



Развитие проекта

ATLAS EventIndex

Семинар Лаборатории Ядерных Проблем

16.05.2019



- **EventIndex** это система, созданная с целью каталогизировать события эксперимента **ATLAS**, полученные на установке или в результате компьютерного моделирования


Событие – основная единица данных ATLAS


- Каждое событие содержит информацию о результатах одного столкновения частиц:
 - сигналы с детекторов
 - восстановленные частицы и их параметры
 - триггерные решения
- Каждое событие имеет уникальный идентификатор определяемый номером Run-а и номером события
- Информация о событии хранится в нескольких экземплярах на различных серверах сети GRID
- Форматы в которых представлена информация различаются в зависимости от назначения, например для различных физических анализов создаются наборы данных (**датасеты**) со специально отобранными событиями и их параметрами

- **Отбрать событие (Event Picking)**
 - получить событие в нужном формате и обработке
- **Подсчитать и выбрать события на основании триггерных решений**
- **Проверить целостность и согласованность данных**
 - Искажение данных, потерянные и/или повторяющиеся события
- **Создание матриц перекрытия триггерных цепочек**
- **Создание матриц перекрытия наборов данных**
- **Быстрый просмотр датасетов**
 - Поиск требуемых датасетов
 - Составление отчетов
 - Проверка датасетов

Подробнее здесь:

<https://twiki.cern.ch/twiki/bin/view/AtlasComputing/EventIndexUseCases>





Partitioned architecture, определяемая потоком данных

Data production

- ◆ Извлечение метаданных событий из файлов, созданных на **Tier-0** или **Grid**

Data collection

- ◆ Передача собранной задачей **EI** информации на сервера в **CERN**

Data storage and Query interfaces


- ◆ Обеспечивает постоянное хранение данных **EventIndex**.
- ◆ Полная информация хранится в системе **Hadoop**
- ◆ Сокращенная информация (без триггеров) хранится в **Oracle**, для быстрых запросов

Monitoring


- ◆ Позволяет отслеживать работоспособность системы, контролировать потоки данных и выявлять проблемы



TIER0 @ CERN



GRID




Tier0 @ CERN : ~60 M событий/день Grid Sites : ~280 M событий/день

Всего (Tier0 + Grid):


- В пиках индексируется до **3500 M** событий в день
- **~100 Млрд** событий проиндексировано за последний год




- На **Tier-0** индексируются полученные на установке данные в формате **AOD**, а также собираются ссылки на сырые данные
- Данные прошедшие дальнейшую обработку на серверах **Grid**, обрабатываются на них же. Информацию о готовности данных предоставляют системы **AMI** и **Rucio**
- Периодически поступают на обработку специальные наборы данных для отдельных задач и рабочих групп
 - В последнее время **EI** активно используется для контроля качеств новых
- Система запущена весной **2015** года и работает в штатном режиме
- Сбои крайне редки и вызваны в основном проблемами серверов **Grid** либо поврежденными данными
- Объемы данных в **Hadoop**:
 - Реальные данные: **21 ТБ**
 - Монте-Карло: **5 ТБ**
 - Другое (бэкап, временные, etc...): **150 ТБ**




	current
Real AOD	19.2 TB
Real DAOD	4.46 TB
Real DESDM	40 GB
Real DRAW	39 GB
Real ESD	57 GB
Real RAW	0 GB
MC AOD	8.97 TB
MC DAOD	355 GB
MC EVNT	552 GB
Other	9 GB



- Триггерные решения записаны в файлах данных в виде битовых полей (**trigger masks**).
- Положение установленных битов (**bit counter**) указывает, какие из триггерных цепочек сработали в данном событии.
- Триггерная информация сохраняется в **EventIndex** в декодированном виде
- Для данных с установки триггерные биты конвертируются в имена триггерных цепочек используя таблицы соответствий из базы метаданных параметров работы (**COMA, the conditions metadata database**)
- Декодирование триггерной информации для моделированных данных (**MC**) производится с помощью таблиц взятых из другого источника (**TRIGGERDBMC**)





- Если информация о SMK отсутствует в записи события – используется версия реконструкции (**r-tag**)
- В AMI содержится информация о SMK для каждого **r-tag**
- **r-tag** берется из записи события или имени датасета

[mc16_13TeV.364109.Sherpa_221_NNPDF30NNLO_Zmumu_MAXHTPTV280_500_CVetoBVeto.merge.AOD.e5271_e5984_s3126_r10517_r10210](#)



EventIndex позволяет подсчитывать частоту срабатывания триггерных цепочек для оценки эффективности триггеров.

PNG histogram		PNG histogram	
data18_13TeV.00349842.physics_Main.merge.AOD.f933_m1960@00		data18_13TeV.00349842.physics_Main.merge.AOD.f933_m1960@00	
	evt=1.8657944E7		evt=1.8657944E7
L1_EM22VHI	9139599 (48.99%)	HLT_j0_perf_dsl_L1J100	4507426 (24.16%)
L1_EM24VHI	8681555 (46.53%)	HLT_e26_lhtight_nod0	2579342 (13.82%)
L1_EM24VHIM	8477955 (45.44%)	HLT_mu26_ivarmedium	2520177 (13.51%)
L1_MU20	4951122 (26.54%)	HLT_mu26_ivartight	2456332 (13.17%)
L1_MU20_FTK	4951122 (26.54%)	HLT_e26_lhtight_nod0_ivarloose	2327194 (12.47%)
L1_MU21	4871574 (26.11%)	HLT_mu28_ivarmedium	2215895 (11.88%)
L1_TAU60	4592084 (24.61%)	HLT_mu28_ivartight	2168251 (11.62%)
L1_J100	4511415 (24.18%)	HLT_e28_lhtight_nod0	2166217 (11.61%)
L1_EM15VHI_TAU40_2TAU15	4254325 (22.80%)	HLT_e28_lhtight_nod0_ivarloose_L1EM22VHI	2122560 (11.38%)
L1_SC111-CJ15	4185692 (22.43%)	HLT_e28_lhtight_nod0_ivarloose	1995290 (10.69%)
L1_HT190-J15s5.ETA21	3824623 (20.50%)	HLT_e28_lhtight_nod0_ivarloose_L1EM24VHIM	1935065 (10.37%)
L1_XE50	3812247 (20.43%)	HLT_e32_lhtight_nod0_ivarloose	1627066 (8.72%)
L1_J120	3628486 (19.45%)	HLT_mu50	807739 (4.33%)
		HLT_tau35_medium1_tracktwoEF_tau25_medium1_tracktwoEF_L1DR-TAU20ITAU12I-J25	684287 (3.67%)
		HLT_tau35_medium1_tracktwo_tau25_medium1_tracktwo_L1DR-TAU20ITAU12I-J25	628693 (3.37%)

data18_13TeV.00349842.physics_Main.merge.AOD.f933_m1960

* [Catalog](#) - [Dataset Overlaps](#) - [Trigger Statistics](#) - [Trigger Overlaps](#) - [TagFile Sample](#) - [TagFile Info\(*\)](#) - [Journal\(run\)\(tag\)\(*\)](#) - [AMI\(+\)](#) - [Rucio\(+\)](#) - [COMA\(+\)](#)

* Generic: [Catalog](#) - [Event Index](#)

* For experts: [EI](#) - [EL](#) - [TI](#) - [Inspect](#) - [Journal](#) - [Full Service-oriented Portal](#)

(*) ... may be slow, (+) ... external service

Матрицы перекрытий используются для оптимизации триггерных меню, доступно также представление в виде графов отношений

PNG
Show Selection inclusive

Trigger	Count (%)	Selection
HLT_e100_lhvloose_nod0	7910568 (42.40%)	<input checked="" type="checkbox"/>
HLT_e100_lhvloose_nod0_L1EM24VHIM	7798626 (41.80%)	<input checked="" type="checkbox"/>
HLT_e10_lhvloose_nod0_L1EM7	14813658 (79.40%)	<input checked="" type="checkbox"/>
HLT_e120_lhvloose_nod0	7164288 (38.40%)	<input checked="" type="checkbox"/>
HLT_e120_lhvloose_nod0_L1EM24VHIM	7556085 (40.50%)	<input type="checkbox"/>
HLT_e12_lhloose_cutd0dphideta_L1EM10VH	11865852 (63.60%)	<input type="checkbox"/>

Trigger	HLT_e100_lhvloose_nod0	HLT_e100_lhvloose_nod0_L1EM24VHIM	HLT_e10_lhvloose_nod0_L1EM7	HLT_e120_lhvloose_nod0
data18_13TeV.00349842.physics_Main.merge.AOD.f933_m1960 evt=18657944,t3=1.8675657E7	7910568 (42.40%)	7798626 (41.80%)	14813658 (79.40%)	7164288 (38.40%)
HLT_e100_lhvloose_nod0 7910568 (42.40%)	100.00%,100.00%	94.34%,95.69%	100.00%,53.40%	87.26%,96.35%
HLT_e100_lhvloose_nod0_L1EM24VHIM 7798626 (41.80%)	82.46%,94.34%	100.00%,100.00%	52.64%,100.00%	87.08%,94.79%
HLT_e10_lhvloose_nod0_L1EM7 14813658 (79.40%)	53.40%,100.00%	52.64%,100.00%	100.00%,100.00%	48.36%,100.00%
HLT_e120_lhvloose_nod0 7164288 (38.40%)	96.35%,87.26%	94.79%,87.08%	100.00%,48.36%	100.00%,100.00%

data18_13TeV.00349842.physics_Main.merge.AOD.f933_m1960

* [Catalog](#) - [Dataset Overlaps](#) - [Trigger Statistics](#) - [Trigger Overlaps](#) - [TagFile Sample](#) - [TagFile Info\(*\)](#) - [Journal\(run\)\(tag\)\(*\)](#) - [A](#)


* Generic: [Catalog](#) - [Event Index](#)


* For experts: [EJ](#) - [EL](#) - [TI](#) - [Inspect](#) - [Journal](#) - [Full Service-oriented Portal](#)

(*) ... may be slow, (+) ... external service



- Данные о состоянии и производительности системы (~15k значений в день) собираются разными способами (сканирование журналов и HDFS, REST запросы и анализ WEB-страниц)
- Сбор и обработка информации управляется планировщиком
- Результаты загружаются в InfluxDB / Grafana через REST







В настоящее время:

- Информация о событиях, относящаяся к различным этапам обработки (RAW, ESD, AOD, DAOD) физически хранится в разных файлах системы хранения данных HADOOP (HDFS)

В перспективе:

- Одна единственная логическая запись для события
 - Идентификация события
 - Неизменная информация (lumblock, триггер)
 - Для каждого этапа обработки:
 - Ссылка на алгоритм (конфигурация задачи обработки)
 - Указатели на результаты обработки
 - Флаги для оффлайн селекции
- Виртуальный датасеты – логические набор событий
 - Создается явным образом из коллекции идентификаторов событий, либо на основании выборки из уже имеющихся наборов



В настоящее время:

- Все процессы ATLAS производят ~30 миллиардов событий в год (в среднем до 350 Гц).
- Это новые и обновленные данные, относящиеся ко всем годам, полученные как на установке, так и в результате моделирования
- EventIndex обрабатывает 8 миллионов файлов в день

В перспективе:

- Необходимо масштабировать систему для ожидаемого роста потоков данных :
 - Run3 (2021-2023): 35 млрд новых реальных событий в год и 100 млрд. моделированных событий в год (рост как минимум на половину порядка величины).
 - Run4: 100 млрд новых реальных событий в и 300 млрд. Монте-Карло событий в год.
 - Плюс репликация и репроцессинг



- Используемые в EventIndex технологии в основном позволили обеспечить производительность удовлетворительную для условий Run 2.
- С ростом объема данных стали проявляться проблемы масштабирования:
 - Медленная обработка запросов, рост объема данных
- В Run3 ожидается существенное возрастание объемов данных т темпа их поступления
- Предполагается провести модернизацию EventIndex с использованием современных технологий BigData для работы в условиях Run 3
- Модернизация предполагает использование **HBase** для хранения данных и **Apache Phoenix** для организации запросов.
- Эти продукты принадлежат к семейству Hadoop и будут поддерживаться CERN на протяжении всего Run 3.



- Apache HBase принадлежит к семейству HADOOP.
 - Нереляционная база данных с открытым кодом
 - Распределенное и масштабирование хранилище данных
- HBase организует данные в виде таблиц
 - Ряды таблицы имеют уникальный ключ-идентификатор
 - Каждый ряд может иметь свою схему
 - Данные в каждом ряду могут быть сгруппированы в заранее заданное семейства колонок
 - Доступ к значениям возможен по ключу и имени колонки
- Свойства такой организации (**RowKey**):
 - Относительно небольшой размер
 - Позволяет уникально идентифицировать события
 - Позволяет производить поиск по интервалам
 - При росте таблиц используется гомогенное пространство RowKey
- Hbase уже использовалась для триггерных таблиц





- Средства для SQL на HBase:

-  • **Apache Impala**
 -  • **Apache Hive**
 -  • **Apache Spark**
- Обращение с отображением ключей рядов должно осуществляться приложением преимущественно для пакетных задач



Apache Phoenix


Транзакционная система и операционная аналитика для HBase

- Принимает SQL запросы
- Преобразует их в серии сканирований в HBase
- Напрямую использует API HBase, а также сопроцессоры и специальные фильтры
- Выдает результаты запросов JDBC
- Дизайн RowKey адаптируется к типам и размерам Phoenix за счет небольшого уменьшения производительности
- Phoenix позволяет использовать поля RowKey в запросах, при этом они сохраняются как один объект в HBase



- Запросы Phoenix к HBase были протестированы на прототипах таблиц EventIndex с обнадеживающими результатами

- Варианты схем таблиц
- Готовы базовые функции
- Идет работа над производительностью и интерфейсами
- Необходимо продолжать тестирование с большими объёмами данных для получения показателей производительности



- Планируется ввести новую систему в действие в течении **2019** года, параллельно с уже имеющейся
- Снятие с эксплуатации старой системы планируется в течении **2020** г (до начала Run 3 на LHC)



- Технологии работы с «Большими Данными» активно развиваются
- Появления и развитие новых средств обработки и хранения данных позволяет провести **глубокую модернизацию** EventIndex с переходом на принципиально другую платформу и **расширением возможностей**
- В любом случае, участие в проекте **EventIndex** позволяет не только внести вклад в эксперимент ATLAS, но и позволяет работать с **самым современным** технологиями **Больших Данных**, с перспективой использования полученного опыта в других экспериментах или образовательных проектах.