Введение в анализ данных: Поиск похожих объектов. MapReduce

Юля Киселёва
juliakiseleva@yandex-team.ru
Школа анализа данных

План на сегодня

- Поиск похожих объектов
  - Мотивация
  - Метрики расстояний
- MapReduce

Многомерные данные

Много реальных задач:

– Веб-поиск и анализа текста
  - Миллиард документов, миллион термов
– Системы рекомендаций для продуктов
  - Миллионы покупателей, миллионы продуктов
– Онлайн реклама, анализ поведения пользователя
  - Действия покупателей на сайте, поисковые запросы

Поиск похожих объектов

- Многие задач, которые могут быть озвучены, как «найти похожие объекты»
- Примеры:
  - Веб-страницы с похожими словами (классификация, определение дубликатов)
  - Покупатели с «похожими интересами» (NetFlix пользователи с похожими вкусами в кино)
  - Изображения с «похожими признаками»
  - Пользователи, которые посещают один и тот же веб-сайт

Многомерные данные

- Предположим, что есть набор данных с фиксированным числом N точек

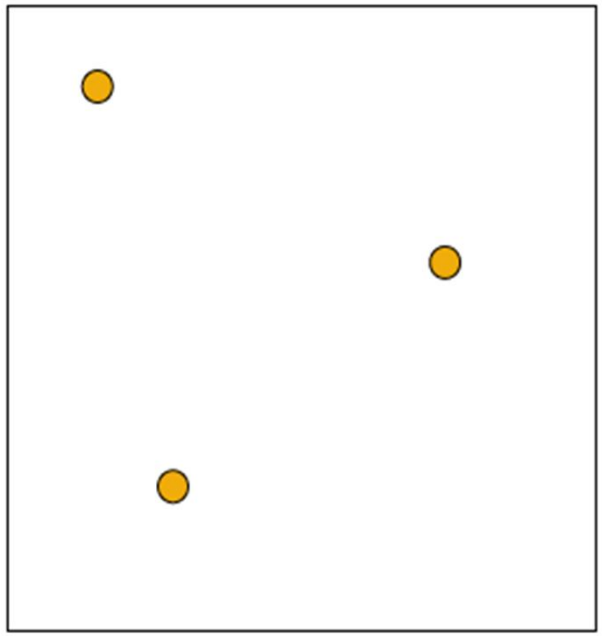

- Если увеличить размерность пространства, в котором находятся данные точки, то средняя длина между точками в этом пространстве будет увеличиваться

Многомерные данные (2)

- Представление данных в векторном виде:
  - Все данные состоят из a, b, c, d
  - ab = (1, 1, 0, 0)
  - bdc = (0, 1, 1, 1)
- **Tf*Idf:**
  - *D = (d1, d2, …, di, …,dn)*
  - *Tf (term frequency)* = частота слова (терма) в данном документе
  - *IDF (inverse document frequency)* $\mathrm{IDF} = \log \frac{|D|}{|(d_i \supset t_i)|}$
  - di = (w1, w2, …, wn), где wi = *tf(t,d)*idf(t)* для i-ого терма

Проблема разреженности данных

- Большинство покупателей не покупают большинство продуктов
- Большинство документов не содержат большинство слов
- Простое решение: Добавьте больше данных!
  - Больше покупателей, более длинная история покупок
  - Больше документов

Метрики расстояний

- Определим «ближайших соседей» как точки, которые имеют «маленькое расстояние» между друг другом
- Для каждого случая нужно определить, что означает «расстояние»
- Существует два основных класса расстояний:
  - Евклидово
  - Не-евклидово

Евклидово и Не-евклидово

- Евклидов пространство имеет определенную размерность

- *Евклидово расстояние* определяется на основе положения точек в пространстве
- *Не-евклидово расстояние* определяется на основе свойств точек, но не на основе их положения в пространстве

Аксиомы метрик расстояний

- d – является метрикой расстояния, если это функция, которая отображает пару точек в вещественное число и удовлетворяет следующим аксиомам:

1. Не отрицательность $d(p,q) \geq 0$
2. Тождественность $d(p,q) = 0 \text{ iff } p = q$
3. Симметрия $d(p,q) = d(q,p)$
4. Неравенство треугольника $d(p,q) \leq d(p,r) + d(r,q)$

Некоторые евклидовы метрики расстояния

L_2 *norm*: d(p,q)

$$\mathrm{d}(\mathbf{p},\mathbf{q}) = \mathrm{d}(\mathbf{q},\mathbf{p}) = \sqrt{(q_1-p_1)^2+(q_2-p_2)^2+\cdots+(q_n-p_n)^2} = \sqrt{\sum_{i=1}^{n}(q_i-p_i)^2}.$$

L_1 *norm*: Сумма абсолютных разниц по каждому измерению

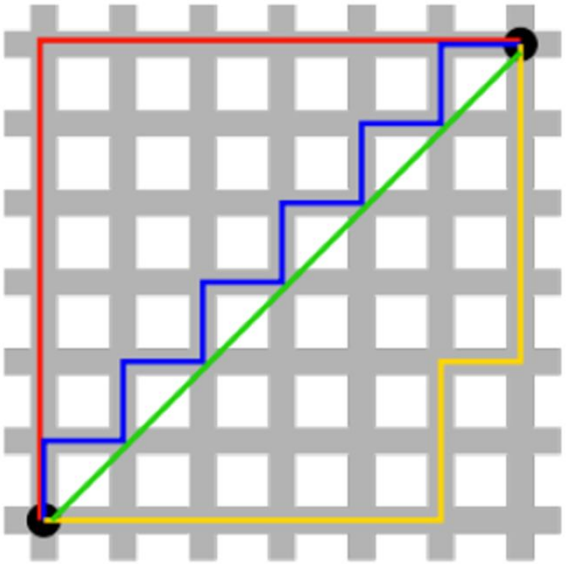

Манхетанновское расстоние (Manhattan distance) = расстояние, при котором вы можете путешествовать только по осям

$$d_1(\mathbf{p},\mathbf{q}) = \|\mathbf{p}-\mathbf{q}\|_1 = \sum_{i=1}^{n}|p_i-q_i|,$$

Другие евклидовы расстояния

L_∞ *norm*: d(x,y) = максимум разниц между x и y по каждой оси

$$D_{\text{Chebyshev}}(p,q) := \max_i(|p_i - q_i|).$$

L_p norm:

$$d([x_1, x_2, \ldots, x_n],\ [y_1, y_2, \ldots, y_n]) = (\sum_{i=1}^{n} |x_i - y_i|^r)^{1/r}$$

Не-евклидовы метрики расстояний

1. Косинусное расстояние (Cosine Distance) = это угол между векторами
2. Edit distance = число вставок, удалений, которое нужно чтобы преобразовать одну строку в другую
3. Расстояние Хемминга (Hamming Distance) = число позиций, в которых соответствующие символы двух слов одинаковой длины различны

Косинусное расстояние

- Объект представлен в виде вектора
- Между двумя векторами образуется угол и значение косинуса этого угла – это нормализованное скалярное произведение:

$$\text{similarity} = \cos(\theta) = \frac{A \cdot B}{\|A\|\|B\|} = \frac{\sum_{i=1}^{n} A_i \times B_i}{\sqrt{\sum_{i=1}^{n} (A_i)^2} \times \sqrt{\sum_{i=1}^{n} (B_i)^2}}$$

- Пример: A = 00111; B = 10011
  - $A \cdot B = 2$; $\|A\| = \|B\| = \sqrt{3}$
  - $\cos(\theta) = 2/3$;

Косинусное расстояние: диаграмма

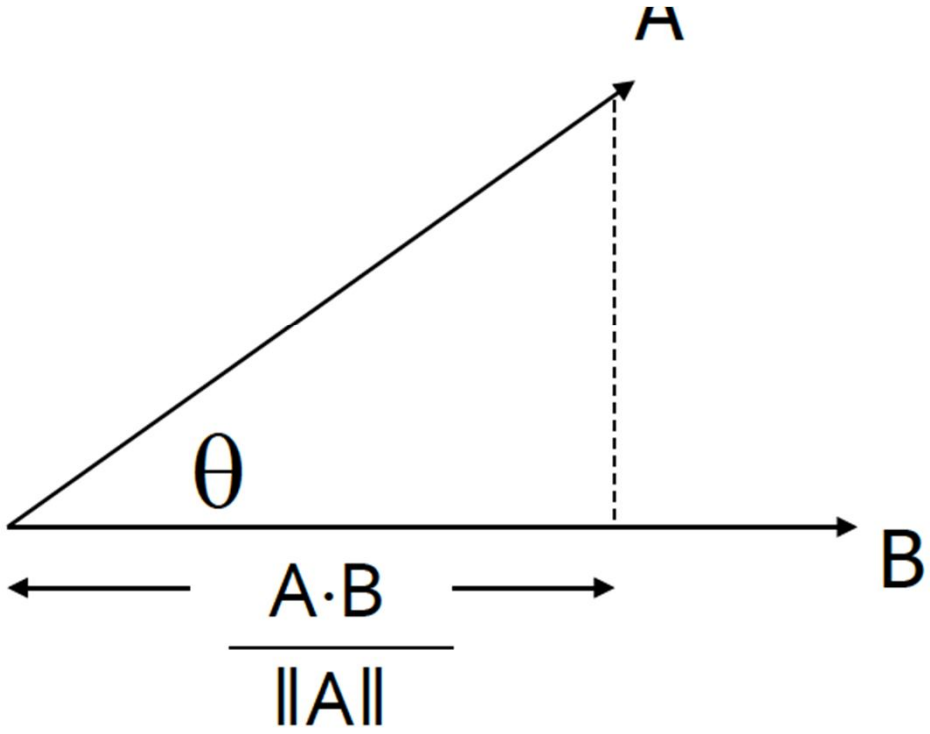

$$d(A, B) = \theta = \arccos(A \cdot B / \|A\| \, \|B\|)$$

Косинусное расстояние – это метрика

- d(x, x) = 0 потому что arccos(1)=0
- d(x,y) = d(y,x) по симметрии : очевидно, что угол между *x* и *y* равен углу между *y* и *x*
- d(x,y)>= 0 потому что мы рассматриваем углы от 0 до 180 градусов
- неравенство треугольника (физический смысл)

Edit Distance (редакционное расстояние или дистанция редактирования)

- Edit distance между двумя строками – это число вставок и удалений символов, которые необходимо сделать, чтобы преобразовать одну строку в другую

  Эквивалентно:

$$d(x,y) = |x| + |y| - 2|LCS(x,y)|$$

- LCS (**l**ongest **c**ommon **s**ubsequence) = наибольшая общая подпоследовательность

Edit Distance: пример

- x= abcde; y = bcduve
- Преобразование x в y:
  - Удалить a
  - Вставить u и v после d
  - Edit distance = 3
- Или : LCS(x,y) = bcde

$$d(x,y) = |x| + |y| - 2|LCS(x,y)|$$

$$=5 + 6 -2*4 = 3$$

Edit Distance – это метрика

- d(x, x) = 0
- d(x,y) = d(y,x): потому что вставка/удаление являются обратными по отношению друг к другу
- d(x,y)>= 0: «отрицательное редактирование» не имеет смысла
- неравенство треугольника: преобразование x к z и затем к y – это один из путей преобразовать x к y

Расстояние Хемминга

- Расстояние Хемминга (Hamming Distance) – число позиций, в которых соответствующие символы двух слов одинаковой длины различны
- Пример: x = 10101; y = 10011
- Ответ:

d(x,y) = 2

Jaccard Similarity

- Jaccard Similarity между двумя наборами – это размер их пересечения, разделенного а размер их объединения
  - $Sim(C_1, C_2) = |C_1 \cap C_2| / |C_1 \cup C_2|$
- Jaccard Distance между двумя наборами – это 1 минус Jaccard Similarity
  - $d(C_1, C_2) = 1 - |C_1 \cap C_2| / |C_1 \cup C_2|$

Пример: Jaccard Distance

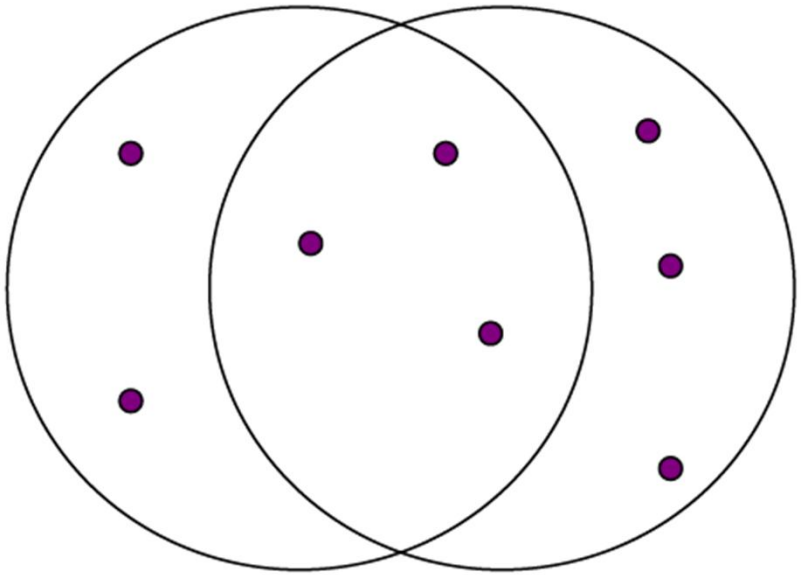

Пересечение = 3
Объединение = 8
Jaccard Similarity = 3/8
Jaccard Distance = 5/8

План на сегодня

- Поиск похожих объектов
  - Мотивация
  - Метрики расстояний
- MapReduce

Мотивация

- 20+billon веб-страниц * 20 KB = 400+ TB
- 1 компьютер читает со скоростью 35 MB/sec с диска

  ~ 4 месяца, чтобы скачать веб
- И еще нужно анализировать данные

Пример: большие вычисления – большие машины

- Traditional big-iron box (2003)
  - 8 2GHz Xeons
  - 64GB RAM
  - 8TB disk
  - 758,000 USD
- Prototypical Google rack (2003)
  - 176 2GHz Xeons
  - 176GB RAM
  - ~7TB disk
  - 278,000 USD
- In Aug 2006 Google had ~450,000 machines

Масштабные вычисления

- Большие вычисления для АД на кластерах:
  - ПК соединены сетью
  - Процессинг большого объема данных на большом количестве машин
- Проблемы:
  - как организовать распределенные вычисления
  - Распределенные/параллельные вычисления – это сложно
  - Машины могут сломаться (из 1000 серверов в день ломается 1)
- MapReduce помогает бороться со всеми описанными проблемами

Идея и решение

- Идея:
  - Перенести вычисления ближе данных ближе к данным
  - Сохранить файлы несколько раз для надежности
- Что нужно:
  - Программная модель
    - Map-Reduce
  - Инфраструктура – Распределенная Файловая система
    - Google: GFS
    - Hadoop: HDFS
    - Kosmix: KFS
- Типичный шаблон использования:
  - Большие файлы (100s GB)
  - Данные обновляются редко
  - Чтение и добавление – это обычная операция

Распределенная файловая система

- Chunk Servers:
  - Файл разделен на «соседствующие» chunks
  - Типичный размер chunk – это 16-64MB
  - Каждый chunk реплицируется на разные машины (обычно 2 или 3 раза)
- Master node:
  - Хранение мета-данных

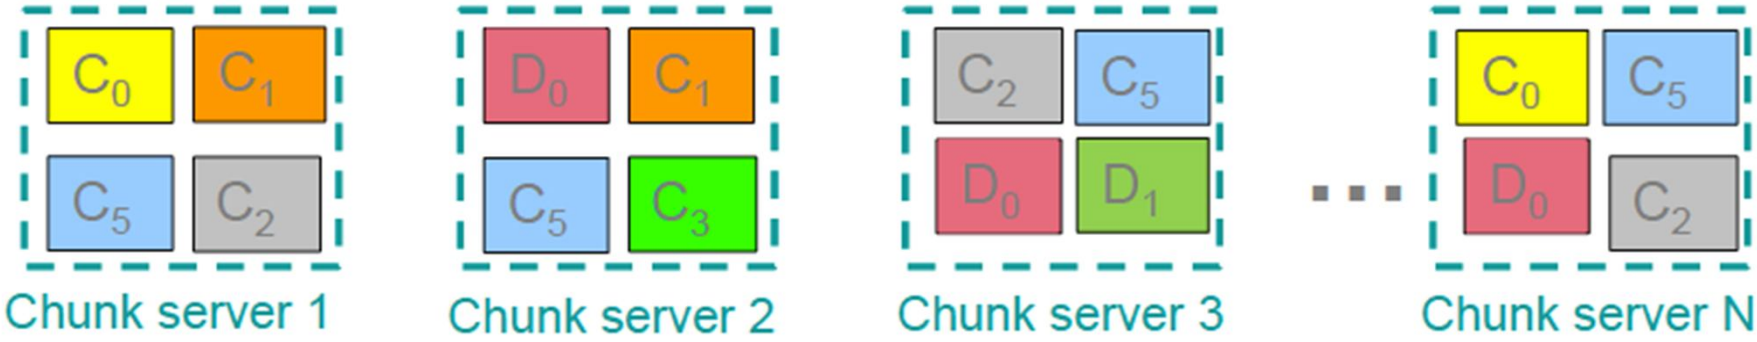

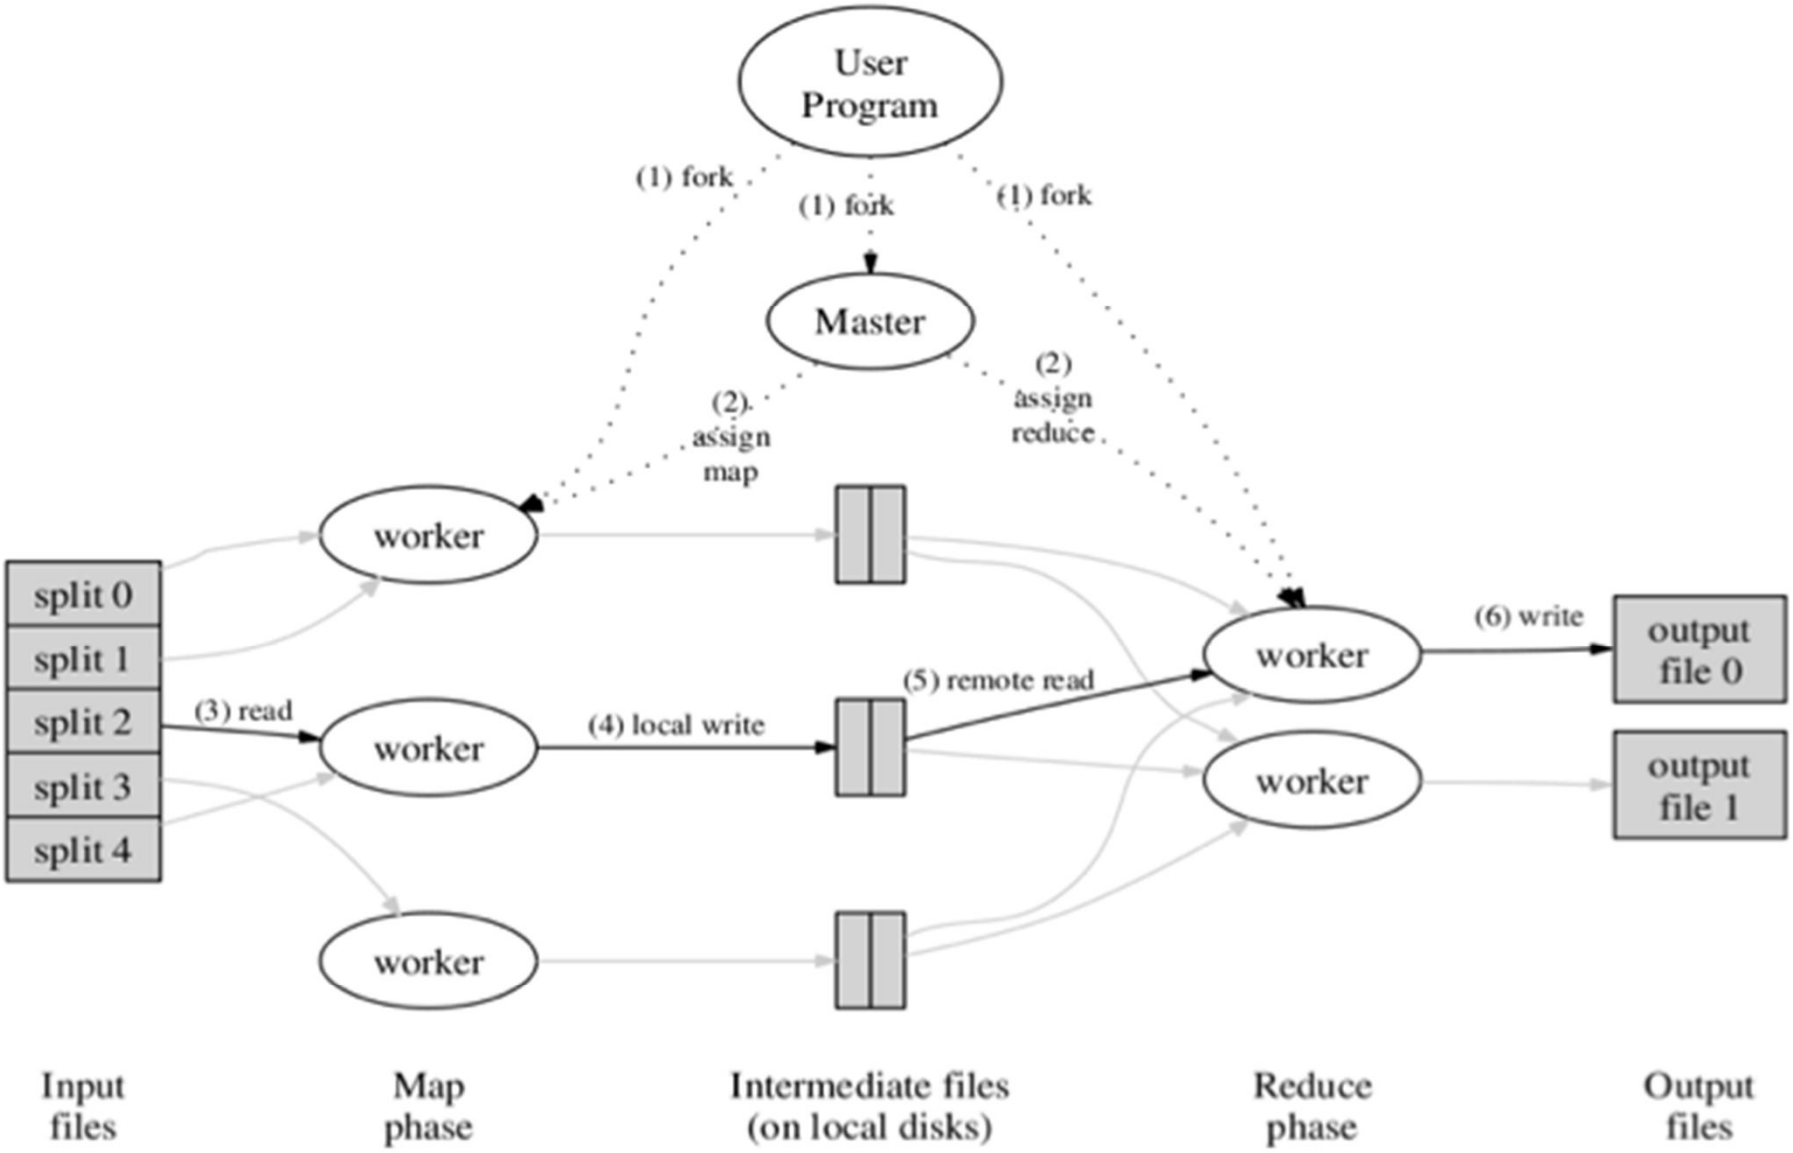

Figure 1: Execution overview

MapReduce: представление

- Читает данные
- Функция – **Map <k,v”>:**
  - Извлекает то, что Вам нужно
- Смешивает и сортирует
- Функция – **Reduce <k, v”> -> <k, v””>:**
  - Агрегирует, суммирует, фильтрует и трансформирует
- Пишет результат

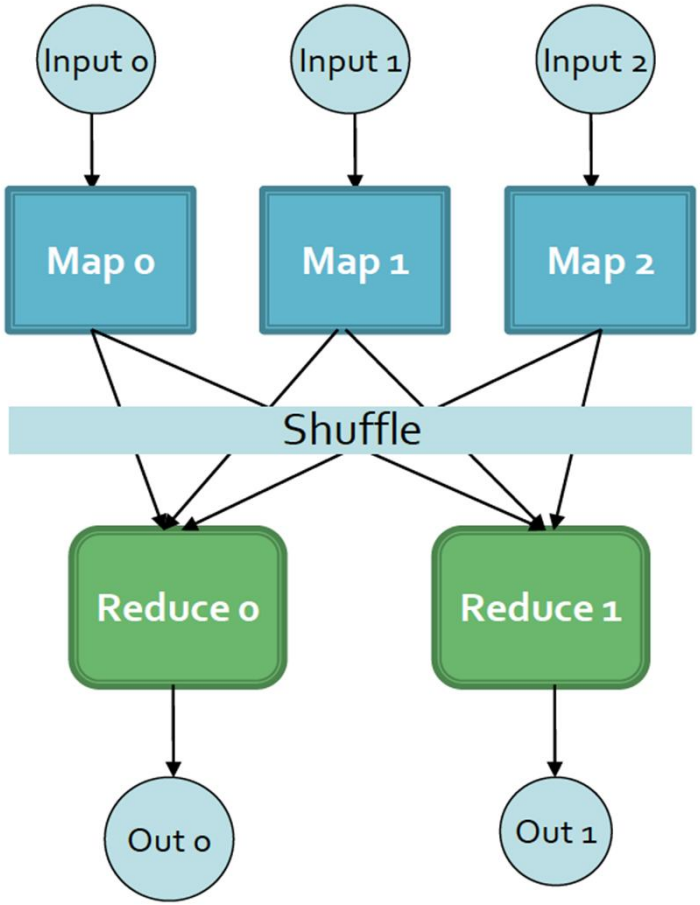

Пример: подсчет статистики по словам

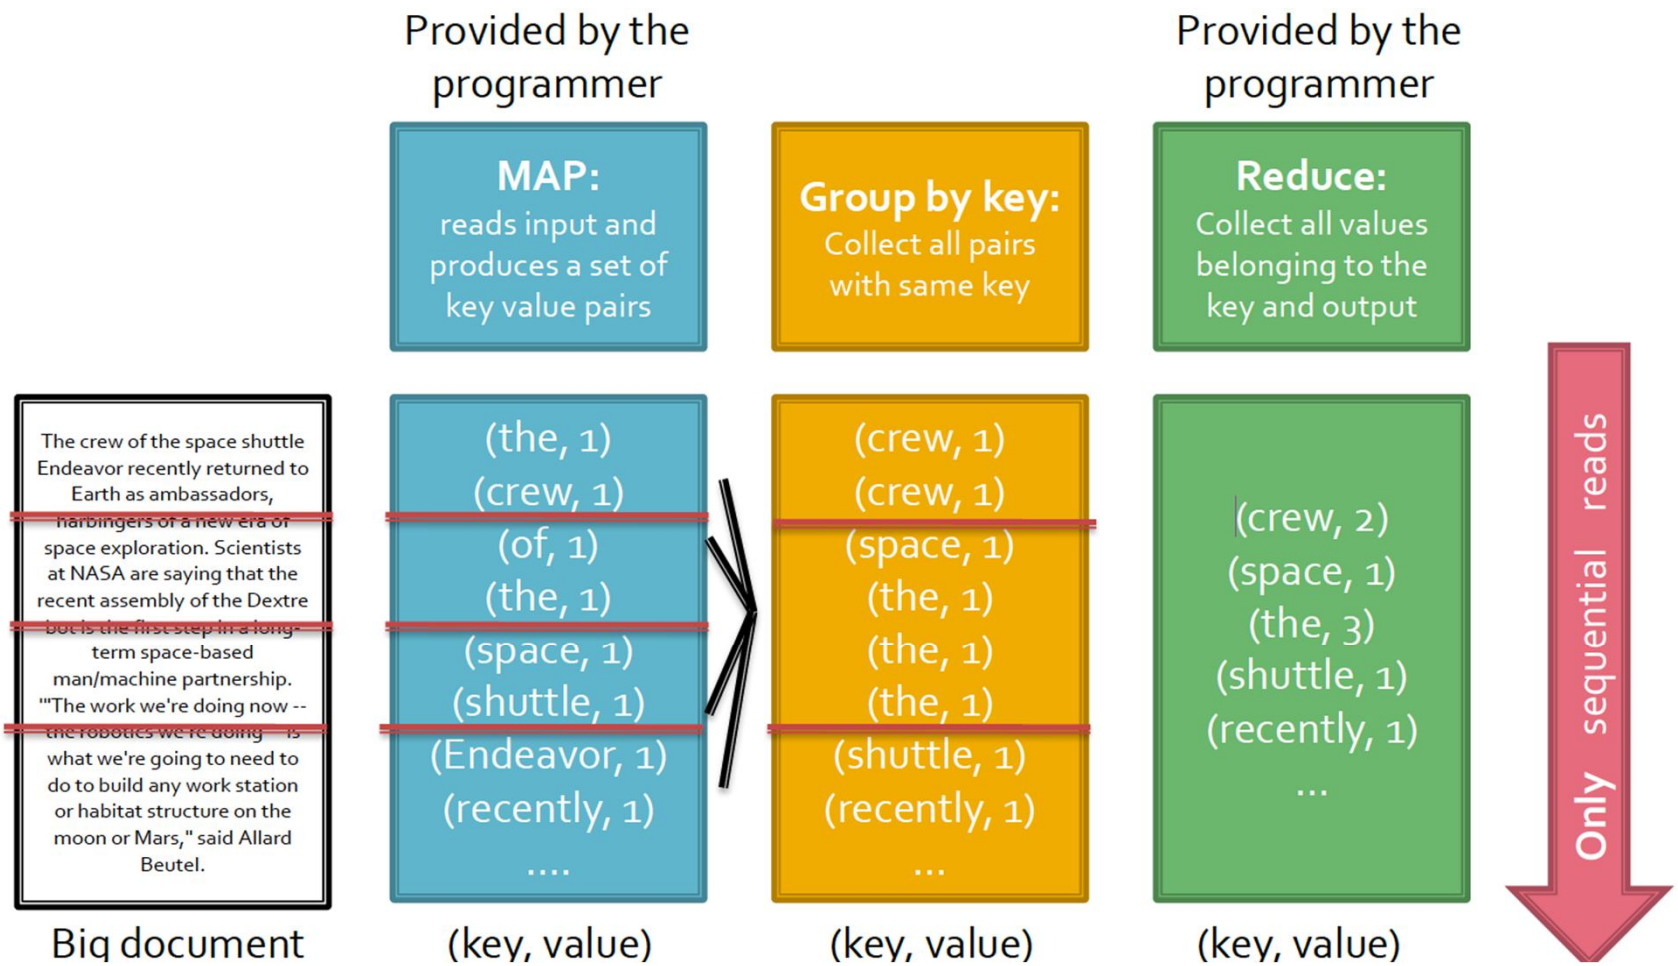

Map Reduce: Enviroment

- MapReduce enviroment заботится о:
  - Partitioning входных данных
  - Расписании выполнения программ на наборе машин
  - Манипулирование «сломанными» машинами
  - Управление внутренней коммуникацией между машинами

Имплементация

- Google
  - Недоступна вне Google
- Hadoop
  - Открытая имплементация на Java
  - Используется HDFS for stable storage
  - Скачать: http://lucene.apache.org/hadoop/
- Aster Data
  - Cluster-optimized SQL Database которая также реализует MapReduce
- MongoDb

Резюме

- Познакомились с техникой Map Reduce
- Сейчас продолжим☺
- Изучили или повторили метрики для нахождения похожих объектов
- Какие узнали метрики?