


Apache Calcite: Платформа для создания продвинутых SQL-оптимизаторов на Java

Владимир Озеров
Querify Labs, CEO

О нас

- Компания Querify Labs [\[1\]](#)
 - Разработка новых СУБД и data management систем: движки, оптимизаторы, storage, протоколы.
- Работал 8 лет над распределенными in-memory движками:
 - Apache Ignite
 - Hazelcast
- Контрибьютор в Apache Calcite [\[2\]](#) и Apache Ignite


Распределенный SQL



- Реляционные СУБД:
 - CockroachDB, TiDB, YugaByte
- BigData/Analytics:
 - Hive, Snowflake, Dremio, Clickhouse, Presto
- NoSQL:
 - DataStax, Couchbase
- Compute/streaming:
 - Spark, ksqlDB, Apache Flink
- IMDG:
 - Apache Ignite, Hazelcast, Gigaspaces



Что делает оптимизатор?

Syntax and Semantic Analysis




Query

Intermediate Representation




Backend

Оптимизация с Apache Calcite



Оптимизация с Apache Calcite



Проекты, которые используют Apache Calcite

- Data Management:
 - Apache Hive
 - Apache Flink
 - Dremio
 - VoltDB
 - IMDGs (Apache Ignite, Hazelcast, Gigaspace)
 - ...
- Applied:
 - Alibaba / Ant Group
 - Uber
 - LinkedIn
 - ...

О чем доклад?

- Что
 - Ключевые алгоритмы и проблемы оптимизаторов SQL-запросов.
 - Как они решены в Apache Calcite.
- Кому
 - Практикующим инженерам, которые используют SQL-продукты.
 - Если вам интересно внутреннее устройство СУБД, или вы хотите стать разработчиком СУБД.
 - Если вы хотите порадоваться за Java.


Основные стадии

- Анализ
 - Парсинг.
 - Семантическая валидация.
 - Трансляция в IR (intermediate representation).
- Оптимизация
 - Логическая - поиск абстрактных операторов (напр, $\text{Join}(A \times B)$ vs $\text{Join}(B \times A)$).
 - Физическая - выбор реализации операторов (напр, hash join vs nested loop join).

Парсинг


- Задача: превратить строку в синтаксическое дерево.
- Парсинг с Apache Calcite:
 - Использует JavaCC для генерации парсера [\[3\]](#).
 - Имеет готовый к использованию сгенерированный парсер [\[4\]](#).
 - Допускает расширения синтаксиса (напр., DDL [\[5\]](#)).

```
var sql = "SELECT ...";  
var parser = SqlParser.create(sql);  
SqlNode ast = parser.parseQuery();
```




Семантический анализ

- Задача: убедиться в семантической корректности синтаксического дерева:
 - Разрешение объектов СУБД (таблицы, колонки, ...).
 - Разрешение функций.
 - Вывод типов.
 - Проверка реляционной семантики.
- Семантический анализ в Apache Calcite:
 - Предоставьте схему.
 - Предоставьте кастомные функции (опционально).
 - Запустите встроенный валидатор [\[6\]](#).



Трансляция в реляционное дерево



- Оптимизировать синтаксическое дерево проблематично из-за высокой сложности SQL-синтаксиса.
- Для задачи оптимизации, удобнее представить запрос в виде дерева реляционных операторов [\[BLOG2\]](#) [\[7\]](#) [\[8\]](#).
- Apache Calcite имеет встроенный транслятор из AST в дерево реляционных операторов [\[9\]](#).
- Большинство трансформаций Apache Calcite работают с реляционными операторами.
- В других системах: Apache Spark [\[37\]](#), Presto/Trino [\[38\]](#).

RelNode

```
abstract class AbstractRelNode {  
    // Доступ к дочерним узлам.  
    RelNode getInput(int i);  
  
    // Список атрибутов ("полей") узла.  
    RelDataType getRowType();  
  
    // Сконструировать уникальную сигнатуру узла.  
    RelWriter explainTerms(RelWriter pw);  
  
    // Посчитать стоимость узла (без учета дочерних узлов).  
    RelOptCost computeSelfCost(RelOptPlanner planner, RelMetadataQuery mq);  
}
```


Реляционные операторы

Оператор	Описание
<i>Scan</i>	Сканировать абстрактный источник данных
<i>Project</i>	Трансформировать кортеж (напр., $a+b$)
<i>Filter</i>	Отфильтровать кортежи (WHERE, HAVING)
<i>Sort</i>	ORDER BY / LIMIT / OFFSET
<i>Aggregate</i>	Агрегация
<i>Window</i>	Оконная агрегация
<i>Join</i>	Классический join двух операторов
<i>Union/Minus/Intersect</i>	Set-операторы

Оптимизация

- Rule-based оптимизация.
- Понятие “стоимости”.
- Итеративный оптимизатор.
- Cost-based оптимизатор.

Rule-based оптимизация



- Правило - это единица оптимизации, состоящая из паттерна и логики трансформации [\[BLOG3\]](#).
- Значительно упрощает эволюцию и поддержку планировщика за счет декомпозиции.
- SQL-движки могут содержать сотни трансформаций.
- **Примеры:** Apache Calcite [\[17\]](#), Apache Spark [\[18\]](#), Presto [\[19\]](#), CockroachDB [\[20\]](#).

Пример правила

```
public class AggregateJoinTransposeRule extends RelRule {
    // Логика
    public void onMatch(RelOptRuleCall call) {
        Join newJoin = ...           // 400 строк сложного кода
        call.transformTo(newJoin); // Сообщить оптимизатору о новом узле
    }



    // Паттерн
    public interface Config extends RelRule.Config {
        Config DEFAULT = EMPTY.as(Config.class)
            .withOperandSupplier(
                b0 -> b0.operand(Aggregate.class)           // Aggregate ...
                .oneInput(b1 -> b1.operand(Join.class))      // ... над Join ...
                .anyInputs()                                  // ... а дальше все равно!
            ).as(Config.class)
    }
}
```

Правила: упрощение операторов




- Упрощение операторов:
 - Определение, что оператор всегда возвращает пустой результат (предикат) [\[25\]](#).
 - Удаление ненужных операций (напр. GROUP BY над уникальной колонкой) [\[26\]](#).

Правила: перемещение операторов




- Перемещение операторов:
 - Filter: pushdown [\[27\]](#), pull-up.
 - Aggregate pushdown (напр. поместить GROUP BY под Join [\[28\]](#)).
 - Join: commute [\[29\]](#), associate [\[30\]](#).

Что делать с правилами?



- Применяя правила, мы генерируем **эквивалентные** планы. Два плана называются эквивалентными, если они порождают одинаковые результаты на любых входных данных (*NB: без учета сортировки!*)
- Задача оптимизатора - попытаться найти оптимальный план. Проблемы:
 - Как понять, что план оптимален?
 - Как “добраться” до оптимального плана?

Что такое “стоимость”?




- Условная величина, которая позволяет сравнивать операторы друг с другом [\[BLOG4\]](#).
- **Теория:**
 - Точная оценка затрат ресурсов на выполнение оператора.
- **Практика:**
 - Грубая модель, полагающаяся на неточные статистики, упрощения и магические константы [\[10\]](#) [\[11\]](#).
 - Скаляр [\[12\]](#).
 - ... или вектор [\[13\]](#) [\[14\]](#), который все равно сравнивается как скаляр [\[15\]](#) [\[16\]](#).

RelOptCostImpl


```
class RelOptCostImpl implements RelOptCost {  
    private final double value;  
  
    public boolean isLe(RelOptCost other) { ... }  
    ...  
}
```

Итеративный планировщик




- Рассматривает один план в каждый момент времени, последовательно применяя правила.
- Быстрый, простой, но не гарантирует оптимальность и подвержен закликиванию.
- **Примеры:** Apache Spark [\[21\]](#), Presto [\[22\]](#), Apache Calcite (Apache Flink, Apache Hive) [\[23\]](#)

Cost-based планировщик




- Рассматривает много планов **одновременно**.
- Выбирает наиболее оптимальный на основе стоимости.
- **Примеры:** Apache Calcite [\[24\]](#), Pivotal Greenplum/Orca [\[31\]](#), CockroachDB [\[32\]](#).

Memoization




- Expression - оператор, входами которого являются другие операторы.
- Group - набор эквивалентных операторов.
- Multi-expression - оператор, входами которого являются **группы**.
- MEMO - набор groups и multi-expressions.

Memoization



- Позволяет **компактно** кодировать большое количество планов.
- **Дедуплицирует** одинаковые узлы.
- Подробнее: [\[BLOG5\]](#)

Cost-based оптимизация



- У каждого оператора есть стоимость: сумма **собственной** стоимости и стоимости входов.
- Если в группе появляется оператор с меньшей стоимостью, он объявляется **winner**, стоимость верхних операторов пересчитывается.


Оптимизаторы в Apache Calcite

- **HepPlanner** - итеративный оптимизатор, с итерациями и циклами [\[23\]](#).
- **VolcanoPlanner** - cost-based оптимизатор, с MEMO и костами [\[24\]](#).

Продвинутые техники


- Физические свойства
- Cascades
- Многофазная оптимизация

Физические свойства




- Оператору MergeJoin необходимо, чтобы его входы были **отсортированы** в соответствии с условием.
- Как сделать так, чтобы MergeJoin учитывал только подходящие операторы?
- Если оператор не подходит, то можно ли его как-то преобразовать, что бы он стал подходящим?

Физические свойства




- **Физическое свойство** оператора - величина, которая не влияет на набор возвращаемых записей, но которая может оказывать влияние на другие операторы (RelTrait [\[33\]](#)).
- Оператор может потребовать, чтобы его входы удовлетворяли определенным свойствам (RelSubset [\[34\]](#)).
- Если оператор не удовлетворяет требованиям, можно автоматически вставить **enforcer**, которые преобразует физические свойства оператора.
- Свойства (и их enforcer-ы) в Apache Calcite [\[BLOG6\]](#):
 - Collation (Sort) - сортировка по атрибутам.
 - Distribution (Exchange) - распределение данных в кластере (sharded, replicated, singleton)
 - Convention (???) - маркер, указывающий, в какой системе выполняется оператор.

Convention




- Каждому оператору присваивается **convention** [35], т.е. целевая система выполнения.
- При переходе между convention вставляются специальные операторы-конвертеры [36] (не показано).
- Позволяет строить federated движки.

Управление свойствами



- Продвинутые оптимизаторы пытаются найти оптимальную **комбинацию операторов** на основе их свойств.
 - Упрощенные алгоритмы: Apache Flink [\[39\]](#).
 - Алгоритм **Cascades** [\[41\]](#) [\[42\]](#) [\[43\]](#): Apache Calcite [\[40\]](#), Pivotal Greenplum [\[31\]](#).
- Катастрофическая комбинаторная сложность!


Cascades: типы операторов и правил



- Типы операторов
 - Logical - не имеют свойств.
 - Physical - имеют свойства.
- Трансформации:
 - Logical-Logical (exploration) - перебираем все альтернативы, так как они могут породить более оптимальные физические имплементации.
 - Logical-Physical (implementation) - перебираем только те, что запрошены.


Cascades: оптимизационные запросы

MergeAggregateRule




- Физический оператор “отправляет” оптимизационный запрос вниз.
- Дочерние операторы ищут способ удовлетворить этот запрос.
- Следствие: перебираем только те физические операторы, которые кому-то нужны.
- В Apache Calcite: TopDownRuleDriver [\[55\]](#).

Cascades: accumulated cost bounding




- Правило хочет сделать физический оператор HashAggregate.
- Но у нас уже есть более дешевый MergeAggregate, поэтому игнорируем HashAggregate.
- Следствие: игнорируем заведомо дорогие физические операторы.
- Работает на **практике**.

Cascades: predicted cost bounding




- **Lower bound** - все физические операторы, созданные из данного логического оператора будут иметь стоимость не меньше данной.
- Можно игнорировать логические операторы, у которых lower bound выше, чем стоимость лучшего физического оператора.
- Пример:
 - Для (AxB) уже найден физический оператор со стоимостью 300.
 - Для (BxA) все физические операторы заведомо имеют стоимость выше 400.
 - Из (BxA) никогда не получится оптимальный план.
- Следствие: игнорируем заведомо дорогие **группы** операторов.
- Работает **в теории**.
- На практике - непонятно, как посчитать lower bound.

Многофазное планирование



- Задача нахождения оптимального плана является **NP-сложной**, и в общем случае не решается за адекватное время. Поэтому оптимизаторы обычно разбивают планирование на несколько последовательных этапов.
- Примеры: Apache Flink [\[44\]](#) [\[45\]](#), Apache Spark [\[46\]](#), Dremio [\[47\]](#).

Многофазное планирование в Apache Flink



- Фазы [\[44\]](#):
 - **Rewrite 1** - subquery unnesting, simplification, predicate pushdown, ...
 - **Join Order Planning** - эвристическое планирование порядка join-ов (отключено по умолчанию).
 - **Rewrite 2** - transient predicates pushdown, упрощение Join, ...
 - **Logical Planning** - cost-based, планирование порядка операторов aggregate pushdown, etc).
 - **Rewrite 3** - дальнейшее упрощение операторов.
 - **Physical Planning** - cost-based, выбор алгоритмов для операторов.
 - **Rewrite 4** - эвристическое добавление локальных агрегатов.
- “Join Order Planning” + “Logical Planning” + “Physical Planning” не гарантируют оптимальный план!

Что осталось за кадром?

- **Subquery unnesting/decorrelation** [\[48\]](#) [\[49\]](#) [\[50\]](#) - мощная техника, которая позволяет переписывать произвольные подзапросы (скалярные, коррелированные) на последовательность операторов Join/Aggregate.
- **Metadata** [\[BLOG1\]](#) [\[51\]](#) - инфраструктура для обмена метаданным между операторами для оценки их стоимости: кардинальности, селективности, и т.п..
- **Enumerable** [\[52\]](#) [\[53\]](#) - встроенный движок выполнения запросов с помощью кодогенерации (Janino). Не подойдет для серьезных проектов, но на “поиграть” - отлично!
- **Avatica** [\[54\]](#) - фреймворк для построения JDBC драйверов.

Итого

- Apache Calcite - платформа для построения SQL-движков.
 - Содержит парсер, семантический анализатор, оптимизатор.
- Оптимизатор:
 - Основной подход: rule-based оптимизация.
 - Планировщики: (1) итеративный, (2) cost-based.
- Практически безальтернативный выбор для новых SQL-движков.
 - Недели до прототипа.
 - Месяцы до MVP.
 - Нет предела совершенству.
- Ссылки: <https://querifylabs.notion.site/Apache-Calcite-SQL-Java-be85ad4f6b5d41c48a484ad3f57d1e22>
- Поработать с Apache Calcite: <https://career.habr.com/companies/querify-labs/vacancies>