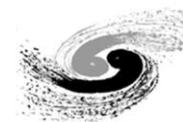




武汉大学
WUHAN UNIVERSITY



中国科学院高能物理研究所
Institute of High Energy Physics
Chinese Academy of Sciences

基于深度学习的漂移室电离计数重建算法的研究

田喆飞 (tianzhefei@whu.edu.cn)¹, 赵光², 董明义²,
刘帅毅², 孙胜森², 伍灵慧², 辛水艇², 张振宇¹, 周详¹

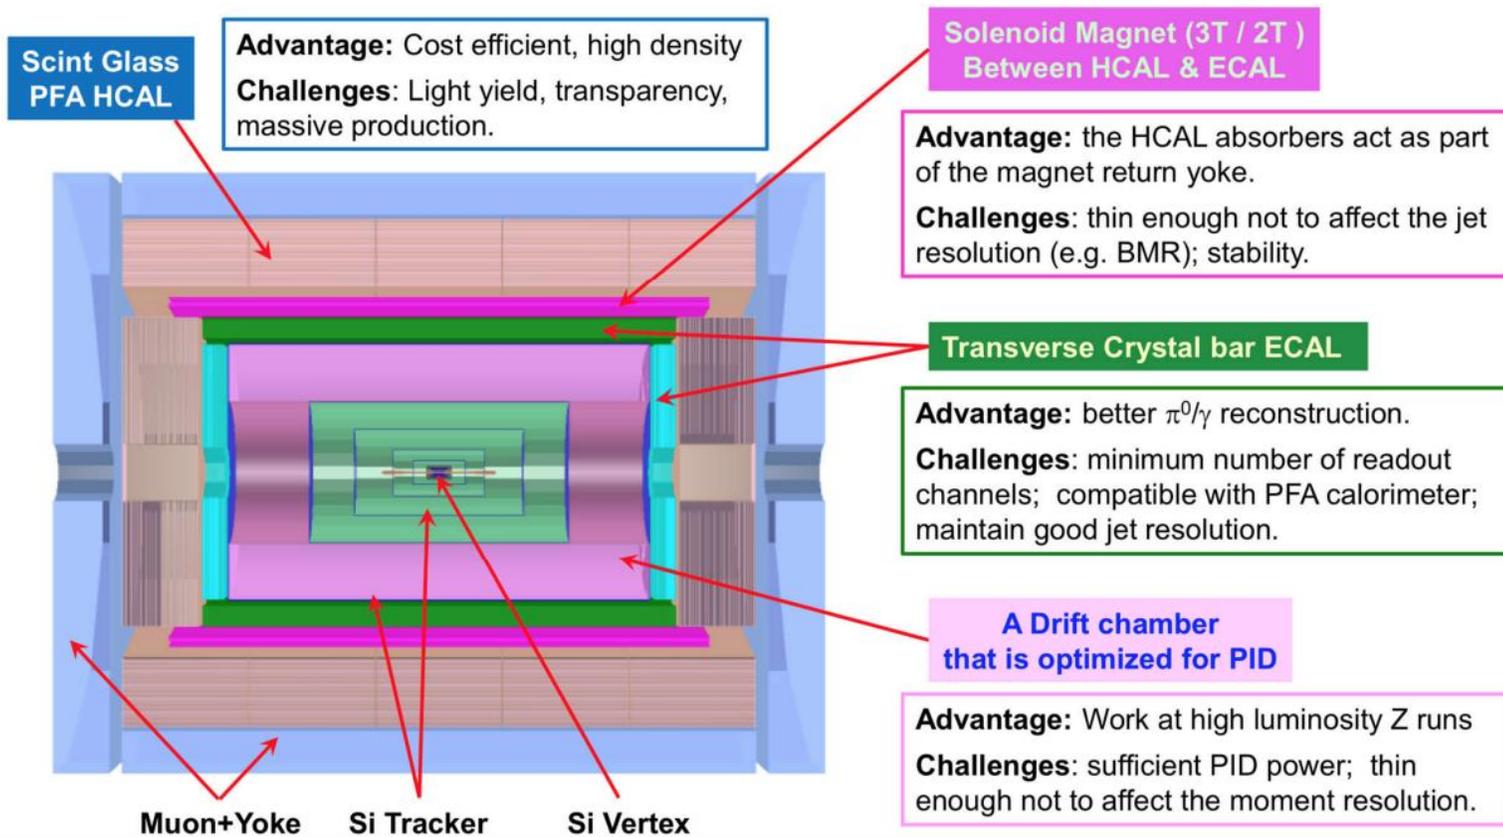
1. 武汉大学

2. 中国科学院高能物理研究所

第二十届全国科学计算与信息化会议

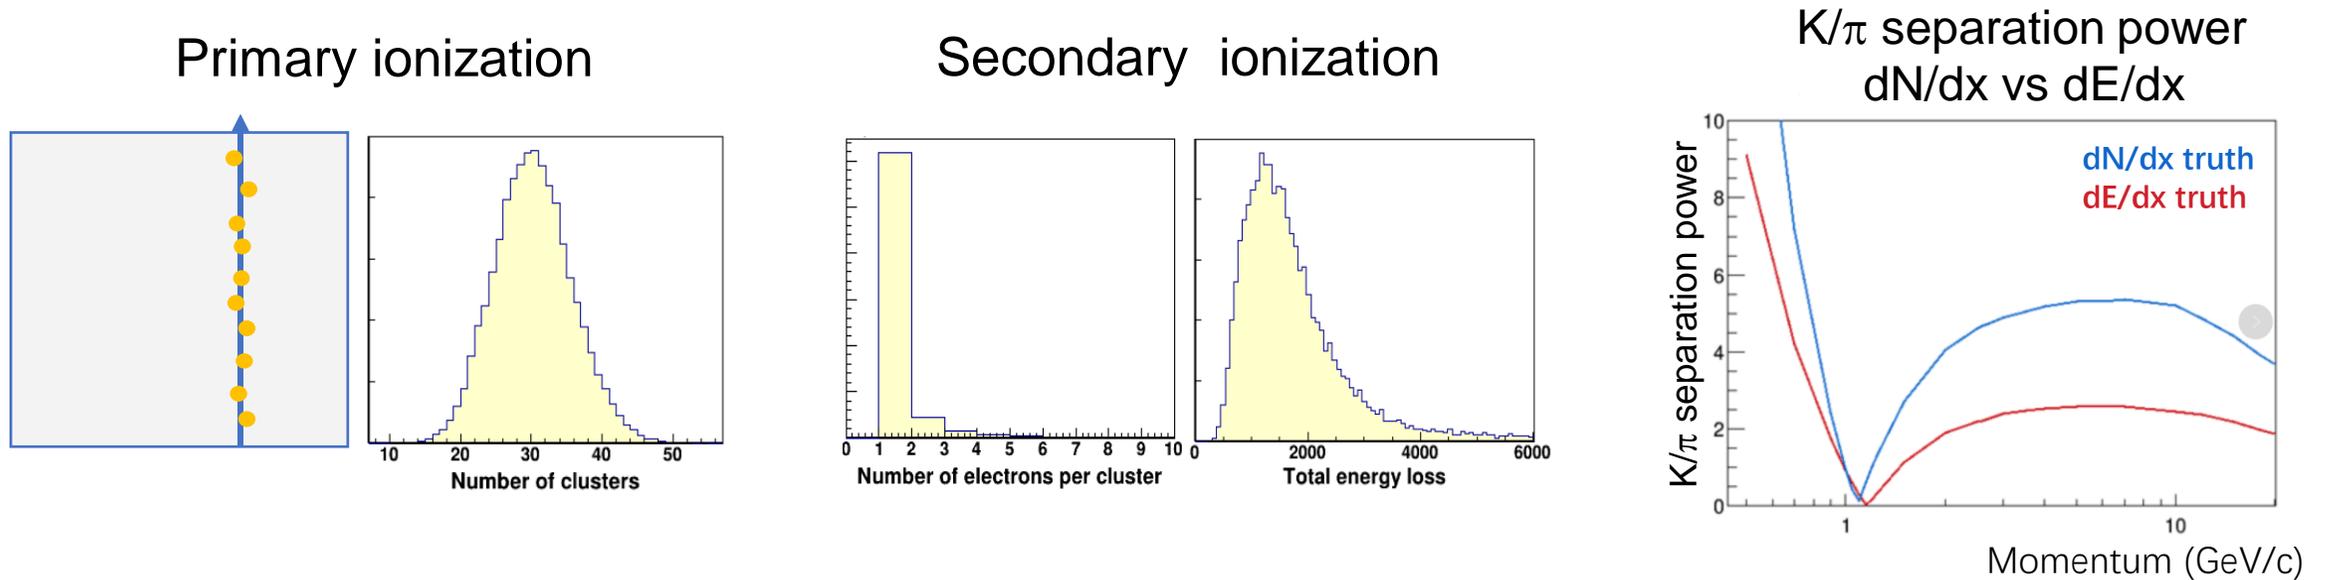
2023年7月11日

CEPC第四个探测器概念



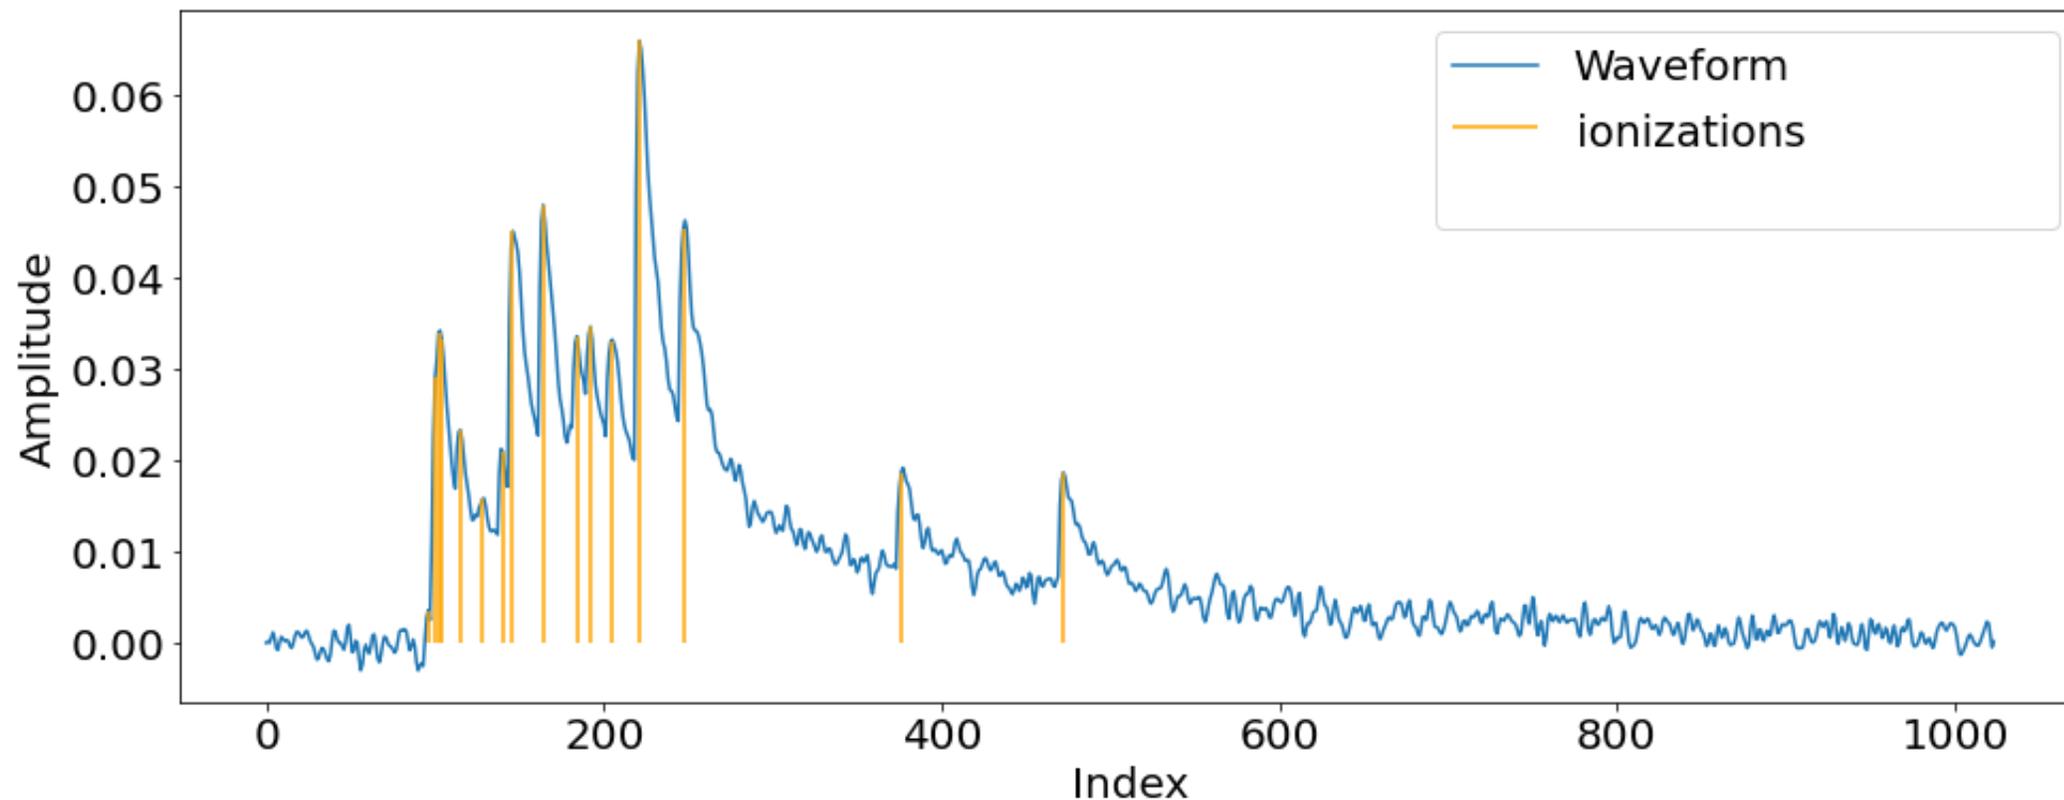
- 硅探测器和漂移室相结合的径迹探测器设计。
- 探测器应用电离簇团计数 (cluster counting) 进行粒子鉴别 (PID)。
- CEPC实验的物理目标要求在20 GeV/c处 K/π 鉴别能力达到 2σ 。

dE/dx vs dN/dx



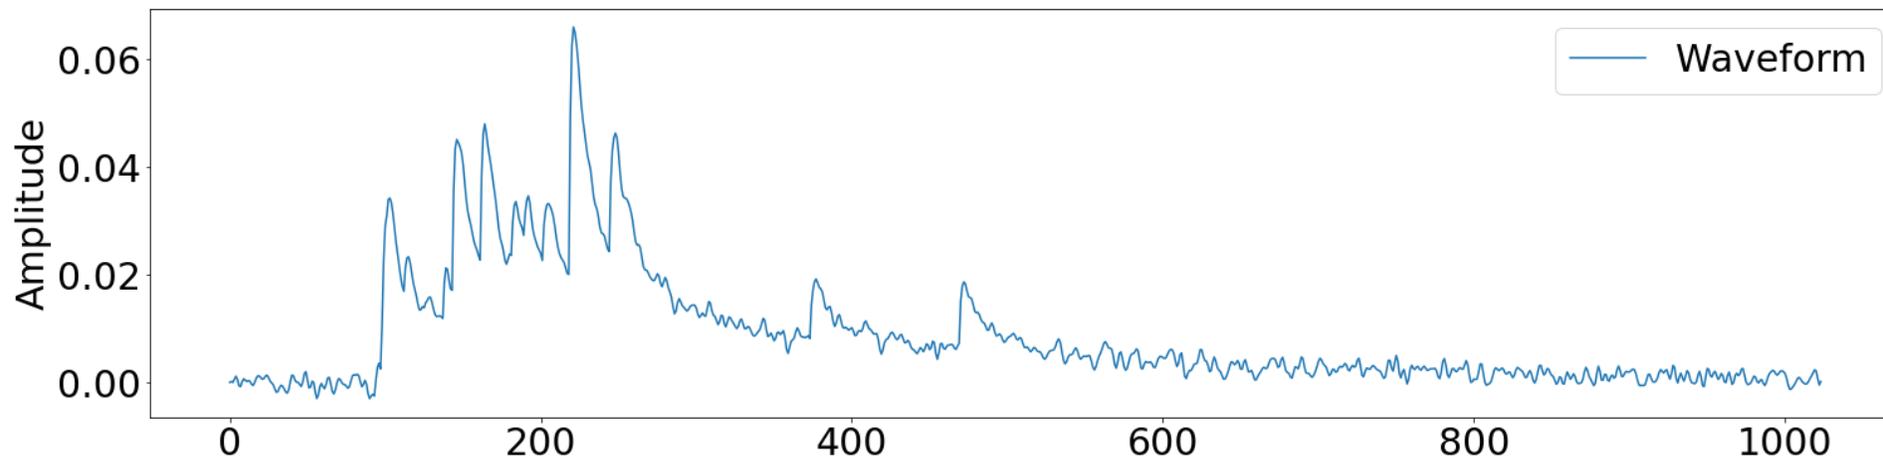
- 带电粒子穿过漂移室，电离工作气体产生原初电离电子，电子在电场作用下向信号丝漂移，并在漂移过程中继续电离产生次级电离电子。两种电子均漂移至信号丝产生信号。
- **传统PID方法**：测量单位距离能损 dE/dx 。
- 与 dE/dx 相比， dN/dx 拥有更好的PID性能
 - dE/dx : 单位距离能损，朗道分布，涨落大
 - dN/dx : 单位距离原初电离数，泊松分布，涨落小
- **电离簇团 (cluster)**: 由原初电离 (**primary ionization**) 和相应的次级电离(**second ionization**) 组成。
- 测量原初电离数=测量电离簇团数(N_{cls}) \Rightarrow **电离计数算法 (Cluster Counting)**

电离计数算法

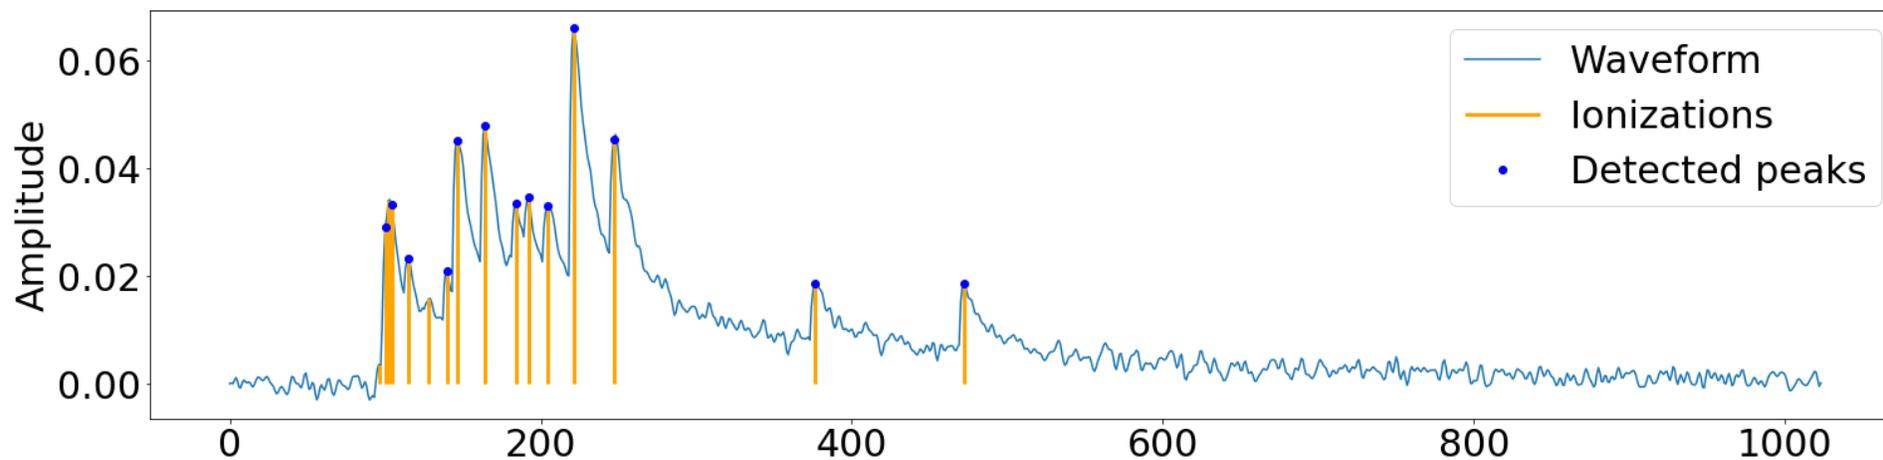


- **电离计数算法**: 从漂移室单元信号丝上产生的感应电流波形中获得电离簇团数 N_{cls}
- 原初电离和次级电离均对波形有贡献，目标是得到原初电离对应的 N_{cls}
- 两步走: **寻峰 (Peak finding) & 合并 (clusterization)**
- 可以使用成熟的机器学习工具: TensorFlow, Keras, PyTorch, ...

Workflow



↓ 寻峰: 从波形中找出电离信号峰



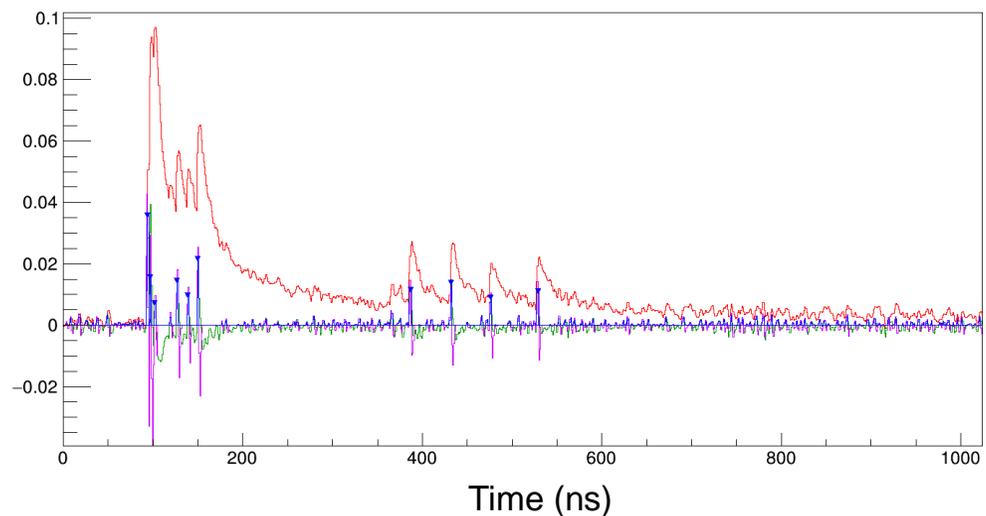
↓ 合并: 获得电离簇团数 N_{cls}

N_{cls} : 电离簇团数/原初电离数

传统方法：导数寻峰+时间差合并

寻峰 (Peak finding)

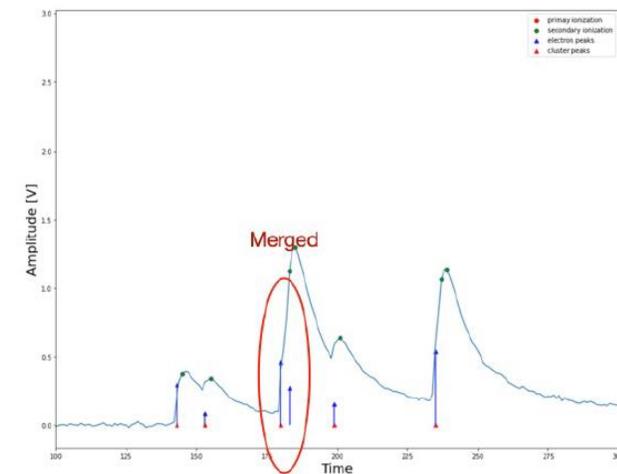
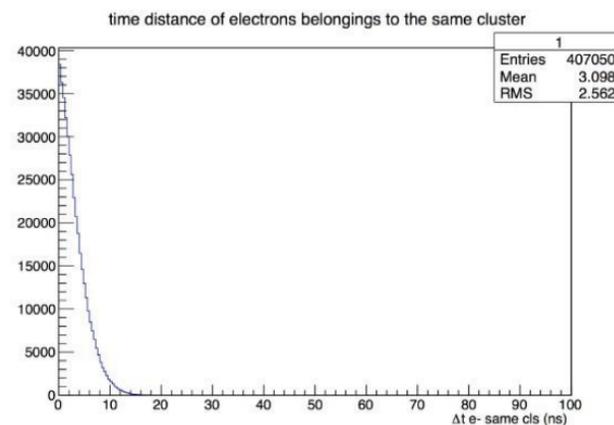
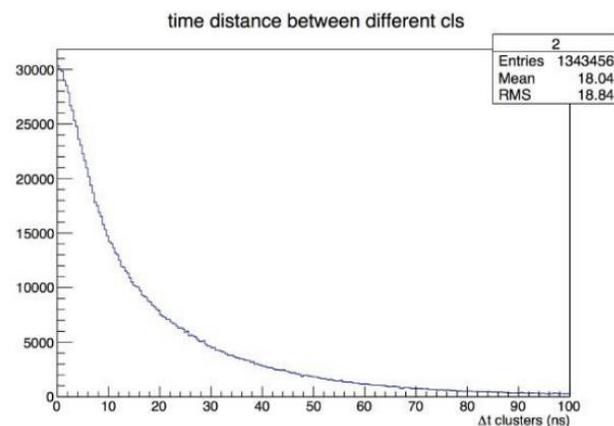
- 利用一阶导数和二阶导数
- 通过上升沿的斜率变化来寻峰



- **优点:** 快速、高效
- **缺点:** 难以应对噪声和重叠的信号峰

合并 (Clusterization)

- 通过 Δt 合并电离峰
- 通过MC样本估计合并的cut条件



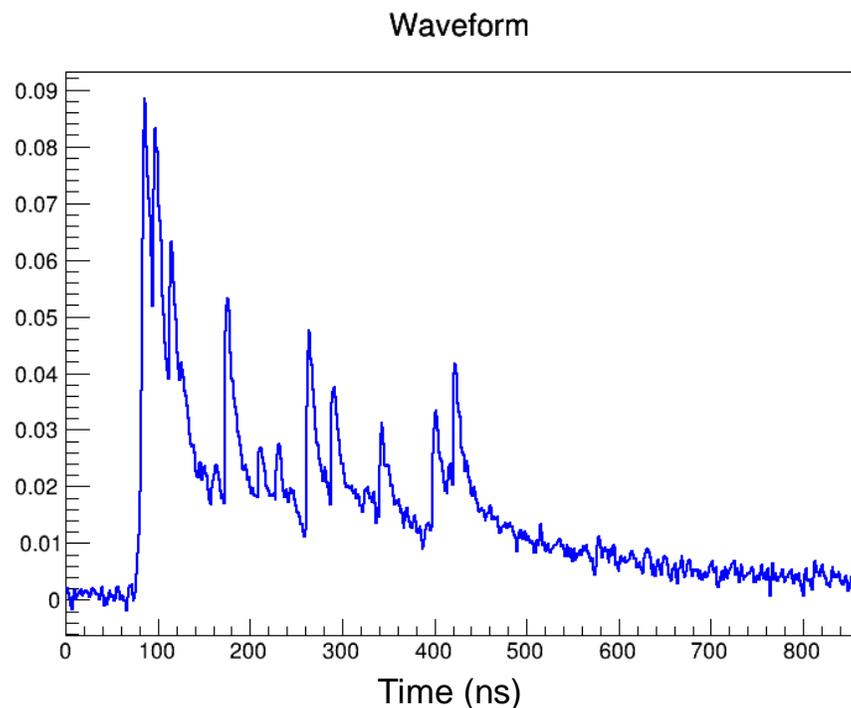
使用机器学习的理由

- **传统算法:** 人类给出规则, 让机器根据规则来达成目的
- **机器学习:** 机器从大量数据中学习规则
- 对于电离计数:
 - 机器学习可以使用波形的全信息, 而非像导数算法那样只使用导数的上升沿。
 - 机器学习或许可以学习得到波形、信号峰、时间分布和 N_{cls} 之间的隐藏关系
 - 问题可以被建模为分类或回归问题 \Rightarrow 适用于成熟的机器学习工具, 如 TensorFlow、Keras、PyTorch

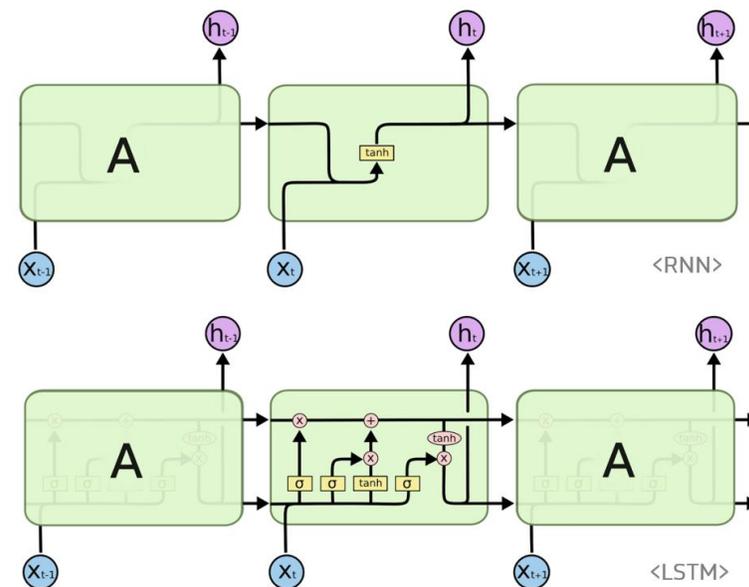


第一步：寻峰

- **寻峰 (Peak finding):** 从波形中提取电离信号峰



- **分类问题:** 分类信号峰和噪声
- 波形数据是时序数据, 适用于循环神经网络 (RNN), 尤其是长短期记忆网络 (LSTM)。

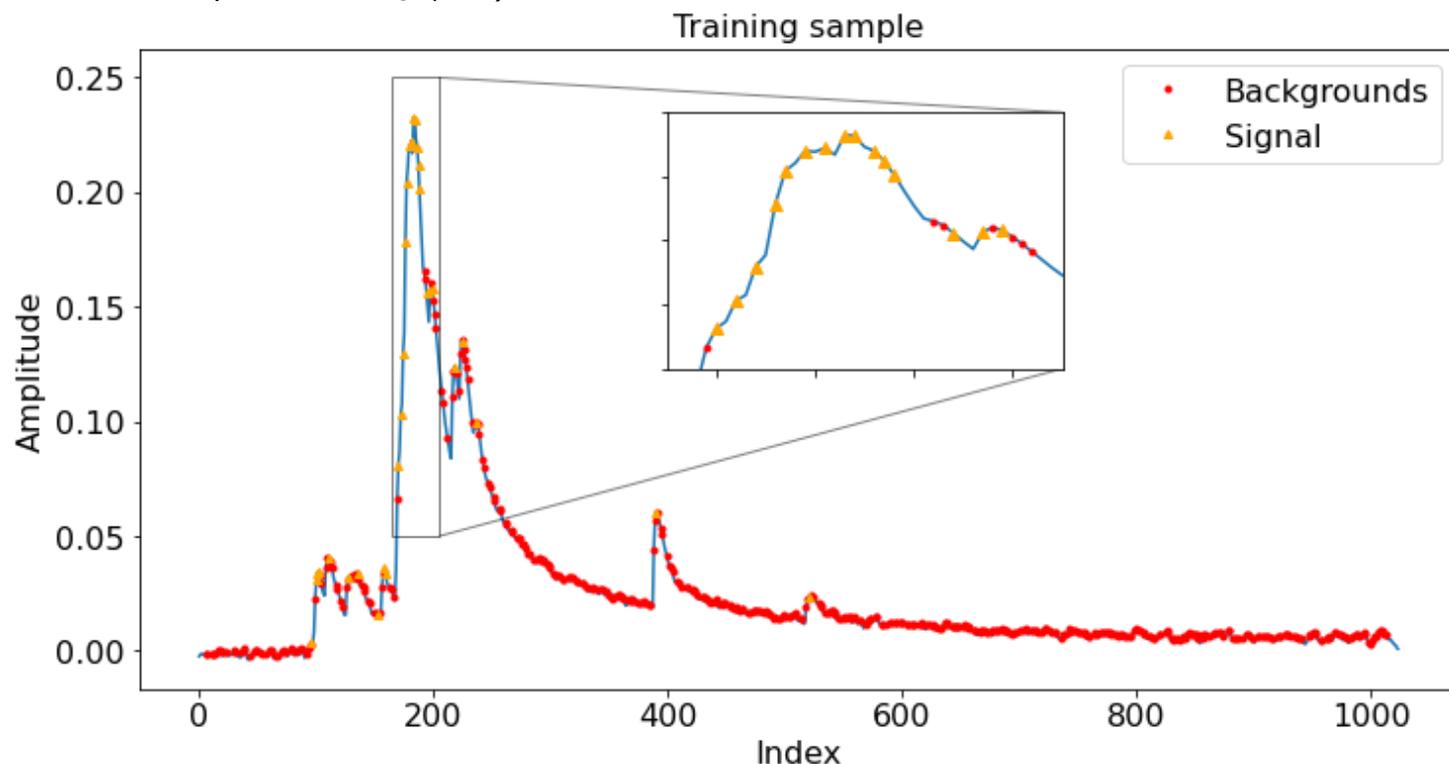


循环神经网络 (Recurrent Neural Network)

- 拥有反馈循环, 有“记忆”功能。
- 最常用的一类RNN为拥有长期记忆功能的LSTM。

训练样本

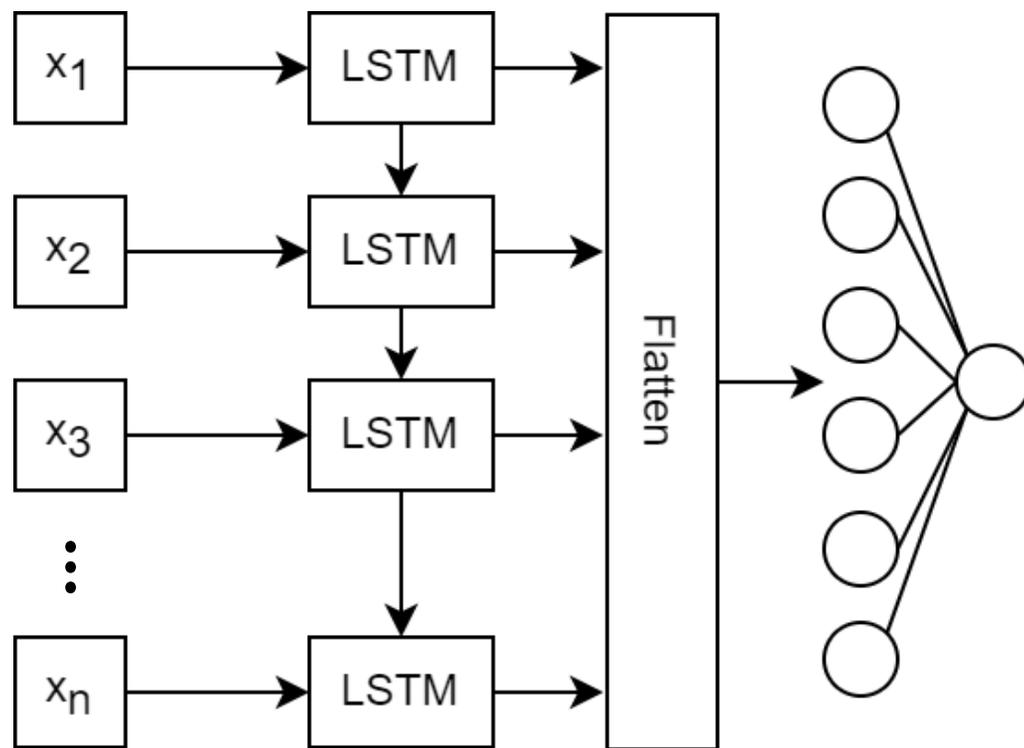
- 训练集：Monte Carlo模拟产生的漂移室单元信号波形样本 (π 粒子, 动量范围为0.2GeV~20GeV, 5%噪声)



- 从波形中提取可能为信号峰的小波段作为输入样本
 - 小波段：全部斜率下降点附近的(-5, +9)小波段
 - 根据MC Truth对小波段打信号/噪声的标签
 - 数据集中噪声远多于信号, 通过欠采样进行平衡

网络结构

- 网络结构: 长短期记忆 (LSTM) 模型

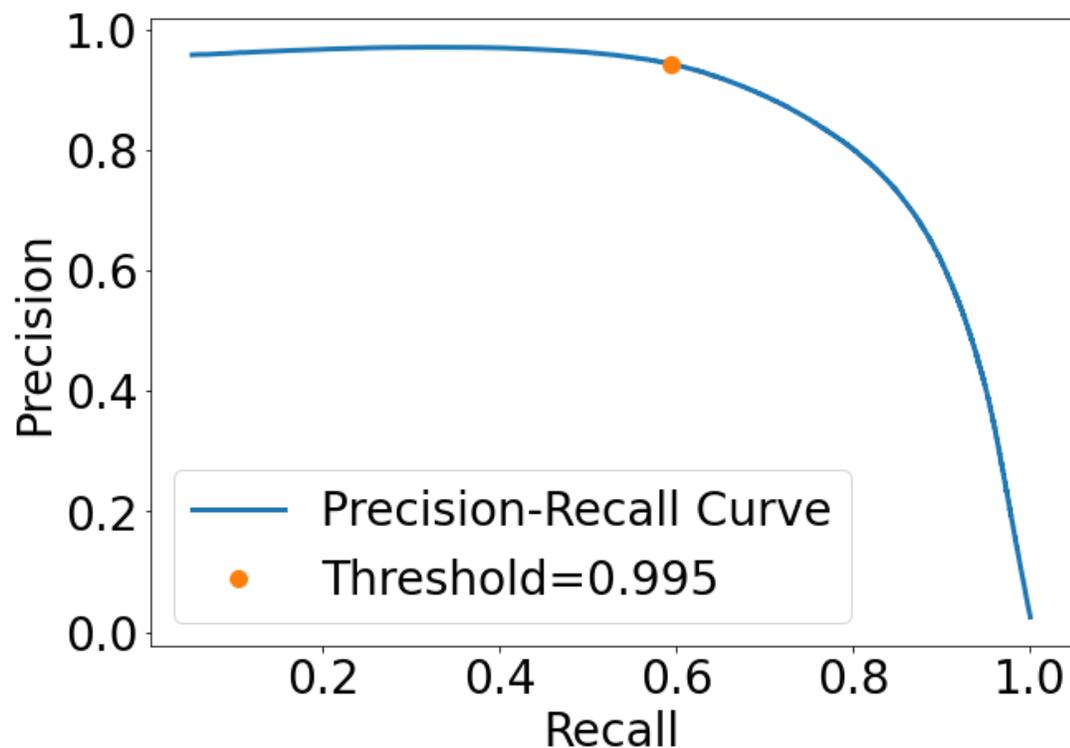


- 数据集: 波形中的候选信号峰 (斜率降低点)
- 标签: 信号 / 本底
- 特征: 信号峰候选附近的15个点组成的小波段的时间 (x) 和振幅 (y)
- 损失函数: BCE loss

⇒ 二元分类问题

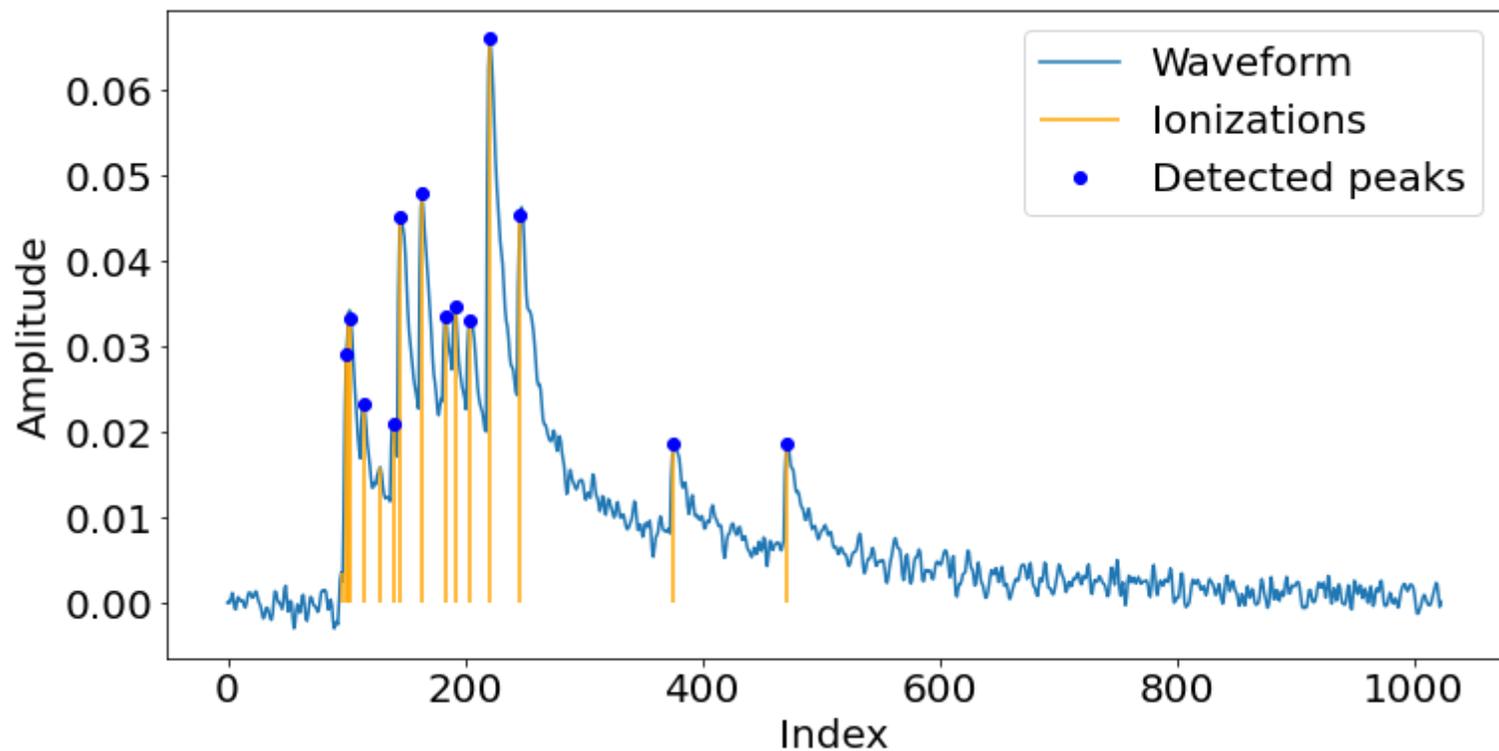
算法评估

- 测试样本：信号波形样本 (π 粒子, 动量范围为0.2GeV~20GeV, 5%噪声)
- 效率 (Recall) = $TP/(TP+FN) = 59.5\%$
- 纯度 (Precision) = $TP/(TP+FP) = 94.3\%$
- 目标是得到信号峰, 要求纯度尽量高 \Rightarrow 提高分类器的概率阈值以确保纯度。

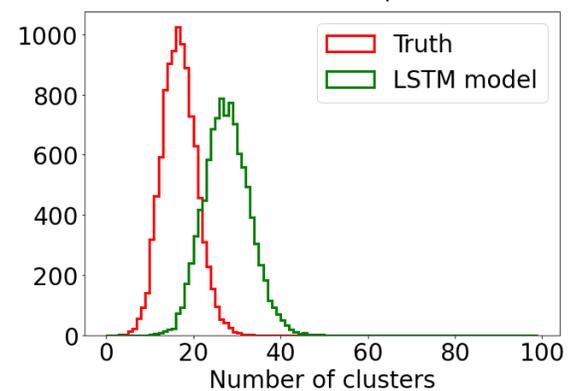
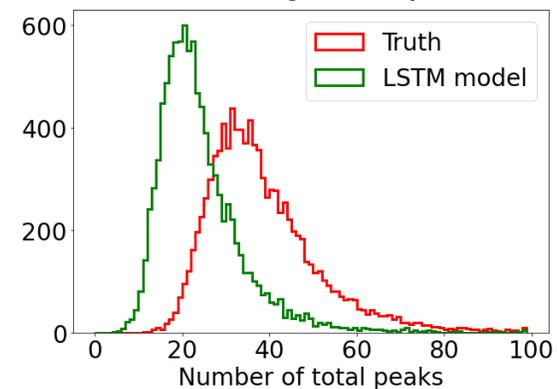
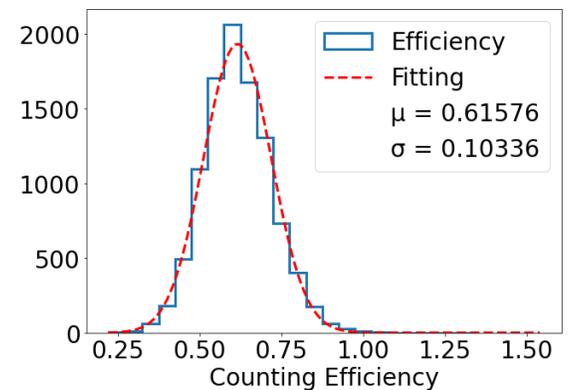


		真实	
		信号	噪声
预测	信号	TP	FP
	噪声	FN	TN

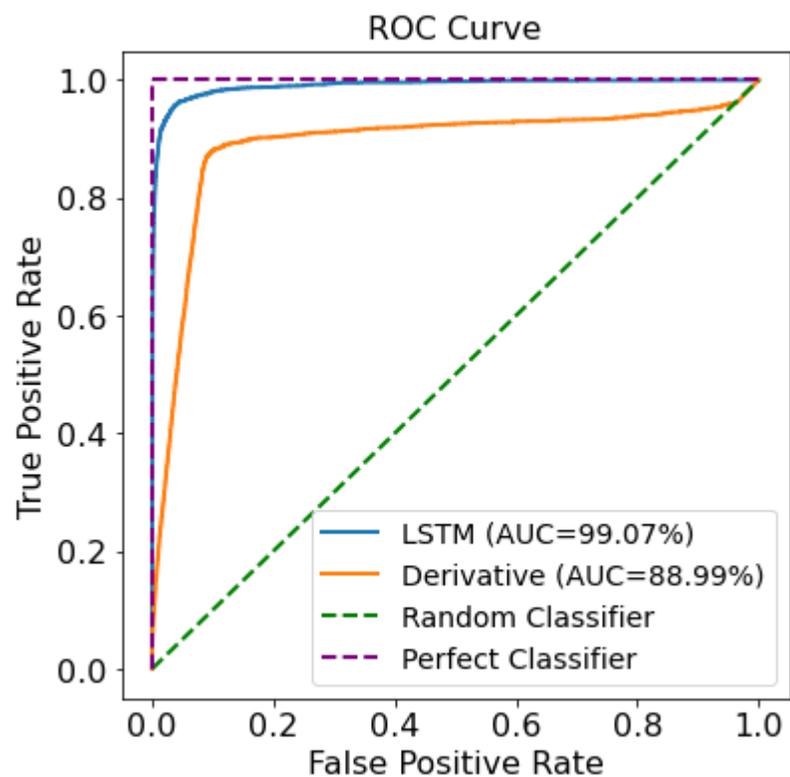
寻峰结果



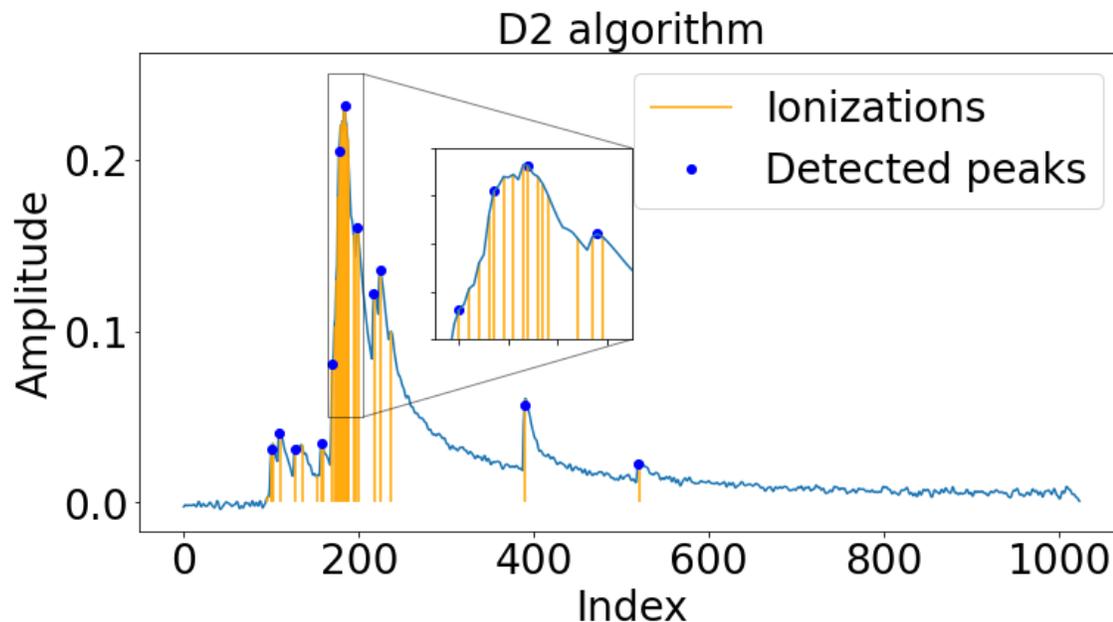
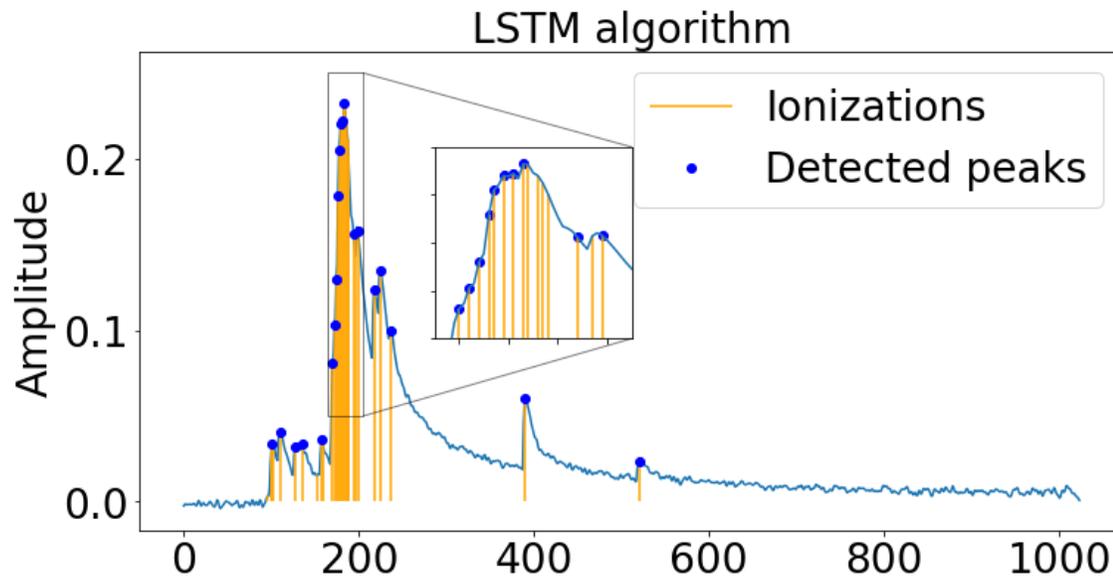
寻峰效率约为60%，对于不同动量的样本效率稳定。
寻峰后得到的原初电离分布仍有良好的泊松形状。



寻峰算法对比

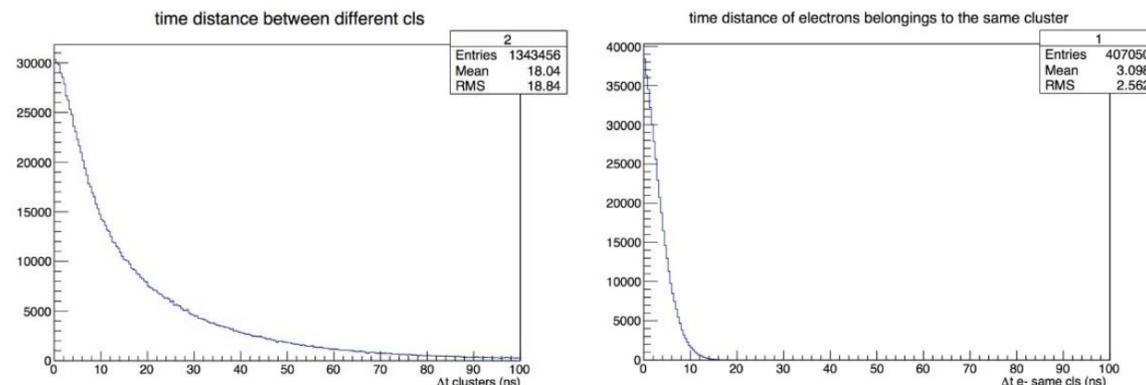
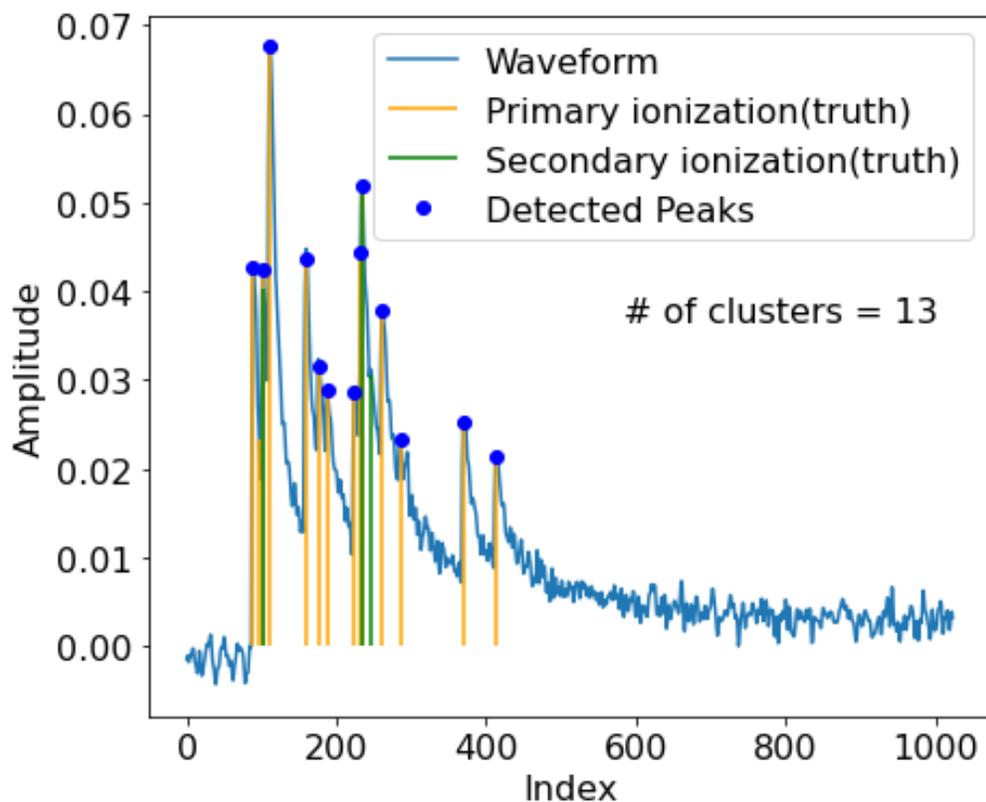


ROC曲线的曲线下面积 (AUC) 越高的分类器越好。LSTM寻峰算法对堆叠信号更灵敏，优于基于导数的寻峰算法。



第二步：合并

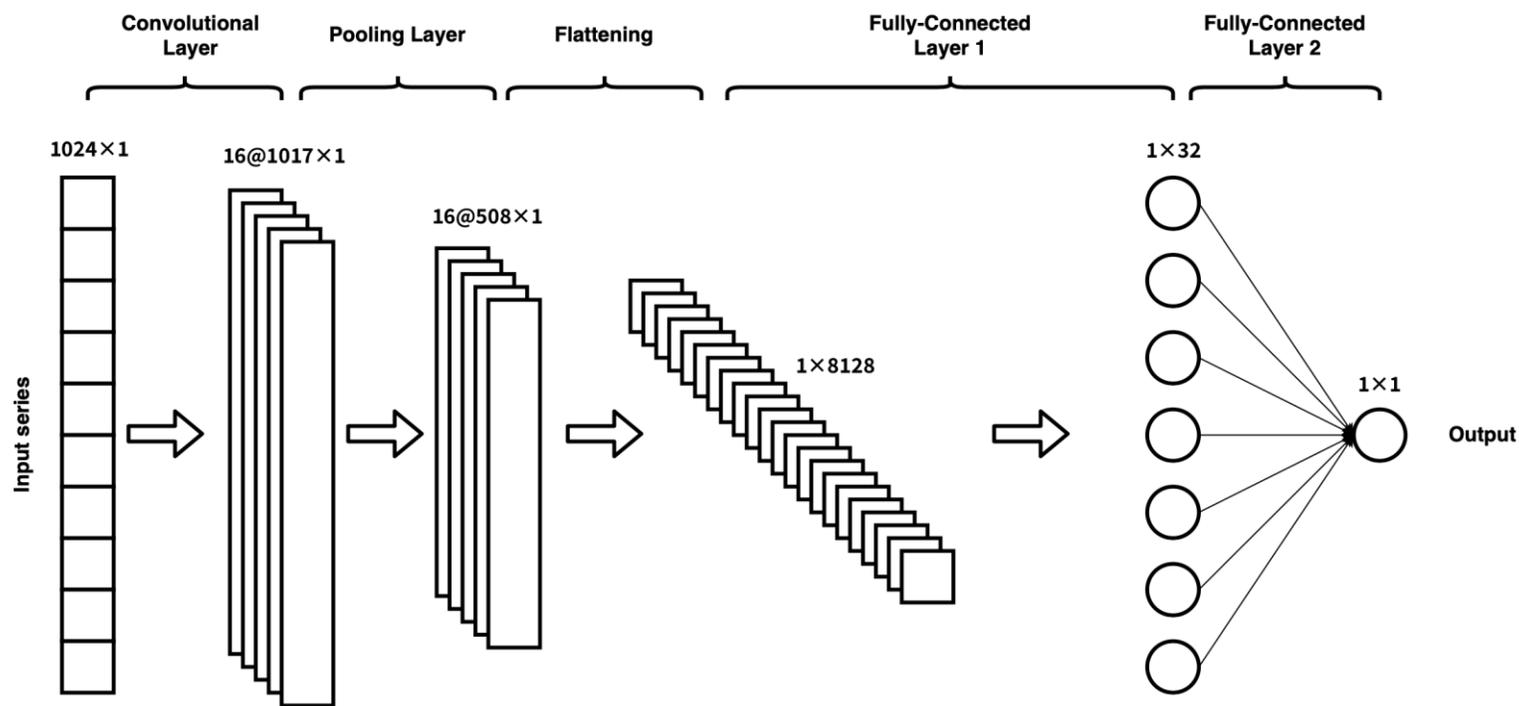
- 合并 (Clusterization): 从寻峰算法得到的电离峰中得到 N_{cls}



- 以寻峰算法得到的电离信号峰为训练样本。

- 目标：从寻峰得到的信号峰中提取 N_{cls}
- 物理上的依据：电离峰之间的时间差
- 思路① CNN回归：
 - 通过信号峰分布预测 N_{cls}
 - 输入数据结构：1D序列
- 思路② GNN分类：
 - 判断每个信号峰是否为原初电离，进一步求出原初电离数 N_{cls}
 - 输入数据结构：图结构数据（点云）

思路①：回归 (CNN)

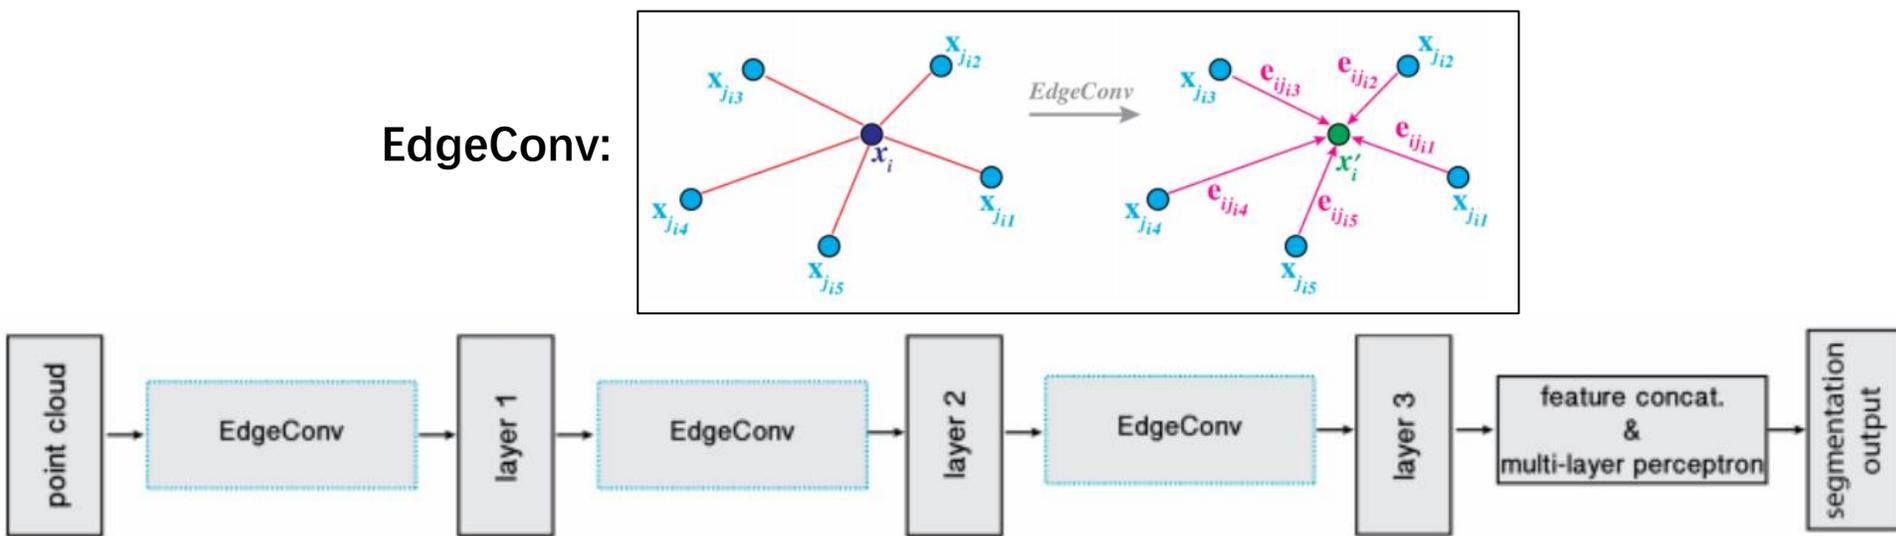


- 数据集 (Dataset): 寻峰算法处理后的波形
- 标签 (Label): 电离簇团数 (原初电离数) N_{cls}
- 特征 (Feature): 形状为 $(n_channels, 1)$ 的数组, 数组中电离峰对应的位置的值为1, 其余位置值为0
- 损失 (Loss): Mean Squared Error

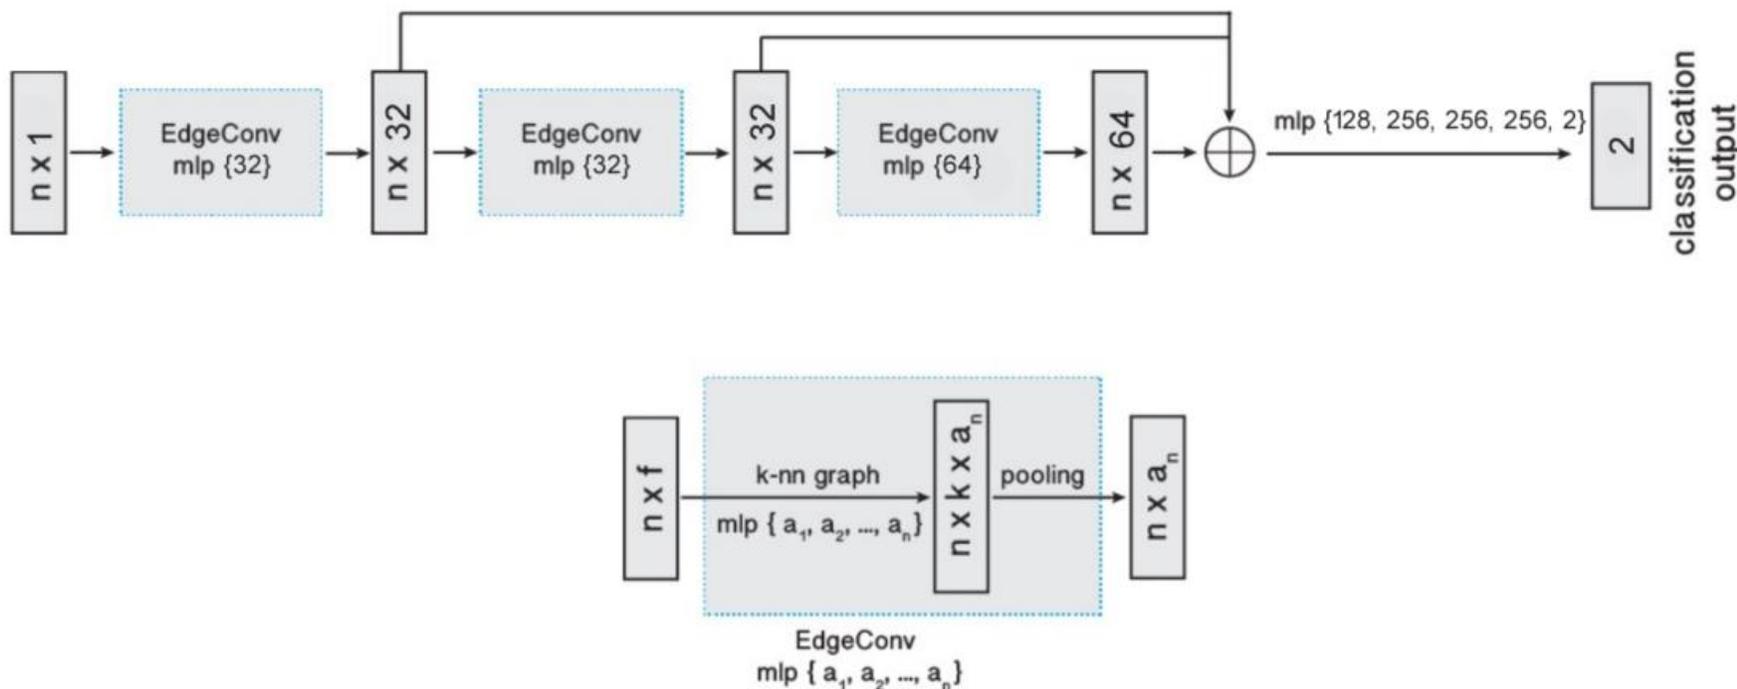
⇒ 回归问题

思路②：分类 (DGCNN)

- 图神经网络 (Graph Neural Network, GNN):
 - 捕捉图结构数据中节点之间的关系。
 - 事例中的一组电离峰 \Rightarrow 图 (Graph), 每个电离峰 \Rightarrow 节点 (Node), 电离峰的时间 \Rightarrow 节点特征 (Node feature), 电离峰之间的关系 \Rightarrow 边 (Edge)
 - 优点: 无序、直观、更泛用
- 动态图卷积神经网络 (Dynamic Graph CNN, DGCNN):
 - 通过k近邻在每一层特征空间动态建立图
 - 可以更好地捕捉局部特征 \Rightarrow 用以捕捉电离簇团特征
 - 已于高能物理领域获得应用 \Rightarrow ParticleNet.



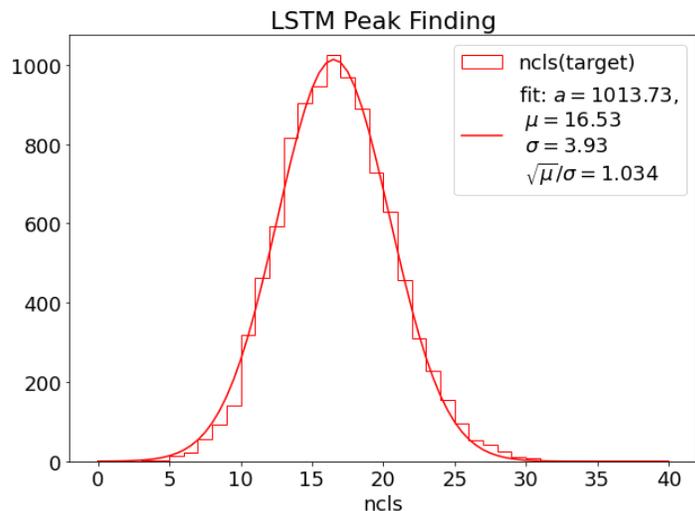
思路②：分类 (DGCNN)



- 图 (Graph): 每个波形对应一张图
- 节点 (Node): 寻峰算法得到的电离峰
- 节点特征 (Node feature): 电离峰的位置 (时间)
- 边 (Edge): EdgeConv层动态计算
- 标签 (Label): 电离峰的种类 (原初电离为1, 非原初电离为0)
- 损失 (Loss): BCE loss

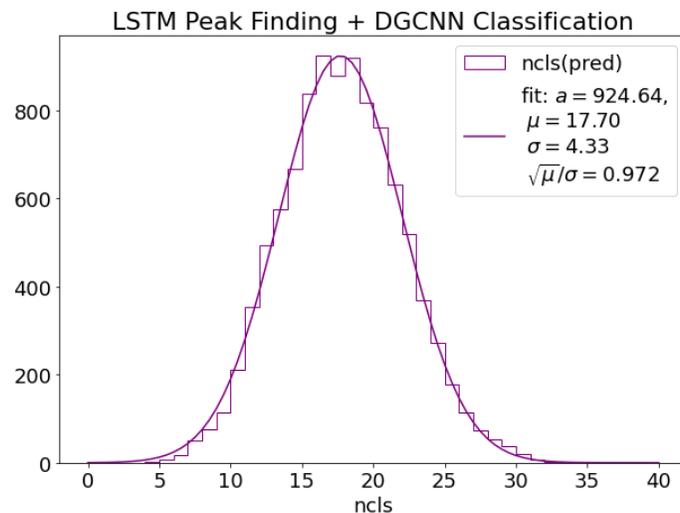
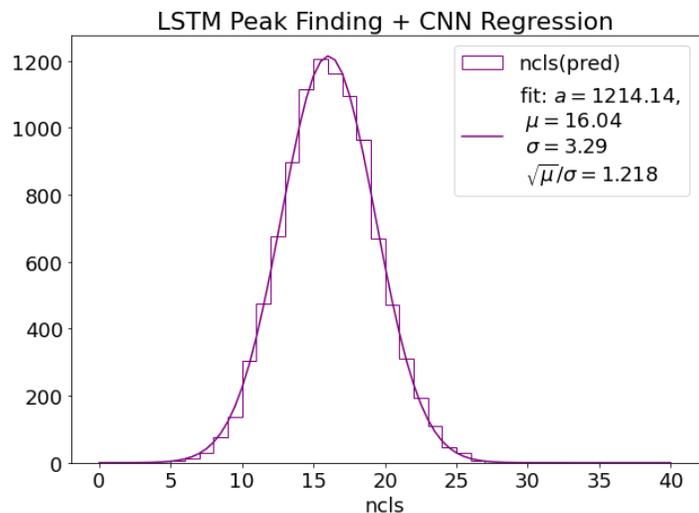
⇒节点分类 (Node classification) 问题

算法评估



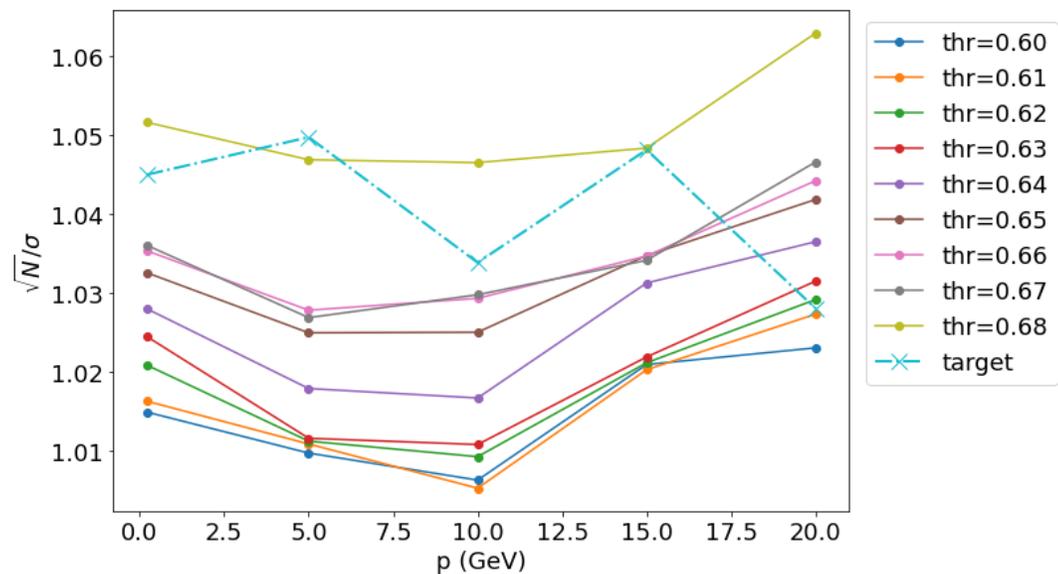
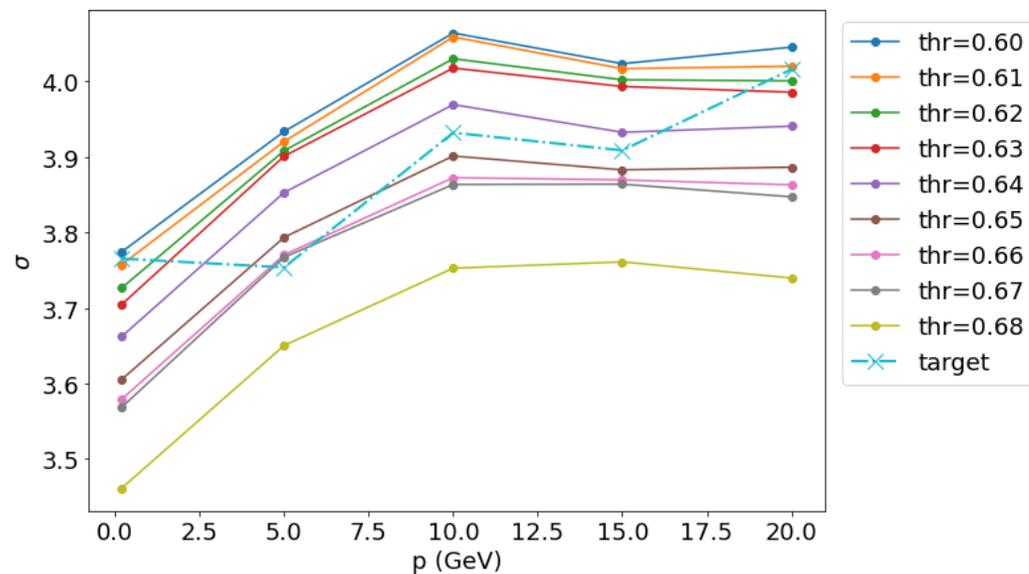
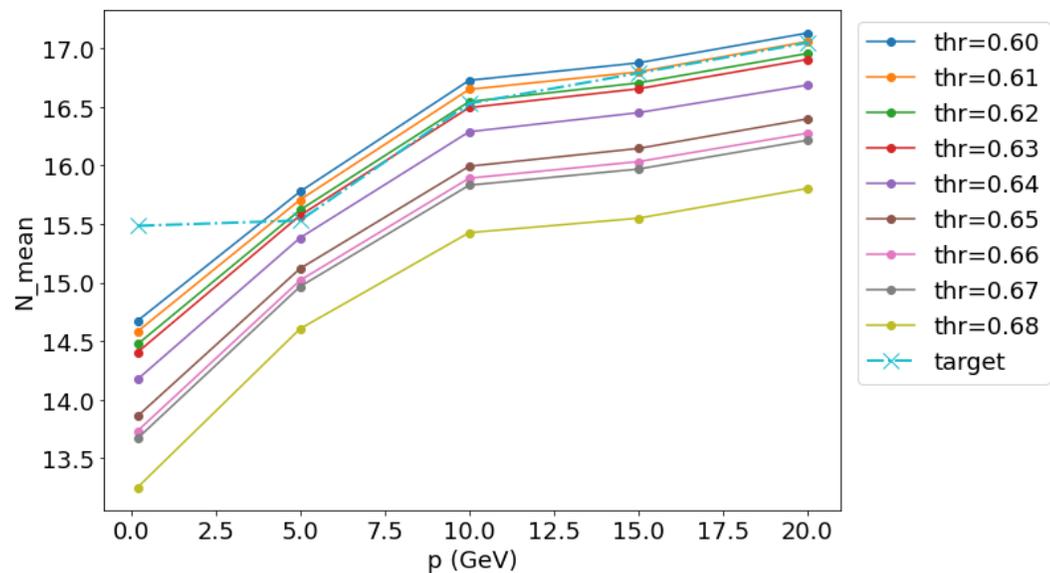
测试样本：信号波形样本 (π 粒子, 动量为固定值, 5%噪声)

合并算法得到的 N_{cls} 即电离计数算法的最终结果。算法的评估基于最终得到的 N_{cls} 分布。 N_{cls} 应该遵守泊松分布, 满足 $\sqrt{N_{mean}}/\sigma \approx 1$ 。



回归法：分布变窄，中心值变低
分类法：分布变宽，中心值变高

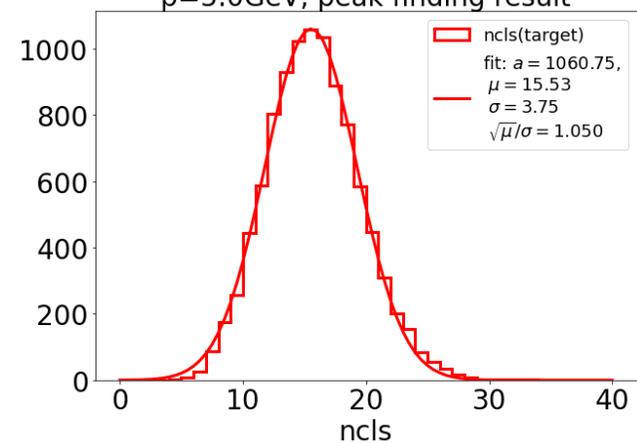
DGCNN分类阈值优化



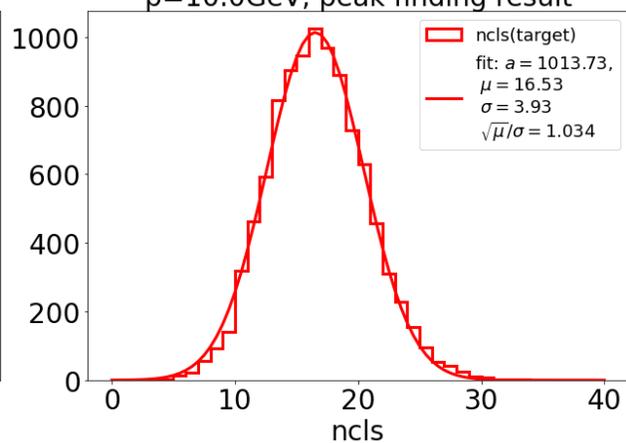
阈值优化:

- 扫描阈值, 并比较不同阈值下预测值和目标的原初电离总数 N_{cls} 分布差异。
- 评估参数: N_{mean} , σ , $\sqrt{N_{\text{mean}}}/\sigma$

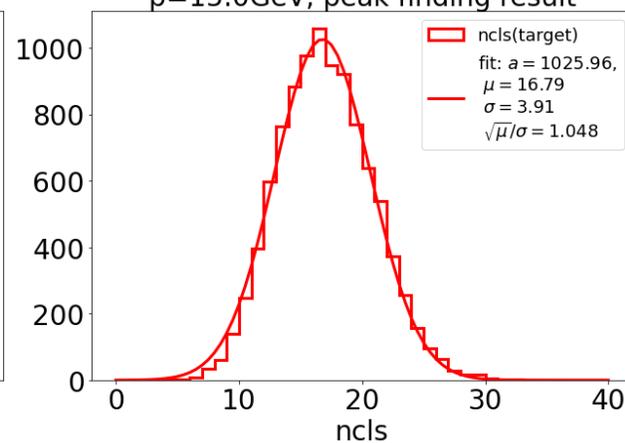
p=5.0GeV, peak finding result



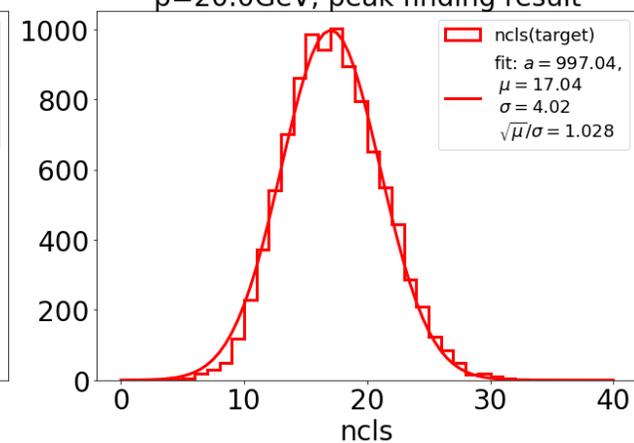
p=10.0GeV, peak finding result



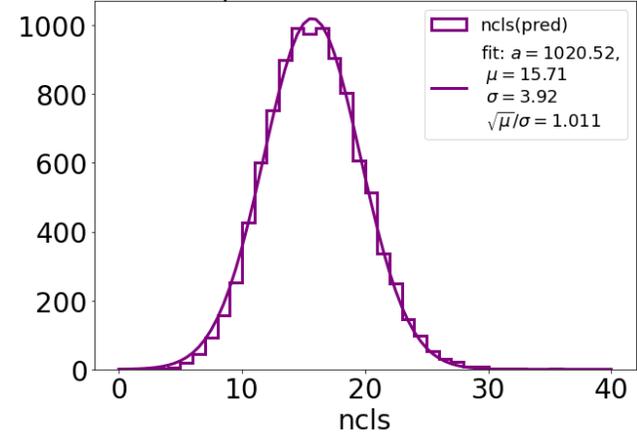
p=15.0GeV, peak finding result



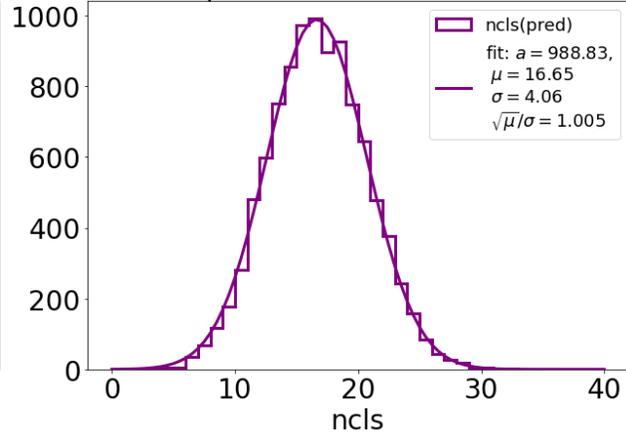
p=20.0GeV, peak finding result



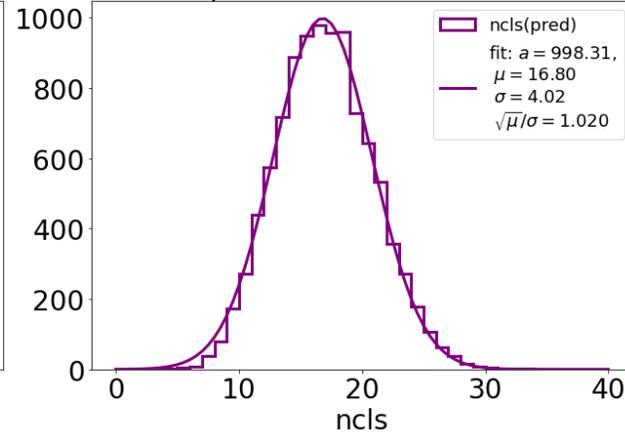
p=5.0GeV,thr=0.610



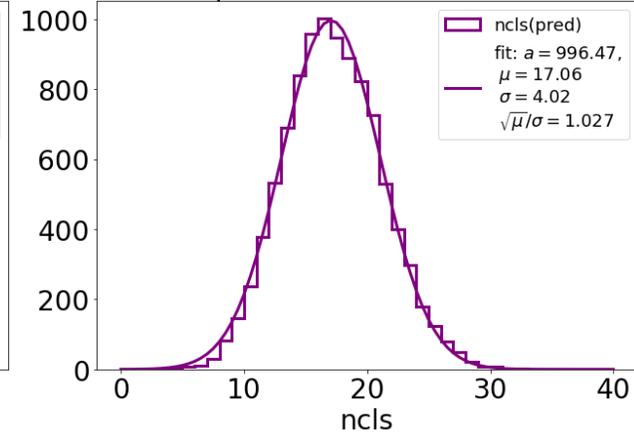
p=10.0GeV,thr=0.610



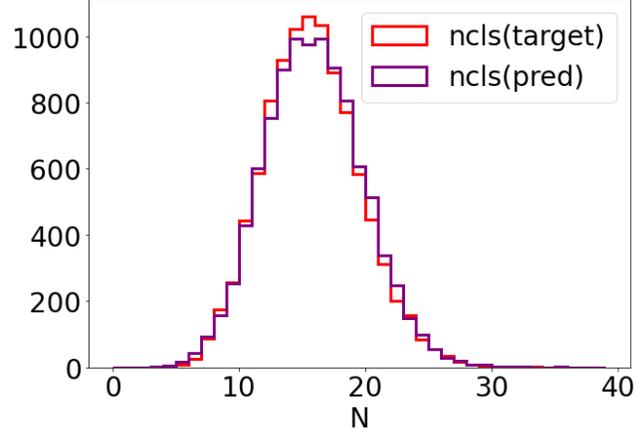
p=15.0GeV,thr=0.610



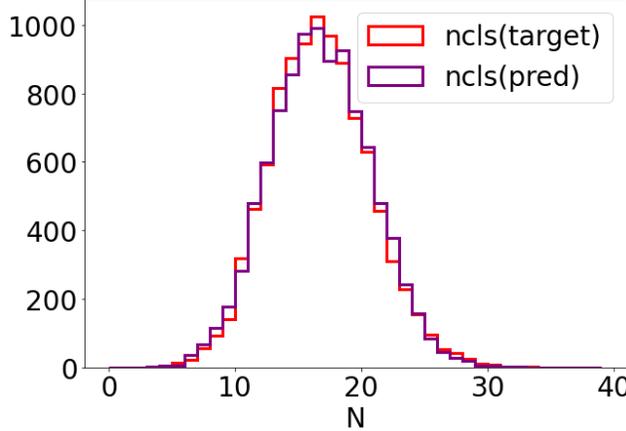
p=20.0GeV,thr=0.610



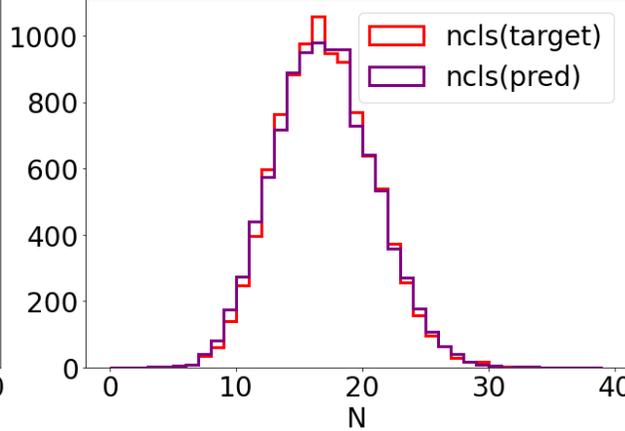
p=5.0GeV,thr=0.610



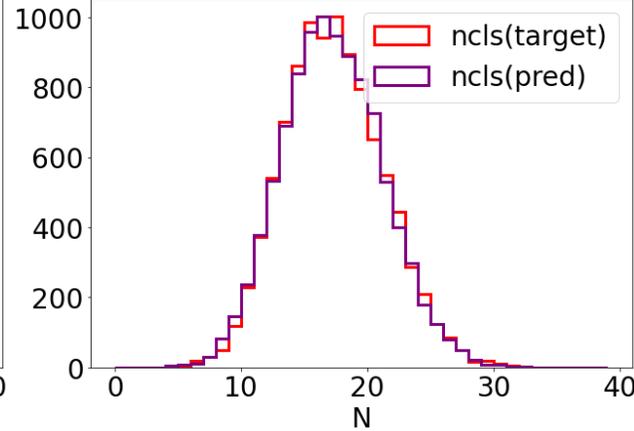
p=10.0GeV,thr=0.610



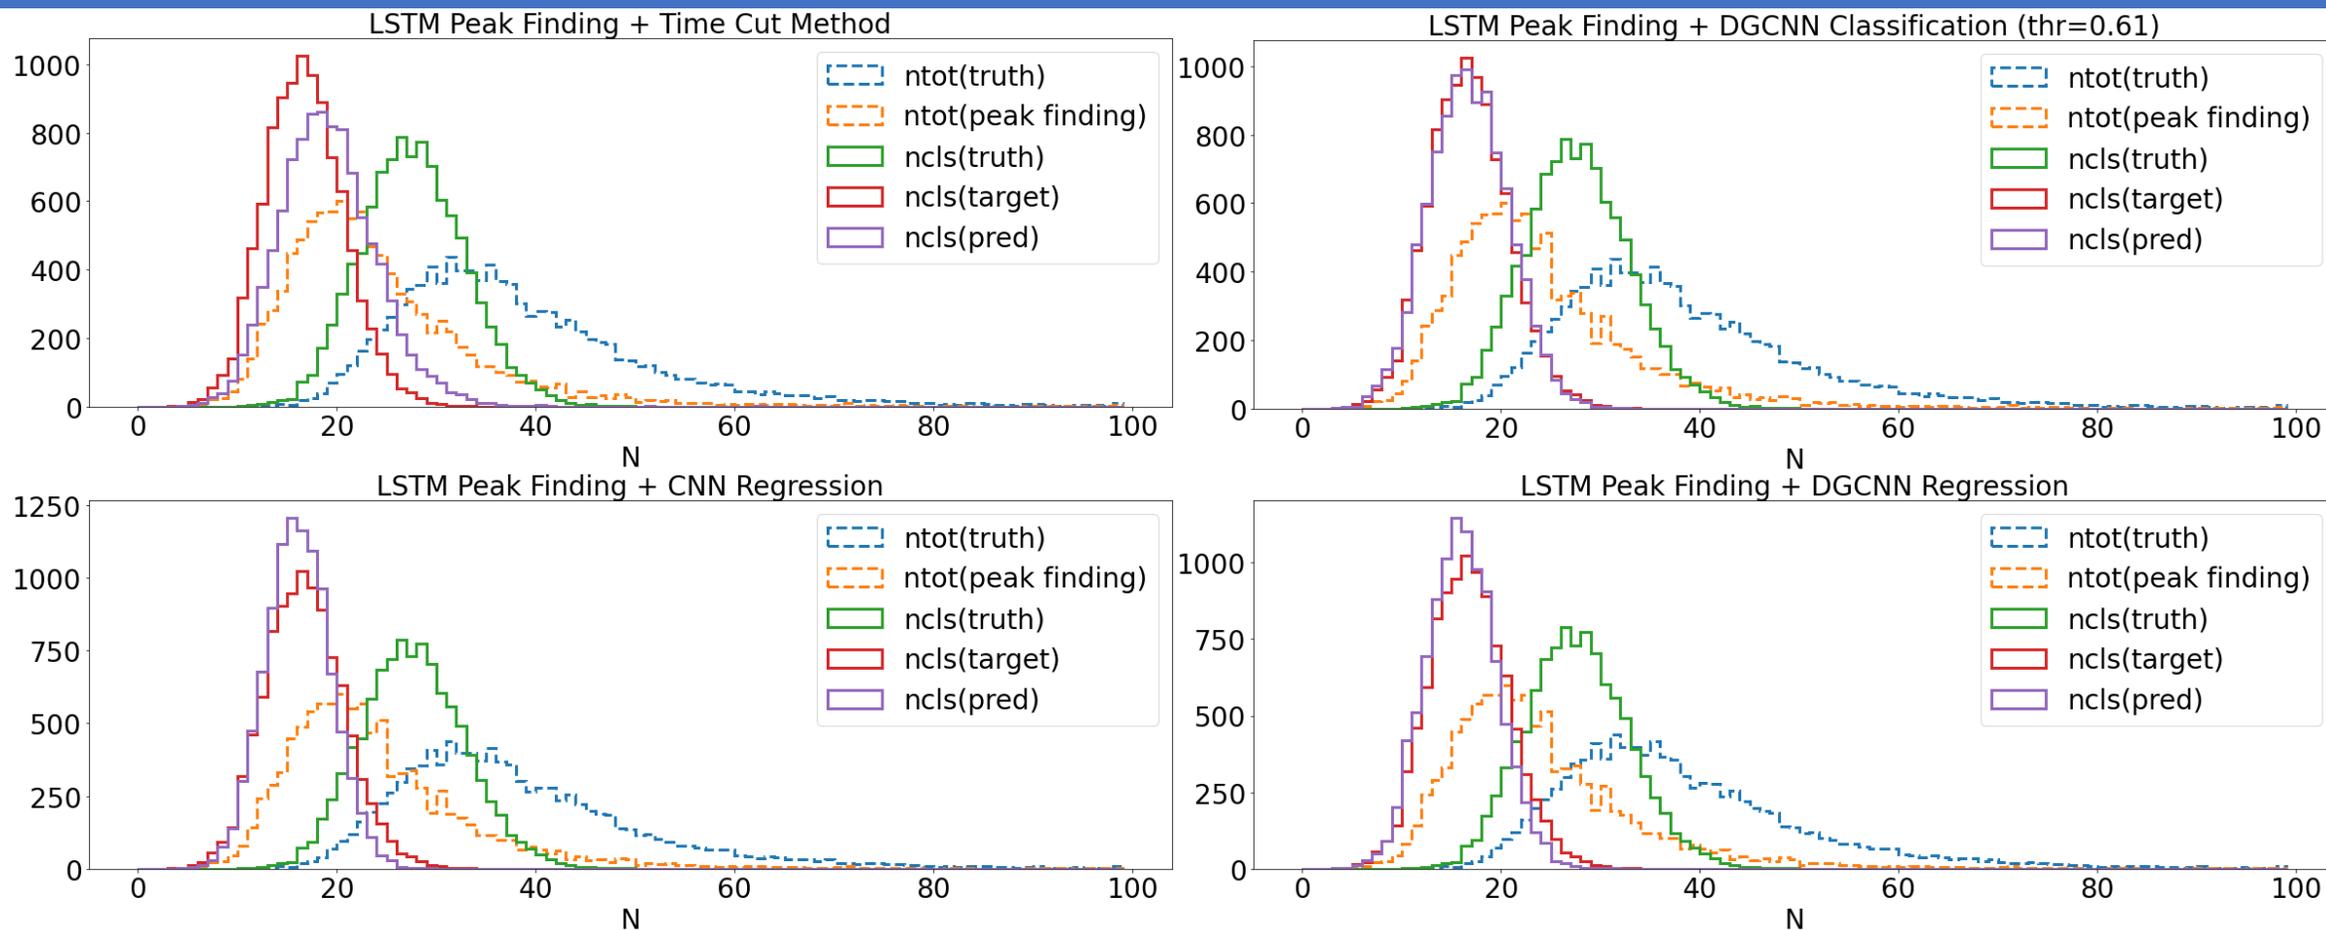
p=15.0GeV,thr=0.610



p=20.0GeV,thr=0.610



结果对比



ntot(truth): MC truth中总电离数;

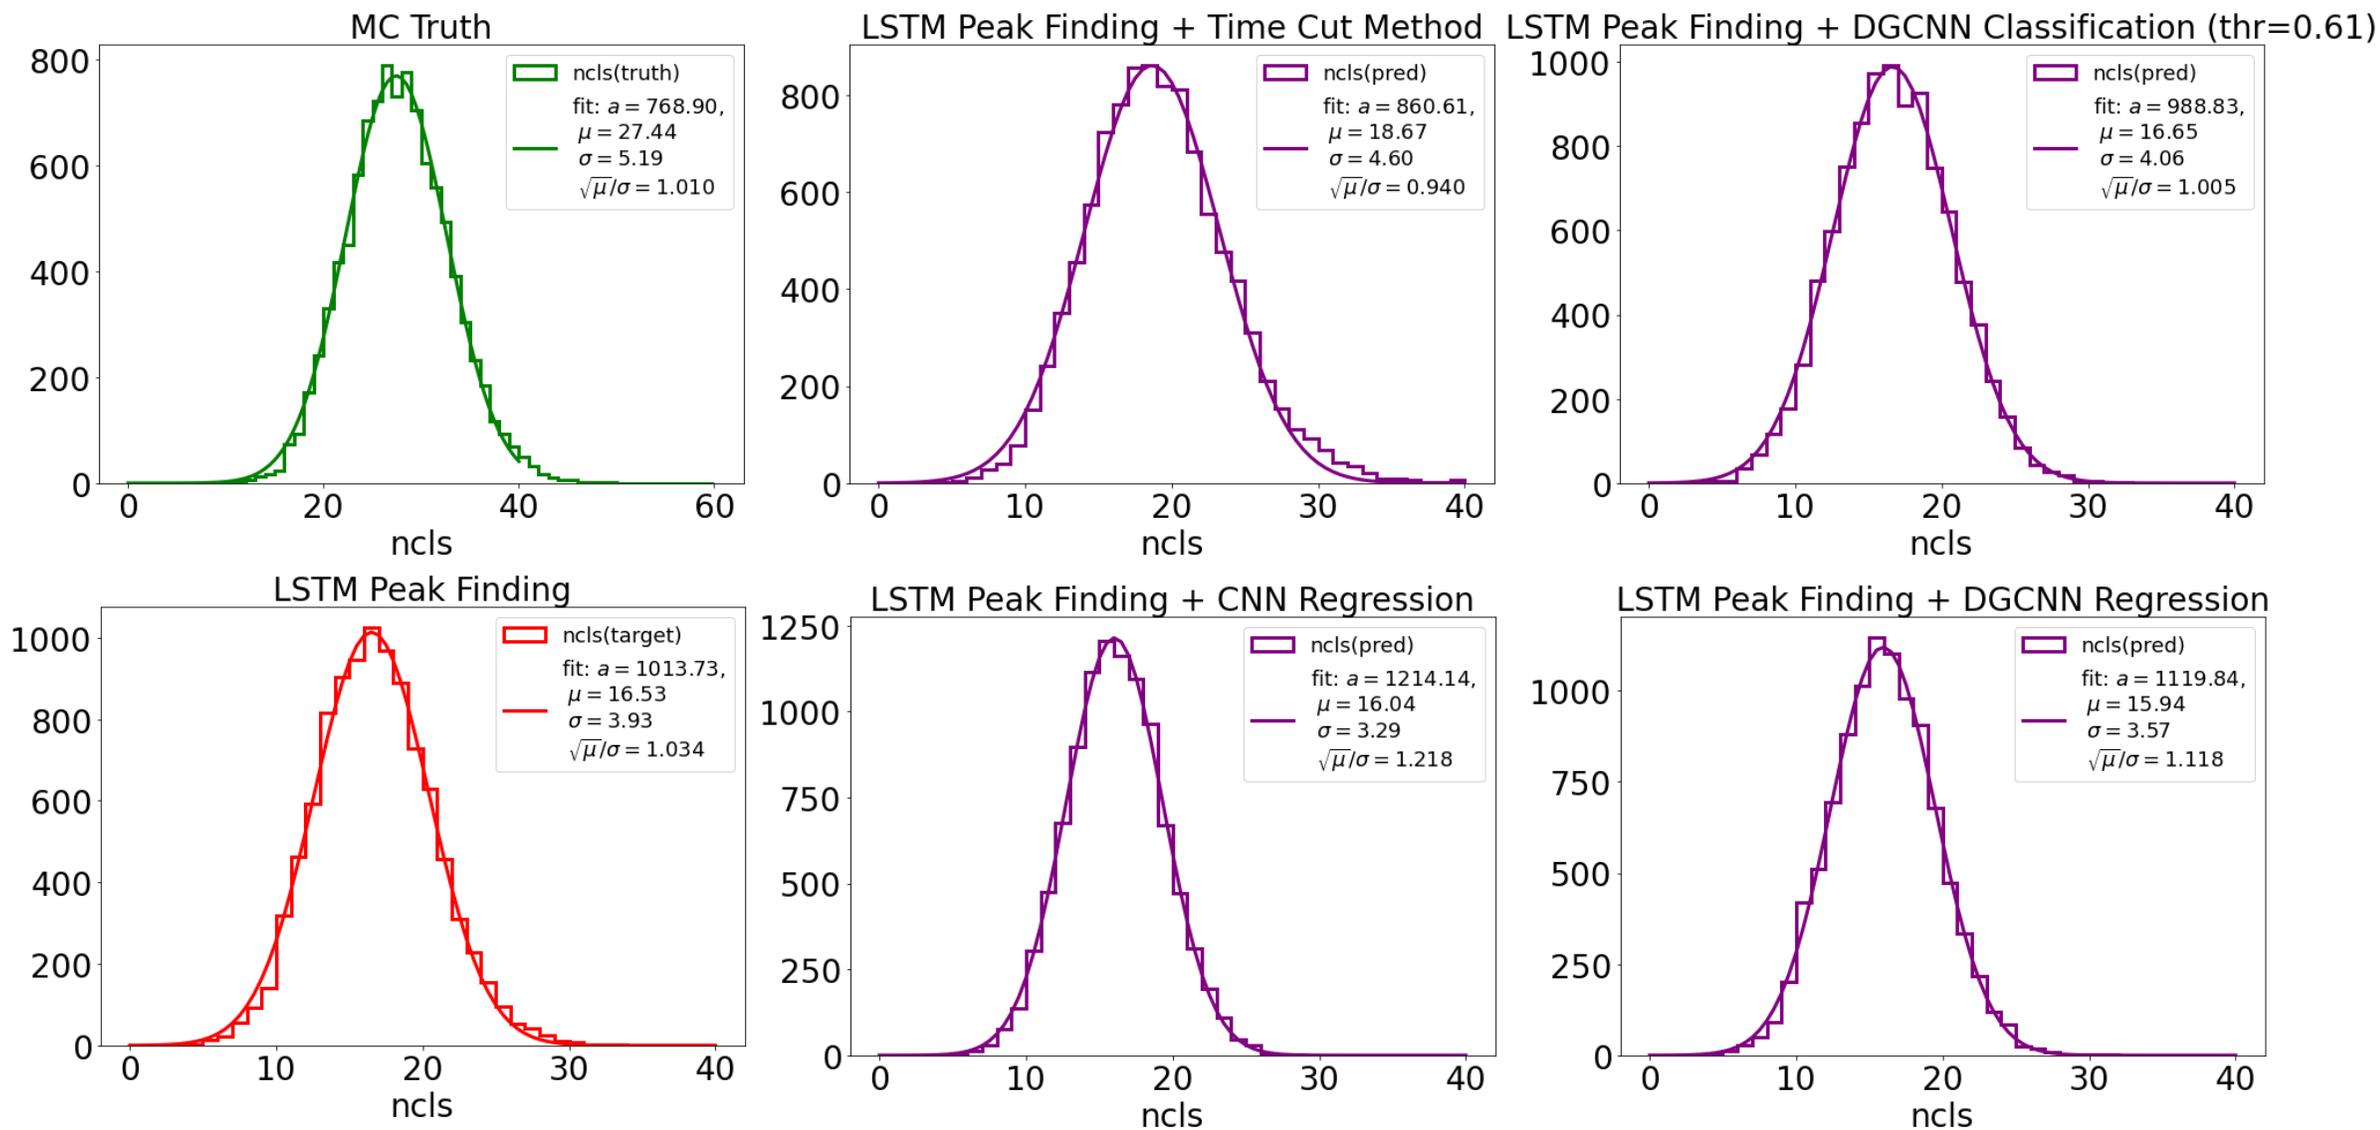
ntot(peak finding): 寻峰算法得到的总电离数;

ncls(truth): 寻峰算法得到的总电离数;

ncls(target): 寻峰算法得到的总电离数中的原初电离数, 合并算法的目标值;

ncls(pred): 合并算法预测得到的原初电离数。

结果对比



相比回归方法和传统方法，DGCNN分类算法获得了与目标值最接近的 N_{cls} 分布。

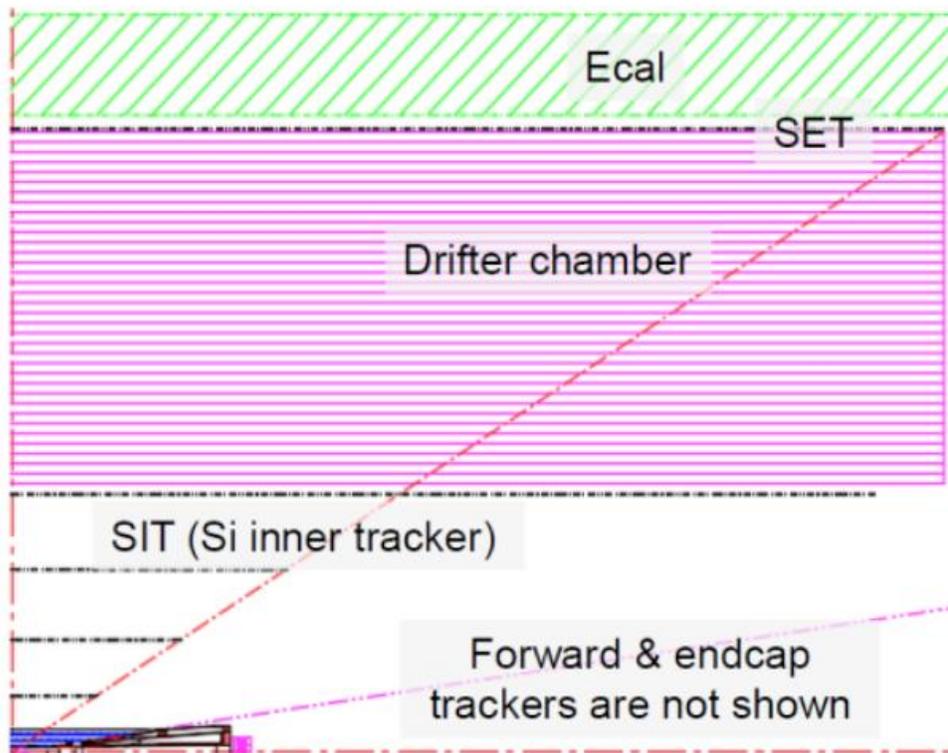
总结与展望

Method	N_{mean}	σ	σ/N_{mean}
Target (MC Truth)	16.53	3.93	23.8%
Classical Method	18.67	4.60	24.6%
CNN Regression	16.04	3.29	20.5%
DGCNN Regression	15.94	3.57	22.4%
DGCNN Classification (thr=0.61)	16.65	4.06	24.4%

- 基于深度学习的电离计数算法较传统算法有较大提升。
 - LSTM寻峰算法的寻峰纯度和灵敏度高于传统导数算法
 - DGCNN合并算法可以获得比传统时间合并算法更好的 N_{cls} 分布。
- 未来将基于beam test真实数据进行进一步的研究。

BACKUP

漂移室设计

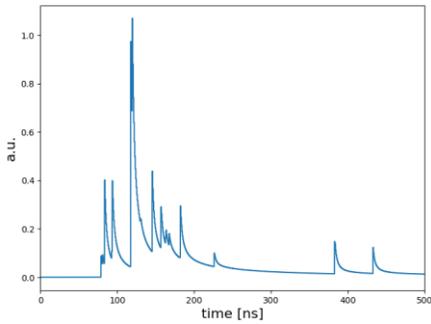


Preliminary DC parameters

Inner radius	800mm
Outer radius	1800mm
Cell size	18 mm \times 18 mm
Gas mixture	He/iC ₄ H ₁₀ =90:10
Length of outermost wires ($\cos\theta=0.82$)	5143mm

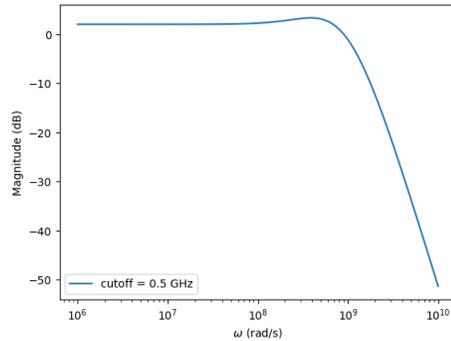
波形模拟

Induced signal



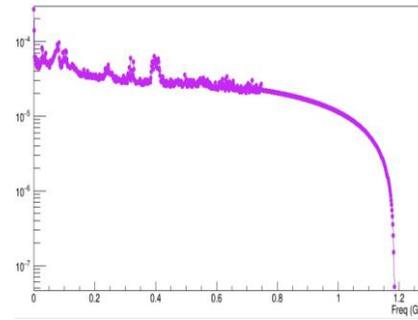
Fast simulation based on Garfield++ study

Electronics response



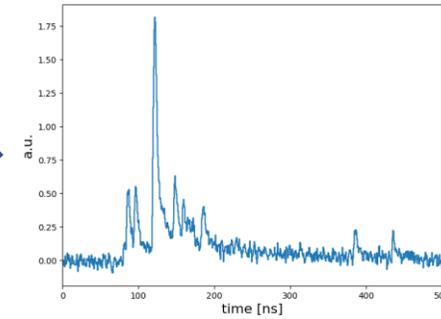
From electronics using in the beam test

Noise



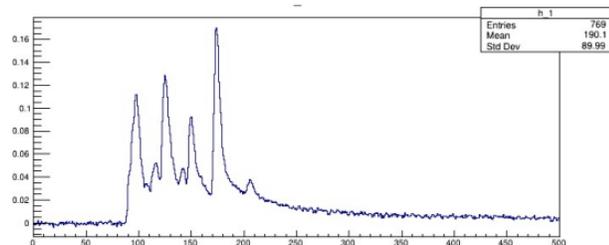
From the beam test

Waveform

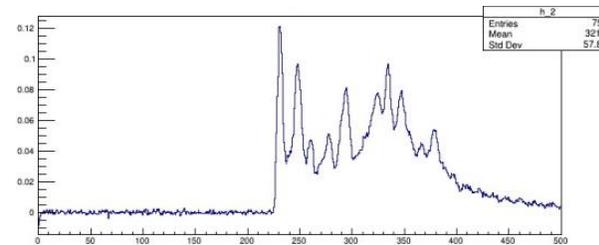


SamplingRate(GHz): 1.5,
TimeWindow(ns): 2000,
CellSize(cm): 1.8,
Particle:
Name: pi,
Pos(cm): [0.2, -1.2, 0.0],
Cos: [0.0, 1.0, 0.0],
Momentum(GeV/c): [0.2, 20.0]
PreAmplifier:
ScaleFactor: 1.0,
ResponseSize: 50,
Option: 0,
Opt0-SimpleAmp-Tau: 2.0,
Noise:
NoiseAmplitude: 0.02405,
NoiseType: FFT noise

Simulation



Beam test data

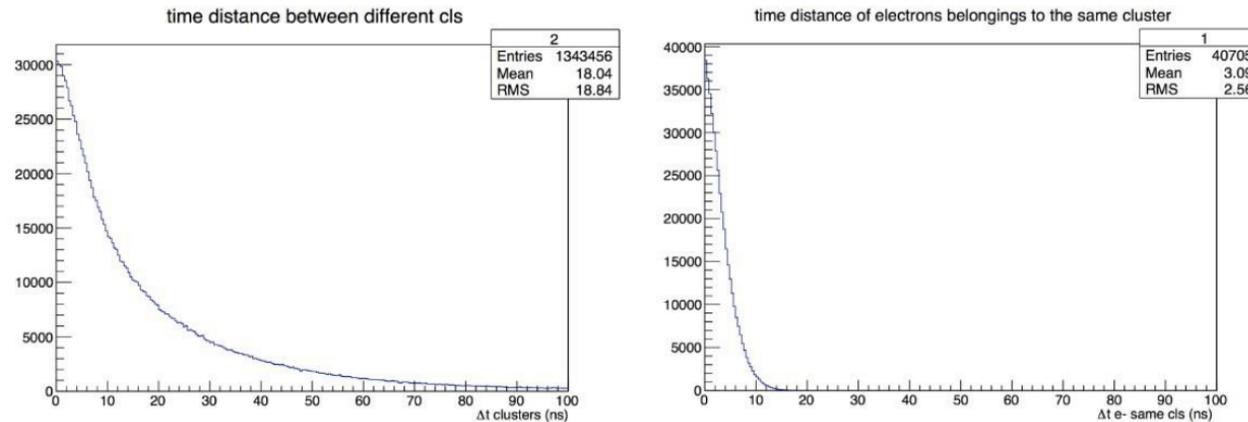


传统合并 (Clusterization) 算法

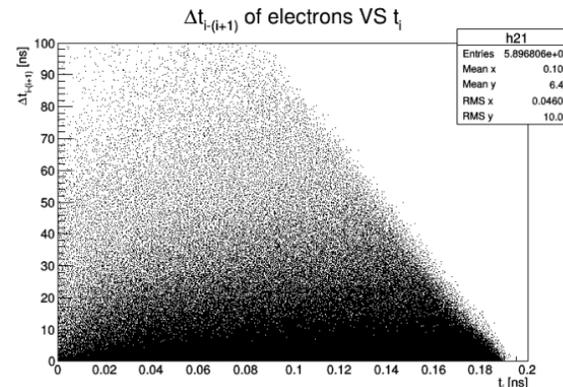
Convert peaks in cluster clusterization

How to convert found peaks in clusters?

- Look to the time difference between electrons belonging to different clusters and those to the same cluster



- Event by event plot the difference $t_i - t_{i+1}$ Vs t_i

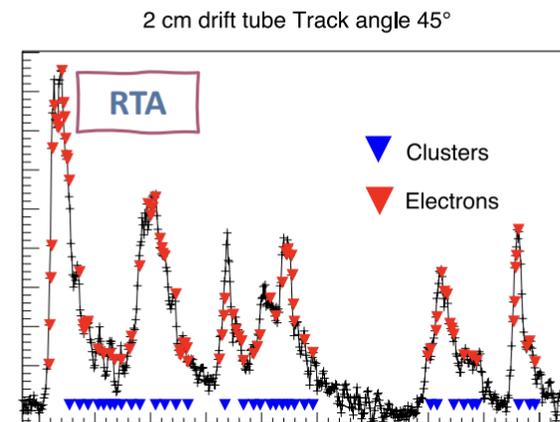
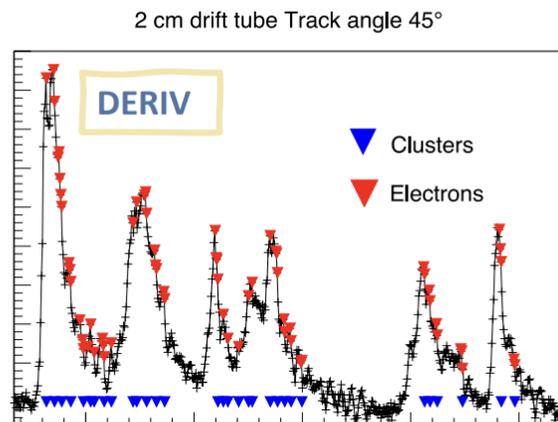


传统合并 (Clusterization) 算法

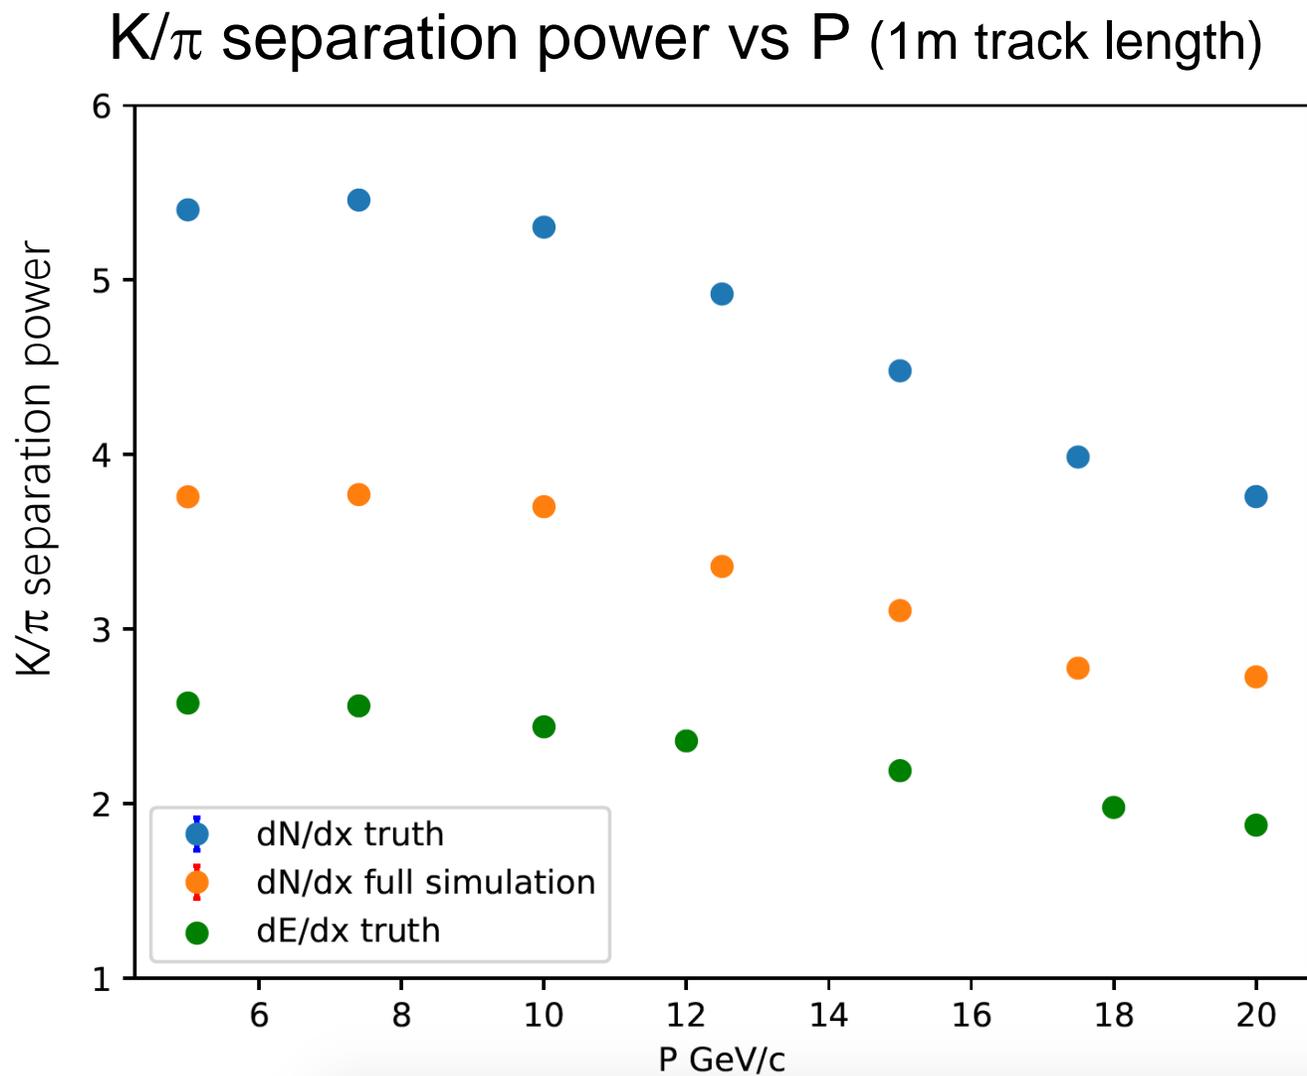
A single clusterization algorithm

Once find the electron peaks, clusterization of the electron peaks into ionization clusters has been implemented:

- 1) Association of electron peaks consisting in consecutive bins (difference in time == 1 bin) electrons to a single electron in order to eliminate fake electrons.
- 2) Contiguous electrons peaks which are compatible with the electrons diffusion time (2.5 ns or 3 bins) must be considered belonging to the same ionization cluster.
- 3) Position of the clusters is taken as the position of the last electron in the cluster.



基于传统ClusterCounting算法的初步结果



Separation power

$$S = \frac{\left| \left(\frac{dN}{dx} \right)_{\pi} - \left(\frac{dN}{dx} \right)_{K} \right|}{(\sigma_{\pi} + \sigma_K)/2}$$