

Выполнение декларативных сценариев аналитической обработки данных на основе оптимизации и приближенного вычисления

Анна Ярыгина, Борис Новиков


Санкт-Петербургский государственный университет

План доклада

- Введение
- Обзор литературы
 - Выполнение точных запросов
 - Адаптивное выполнение запросов
 - Выполнение приближенных запросов
 - Многокритериальная и параметрическая оптимизация
- Подходы к решению и основные результаты
 - Теоретическая модель оптимизации и контролируемого приближенного выполнения нечетких запросов
 - Архитектура системы приближенного выполнения нечетких запросов в реальном времени
 - Задача распределения ресурсов
 - Многокритериальная оптимизация запросов при специфических ограничениях
- Заключение

Пересмотр подходов

- Объем (Volume)
 - Декларативные языки запросов
 - Распределенное выполнение
- Разнообразие (Variety)
 - Данных
 - Структурированные, неструктурированные
 - Статические, динамические
 - Задача отображения схем
 - Запросов
 - Поиск (данные возвращаются пользователю)
 - Статическая аналитика (данные загружаются в хранилище)
 - Динамическая аналитика (данные передаются в аналитический инструмент)
- Скорость (Velocity)
 - Оптимизация
 - Приближенное выполнение
- Качество (Veracity, Validity)



Системы и языки

Системы

- Параллельные вычисления
 - ASTERIX
 - Scope
 - Hive
- Оптимизация и выполнение сложных аналитических сценариев
- Выполнение специфических классов запросов при ограниченных ресурсах (приближенное выполнение на основе выборок)
 - Система приближенного выполнения SQL запросов с агрегированием
 - Система исследования данных на основе приближенного выполнения SQL запросов


Языки

- Algebricks алгебраический слой для оптимизации и параллельного выполнения запросов
- Язык Hyracks
- Язык Scope
- Язык Pig Latin
- Язык HiveQL

План доклада

- Введение
- Обзор литературы
 - Выполнение точных запросов
 - Адаптивное выполнение запросов
 - Выполнение приближенных запросов
 - Многокритериальная и параметрическая оптимизация
- Подходы к решению и основные результаты
 - Теоретическая модель оптимизации и контролируемого приближенного выполнения нечетких запросов
 - Архитектура системы приближенного выполнения нечетких запросов в реальном времени
 - Задача распределения ресурсов
 - Многокритериальная оптимизация запросов при специфических ограничениях
- Заключение

Выполнение точных запросов



- Декларативные языки запросов
- Реляционная алгебра
- Оптимизация
 - Алgebraические тождества
 - Алгоритмы выполнения операций
- Потоковое выполнение

Оптимизация запросов

Задача оптимизации

- Найти план выполнения запроса минимизирующий функцию стоимости


Функция стоимости

- Время выполнения запроса
- Время получения первого кортежа ответа
- Процессорное время
- Объем ввода/вывода

Ресурсы


- Стоимость и ресурсы
- Сложность и конфигурация
- Аддитивный ресурс
 - Распределяемый между операциями
 - Стоимость сценария определяется суммой ресурсов, выделенных операциям

Архитектура оптимизатора





Алгоритмы поиска плана

- Сверху вниз
 - Метод случайного поиска
 - Генетические алгоритмы
 - Метод ветвей и границ
- Снизу вверх
 - Алгоритм динамического программирования
 - Жадный алгоритм



Метод ветвей и границ на графах

- Граф запроса
 - Вершины - отношения
 - Дуги - предикаты
- Идеи
 - Исключение прямые произведений
 - Некоммутативные операции
- Перечисление планов
 - Рекурсивно перечисляем множество всех разбиений
 - Выбираем вершину
 - Рассматриваем ближайших соседей
- Гиперграф запроса



План доклада

- Введение
- Обзор литературы
 - Выполнение точных запросов
 - Адаптивное выполнение запросов
 - Выполнение приближенных запросов
 - Многокритериальная и параметрическая оптимизация
- Подходы к решению и основные результаты
 - Теоретическая модель оптимизации и контролируемого приближенного выполнения нечетких запросов
 - Архитектура системы приближенного выполнения нечетких запросов в реальном времени
 - Задача распределения ресурсов
 - Многокритериальная оптимизация запросов при специфических ограничениях
- Заключение

Адаптивное выполнение запросов

- Цикл адаптивного выполнения запросов
 - Измерение
 - Анализ и оптимизация
 - Выполнение
- Запросов
 - Потоковое выполнение
 - Промежуточная материализация
- Операций

План доклада

- Введение
- Обзор литературы
 - Выполнение точных запросов
 - Адаптивное выполнение запросов
 - Выполнение приближенных запросов
 - Многокритериальная и параметрическая оптимизация
- Подходы к решению и основные результаты
 - Теоретическая модель оптимизации и контролируемого приближенного выполнения нечетких запросов
 - Архитектура системы приближенного выполнения нечетких запросов в реальном времени
 - Задача распределения ресурсов
 - Многокритериальная оптимизация запросов при специфических ограничениях
- Заключение

Понятие приближенности

Природа приближенности

- История потока
 - Бесконечность истории
- Природа данных
 - Надежность источников
- Природа задачи
 - Поиск по подобию
- Объем данных и скорость обработки

Понятия приближенности

- Приближенное выполнение запросов
- Нечеткие запросы

Расширенные алгебры

Расширение реляционной модели

- Пользовательские веса
- Нечеткие множества
- Фиксированный класс данных

Уровни расширения алгебры

- Работа со списками, оценками, рангами
- Поиск лучших объектов
- Поддержка рангов и оценок внутри операций

Найти 5 лучших отелей согласно рейтингам booking.com и TripAdvisor, если рейтинг последнего в 2 раза важнее.

Расширения операций

- Теоретико-множественные
 - Комбинирование оценок
 - Пользовательские веса
 - *Найти изображения красных и полосатых насекомых*
- Выборка
 - Нечеткий предикат
 - *Найти красных насекомых*
- Проекция
 - Оценки дубликатов
- Соединение
 - Комбинирование оценок
 - Нечеткий предикат
 - *Найти недорогой дом и хорошую школу в одном районе*
- Поиск лучших
 - *Найти 10 самых ядовитых насекомых*
- Выборка по порогу
 - *Найти отели с оценкой качества сервиса не ниже 5*

Особенности оптимизации запросов в расширенных языках

Алгебраические тождества

- Поиск лучших объектов и соединение
- Выборка по значению оценки и соединение
- Симметричное соединение

Модели стоимости

- Оценка селективности
- Оценка размера входных данных
- Тяжелые предикаты

Приближенное выполнение

- Приближенные алгоритмы
- Ограничения на ресурсы
- Any-time
 - Приближенные алгоритмы
 - Агрегирование
 - Any-time
 - Оценка качества
 - Соединение на основе подобия
 - Вычисление предиката
 - Доступ к источнику

Качество

- Точность
- Относительный размер выборки

План доклада

- Введение
- Обзор литературы
 - Выполнение точных запросов
 - Адаптивное выполнение запросов
 - Выполнение приближенных запросов
 - Многокритериальная и параметрическая оптимизация
- Подходы к решению и основные результаты
 - Теоретическая модель оптимизации и контролируемого приближенного выполнения нечетких запросов
 - Архитектура системы приближенного выполнения нечетких запросов в реальном времени
 - Задача распределения ресурсов
 - Многокритериальная оптимизация запросов при специфических ограничениях
- Заключение

Многокритериальная оптимизация

- Среди множества планов выполнения запросов выбрать тот, который минимизирует стоимость, вычисленную на основе совокупности критериев
 - время выполнения запроса
 - денежные затраты
 - потеря качества в результате

Параметрическая оптимизация

- Стоимость плана выполнения запроса зависит от параметров с неизвестными в момент оптимизации запроса значениями
- Множество планов, в котором для всех возможных значений параметров запроса имеется хотя бы один оптимальный план

Многокритериальная параметрическая оптимизация

- Понятия
 - Доминирование
 - Регион Парето
 - Множество планов Парето
 - Регион релевантности
- Алгоритм сокращения регионов релевантности
 - Динамическое программирование
 - Сокращение региона релевантности при серии сравнений плана с эквивалентными ему
 - Отбрасывание планов с пустыми регионами релевантности
- Кусочно-линейные функции стоимости (политопы)

Направления развития



Методы и средства эффективного
выполнения декларативных сценариев
аналитической обработки данных

План доклада

- Введение
- Обзор литературы
 - Выполнение точных запросов
 - Адаптивное выполнение запросов
 - Выполнение приближенных запросов
 - Многокритериальная и параметрическая оптимизация
- Подходы к решению и основные результаты
 - Теоретическая модель оптимизации и контролируемого приближенного выполнения нечетких запросов
 - Архитектура системы приближенного выполнения нечетких запросов в реальном времени
 - Задача распределения ресурсов
 - Многокритериальная оптимизация запросов при специфических ограничениях
- Заключение

Цель и подходы

Цели




- Единообразно формулировать запросы к данным и описывать их обработку
- Эффективно выполнять сложные запросы
- Выполнение запросов в реальном времени (предсказуемое и контролируемое время ответа)

Предлагаемые подходы

- Набор объектов с оценками
- Расширяемая алгебра операций
- Расширенная модель стоимости (качества)
- Алгоритм распределения ресурсов
- Алгоритмы многокритериальной оптимизации


Как оптимизировать?

Find best 10 hotels in London according to service and cleanliness




Пример: анализ в реальном времени

- 1 group by PriceRange nest (ProductGroup, avg(Rating), avg(Sentiment))
- 2 group join on ProductModel
- 3 group join on ProductModel
- 4 get database product table
- 5 get retailer ratings for products (500 per second)
- 6 get sentiments from tweets for products (300 per second)




		Product Groups									
		Cam		Scan		Print		Fax		MF	
Price range	< 10%	3,14	3,63	4,06	1,67	1,87	4,71	0,17	1,59	1,71	2,08
	10 – 20%	0,48	2,82	4,85	2,66	4,51	3,40	4,23	4,77	2,08	
	20-35%	1,36	2,29	4,43	1,83	3,34	3,04	1,82	4,08	2,22	
	35-60%	4,70	0,97	1,56	0,24	3,91	2,65	0,68	2,43	2,30	
	> 60%	2,99	1,98	0,31	4,56	0,45	0,63	1,35	1,76	0,32	2,10

Влияние распределения ресурсов



		Product Groups										
		Cam	Scan	Print	Fax	MF						
Price range	< 10%	3,14	3,63	4,06	1,67	1,87	4,71	0,17	1,59	1,71	1,71	2,08
	10 – 20%	0,48	2,82	4,85	2,66	4,51	3,40	4,23	4,23	4,77	4,77	2,08
	20-35%	1,36	2,29	4,43	1,83	3,34	3,04	1,82	4,08	2,22		
	35-60%	4,70	0,97	1,56	0,24	3,91	2,65	0,68	2,43	2,30		
	> 60%	2,99	1,98	0,31	4,56	0,45	0,63	1,35	1,76	0,32	2,10	

		Product Groups									
		Cam	Scan	Print	Fax	MF					
Price range	< 10%	3,21	3,73	4,09	1,71	1,94	4,74	0,17	1,61	1,80	4,39
	10 – 20%	0,54	2,88	4,88	2,72	4,60	3,48	4,28	4,79	2,12	
	20-35%	1,41	2,37	4,45	1,90	3,36	3,10	1,89	4,08	2,25	
	35-60%	4,74	1,03	1,64	0,28	3,42	4,00	2,70	0,75	2,52	2,40
	> 60%	3,03	2,07	0,41	4,59	0,53	0,71	1,41	1,81	0,33	2,16



Возможные применения

- ETL процессы
- OLAP запросы
- Непрерывный анализ потоков
- Анализ в реальном времени


План доклада

- Введение
- Обзор литературы
 - Выполнение точных запросов
 - Адаптивное выполнение запросов
 - Выполнение приближенных запросов
 - Многокритериальная и параметрическая оптимизация
- Подходы к решению и основные результаты
 - Теоретическая модель оптимизации и контролируемого приближенного выполнения нечетких запросов
 - Архитектура системы приближенного выполнения нечетких запросов в реальном времени
 - Задача распределения ресурсов
 - Многокритериальная оптимизация запросов при специфических ограничениях
- Заключение

Обзор системы

- Язык и модель данных
- Оптимизация
- Распределение ресурсов
- Исполнение

Предварительная архитектура



Методы и средства эффективного
выполнения декларативных сценариев
аналитической обработки данных

Открытая алгебра

Q-set (q, B, S) множество объектов с оценками над базовым множеством


Список операций

- Первичные операции
Извлечение информации из первичных источников
- Фильтры (простые и обогащающие)
Обработка объектов по одному
- (Нечеткие) теоретико-множественные операции
Аргументы из одного базового множества
- (Нечеткие) соединения
- (Нечеткие) операции агрегирования
- Расщепление
- Группирующие соединения
Комбинация соединения и агрегирования

Расширяемость

- Внешние фильтры
- Пользовательские операции
- Пользовательские предикаты
- Пользовательские функции оценки
- Пользовательские группирующие функции

Архитектура с оптимизацией




Методы и средства эффективного
выполнения декларативных сценариев
аналитической обработки данных

Пересмотр задачи оптимизации

- Классическая (точное выполнение запросов): Найти план выполнения запроса с минимальной стоимостью
- Баланс между стоимостью и качеством
 - Гарантированное качество: Найти план обеспечивающий качество не ниже заданного за минимальное время
 - Ограниченнная стоимость: Найти план обеспечивающий максимальное качество за ограниченное время
 - Многокритериальная оптимизация
- Эвристика: построить план и распределить ресурсы

Архитектура с распределением ресурсов



Приближенные алгоритмы

- С контролируемым качеством (выделенные ресурсы определяют качество результата)
- С фиксируемыми параметрами (фиксированное количество выделенных ресурсов трансформируется в фиксированные параметры вызова операции)

Качество

- Абсолютное качество

- Качество операции

Отношение качества входа к качеству выхода

- Относительное качество

Отношение абсолютного качества выхода при фиксированных ресурсах к абсолютному качеству при неограниченных ресурсах

Развитие модели стоимости

- Базовая (традиционные оптимизаторы)

Resource = operation_cost(argument_size)

- Расширенная


Resource = operation_cost(argument_size, quality)

Quality=operation_quality(argument_size, resource)

Модели качества

- Модель качества
 - **Input**: Статистики входных данных; конфигурация операции
 - **Output**: Кусочно-линейное представление зависимости между ресурсами, выделенными на выполнение операции, и качеством результата
- Функция отображения
 - **Input**: Статистики входных данных; конфигурация операции; количество ресурсов, выделенных на выполнение операции; ожидаемое качество результата
 - **Output**: Параметры вызова операции

Архитектура системы




Методы и средства эффективного
выполнения декларативных сценариев
аналитической обработки данных

Задача распределения ресурсов

Для заданного плана выполнения запроса
найти оптимальное распределение
фиксированного ресурса, обеспечивающего
максимальное качество



Используемые обозначения

- Дерево плана P
- Операции (алгоритмы)
- Функции качества
- Ресурсы (время) T



Функции качества

- $q(x) : \mathcal{R} \rightarrow Q$ (операция)
- $Q(x) : \mathcal{R} \rightarrow \mathcal{Q}$ (план)
- $Q(x) = \min(Q(l); Q(r))q(x)$




Задача оптимизации (распределения ресурсов)

- Дерево плана P и фиксированное количество ресурса T
- Для любой операции $x \in P$ выделить ресурс $t_x \in \mathcal{R}$ так, что $\sum t_x \leq T$ и $Q(\text{root})$ максимально
- Множество $t_P = \{t_x : x \in P\}$ называется распределением ресурсов

Предположения


- Границы $t_{min}(x), t_{max}(x) \in \mathcal{R}$
- Качество выхода
неубывающая функция
от выделенного
количества ресурса
 $\forall x \in P; t_1, t_2 \in \mathcal{R}: t_1 < t_2$
 $q(x)(t_1) < q(x)(t_2)$
- Качество операции
может быть
приближено
непрерывной кусочно-
линейной функцией



Подход к решению

- Леммы о распределении ресурсов в частных случаях:
 - Вдоль пути
 - Между братьями
- Алгоритм
 - Разбиение на фрагменты
 - Итеративное приближенное решение для произвольного плана

Гиперграф




Алгоритм распределения ресурсов


- Input: Дерево плана P , ресурс T
 - Output: Для всех операций $x \in P$ распределенное количество ресурса t_x
- ```
Initialization($P; T$)
while $T > 0 \& !\text{isMaxQualityReached}(P)$ do
 $H = \text{HypergraphConstruction}(C)$
 ResourceAllocation($H; T$)
 QualityEstimation(P)
end while
```

# Производительность

Среднее число итераций




Абсолютное время




# Баланс между стоимостью и качеством


Относительное качество



Относительная производительность



# Оптимизация и выполнение запросов



Методы и средства эффективного  
выполнения декларативных сценариев  
аналитической обработки данных

# План доклада

- Введение
- Обзор литературы
  - Выполнение точных запросов
  - Адаптивное выполнение запросов
  - Выполнение приближенных запросов
  - Многокритериальная и параметрическая оптимизация
- Подходы к решению и основные результаты
  - Теоретическая модель оптимизации и контролируемого приближенного выполнения нечетких запросов
  - Архитектура системы приближенного выполнения нечетких запросов в реальном времени
  - Задача распределения ресурсов
  - Многокритериальная оптимизации запросов при специфических ограничениях
- Заключение


# Сценарий выполнения запроса

- Формулирование запроса (и ограничений)
- Оптимизация запроса
  - Зависимости критериев
  - Множество оптимальных планов
- Исполнение
  - Уточнение ограничений
  - Оптимальный план
  - Конфигурация плана
  - Исполнение плана

| Time       | Quality |
|------------|---------|
| 5 msec     | 10%     |
| 5 sec      | 30%     |
| 10 min     | 80%     |
| 24 hours   | 99%     |
| 1120 years | 99.999% |

# Задача многокритериальной оптимизации

## Многокритериальная оптимизация




## Подход

- Функция качества плана
  - $Q_P: \mathcal{R} \rightarrow \mathcal{Q}$
  - Свойства
    - $t_{min}, t_{max} \in \mathcal{R}$
    - $\forall t_1, t_2 \in \mathcal{R}: t_1 < t_2 \Rightarrow Q_P(t_1) < Q_P(t_2)$
- Функция качества стратегии
  - $Q_S: \mathcal{R} \rightarrow \mathcal{Q}$
  - Сегменты ассоциированы с планом выполнения запроса

# Доминанта

Доминанта запроса это  
функция качества,  
доминирующая над  
функциями качества всех  
планов (стратегий)  
выполнения запроса




# Решение задачи многокритериальной оптимизации

## – Оптимизация

- Построить функцию качества плана на основе моделей стоимости/качества и стратегии оптимального распределения ресурсов
- Построить доминанту запроса на основе алгоритма перечисления планов

## – Исполнение

- Выбрать оптимальный план выполнения запроса для заданных ограничений на основе доминанты




# Доминанта для запроса

- Слияние функций качества
- Построение доминанта для запроса  
(перечисление планов)
  - Полный перебор
  - Снизу-вверх
  - Сверху-вниз
- Сжатие функций качества



# Цели экспериментов

- Существование нетривиальной доминанты для типичных запросов;
- Производительность построения доминанты запроса
- Точность приближенных доминант

# Нетривиальная доминанта




# Относительная производительность построения доминант





# Построение доминант простых запросов

| Algorithm | Full Time | Skyline Time | Visited Plans |
|-----------|-----------|--------------|---------------|
| SSJJ      |           |              |               |
| FULL      | 562       | 271          | 576           |
| BOTTOM_UP | 246       | 119          | 441           |
| TOP_DOWN  | 171       | 56           | 259           |
| SSSSJJ    |           |              |               |
| FULL      | 36719     | 22673        | 17280         |
| BOTTOM_UP | 2623      | 1428         | 2952          |
| TOP_DOWN  | 752       | 325          | 911           |
| SSFFJ     |           |              |               |
| FULL      | 238       | 106          | 288           |
| BOTTOM_UP | 94        | 38           | 226           |
| TOP_DOWN  | 21        | 11           | 44            |



# Построение доминант со сжатием



# Заключение

- Расширяемая алгебра операций
- Расширенная модель стоимости (качества)
- Алгоритм распределения ресурсов
- Алгоритмы многокритериальной оптимизации

# План доклада

- Введение
- Обзор литературы
  - Выполнение точных запросов
  - Адаптивное выполнение запросов
  - Выполнение приближенных запросов
  - Многокритериальная и параметрическая оптимизация
- Подходы к решению и основные результаты
  - Теоретическая модель оптимизации и контролируемого приближенного выполнения нечетких запросов
  - Архитектура системы приближенного выполнения нечетких запросов в реальном времени
  - Задача распределения ресурсов
  - Многокритериальная оптимизация запросов при специфических ограничениях
- Заключение