}$
- 具备未来进一步提升峰值亮度和实现束流极化的空间

物理目标

- c 夸克和 τ 轻子的物理研究
- 非微扰强相互作用和强子结构
- 新物理寻找



从相互作用点向外, STCF包括
径迹系统 (ITK 和 MDC), 粒子鉴别系统
(PID), 电磁量能器 (EMC), 超导线圈
(SCS), 缪子探测器 (MUD)

ITk	Cylindrical μ RWELL CMOS MAPS
• $< 0.25\% X_0 / \text{layer}$	
• $\sigma_{xy} < 100 \mu\text{m}$	
MDC	Cylindrical Drift chamber
• $\sigma_{xy} < 130 \mu\text{m}$	
• $\sigma_{p/p} \sim 0.5\% @ 1 \text{ GeV}$	
• $dE/dx \sim 6\%$	
PID	RICH with MPGD DIRC-like TOF
• π/K (and K/p) 3-4 σ separation up to 2 GeV/c	
EMC	pCsl + APD
E range: 0.025-3.5 GeV	
$\sigma_E (\%) @ 1 \text{ GeV}$	
Barrel: 2.5	
Endcap: 4	
Pos. Res.: 5 mm	
MUD	RPC + scintillator
• 0.4 - 2 GeV	
• π suppression > 30	



粒子鉴别(PID)是对撞机实验中进行物理研究的重要工具,为了更好的满足物理需求,STCF对PID的性能提出了更高的要求。

- $p < 2 \text{ GeV}/c$ 时, π/k 误判率 < 2%时, 相应鉴别效率 > 97%
- $p > 0.7 \text{ GeV}/c$ 时, μ 子鉴别效率 > 95% ; $0.5 < p < 0.7$ 时, 其 > 70%
- 良好的中性粒子鉴别能力

为了进一步提高PID的效率, STCF设计了一个PID系统, 使用两种切伦科夫探测技术:

- 环形成像的切伦科夫探测器(RICH), 位于桶部
- 基于探测内部全反射切伦科夫光的飞行时间探测器(DTOF), 位于端盖

主要针对 π/K 的鉴别, 也能为分辨 μ/π 提供鉴别的能力





基于机器学习的粒子鉴别技术

仅依赖单个探测器的信息很难准确地分辨粒子, 传统方法对于高PID性能的要求面临巨大的挑战。


机器学习技术凭借在高维数据空间中提取有用特征的能力, 在PID领域表现出优异的性能。

- 联立多个探测器的信息进行粒子鉴别
- 能够充分利用探测器的原始响应
- 决策树, 神经网络和支持向量机等技术逐渐成为PID的主流方法





目前已基于机器学习算法开发了多种粒子鉴别技术, 以适应不同类型的探测器。后续可基于ONNX移植到OSCAR框架。



本报告针对DToF π/K 鉴别问题, 利用探测器的原始响应和重建特征来开发CNN/Transformer架构的算法, 以满足STCF对其高PID能力的要求。



DTOF作为STCF的端盖PID探测器, 是基于探测内部全反射切伦科夫光的技术。

- 由两个相同的圆盘组成, 含多个相同的扇区
- 探测器覆盖的极角约为 23° - 36°
- 熔融二氧化硅作为切伦科夫辐射体产生光子
- 外侧耦合多阳极微通道光电倍增管探测切伦科夫光子






利用DTOF探测器原始响应, 构建二维pixel map:

- X-label: PMT所接收的切伦科夫光子的读出通道 (空间坐标 X 和 Y 合并为 768 个一维通道)
 - Y-label: PMT所接收的切伦科夫光子的到达时间
 - Value: bin内的光子数目
-
- $0 \leq 4 * \text{Channel_x} + \text{Channel_y} \leq 768$ ($191 * 4 + 4$)
 - $5 \leq \text{Time} \leq 20 \text{ ns}$ (Time resolution : 50 ps)
 - Bin number: $\text{Channel_bin} * \text{Time_bin} = 192 * 300$

数据样本

使用OSCAR(2.7.0)离线软件模拟单粒子 π/K 的MC样本



- 动量0.3-3.5GeV/c
- 极角 20° - 39°
- 每类粒子事例数400W
- 选择击中单扇区的单个粒子数据
- 输入：2D图像 + 3D 击中位置 & 动量（可由径迹探测器外推得到）




EfficientNet

V2: 更轻量化的网络, 相较于V1, 减少了参数量, 加快了计算速度

V1准确率




V2改进



- 使用 EfficientNetV2-S 作为基准模型并进行调整优化
- 依赖光子击中通道和到达时间构建二维图像作为模型输入
- 全连接层额外添加外推得到的粒子击中DTOF时的动量和位置

Transformer 架构: 基于自注意力的全局特征提取



Transformer 架构

- 输入特征表示为 token 序列
- Self-Attention 建模全局关联
- 多层 Encoder 提取高层特征

相比 CNN 的优势

- CNN 偏重局部模式, Transformer 更关注全局依赖
- 对稀疏、非规则点云输入更加灵活
- 适合捕捉 DTOF photon hits 的整体时空结构

方法	输入形式	特征提取方式	主要特点
CNN	2D pixel map	局部卷积核	擅长提取局部空间纹理
Transformer	token 序列 / 点云特征	Self-Attention	擅长建模全局依赖关系

利用DTOF探测器原始响应, 构建三维点云特征:

- X-label: PMT所接收的切伦科夫光子的读出通道 (Channel_x)
- Y-label: PMT所接收的切伦科夫光子的读出通道 (Channel_y)
- Z-label: PMT所接收的切伦科夫光子的到达时间


进行点云特征归一化, 将数值映射到0到1之间, 以便神经网络更好地提取局部空间模式


- X 通道: 探测器在 X 轴向有 192 个通道,

$$X_{norm} = \frac{X}{191}$$

- Y 通道: 探测器在 Y 轴有 4 个通道, $Y_{norm} = \frac{Y}{3}$

- 时间窗口: $Time_{norm} = \frac{Time-5.0}{15.0}$








$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$

- 使用 **Transformer** 作为基础架构并进行调整优化
- 依赖**点云特征**和**运动学特征**作为模型输入
- 通过**注意力权重**衡量不同 photon hits 之间的相关性
- 采用**早期融合**和**晚期融合**，加强模型对物理规律的学习

Pion和Kaon在不同动量和极角范围下的信号效率和本底误判率, 每类粒子事例数400W(π/K)




将Kaon作为本底控制其误判率 $<2\%$, Pion的信号效率分布如下:



- 图像特征+运动学特征
- 高动量、大角度区域效率有所衰减

Pion和Kaon在不同动量和极角范围下的信号效率和本底误判率, 每类粒子事例数400W(π/K)


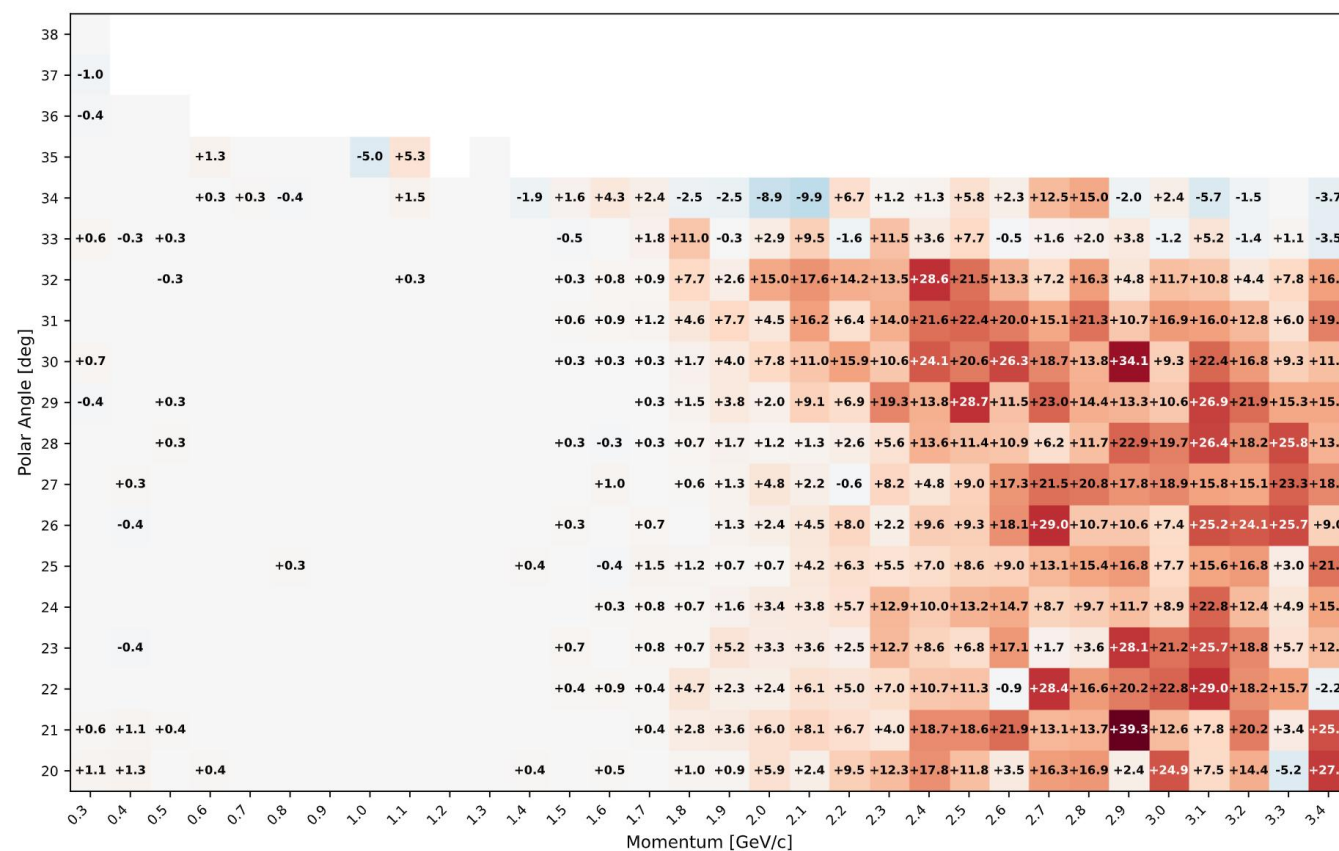

将Kaon作为本底控制其误判率 $<2\%$, Pion的信号效率分布如下:



- 点云特征+运动学特征
- 高动量、大角度区域效率有所衰减

比较 Transformer 与 CNN 在不同动量和极角区域下的 Pion 鉴别效率差异

Efficiency Difference (Transformer - CNN) @ 2% FPR



- $\Delta \text{Eff} = \text{Eff}(\text{Transformer}) - \text{Eff}(\text{CNN})$

- 红色：Transformer 更优
- 蓝色：CNN 更优

- 低动量区：两种模型性能接近
- 高动量区：Transformer 整体优势更明显

- 高动量下 π/K 差异减小，鉴别更依赖全局 photon hit 分布

- 针对STCF DTOF的 π/K 鉴别需求，成功开发了基于 CNN（2D图像特征） 和 Transformer（3D点云特征） 的两种深度学习鉴别算法。
- 当前研究主要针对单个粒子进入 DTOF 扇区的情况，使用单粒子样本完成训练与性能评估。
- 在 Kaon 误判率 $< 2\%$ 条件下，两种算法在低动量区均具有较高鉴别效率。
- 在高动量区域，Transformer 对 photon hits 全局时空关联的建模能力更强，整体性能优于 CNN。
- 后续将研究多个粒子同时进入同一 DTOF 扇区的情况，例如两个或三个粒子产生的 hit pattern 发生重叠时的 π/K 鉴别问题。进一步发展多粒子 hit pattern 分离、特征关联和多粒子 PID 方法。

2026年超级陶浆装置研讨会

Thanks