

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



国家高能物理科学数据中心  
National HEP Data Center



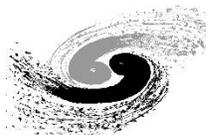
高能所计算中心  
IHEP Computing Center

# 面向HEPS的 IO方法设计和优化

汇报人：符世园

<fusy@ihep.ac.cn>

中国科学院高能物理研究所



# 目录



国家高能物理科学数据中心  
National HEP Data Center



高能物理计算中心  
HEP Computing Center

- 高能同步辐射光源HEPS
- 优化方法
- 架构设计
- 下一步计划





## ●HEPS预计产生海量原始实验数据

- 包含14条线站
- 多模态、跨尺度、高帧率
- 面向多学科、多方法学



| 线站名称 | 每天数据量峰值 (TB) | 每天数据量均值 (TB) |
|------|--------------|--------------|
| B1   | 600          | 200          |
| B2   | 500          | 200          |
| B3   | 8            | 3            |
| B4   | 10           | 3            |
| B5   | 10           | 1            |
| B6   | 2            | 1            |
| B7   | 1000         | 250          |
| B8   | 80           | 10           |
| B9   | 20           | 5            |
| BA   | 35           | 10           |
| BB   | 400          | 50           |
| BC   | 1            | 0.2          |
| BD   | 10           | 1            |
| BE   | 25           | 11.2         |
| BF   | 1000         | 60           |
| 总计   |              | 805          |



## 海量数据为科学计算带来极大压力

### 目前的数据处理流程 (以B7为例)

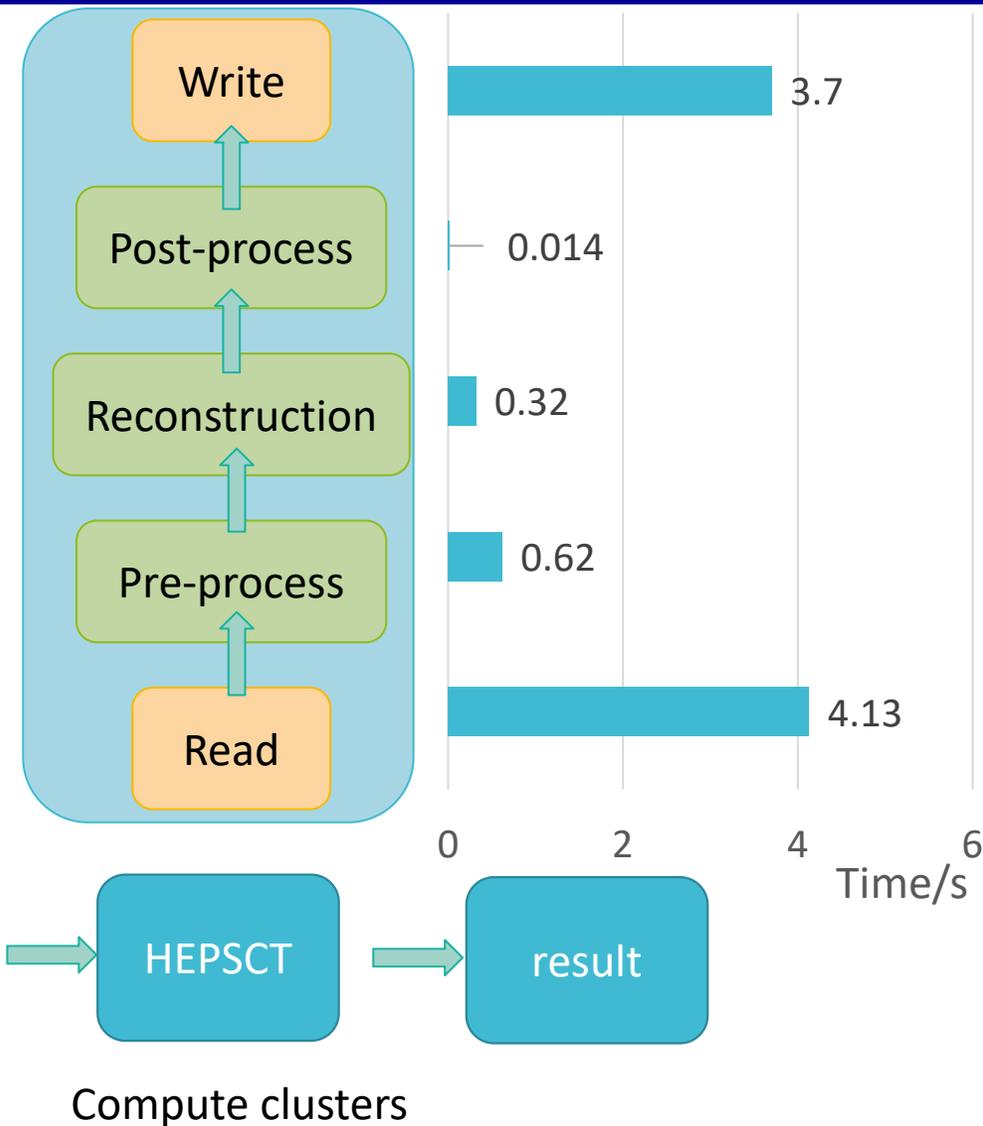
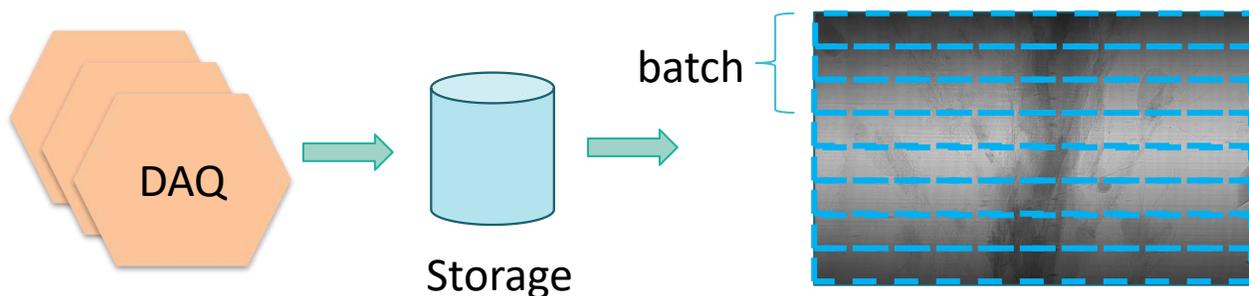
◆ B7主要计算任务是CT重建 (HEPSCT)

➢ 重建最小单位 (unit) : 所有图像的同一行数据

◆ 计算过程分为多个batch, 相互独立

◆ 读写占据绝大部分时间

➢ IO瓶颈严重影响计算效率





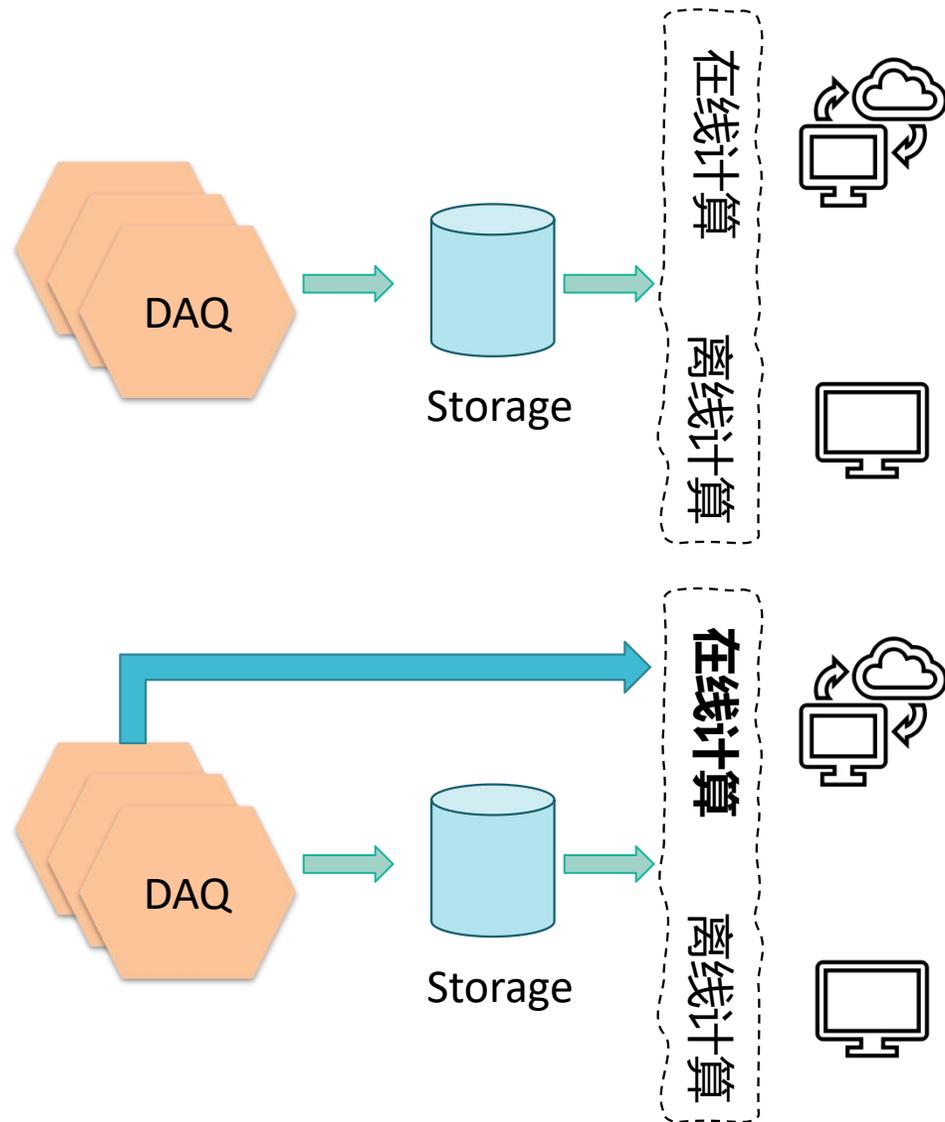
## • 优化方法

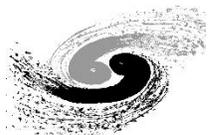
### ■ STEP 1. 批处理IO加速

- ◆ 目前数据处理流程：数据落盘后再读取
- ◆ 文件格式：HDF5 TIFF
- ◆ 加速方法：异步、多线程、多进程等

### ■ STEP 2. 对于在线计算引入流数据IO

- ◆ 从DAQ直接获取数据发送到计算节点
- ◆ 避免数据落盘再读取导致的时延和IO瓶颈
- ◆ 在实验级别实现所见即所得



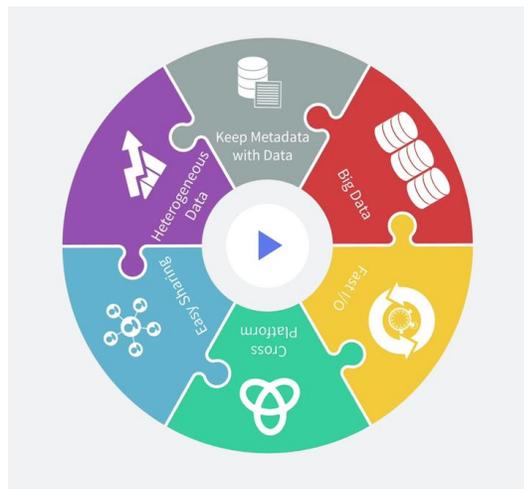


## ●数据格式：HDF5、TIFF

- HDF5：一种数据模型、文件格式和 I/O 库
  - ◆用于存储、交换、管理和归档复杂数据，包括科学、工程和遥感数据
- TIFF：图像格式

## ●IO加速方法：

- 多进程：与并行计算结合，多个batch同时计算
- 多线程：加速单个batch的数据读取
- 异步IO：读写和处理过程异步执行，加速数据处理
- HDF5分块存储
- 具体实现需要结合具体计算任务





## 异步

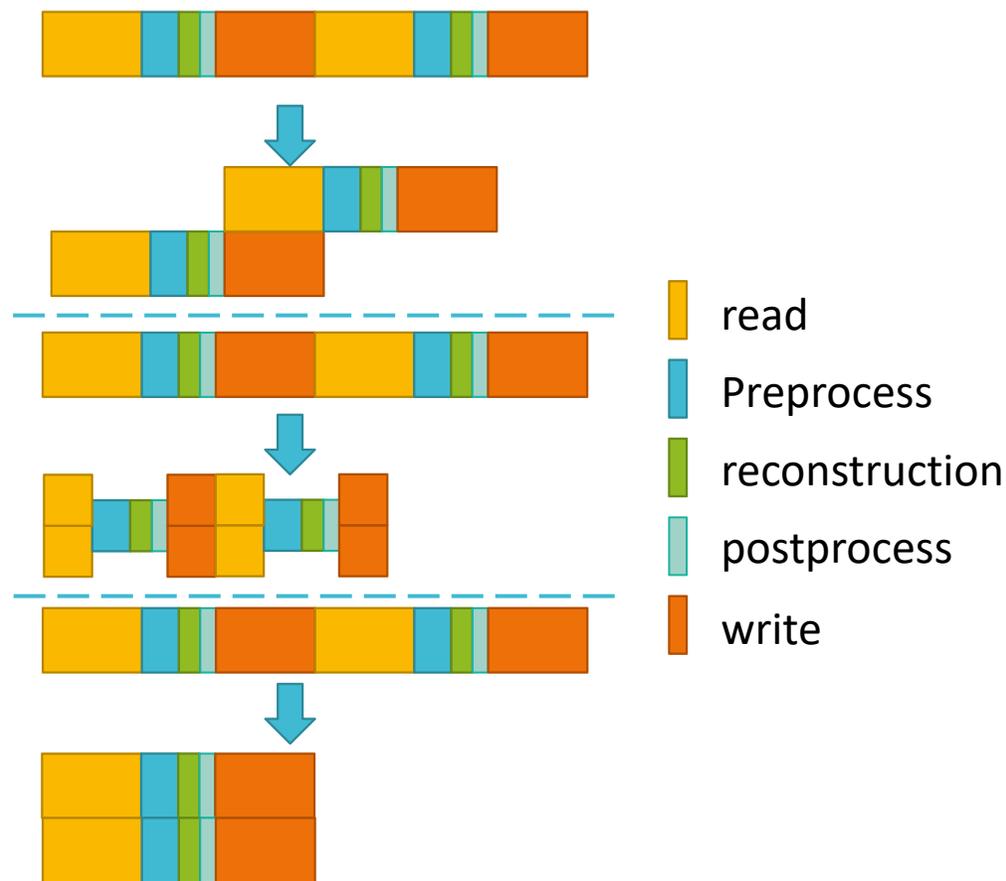
- HEPSCCT中相邻batch读写操作可以异步执行
- 加速效果: ~100s-->~75s

## 多线程

- 加速单个batch的数据读取 (TIFF)
- 第一个batch读取~10s, 后续batch读取 < 1s

## Pipeline流水线技术

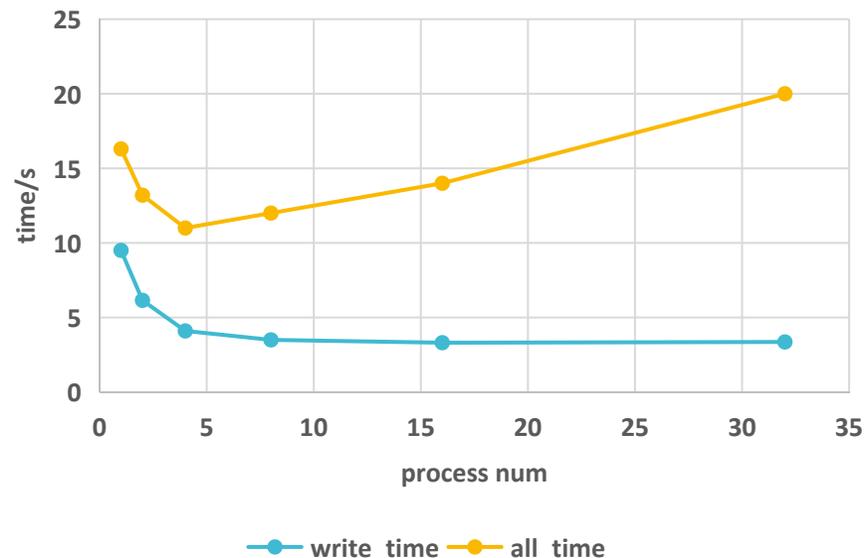
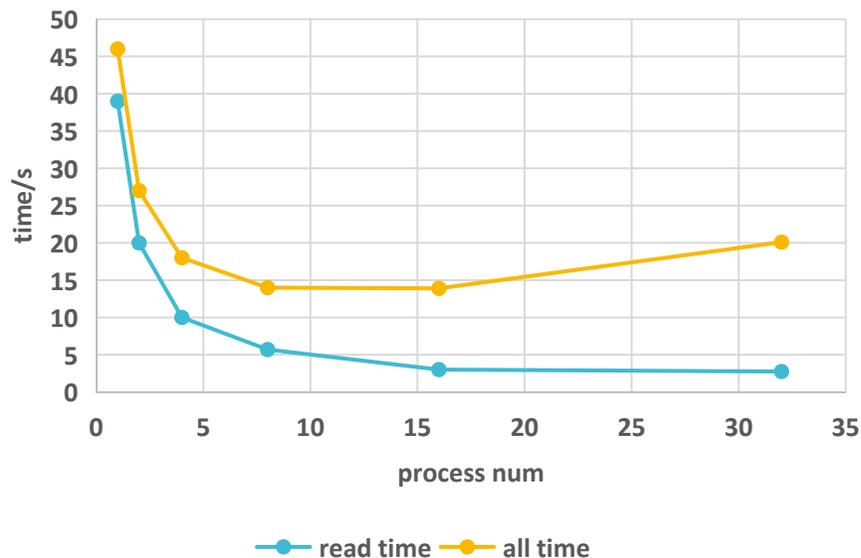
- 与并行计算结合
- 多个batch同时计算





## ●HDF5特性-并行

- 基于MPI
- 测试数据: 5000(frames)×400(rows)×500(cols) , 保存为10个HDF5文件
- 每次读取的batch大小: 500×1×500 vs. 500×10×500



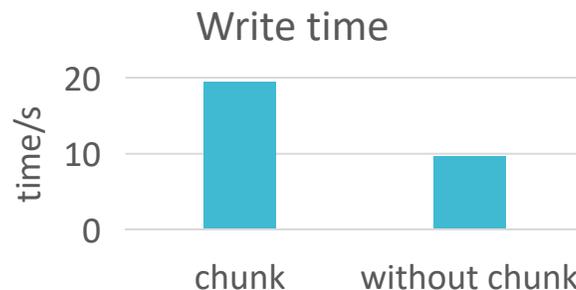
- 结论: 多进程可以有效加速HDF5读取速度





## •HDF5特性-分块chunk

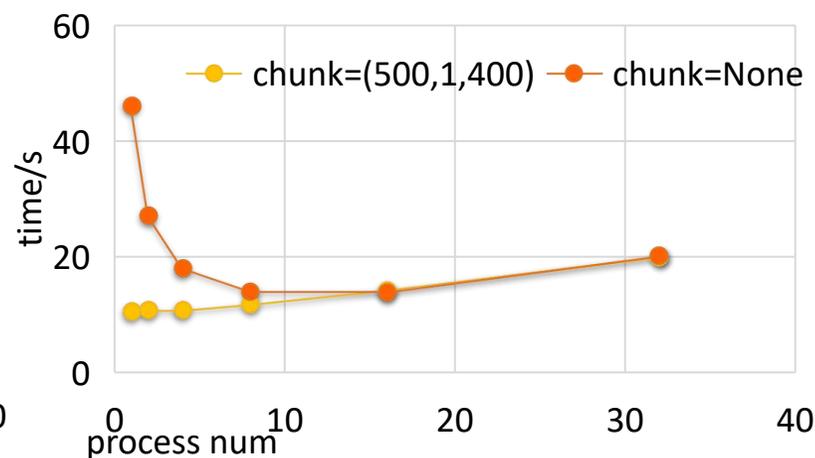
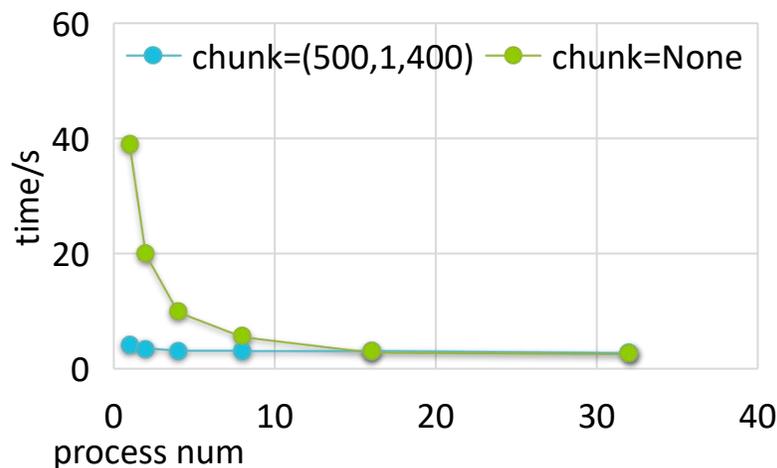
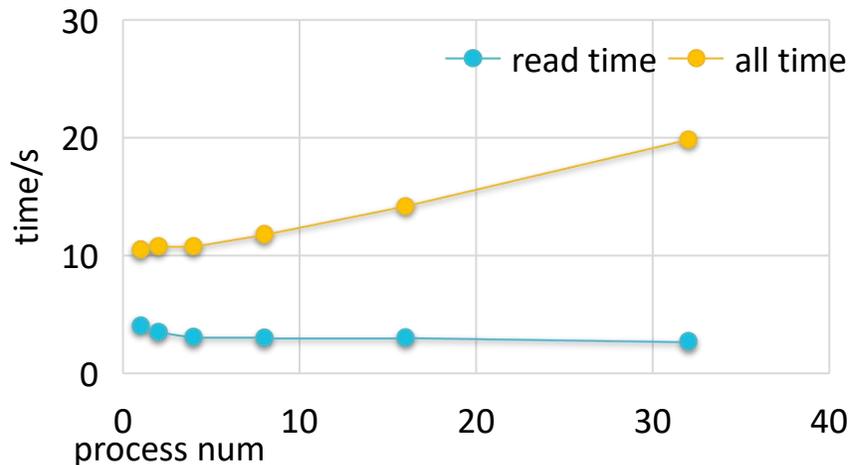
- Data: 5000(frames) × 400(rows) × 500(cols)
- chunk和读取batch大小: 500 × 1 × 500



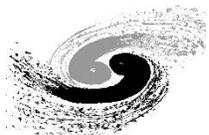
分chunk后读时间

分chunk前后read time对比

分chunk前后all time对比



- 结论：块大小和读取batch一致时可以以更少的进程数大幅加速数据读速度
  - ◆ 局限性：分块属性需要在文件写入时指定，影响文件写入效率；块大小的精确设置
  - ◆ 解决方法：多线程、多进程；块大小设置的模糊值



## 流数据IO连接DAQ与计算平台

### 面向DAQ:

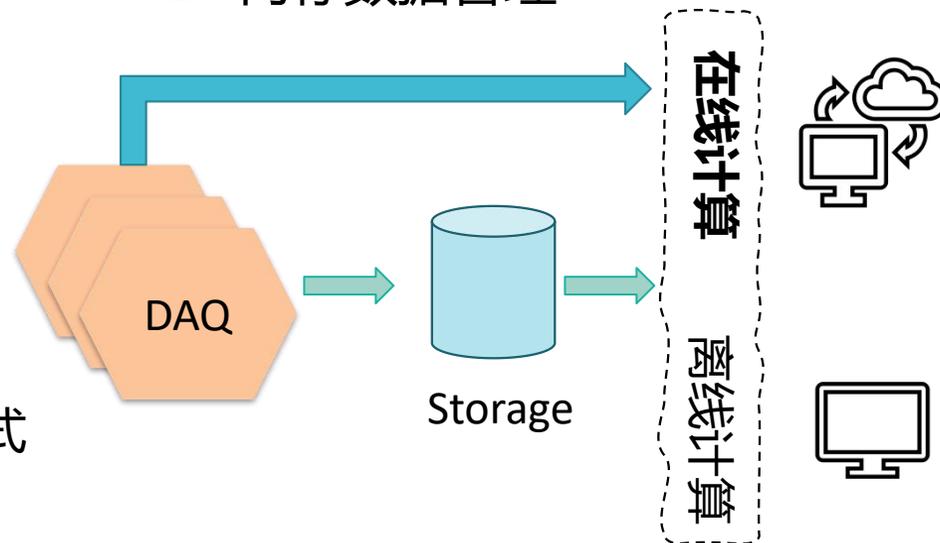
- ◆ 稳定的流数据接收器
- ◆ 大内存存储从DAQ接收的数据

### 面向计算平台

- ◆ 流数据IO接口与批处理IO接口的统一性
  - 不同计算任务、不同数据来源、不同数据格式
- ◆ 统一内存数据模型
  - 满足跨语言跨平台计算任务需求

数据流稳定接收和暂存

1. 数据流接收
2. 内存数据管理



数据访问统一化

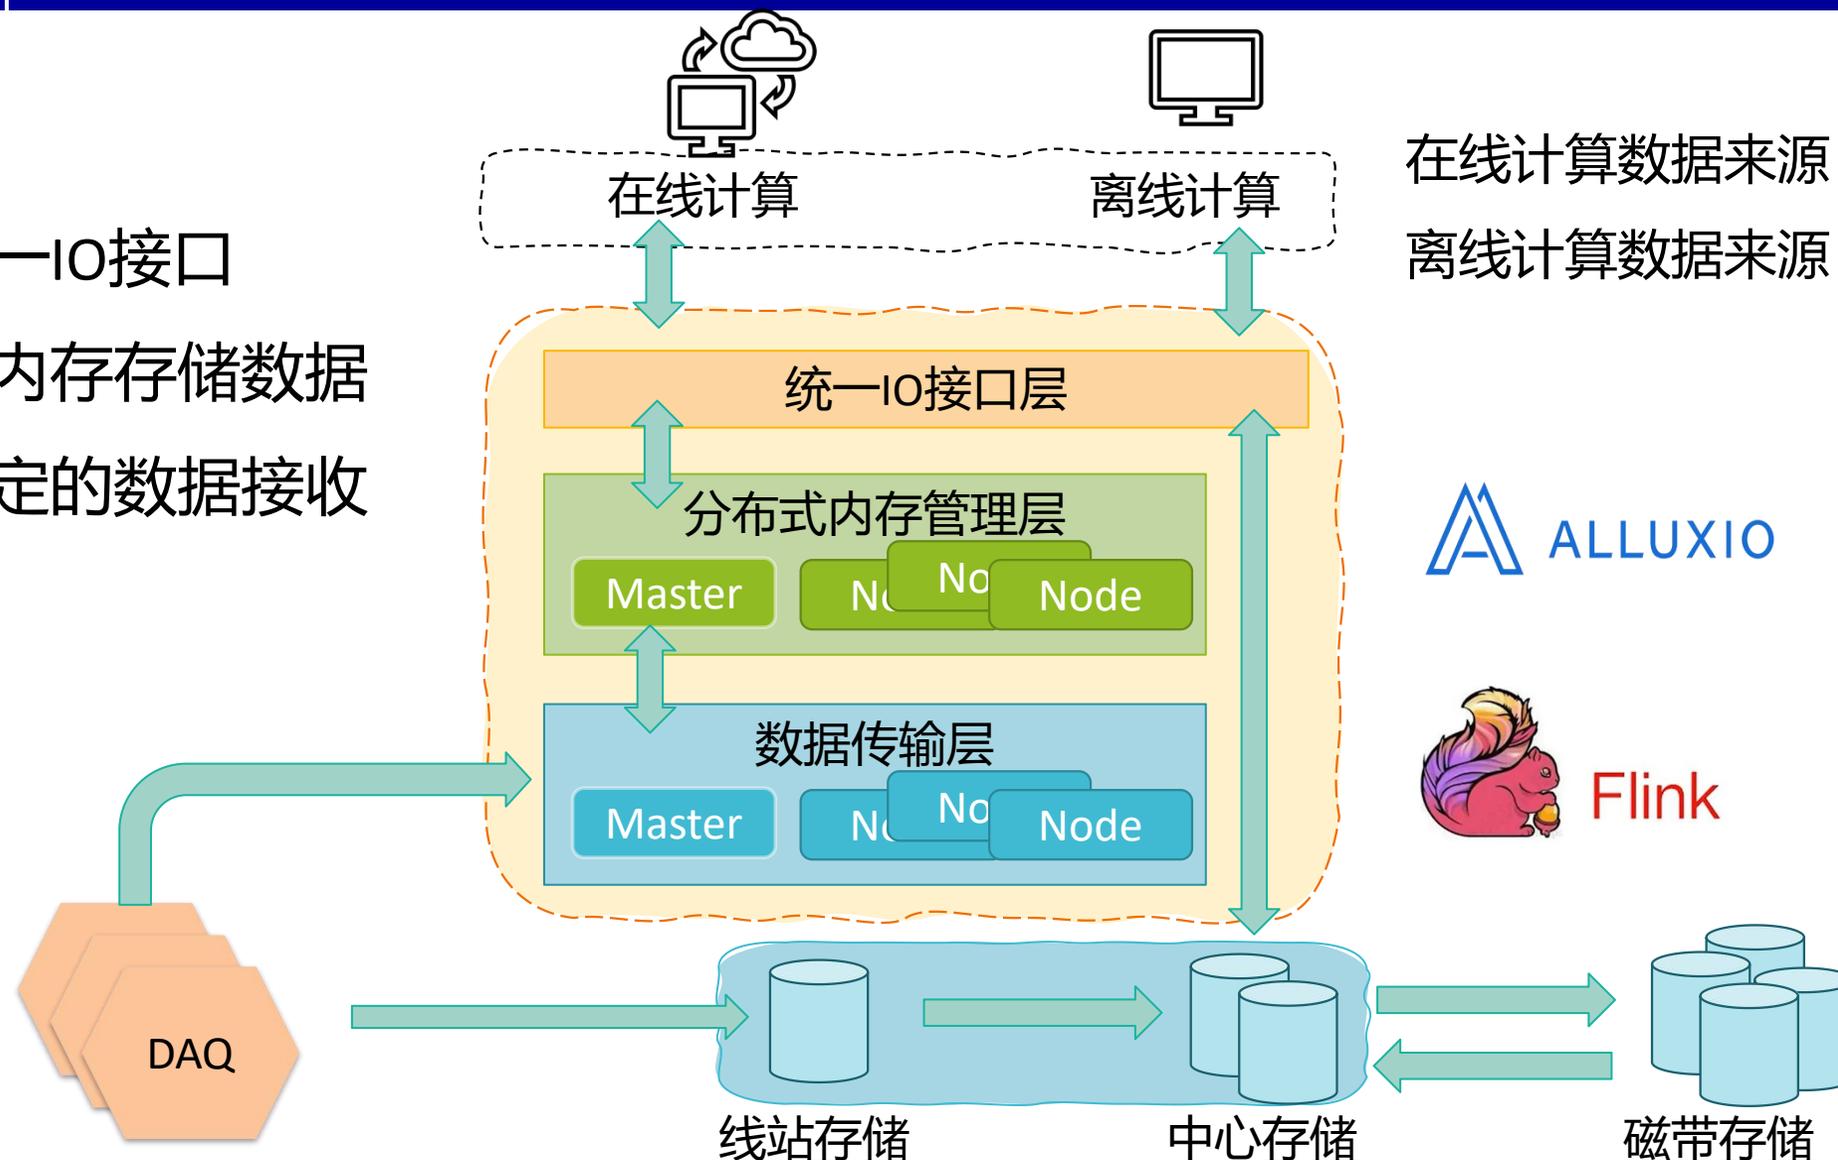
1. 数据接口一致
2. 数据模型跨平台跨语言访问
3. 兼容不同数据格式



# 整体架构设计



- 目标：
  - 统一IO接口
  - 大内存存储数据
  - 稳定的数据接收



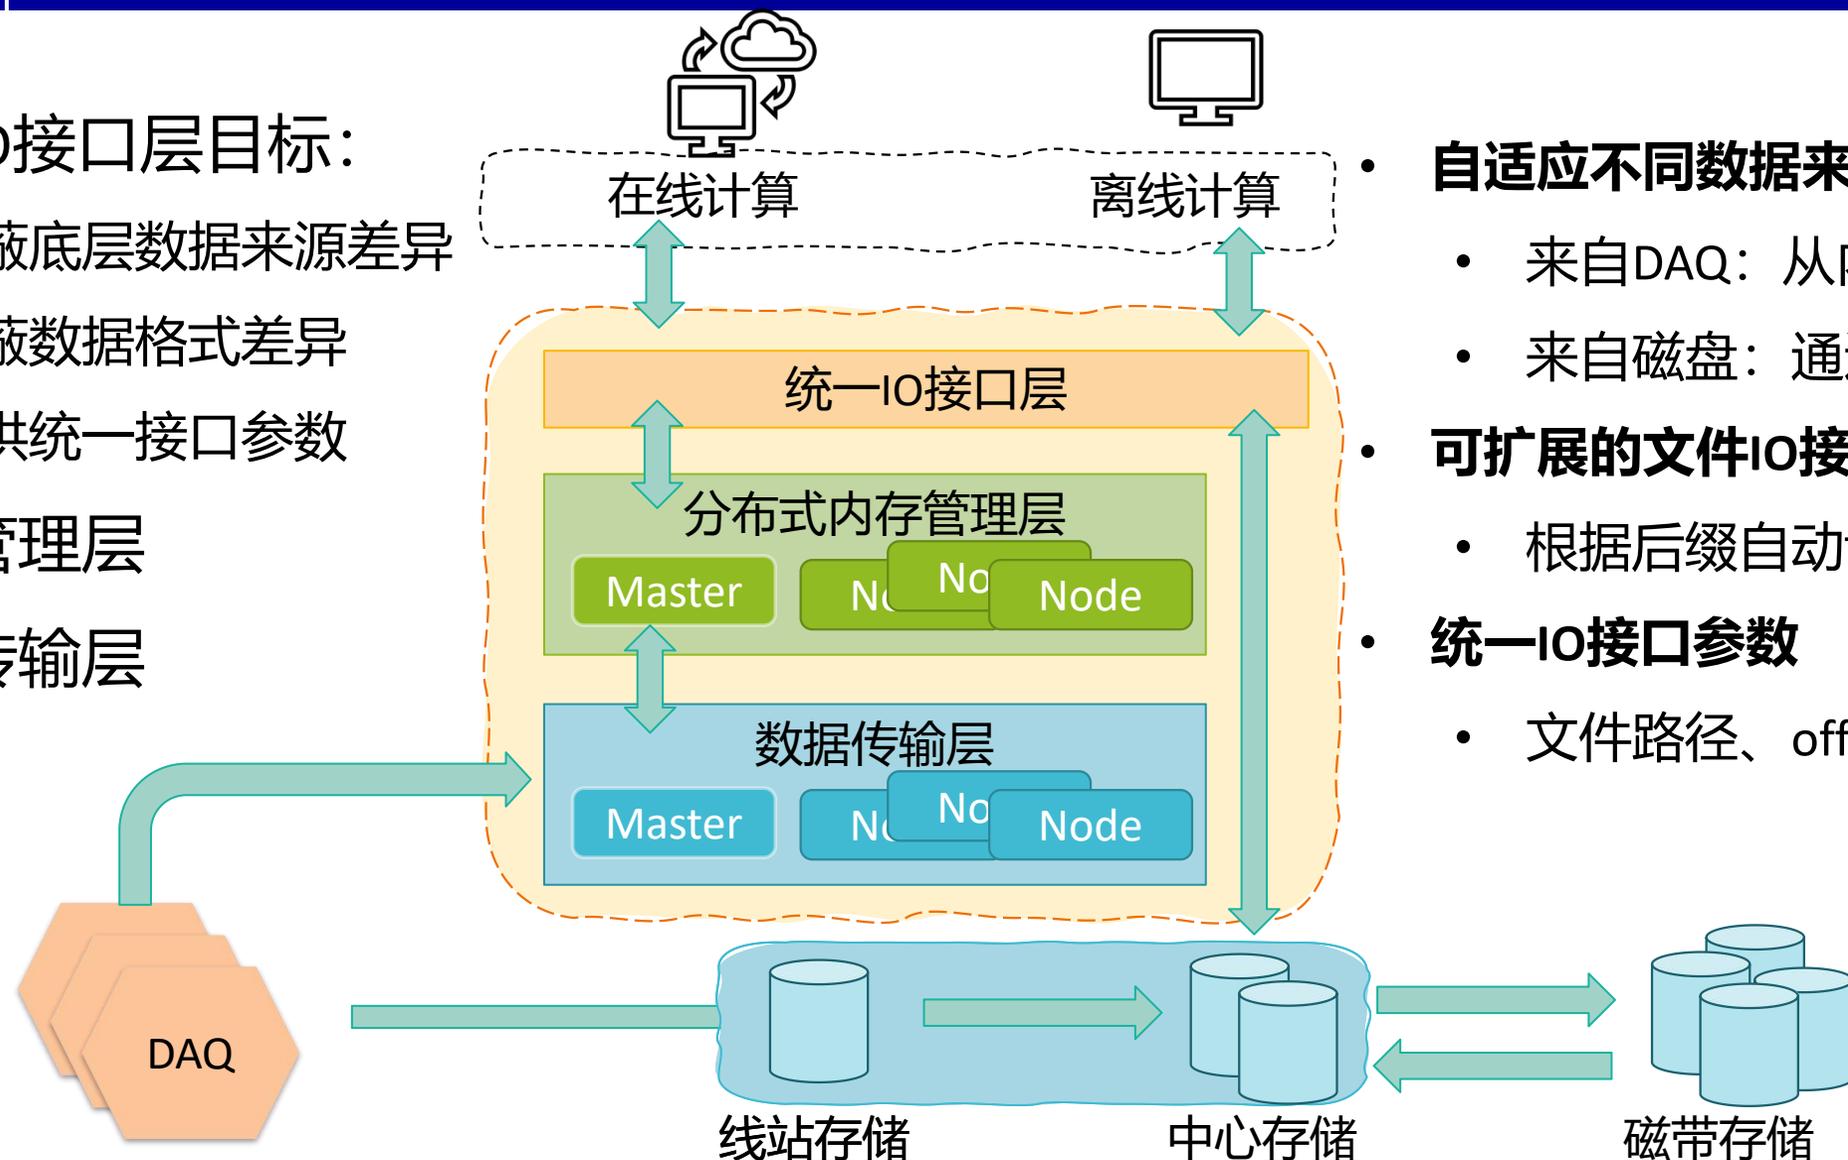
在线计算数据来源：DAQ和线站存储  
 离线计算数据来源：中心存储



# 架构设计-统一IO接口



- 统一IO接口层目标:
  - 屏蔽底层数据来源差异
  - 屏蔽数据格式差异
  - 提供统一接口参数
- 内存管理层
- 数据传输层



## 自适应不同数据来源

- 来自DAQ: 从内存中获取数据
- 来自磁盘: 通过挂载的方式获取

## 可扩展的文件IO接口

- 根据后缀自动调用对应IO接口

## 统一IO接口参数

- 文件路径、offset、batch\_size等



# 架构设计-内存管理



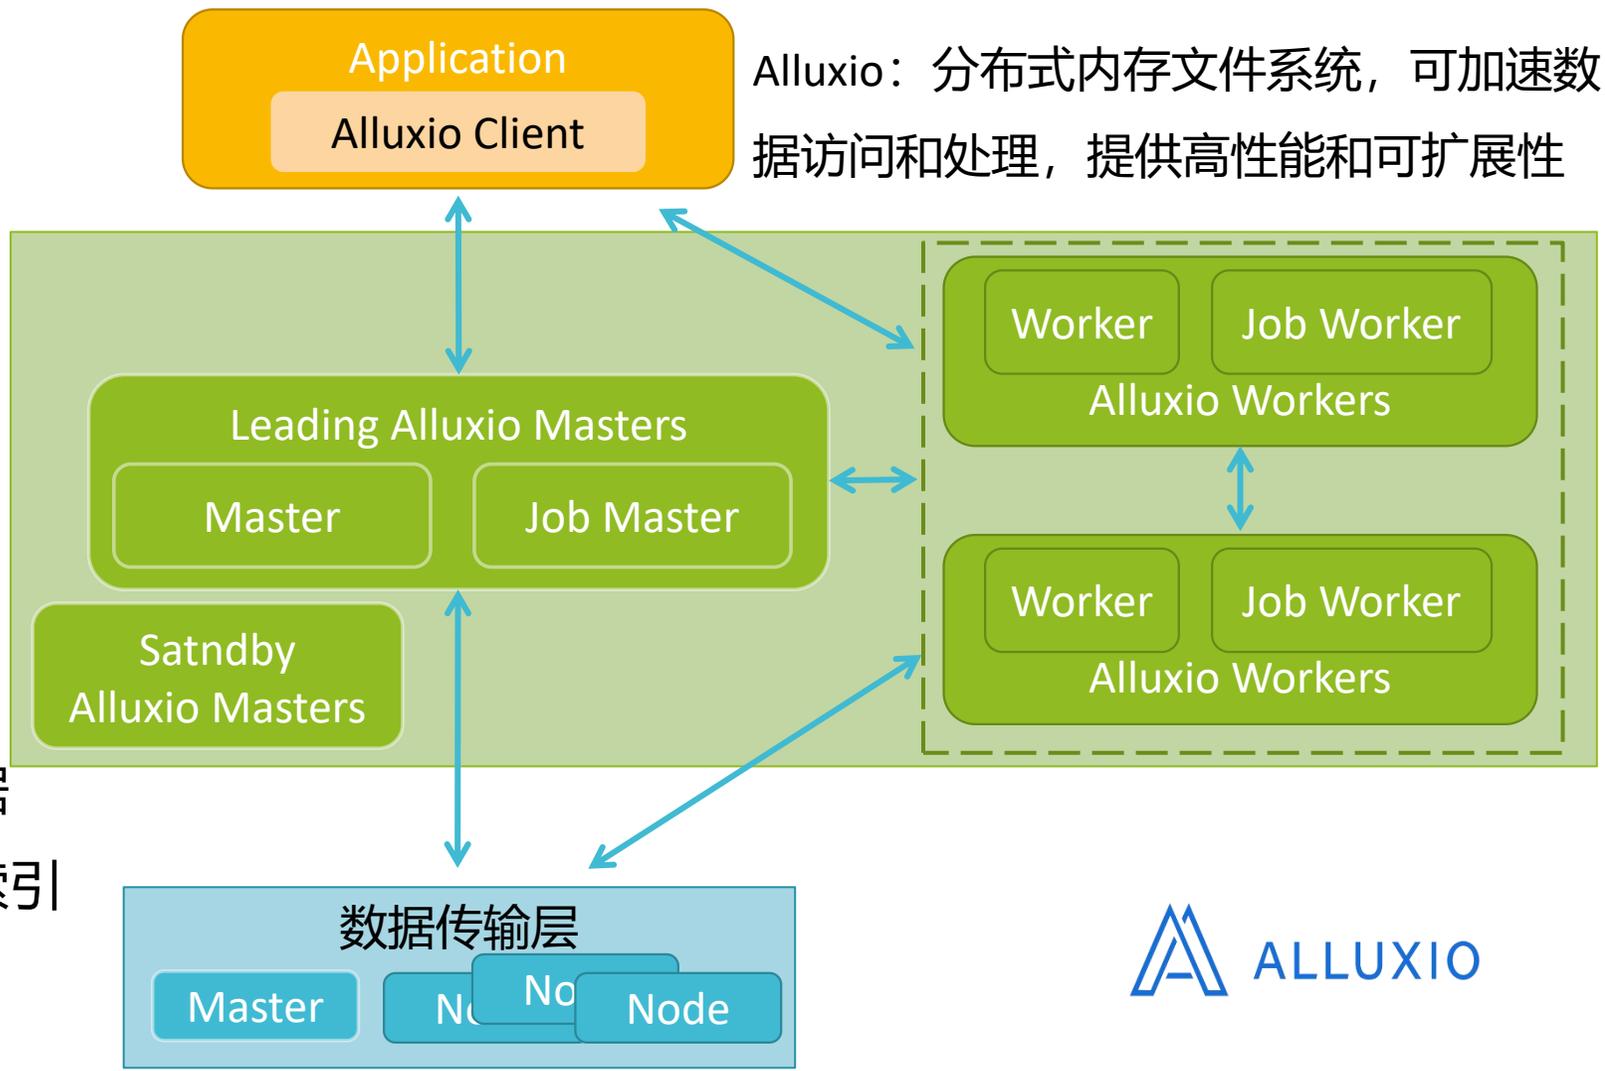
## 内存管理层目标:

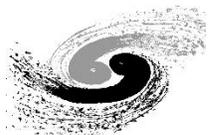
- ✓ 暂存实验数据-->分布式内存
- ✓ 建立临时索引-->元数据管理
- 统一内存数据模型



## 基于Alluxio的分布式内存管理

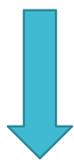
- 通过分布式内存节点存储流数据
- 注册临时目录为数据建立唯一索引



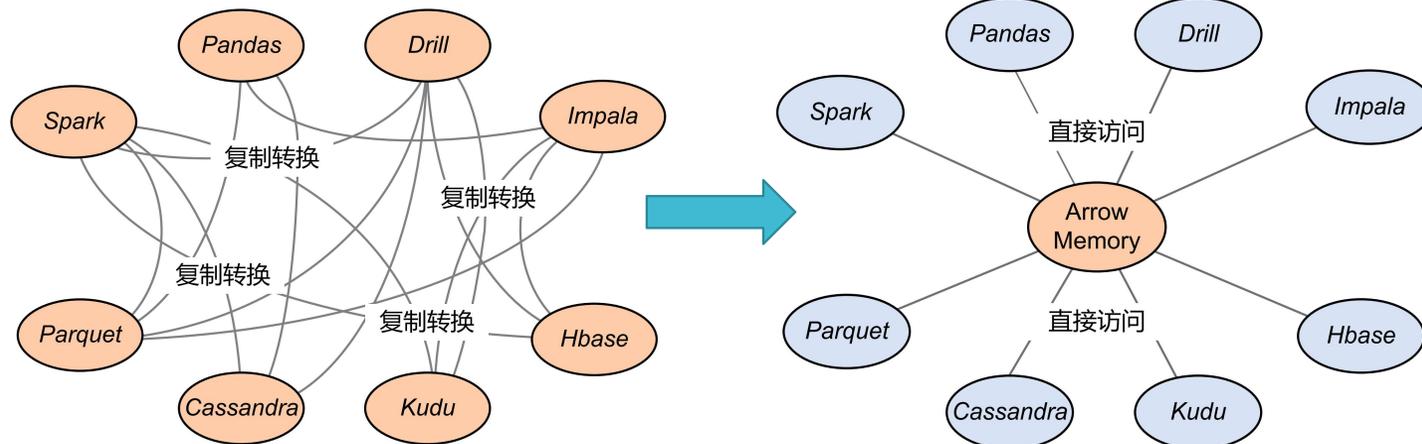


## 内存管理层目标:

- 暂存实验数据
- 建立临时索引
- ✓ 统一内存数据模型-->跨语言跨平台



- 高性能: 使用zerocopy技术减少数据序列化反序列化开销,
- 跨平台和跨语言: 可在不同的计算引擎和编程语言之间共享数据



## 基于Arrow的共享内存数据模型

- 在Python中, 可使用pyarrow库将NumPy数组转换为Apache Arrow格式
  - `arrow_array = pyarrow.array(numpy_array)`
- 在转换过程中, Arrow并不会复制整个数据数组, 而是创建一个元数据对象来引用NumPy数组的数据
- 下一步需要根据具体情况进行性能测试和优化

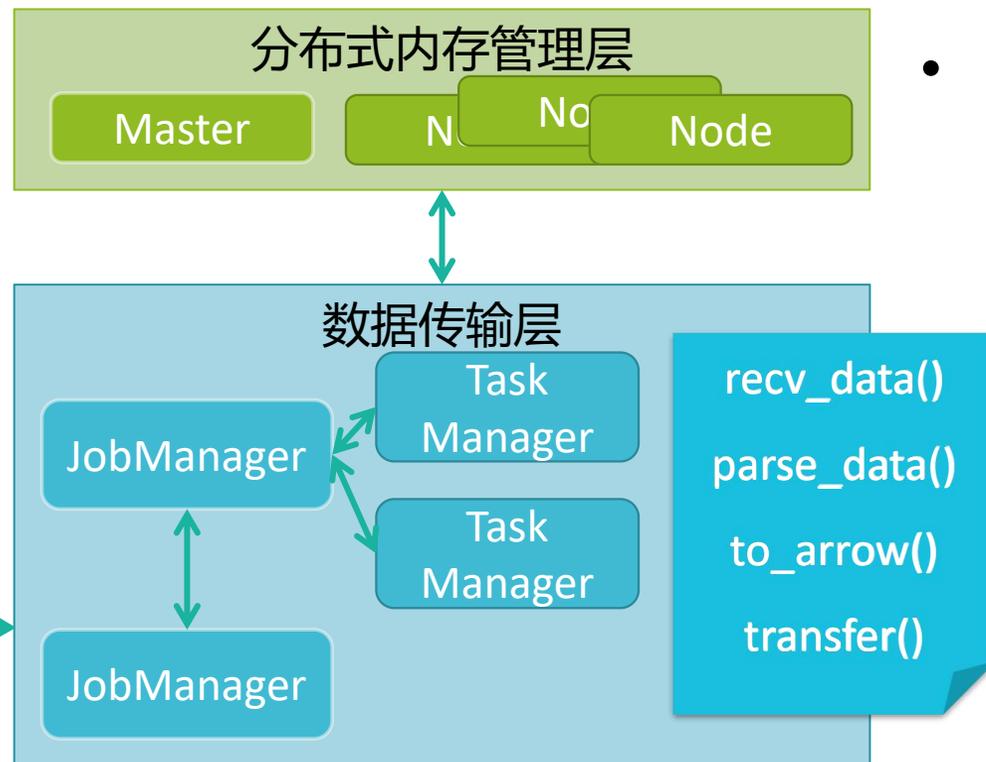


# 架构设计-流数据消费



## • 数据传输层目标:

- 流数据消费
- 高吞吐量
- 数据解析与格式转换



## • Flink特点:

- 通过优化的流处理引擎和内存管理, 实现了高吞吐和低延迟的数据处理。
- 可以与各种数据源 (如Kafka、Hadoop、Amazon S3等) 和数据接收器进行集成

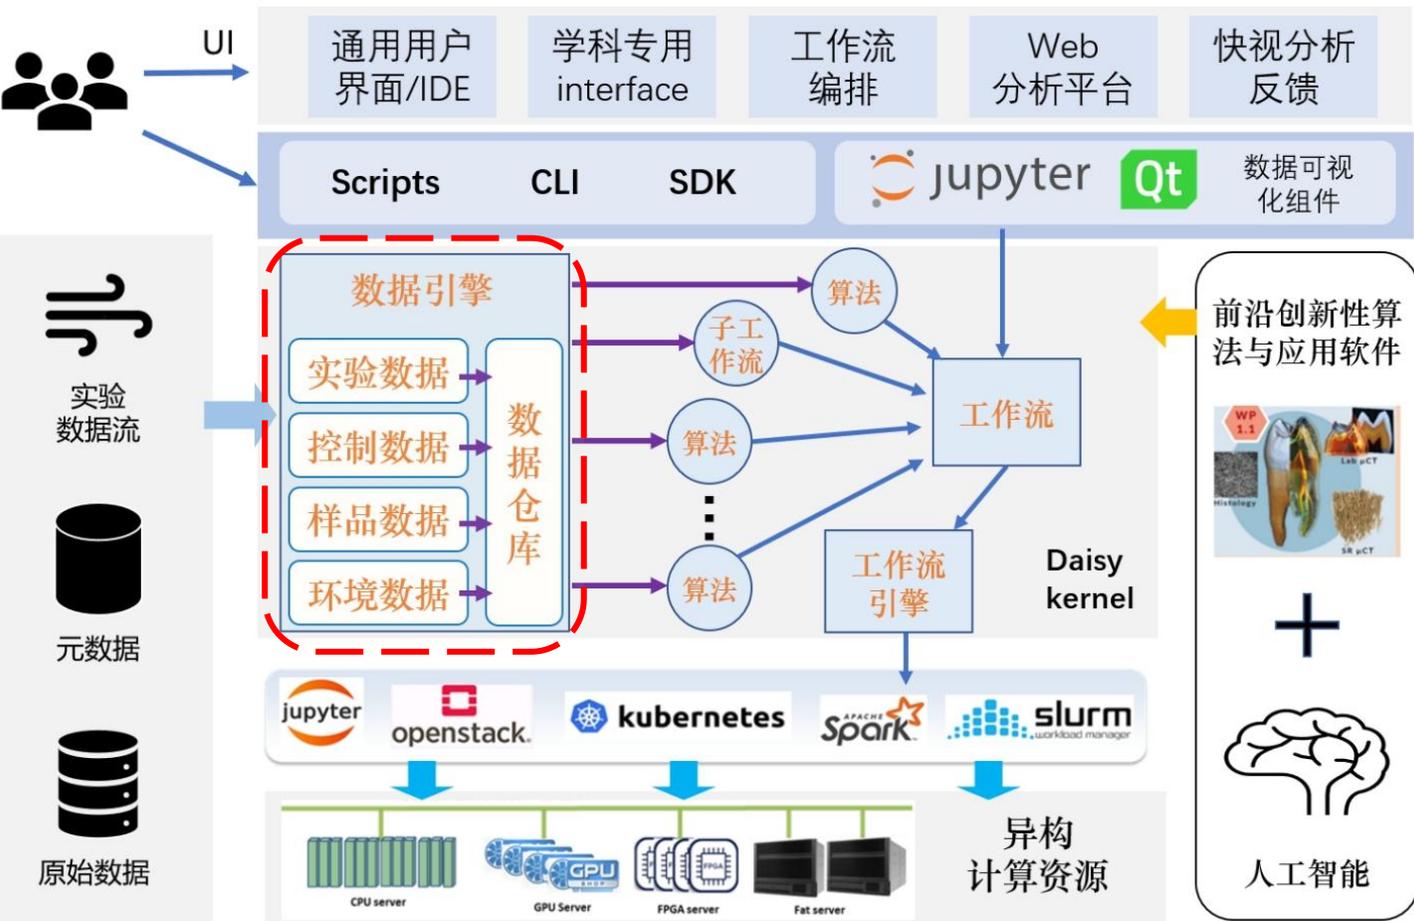
## • 基于Flink的流数据消费与转换

- 高可用性架构
  - 部署多个JobManager
  - 稳定高效消费数据流
- 流数据格式自动解析
  - 不同线站流数据内容不同
- 格式转换与存储
  - 解析完毕的数据转换为Arrow格式并存储到Alluxio





# Daisy-数据引擎



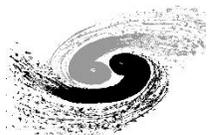
## • 作为Daisy中的数据引擎

- 接收来自DAQ和存储系统的数据
  - 数据流和文件
- 向计算引擎提供所需数据
  - 使用接口即可，屏蔽底层差异
- 提供流数据处理和批处理能力
- 优化IO速度
- 屏蔽地层差异

DAISY(Data analysis integrated software system) 是为先进光源在线数据处理而设计开发的软件框架。目标设计实现一个通用的、具有良好扩展性的基础软件架构，集成多种方法学算法和工具，屏蔽计算架构的复杂性和计算资源的多样性，为上层应用软件和用户提供统一和简单的调用接口，并在此基础上开发数据可视化和分析桌面等通用组件，以期形成一个丰富和繁荣的软件生态环境。

Daisy详见:

《HEPS数据处理软件框架Daisy的进展及规划》胡誉



# 下一步计划



- 批处理优化

- HDF5多线程IO

- 与并行计算的结合

- IO框架性能测试

- Flink消费流数据的能力是否满足HEPS产生的数据量

- Arrow内存测试及优化

- 稳定性测试

谢谢!

敬请批评指正!



国家高能物理科学数据中心

National HEP Science Data Center



高能所计算中心

IHEP Computing Center