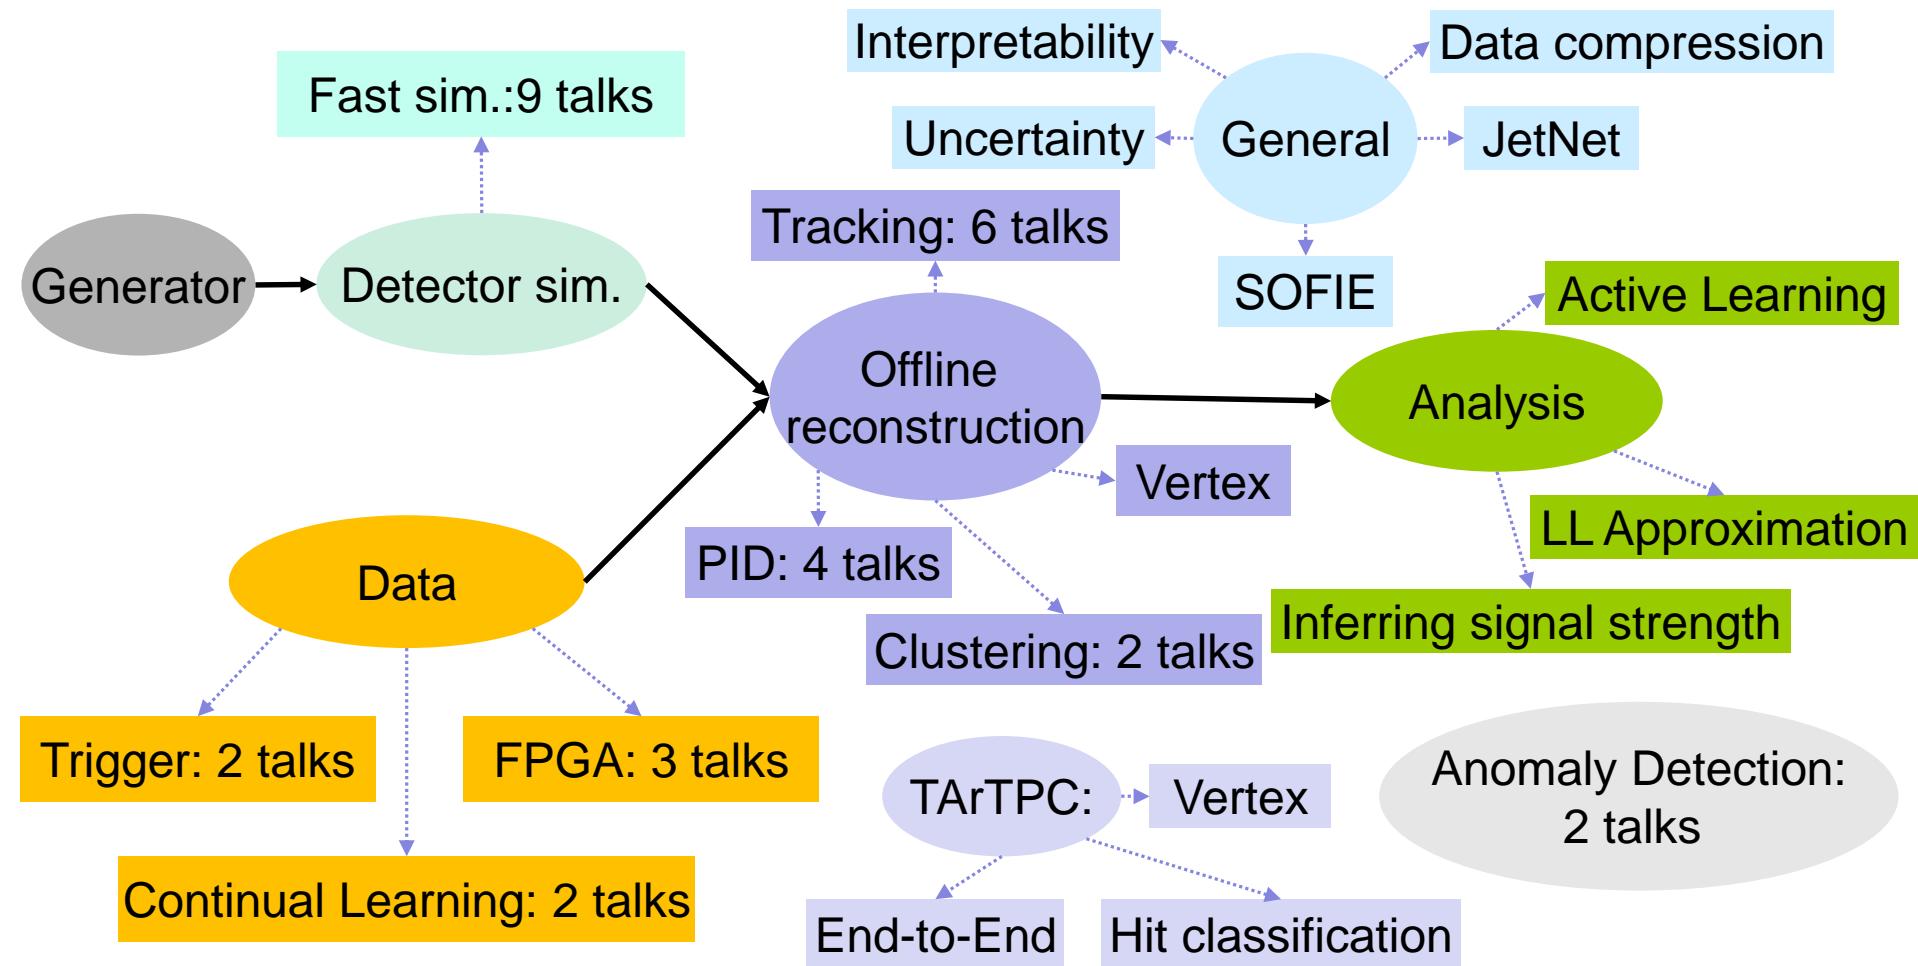


# CHEP2023 机器学习 进展分享

Wenxing Fang (IHEP)

2023年粒子物理实验计算软件与技术研讨会，2023.06.09-12，  
山东大学青岛校区

# 机器学习口头报告内容



# 快速模拟

- ❖ 背景：未来的 HL-LHC 实验将产生海量实验数据，数据处理、分析、模拟数据产生等都需要大量计算资源。如果不进行 R&D 研究将面临计算资源不足的问题
- ❖ 其中实现 MC 快速模拟能够大幅降低计算资源的需求，具有重要意义
  - 传统方法: shower 参数化、Frozen shower、快径迹模拟（简化几何和物理过程）、模拟部分粒子、全参数化 (Delphes) 模拟
  - 机器学习方法：主要集中在量能器的快速模拟和 Ultra-Fast Simulation (跳过 Geant4) 的 End-to-end 模拟

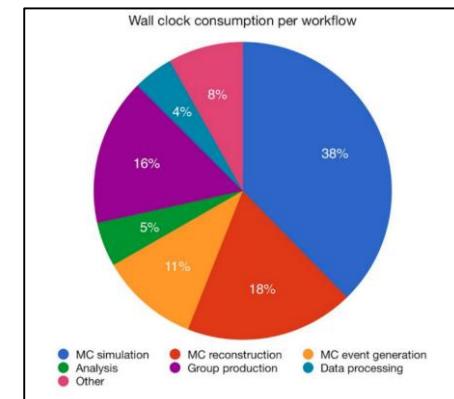
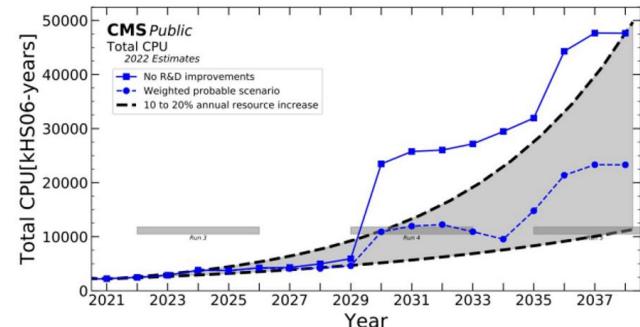
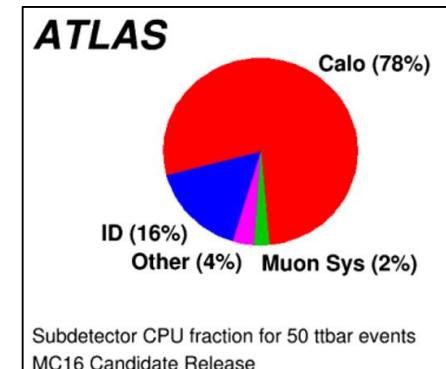
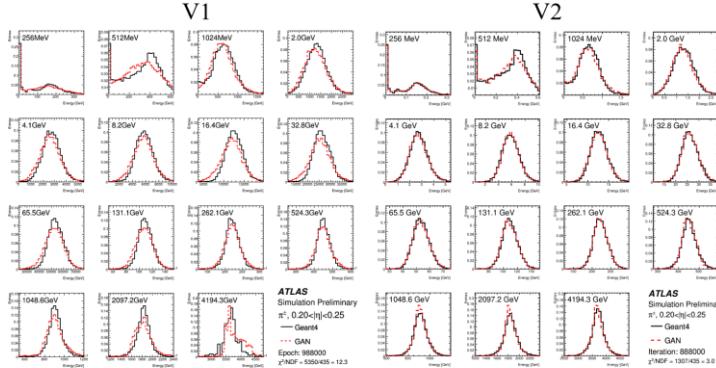
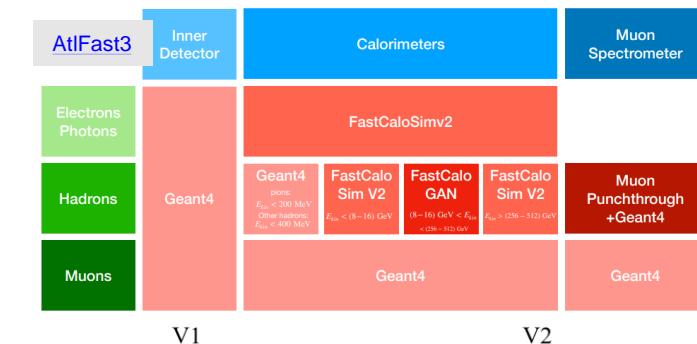
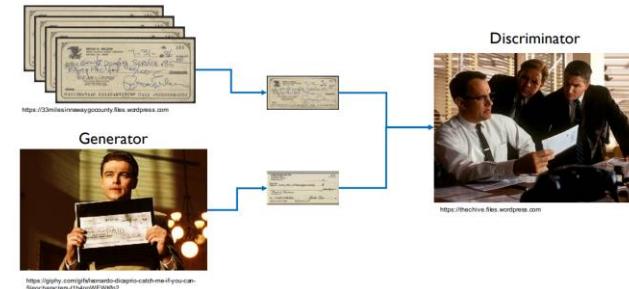
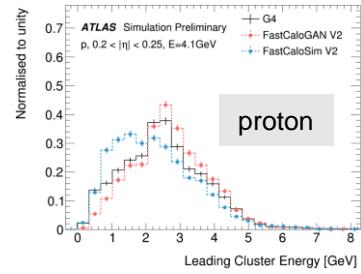
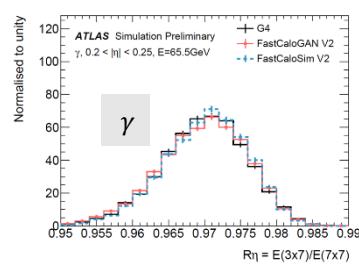
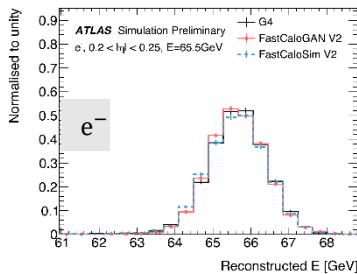


Figure 1: ATLAS CPU hours used by various activities in 2018



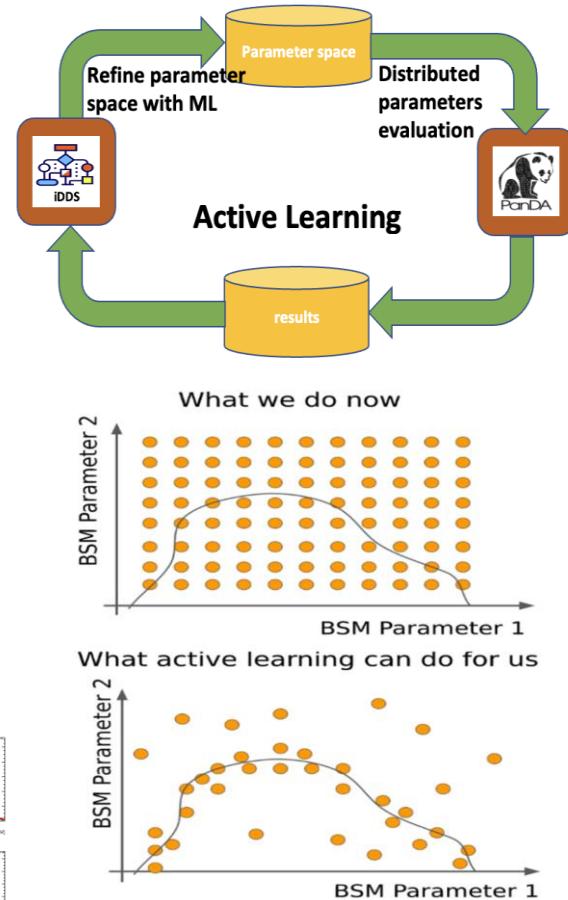
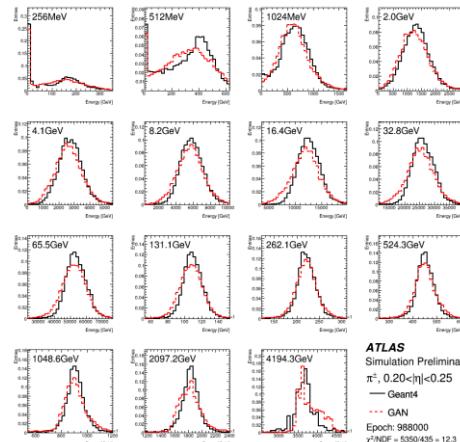
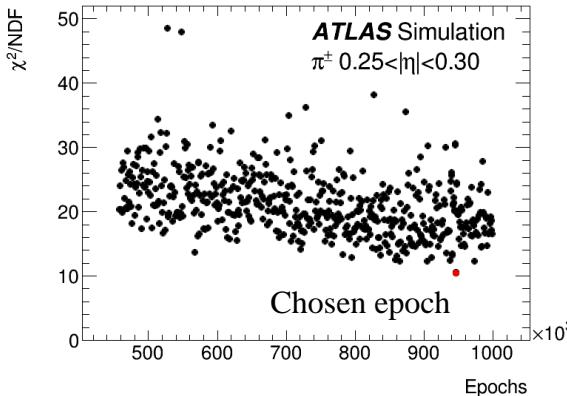
# 量能器快速模拟 (1)

- ❖ 2017 年 [CaloGAN](#) 被提出来，使得基于 GAN 的量能器快速模拟成为研究热点
- ❖ 目前 ATLAS 的 AltFast3 快速模拟软件已经将 GAN 整合其中，用于 Run2 的模拟数据产生 (2B)
- ❖ 最新的 FastCaloGAN v2 对实现了更加精确的模拟：
  - 不同种类粒子、能量、方向 ( $\eta$ )。从原先 1 个 GAN 到 500 个 GAN
  - 将被广泛用于 Run3 的模拟样本产生



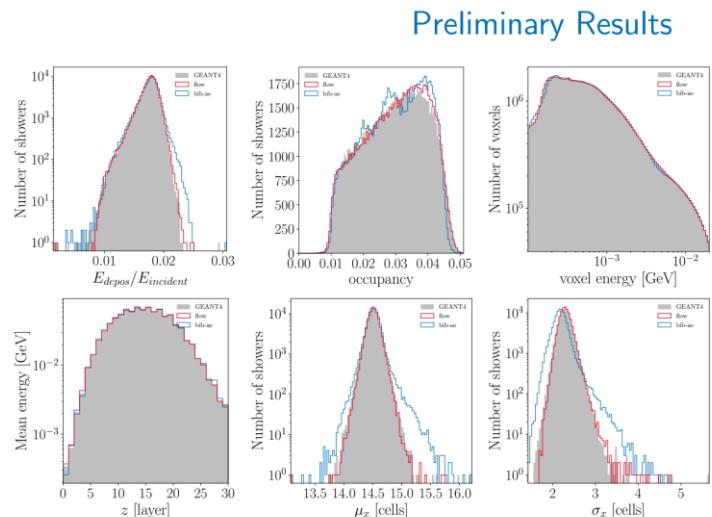
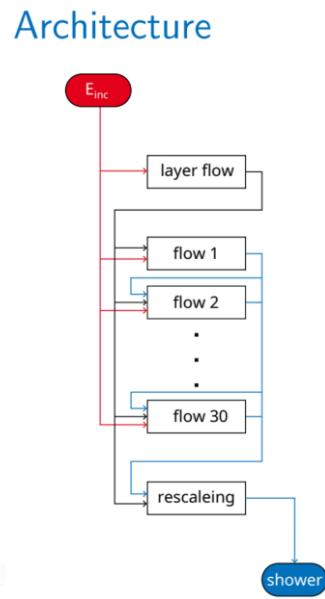
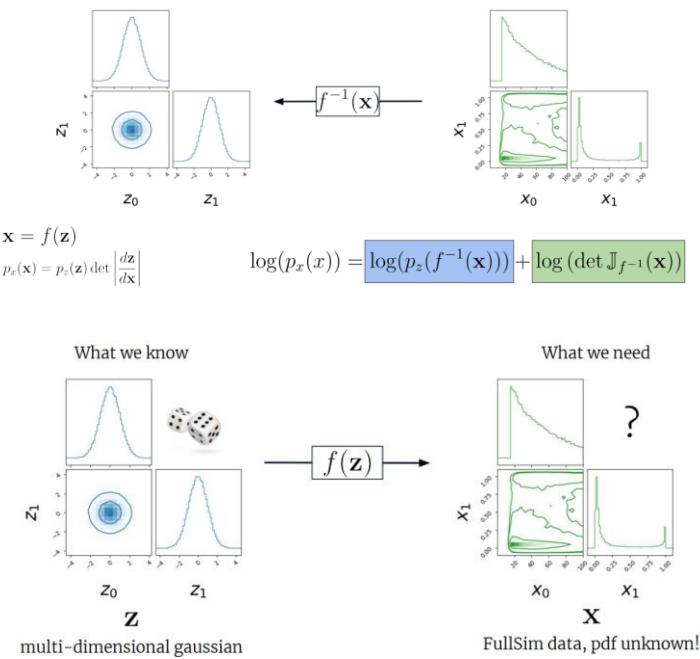
# 量能器快速模拟 (1)

- ❖ 由于要训练的 GAN 模型个数多 (500 个)，且每个 GAN 模型的训练也不容易 (训练过程不稳定、需要优化超参数)。因此，需要解决 GAN 模型训练的问题
- ❖ 为此 ATLAS 实验利用 Active Learning 的技术，实现网络模型的自动训练和超参数的优化：
  - iDDS (intelligent Data Delivery Service) 负责根据当前模型训练的结果产生下一批模型训练作业 (如利用贝叶斯算法、GP 等算法缩小超参数范围)
  - PanDA 系统将作业调度到分布式的异构计算资源上进行模型的训练，返回训练结果



# 量能器快速模拟 (2)

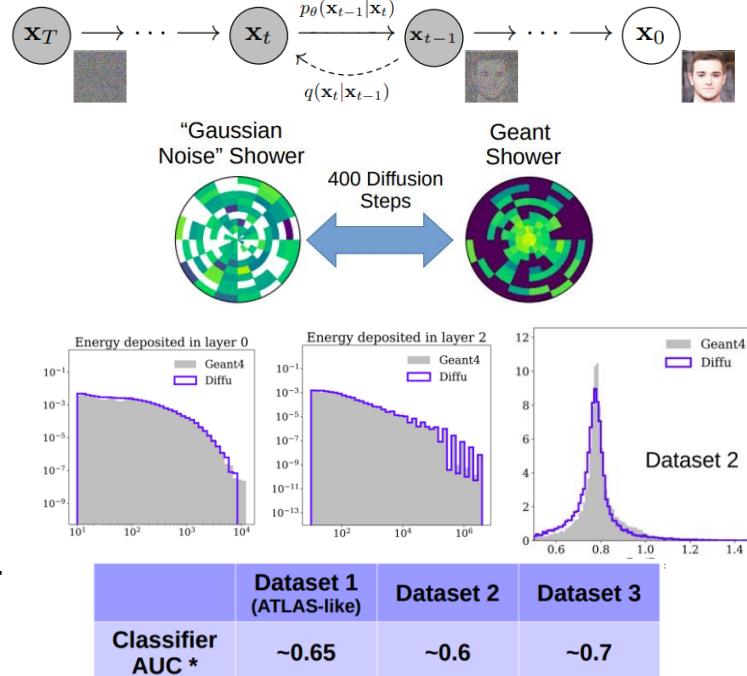
- ❖ 近些年，基于其它机器学习技术的量能器快速模拟也在快速发展
- ❖ 2021年提出的 CaloFlow 基于 Normalizing Flows 技术，能够得到比 CaloGAN 更精确的模拟。相比 GAN，其训练更加稳定，能够收敛。在推理速度上要比 GAN 慢一个量级左右



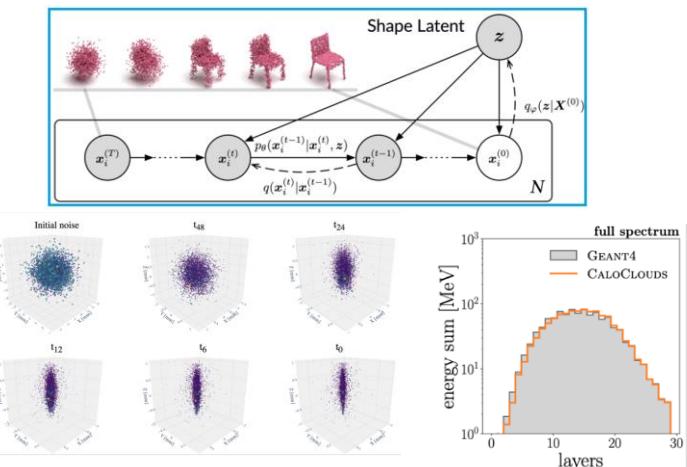
Simulator	Hardware	Batch size	time [ms]	Speedup
GEANT4	CPU	1	4081.53 ± 169.92	×1.0
BIB-AE	CPU	1	102.25 ± 0.64	×40.0
		10	37.81 ± 0.13	×108.0
		100	48.51 ± 0.01	×84.1
		1000	48.19 ± 0.01	×84.7
Flow	CPU	1	1746.61 ± 64.50	×2.3
		10	392.61 ± 0.34	×10.4
		100	228.86 ± 7.09	×17.8
		1000	275.55 ± 3.01	×14.8
BIB-AE	GPU	1	74.22 ± 3.18	×42.5
		1000	0.249 ± 0.002	×16326.1
Flow	GPU	1	2471.07 ± 70.20	×1.7
		1000	3.39 ± 0.09	×1202.3

# 量能器快速模拟 (3)

- ❖ 2020年提出 Diffusion model，其能生成非常逼真的图像，目前基于 Diffusion model 的图像生成算法已经成为主流
- ❖ CaloDiffusion (CHEP2023) : 基于 Diffusion 的能量器快速模拟
  - 大部分模拟结果能和 Geant4 一致，有些全局变量符合的还不是很好
  - 速度上比其它机器学习方法慢 (比 Geant4 快)
- ❖ CaloCloud: 基于 Diffusion 和 Point cloud 的量能器快速模拟
  - 克服几何不规则问题
  - 得到 promising 结果，证明方法可行
  - 模拟速度需要提高

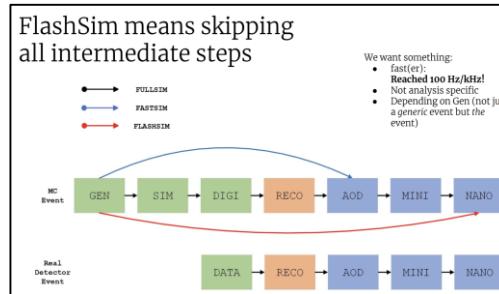
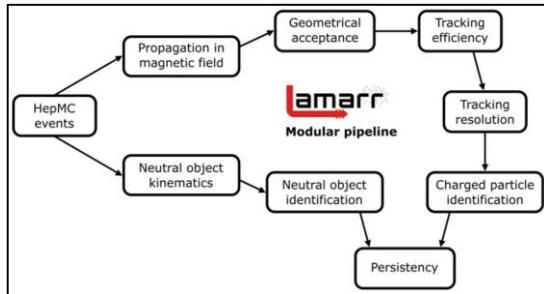


Hardware	Simulator	Time / Shower [ms]	Speed-up
CPU	GEANT4	$4082 \pm 170$	$\times 1$
	CALOLOUDS	$3509 \pm 220$	$\times 1.2$
GPU	CALOLOUDS	$38 \pm 3$	$\times 107$



# End-to-end 快速模拟

- ❖ Ultra-Fast Simulation。跳过 Geant4 模拟，实现从 MC Particle 到用于物理分析的高级对象的模拟
  - 例如 LHCb 的 [Lamarr](#), CMS 的 [FlashSim](#)



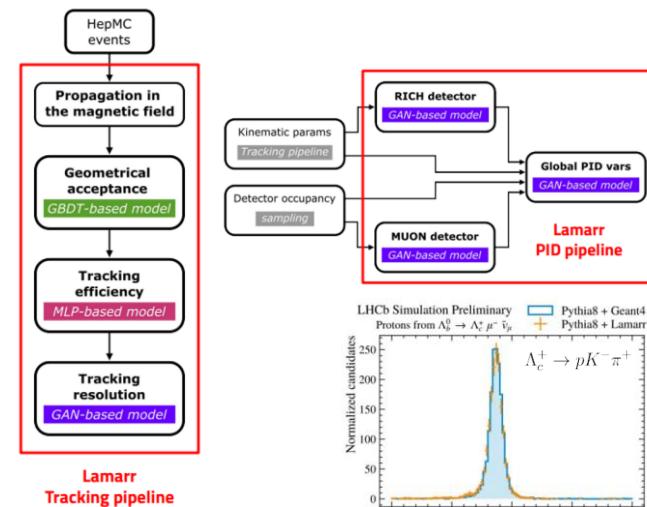
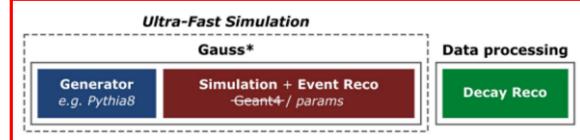
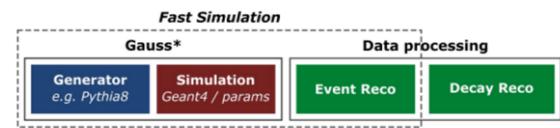
- ❖ 大部分的模拟是基于机器学习的：

- 使用 GBDT 模拟几何的 acceptance
- 使用 MLP 模拟 tracking 效率
- 使用 GAN 模拟 tracking 分辨率、PID

- ❖ 对于 fake object 或者粒子之间关联的问题需要额外处理：

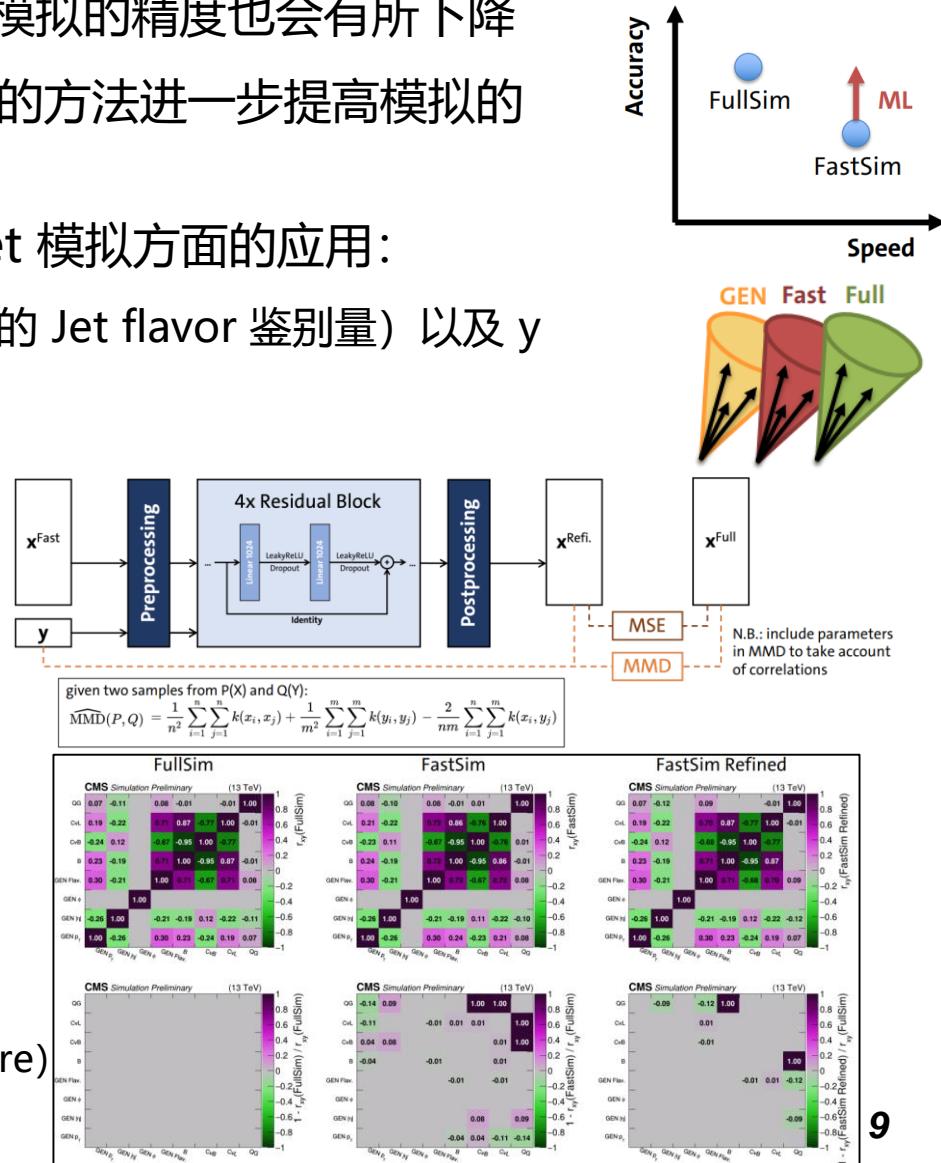
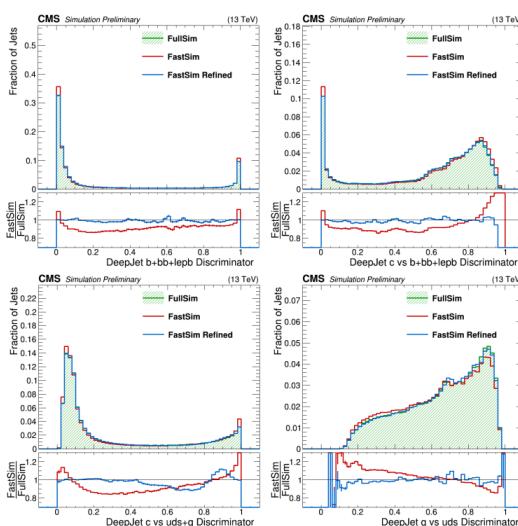
- 例如，n 个产生的光子到 m 个重建的 cluster 的模拟。可以类比语言翻译问题

- ❖ 快速模拟可以在探测器设计、机器学习训练、系统误差研究等方面减轻 CPU 的压力。其不会完全取代 Geant4



# 快速模拟物理性能的优化

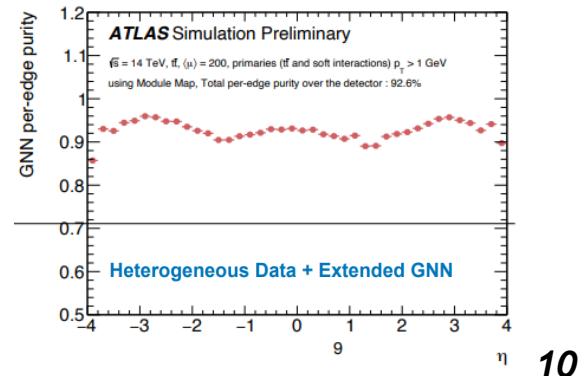
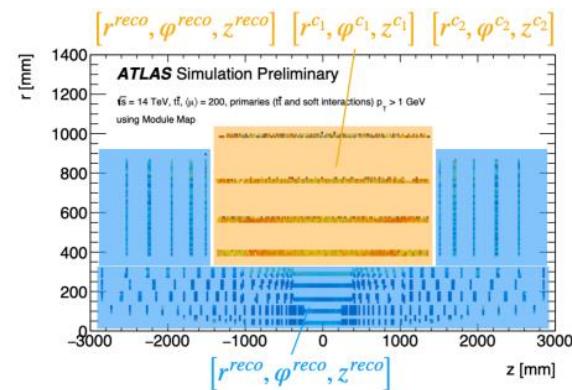
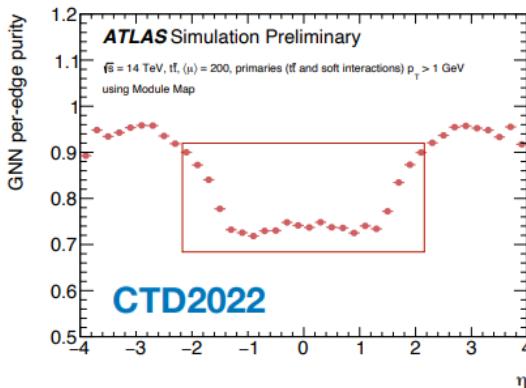
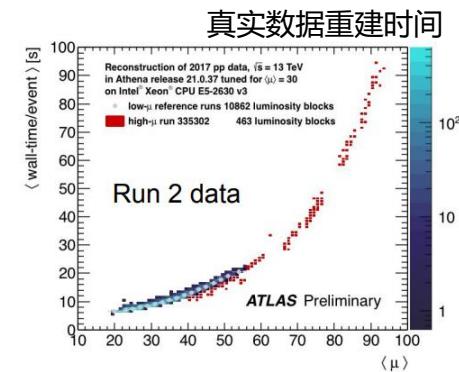
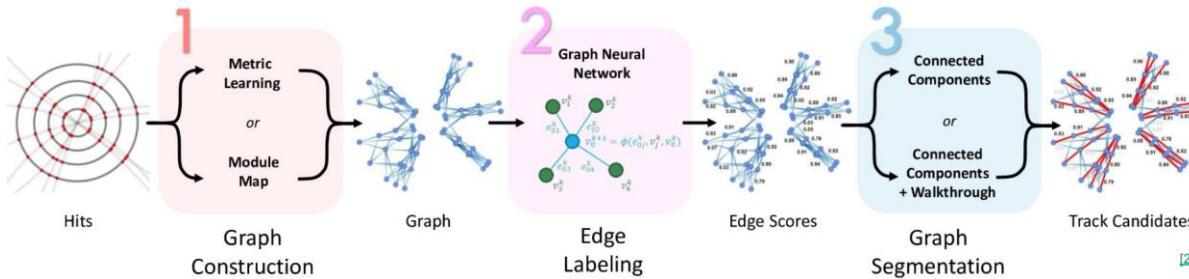
- 虽然快速模拟能够节约计算资源，但模拟的精度也会有所下降
- 可以采用 Reweighting 或 Refining 的方法进一步提高模拟的精度
- CMS 实验展示了 Refining 方法在 Jet 模拟方面的应用：
  - 网络输入： $x^{\text{Fast}}$  (4 个快速模拟得到的 Jet flavor 鉴别量) 以及  $y$  (Gen Jet 的  $p_T$ ,  $\eta$ , flavor)
  - 网络输出：经过 refined 的  $x$  值



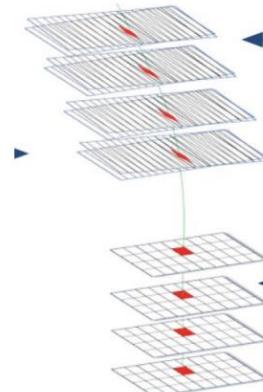
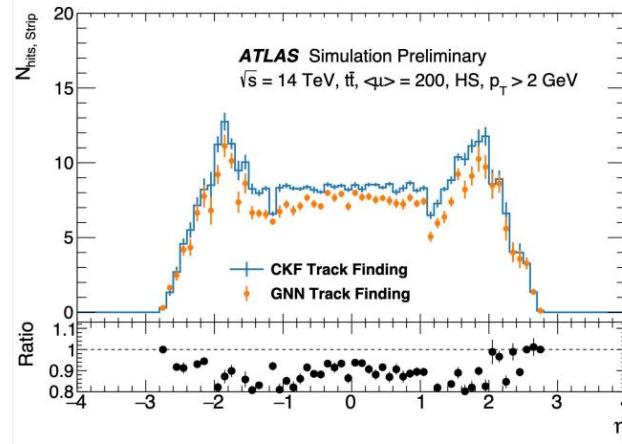
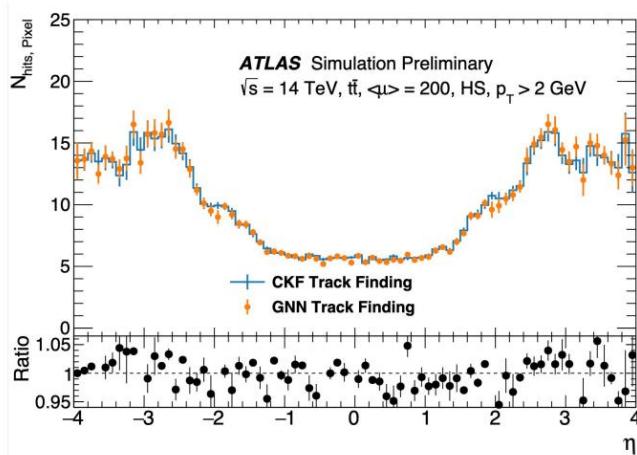
- 扩展用于其它量的 refining (e.g. jet substructure)
- 直接 refining 到真实数据？

# 径迹重建

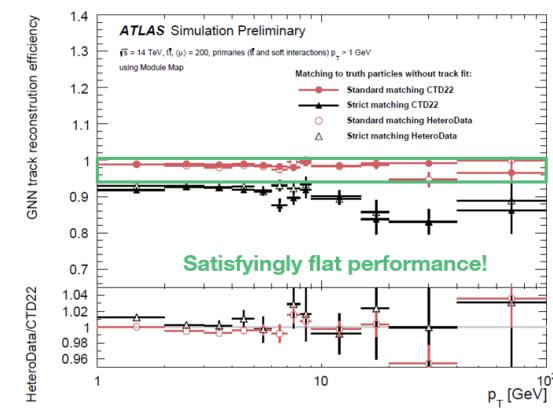
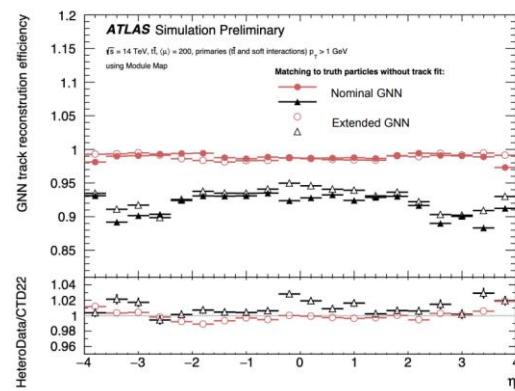
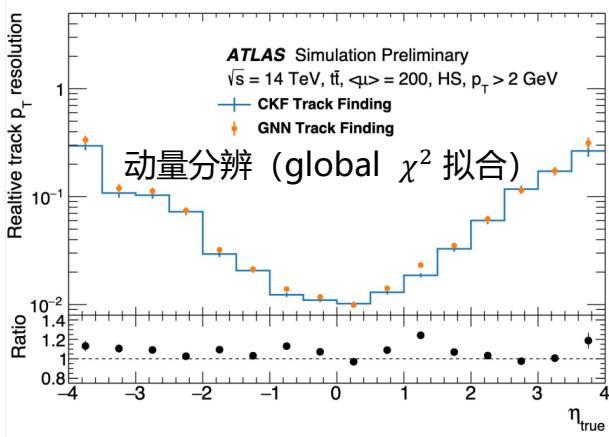
- ❖ 由于带电径迹重建的重要性，其一直是机器学习研究的热点之一
- ❖ 其主要目的是提升重建速度（例如在线重建）、物理性能
- ❖ ATLAS 实验研究了基于 GNN 的 ITK 径迹重建：
  - 在线：将模型部署到 FPGA 上，加快径迹重建速度
  - 离线：节约计算资源，径迹重建时间占总重建时间~40%



# 径迹重建



- ❖ 比较 GNN 和 CKF 方法的径迹上击中数目，pixel 基本一致，strip 偏少：
  - 可能有的 strip missing 的击中，导致被 GNN 重建忽略



Relative track  $p_T$  resolution is measured as the multiplication of  $p_T^{\text{true}}$  and the RMS of the pull distribution of  $(q/p_T^{\text{reco}} - q/p_T^{\text{true}})/q/p_T^{\text{true}}$ .

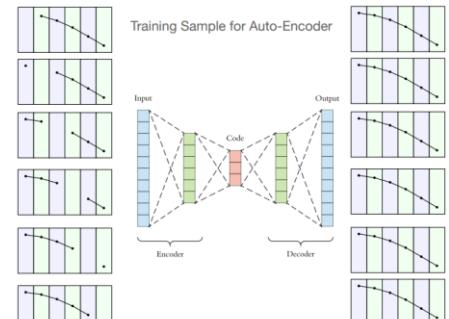
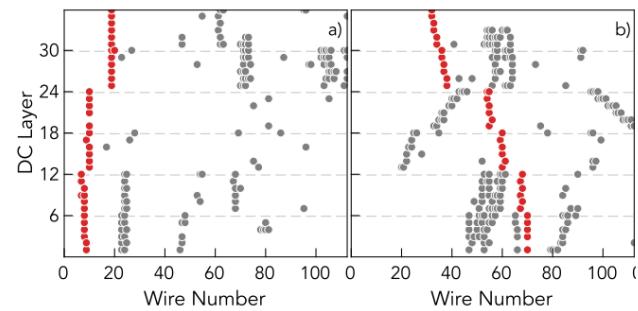
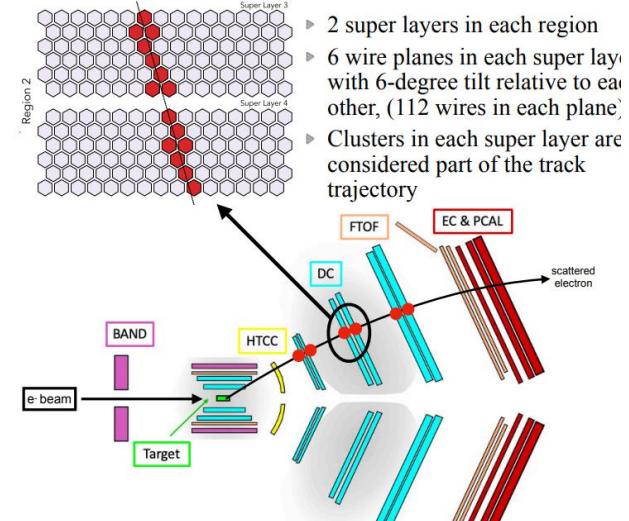
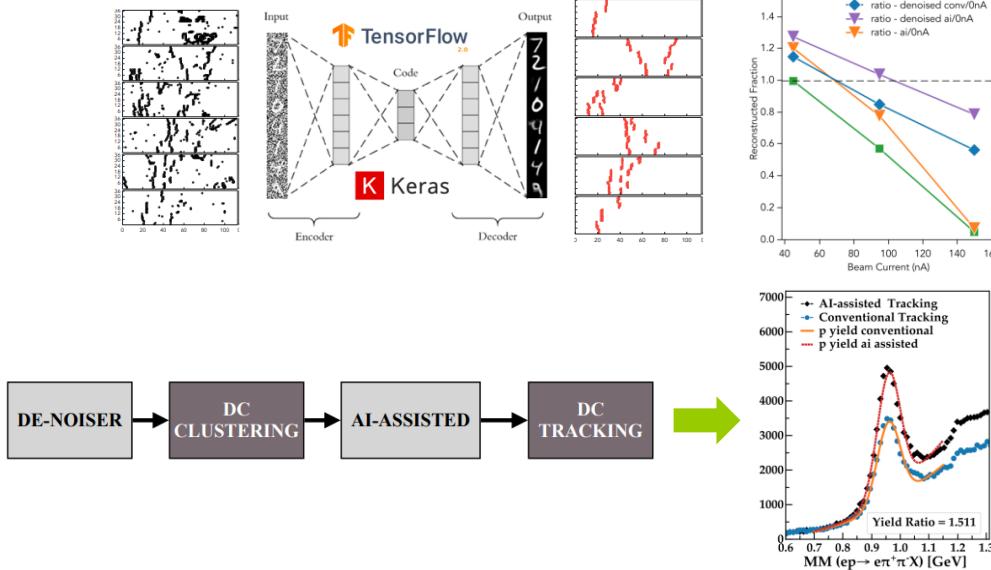
- GNN track reconstruction efficiency calculated with two matching schemes:
- Red circle ("standard matching") : > 50% of the spacepoints in the reconstructed track are matched to a true track
  - Black triangle ("strict matching") : 100% of the spacepoints in the reconstructed track are matched to a true track

- Fake rate is  $O(10^{-3})$  using standard truth matching

# 径迹重建

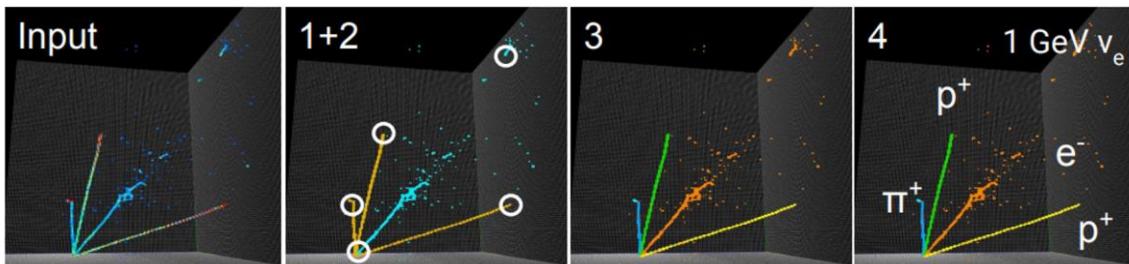
❖ JLab 的 CLAS12 实验 (打靶实验) 展示了在机器学习的辅助下径迹重建性能的提升

- 1, 利用 MLP 去判断不同的超层径迹段是否来自同一条径迹, 提升径迹重建速度~30%
- 2, 利用 MLP Auto-Encoder 去补全缺失的径迹段, 单径迹重建效率可以提升~10% (双径迹~20%)
- 3, 随束流强度的增加 (噪声增加) 径迹重建效率会明显下降。在降噪网络 (CNN Auto-Encoder) 的帮助下, 可以大幅缓解噪声带来的影响

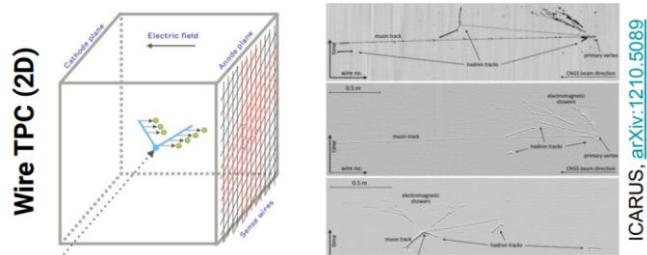


# The Liquid Argon TPC (LArTPC) 重建

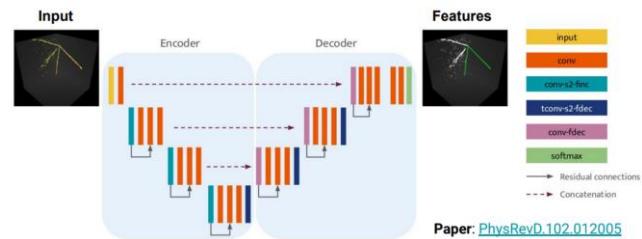
- ❖ 研究基于机器学习的 End-to-end 重建
  - 利用探测器测量得到的图像信息，实现 pixel level 和 particle level 的重建
- ❖ Pixel level: 利用 UResNet 网络实现对 pixel 的分类，例如是否为反应顶点，是否来自shower 或 track 等
- ❖ Particle level: 利用 GNN 网络实现对 pixel 的聚类以及最终粒子的重建和 PID



The modern Particle Imaging Detector

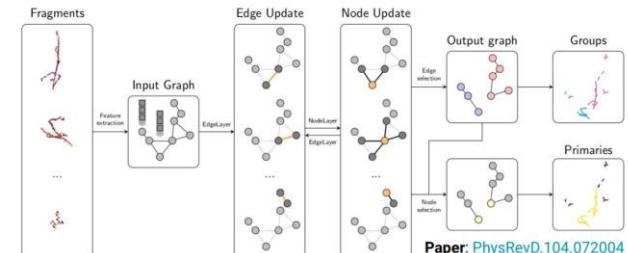


UResNet ([UNet](#) + [ResNet](#) + [Sparse Conv.](#)) as the backbone feature extractor



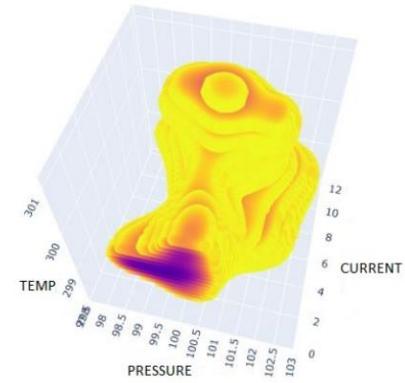
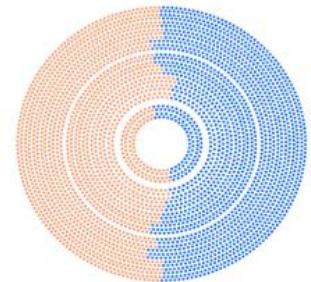
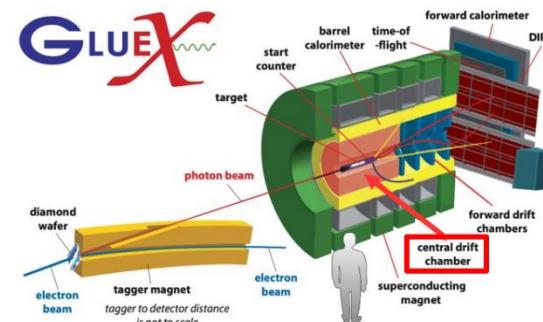
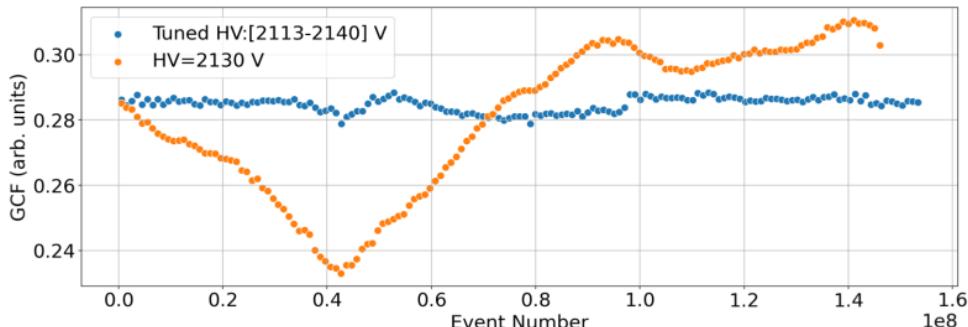
Graph Particle Aggregator (GrapPA)

Graph Neural Network: fragments/particles (nodes), correlations (edges)



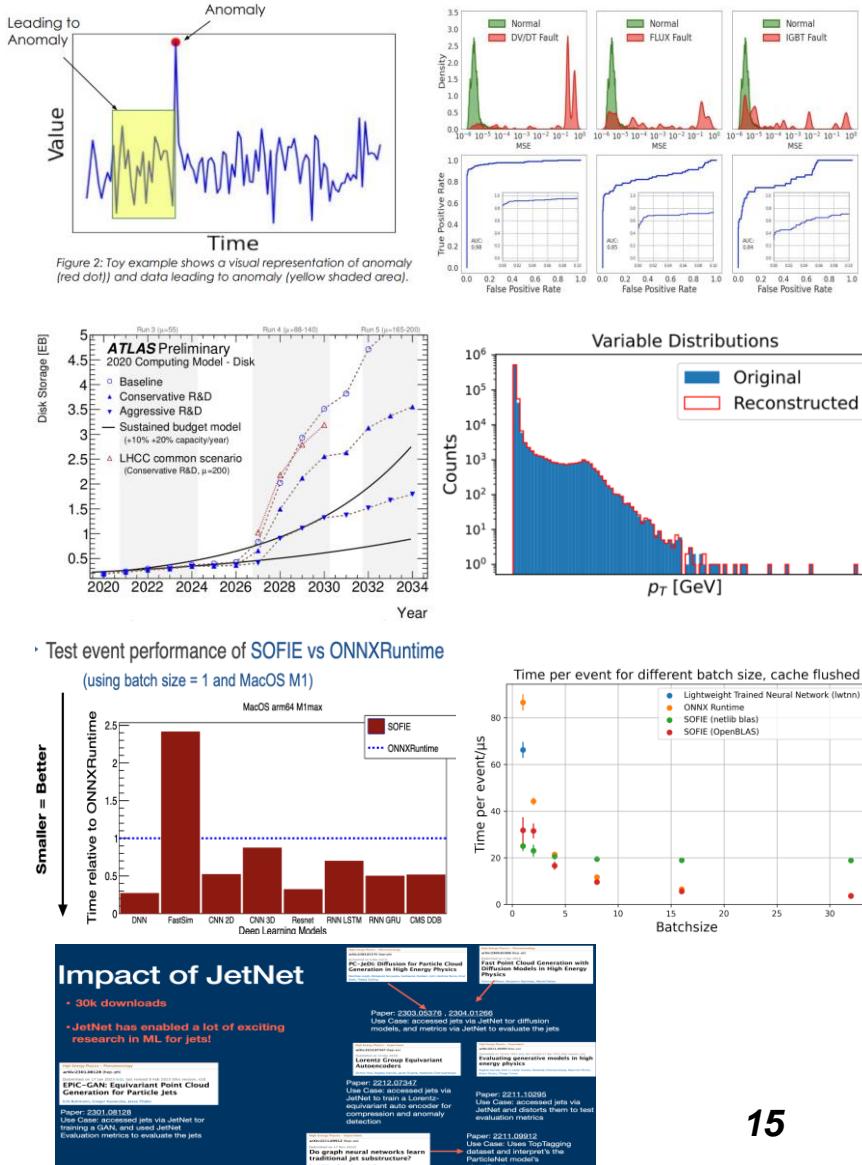
# 在线刻度

- ❖ 刻度对获得高质量的分析数据至关重要，一般是在离线环境进行
- ❖ 如果能实现在线环境的刻度，则能得到更高质量的实验数据
- ❖ JLab 的 [GlueX](#) (光子打靶实验) 利用机器学习方法 (Gaussian Process)，根据漂移室气压、温度以及束流情况对漂移室的工作高压进行在线调整
  - 将漂移室分成 2 左右部分，左边是固定高压，右边是机器学习控制的高压 (每 5 分钟自动调整一次)
  - 该机器学习方法还能给出需调整高压值的不确定程度，确保高压的调整是合理、可控的



# 其它

- ❖ 异常检测：基于 VAE 网络实现对 SNS 加速器相关模块异常的提前预测，减少加速器维修时间
- ❖ 数据压缩：为了解决未来 HL-LHC 实验存储空间不足的问题，研究了基于 Auto-Encoder 的数据压缩方法，结果 promising
- ❖ 模型部署：ROOT/SOFIE 可以根据用户提供的网络模型 (onnx, Pytorch, Keras) 产生相应的 C++ 代码，将模型部署在 C++ 环境中，实现高性能的推理（性能和ONNXRuntime 相当）
- ❖ JetNet: 提供公共数据集、数据分析工具、模型性能评价指标，让用户将精力集中在模型的构建和训练



# 总结

---

- ❖ 机器学习已经广泛应用于各个实验的各个方面，具有广阔的前景
- ❖ 基于机器学习的模拟是目前研究的热点之一
  - 量能器快速模拟，End-to-end 快速模拟
  - 实验数据驱动的模拟可以减小系统误差（BES3  $dE/dx$ 、量能器模拟等）
- ❖ 面对未来高噪声水平的情况（例如 BEPCII 升级，STCF 实验），机器学习在降低漂移室噪声、提高寻迹效率方面应该能发挥比较重要作用
- ❖ 在线刻度能够提高实验数据的质量，应该是未来发展的方向之一

谢谢！

# Backup

# Detector simulation

---

- ❖ Calorimeter Fast simulation:

- [FastCaloGAN: a fast simulation of the ATLAS Calorimeter with GANs](#)
- [gaede\\_chep23\\_caloml\\_v01 \(jlab.org\)](#)
- [Generating Accurate Showers in Highly Granular Calorimeters Using Normalizing Flows](#)
- [Fast and Accurate Calorimeter Simulation with Diffusion Models](#)
- [Transformers for Generalized Fast Shower Simulation](#)

- ❖ Ultra-fast simulation

- [THE LHCb ULTRA-FAST SIMULATION OPTION, LAMARR](#)
- [Flashsim: an ML simulation framework](#)

- ❖ [Refining fast simulation using machine learning](#)

- ❖ [Hadronic Simulation with conditional Masked Autoregressive Flow](#)

# Reconstruction

## ❖ PID:

- [Particle identification with machine learning in ALICE Run 3](#)
- [Pion/Kaon Identification at STCF DTOF Based on Classical/Quantum Convolutional Neural Network](#)
- [Fast Inclusive Flavor Tagging at LHCb](#)
- [A deep-learning reconstruction algorithm for cluster counting](#)

## ❖ Vertex:

- [Advances in developing deep neural networks for finding primary vertices in proton-proton collisions at LHC](#)

## ❖ Tracking:

- [An Object Condensation Pipeline for Charged Particle Tracking](#)
- [End-to-End Geometric Representation Learning for Track Reconstruction](#)
- [BESIII track reconstruction algorithm based on machine learning](#)
- [Track Identification for CLAS12 using Artificial Intelligence](#)
- [Novel fully-heterogeneous GNN designs for track reconstruction at the HL-LHC](#)
- [HyperTrack: neural combinatorics for high energy physics](#)

## ❖ Cluster:

- [Improved Clustering in the Belle II Electromagnetic Calorimeter with Graph Neural Networks](#)
- [Development of particle flow algorithms based on Neural Network techniques for the IDEA calorimeter at future colliders](#)

## ❖ LArTPC:

- [Neutrino interaction vertex-finding in a DUNE far-detector using Pandora deep-learning](#)
- [Scalable, End-to-End, Machine-Learning-Based Data Reconstruction Chain for Particle Imaging Detectors](#)
- [Graph Neural Network for 3D Reconstruction in Liquid Argon Time Projection Chambers](#)

# Online

---

- ❖ Trigger:
  - [Applications of Lipschitz neural networks to the Run 3 LHCb trigger system](#)
  - [Development of a Deep-learning based Full Event Interpretation \(DFEI\) algorithm for the future LHCb trigger](#)
- ❖ Continual Learning :
  - [The Deployment of Realtime ML in Changing Environments](#)
  - [Embedded Continual Learning for HEP](#)
- ❖ FPGA:
  - [Symbolic Regression on FPGAs for Fast Machine Learning Inference](#)
  - [Machine Learning for Real-Time Processing of ATLAS Liquid Argon Calorimeter Signals with FPGAs](#)
  - [Acceleration of a CMS DNN based Algorithm](#)

# Analysis

---

- ❖ Efficient search for new physics using Active Learning in the ATLAS Experiment
- ❖ Using a Neural Network to Approximate the Negative Log Likelihood Distribution
- ❖ A method for inferring signal strength modifiers by conditional invertible neural networks

# Anomaly Detection

---

- ❖ Multi-Module based VAE to predict HVCM faults in the SNS accelerator
- ❖ Resilient Variational Autencoder for Unsupervised Anomaly Detection at the SLAC Linac Coherent Light Source

# General

---

- ❖ Uncertainty Aware Machine Learning Models for Particle Physics Applications
- ❖ Exploring Interpretability of Deep Neural Networks in Top Tagging
- ❖ JetNet library for machine learning in high energy physics
- ❖ New developments of TMVA/SOFIE: Code Generation and Fast Inference for Graph Neural Networks
- ❖ Machine learning based compression for scientific data