Cassandra

Курс «Базы данных»

Цесько Вадим Александрович
http://incubos.org
@incubos

Computer Science Center

30 сентября 2013 г.

Содержание

History

- July 2008 — open-sourced by Facebook[1]
- March 2010 — graduated from the Apache Incubator
- Influenced by Amazon Dynamo
- Committers: Rackspace, Digg, Twitter, Amazon, Microsoft

[1] Facebook. Cassandra — A Decentralized Structured Storage System: `http://www.cs.cornell.edu/projects/ladis2009/papers/lakshman-ladis2009.pdf`

Features

- Decentralized — no SPoF, every node is identical
- Multi data center replication
- Elastic Scalability
- High Availability and Fault Tolerance
- Tunable consistency
- CQL

Data Model

- Based on Google Bigtable
- Hybrid: Key-value + Column-oriented
- Каждая строка содержит множество колонок
- Колонка (ячейка): имя + значение
- Разные строки могут иметь разный набор колонок
- Группировка колонок в семейства и суперсемейства

Table

A distributed multi dimensional map indexed by a key

ACID

- Никаких JOIN-ов и внешних ключей
- *Атомарность* на уровне строк, нет rollback
- Можно получить ошибку при записи, но запись состоится
- Отметки времени от клиента при конфликтах
- Настраиваемая *консистентность* (количество реплик)
- *Изоляция* на уровне строк
- *Durability*: commit log + replication

CAP

- Tunable Consistency
- Tunable Availability
- Partition Tolerance

Пользователи

Самое популярное колоночное хранилище[2]:

- Cisco
- CERN
- Digg
- Facebook
- IBM
- Netflix
- Reddit
- SoundCloud
- Twitter
- Odnoklassniki
- Yandex

[2] http://db-engines.com/en/ranking/wide+column+store

Мотивация

If I had asked people what they wanted, they would have said faster horses.

Henry Ford

Что не так с RDBMS?

Очень рекомендую Chapter 1. "What's Wrong with Relational Databases?"in "Cassandra: The Definiteve Guide"[a]

[a] Eben Hewitt. Cassandra: The Definitive Guide. 2010. ISBN 1449390412.

У нас есть сервис на RDBMS

Всё работает?

Не трогай!

С чем могут быть проблемы:

- (Distributed) Transactions[3]
- (Distributed) JOINs
- (Distributed) Schema evolution
- Sharding[4]
  - Functional segmentation
  - Key-based sharding
  - Lookup table

[3] Gregor Hohpe. Starbucks Does Not Use Two-Phase Commit: `http://www.eaipatterns.com/ramblings/18_starbucks.html`

[4] Michael Stonebraker. The Case for Shared Nothing. 1986

Use Case: RDBMS Scaling

LiveJournal

Brad Fitzpatrick. LiveJournal's Backend: A history of scaling[a]. August 2005.

[a] http://www.danga.com/words/2005_oscon/oscon-2005.pdf

Web Scale

IDC. The Expanding Digital Universe[5]. March 2007:

- YouTube: 2007 — 100 M videos/day, **2008** — 1 B videos/day
- Chevron: 2 TB/day
- Internet: 2006 — 166 EB, 2010 — 1 ZB
- Wall-Mart: 2000 — 110 TB, 2004 — 0.5 PB
- Email: 1998 — 253 M accounts, 2010 — 2 B accounts
- etc.[6]

---

[5] http://www.emc.com/collateral/analyst-reports/expanding-digital-idc-white-paper.pdf

[6] http://highscalability.com/

Модель данных

- Cassandra — партиционированное хранилище рядов
- Исходим из запросов, а не из сущностей и связей
- Таблица — коллекция упорядоченных колонок
- Keyspace — группа таблиц (обычно per application)

Если глубже

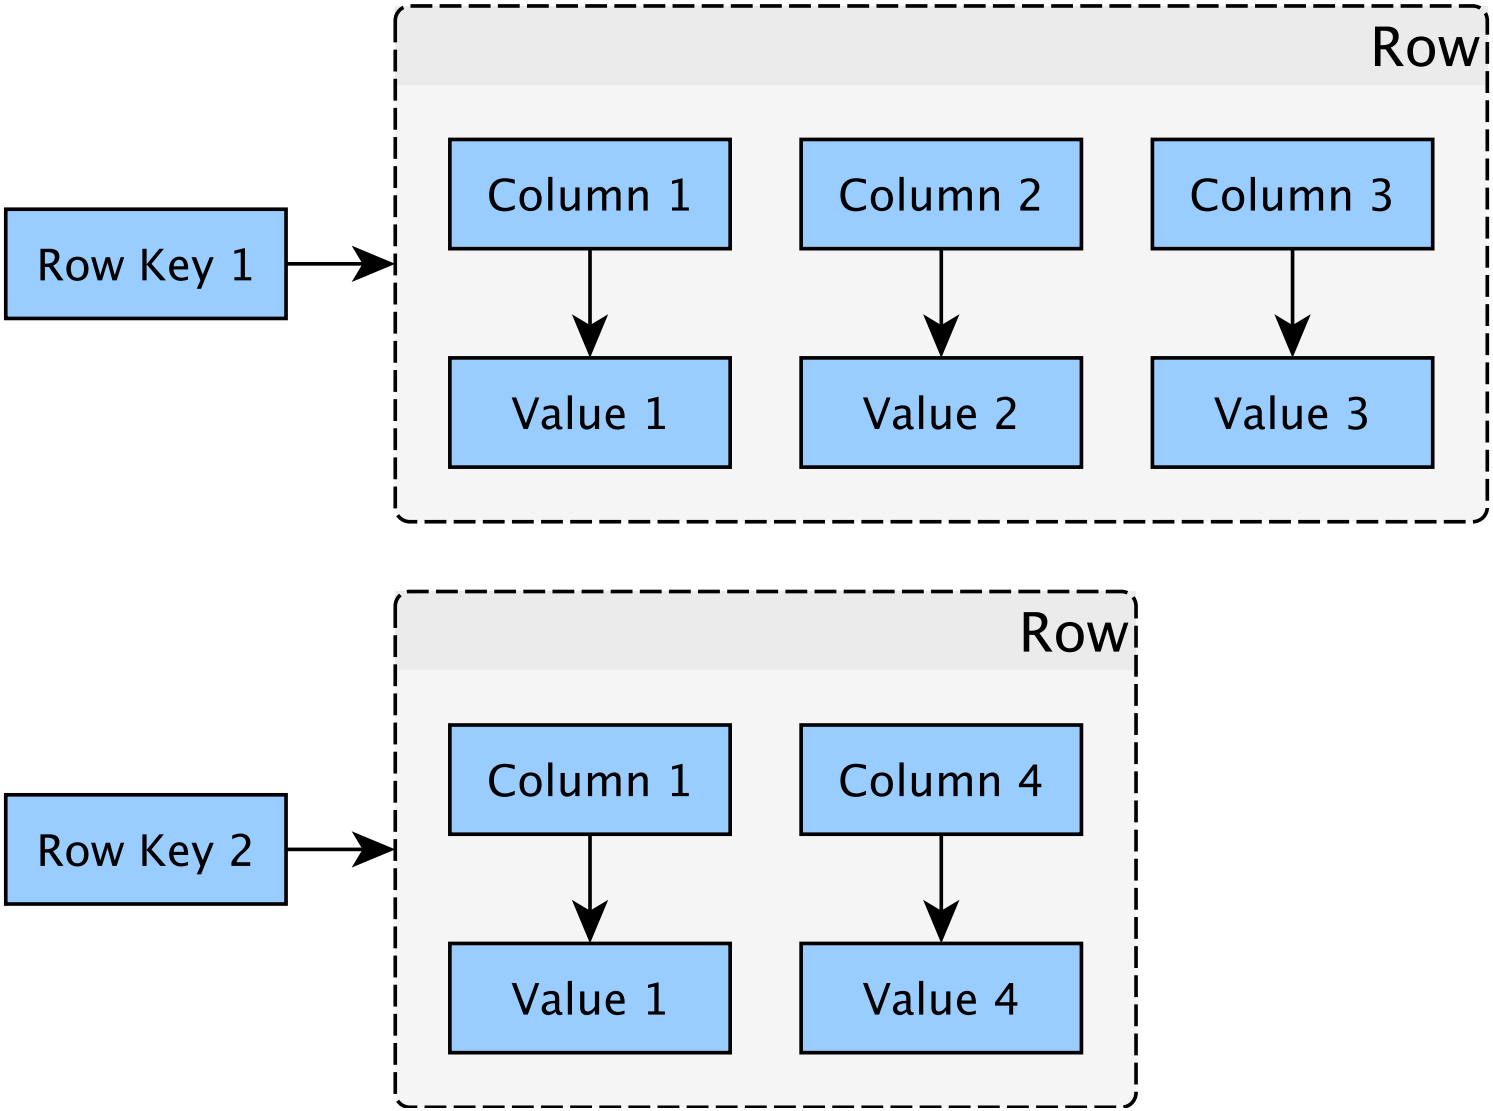
Row
Row Key 1
Column 1
Column 2
Column 3
Value 1
Value 2
Value 3
Row
Row Key 2
Column 1
Column 4
Value 1
Value 4

Интерфейсы

- Thrift API
  - Исторически первый
  - Низкоуровневый
  - Довольно многословный
- **CQL** (текущая версия 3.1)
  - SQL-подобный
  - (Почти насколько же) выразительный
  - Развивается

Пример

```
1 CREATE TABLE songs (
2   id uuid PRIMARY KEY,
3   title text,
4   album text,
5   artist text,
6   data blob
7  );
```

```
1 CREATE TABLE playlists (
2   id uuid,
3   song_order int,
4   song_id uuid,
5   title text,
6   album text,
7   artist text,
8   PRIMARY KEY (id, song_order));
```

Особенности

- Compound keys (clustering)
- Indexes
- Collection types[7]: `set`, `list`, `map`
- `INSERT` = `UPDATE` = `UPSERT`
- `DELETE` для строки или набора ячеек
- TTL
- Counters
- См. спеку[8]

[7] `http://www.datastax.com/dev/blog/cql3_collections`

[8] `http://www.datastax.com/documentation/cql/3.1/webhelp/index.html`

Компоненты

- **Consistent Hashing** + **VNodes** (см. лекцию 1)
- **Gossip** — состав и состояние узлов
- **Partitioner** — данные по узлам
- **Replica placement strategy** — реплики по узлам
- **Snitch** — топология (ДЦ и стойки)

Virtual Nodes

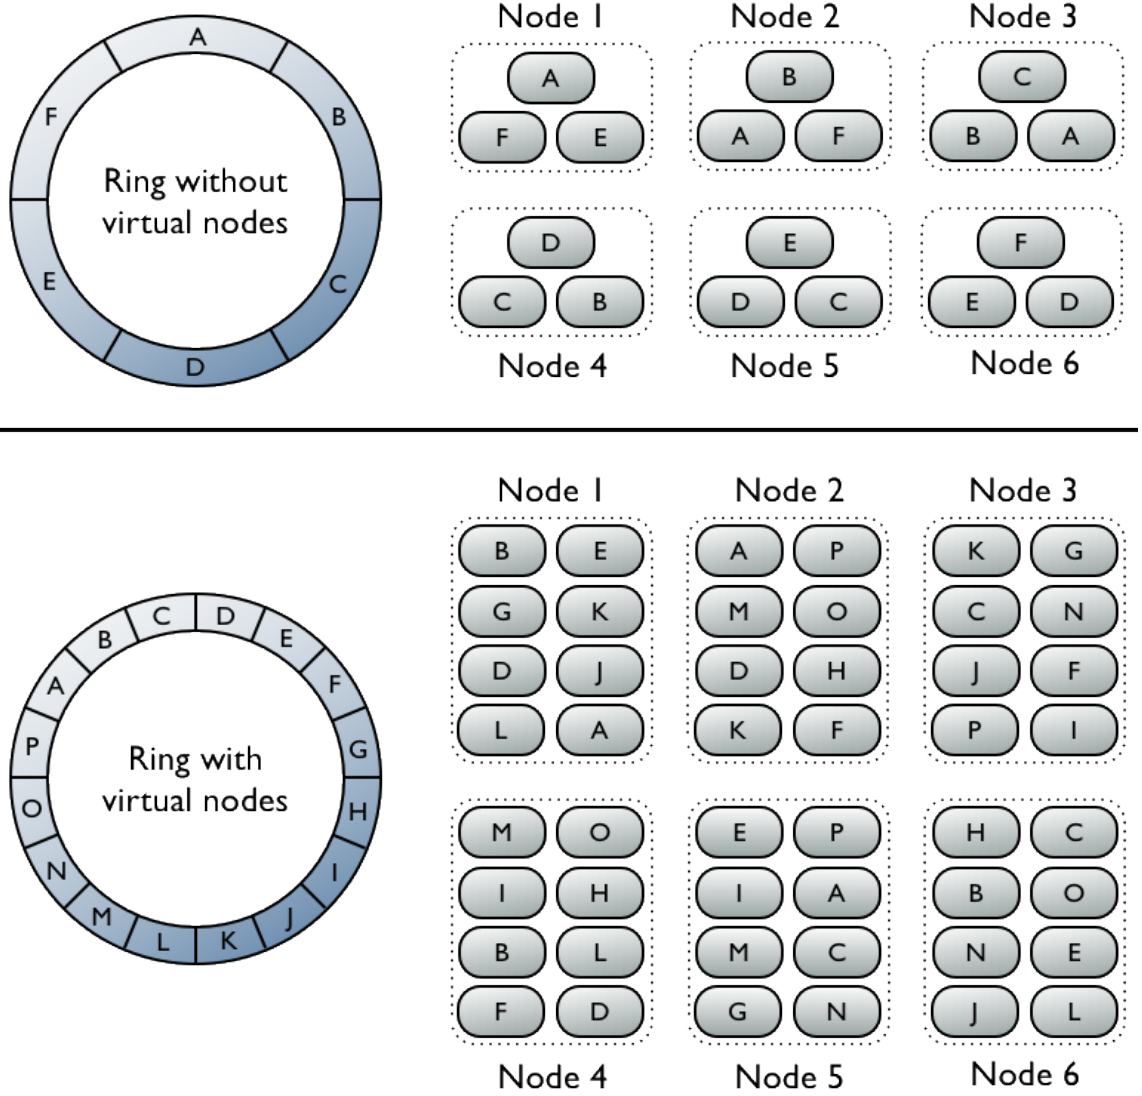

Gossip

- Узлы периодически обмениваются информацией о себе и других узлах
- Каждую секунду не больше чем с тремя узлами
- Все узлы быстро узнают информацио обо всех узлах
- Сообщения имеют версию — устаревшая информация затирается
- Seed nodes во избежания партиционирования
- Gossip-информация хранится на каждой ноде персистентно
- Обнаружение сбоев узлов (+ dynamic snitch)[9]

[9] Naohiro Hayashibara, Xavier Défago, Rami Yared and Takuya Katayama. The ϕ Accrual Failure Detector. 2008

Partitioner

- Consistent Hashing[10]
- Новый `Murmur3Partitioner` (-2^{63} to $+2^{63}$) и старый `RandomPartitioner` (0 to $2^{127} - 1$)
- `ByteOrderedPartitioner`
  - Лексикографически по байтам ключа
  - Сложная балансировка нагрузки (расчёт диапазонов партиций вручную)
  - Неравномерная балансировка для разных таблиц
  - Последовательная запись упирается в один узел

[10] `http://www.datastax.com/documentation/cassandra/2.0/webhelp/cassandra/architecture/architectureDataDistributeAbout_c.html`

Replica Placement Strategy

- Replication Factor — количество реплик на кластер
- Каждая реплика на отдельном узле
- Все реплики равноправны
- `SimpleStrategy`:
  - 1 ДЦ (если планируете расширяться, не используйте)
  - Первая реплика на узел от Partitioner
  - Остальные — по часовой стрелке по кольцу
- `NetworkTopologyStrategy`:
  - Определяет количество реплик в каждом ДЦ
  - Узлы для реплик — идём по кольцу до следующей стойки
  - Часто стойки вырубаются целиком (питание, охлаждение, сеть, ...)

NetworkTopologyStrategy

Факторы

- Желательно чтение внутри ДЦ
- Учитываем типичные сбои

По 2 реплики в каждом ДЦ

Сбой одного узла — `ConsistencyLevel.ONE`

По 3 реплики в каждом ДЦ

- Сбой одного узла — `ConsistencyLevel.LOCAL_QUORUM`
- Сбой двух узлов — `ConsistencyLevel.ONE`

Snitch

- **Одинаковая конфигурация** на узлах
- Dynamic snitching wrapper[11]
  - По умолчанию и только на чтение
  - Данные с самой быстрой реплики, с остальных — контрольные суммы
  - Статистика Read Latency и текущие задачи узлов
- `SimpleSnitch`: никаких ДЦ и стоек
- `RackInferringSnitch`: (`110.dc.rack.node`)
- `PropertyFileSnitch`: адреса в ДЦ/стойки в файле
- `GossipingPropertyFileSnitch`: локальный ДЦ и стойка в файле на каждом узле + Gossip

[11] `http://www.datastax.com/dev/blog/dynamic-snitching-in-cassandra-past-present-and-future`

Клиентские запросы

- Можно обращаться к любому узлу
- Узел становится координатором для текущего запроса
- Координатор проксирует с учётом Partitioner и Replica Placement Strategy

Write

- Запрос всем репликам независимо от `ConsistencyLevel`
- `ConsistencyLevel` определяет, сколько реплик должно ответить для успеха

Write: Пример

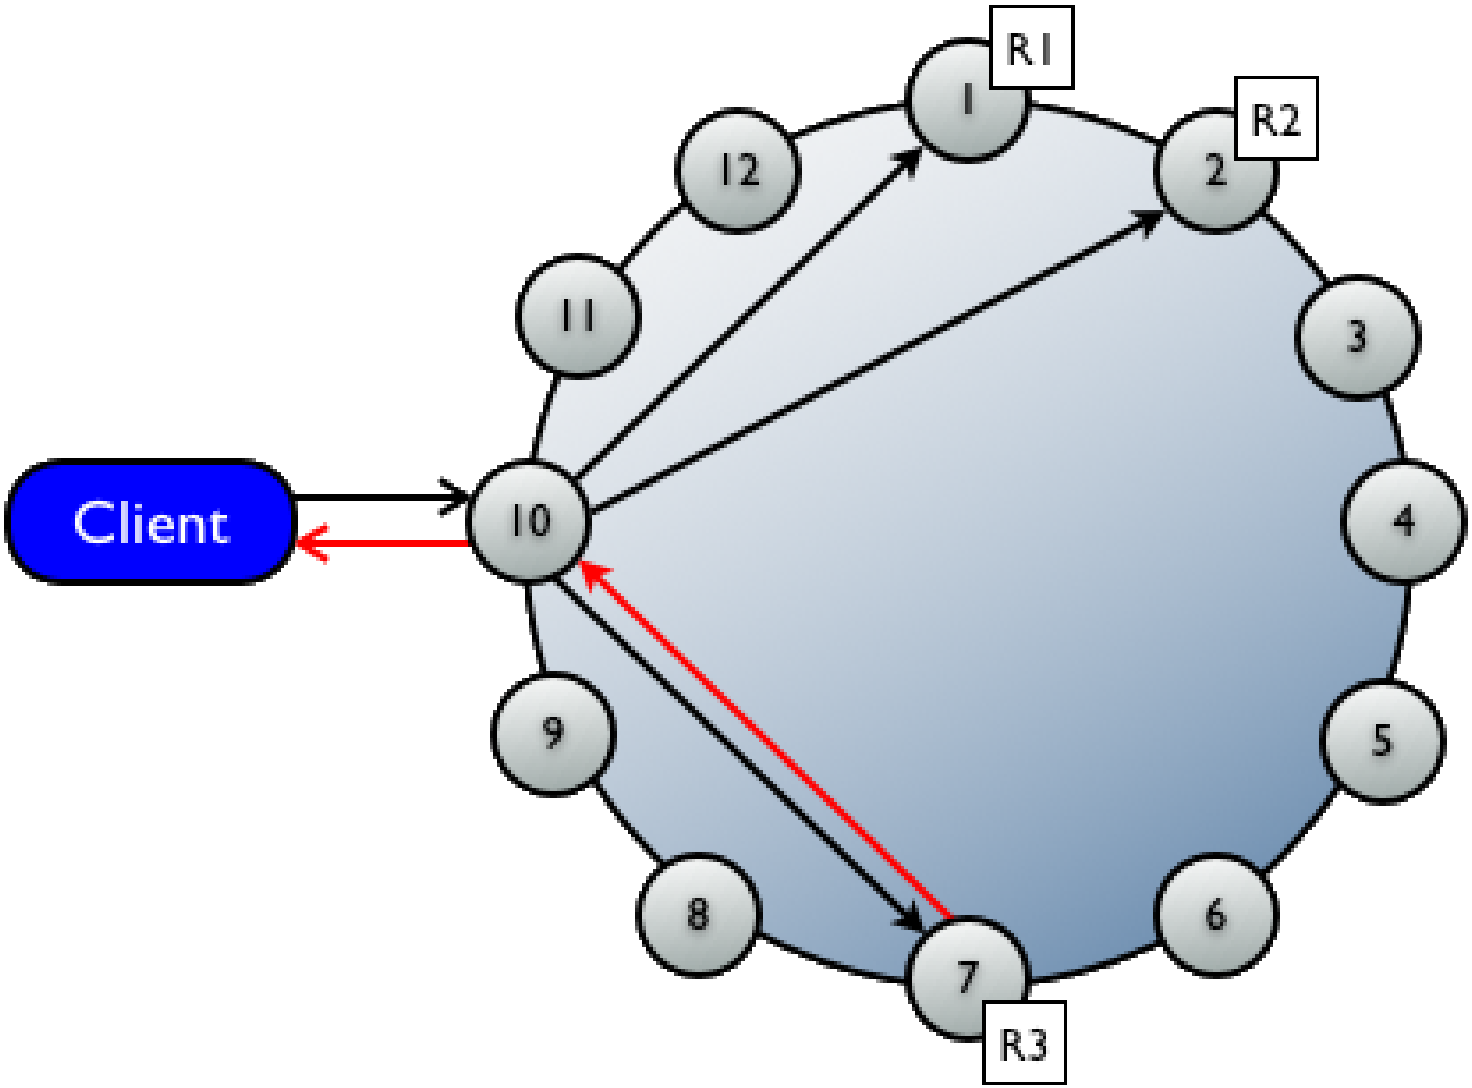

MultiDC Write

- Оптимизация — один координатор в каждом удалённом ДЦ
- `ConsistencyLevel.ONE` или `ConsistencyLevel.LOCAL_QUORUM` — обязаны ответить только локальные узлы (география не влияет на задержку)

MultiDC Write: Пример

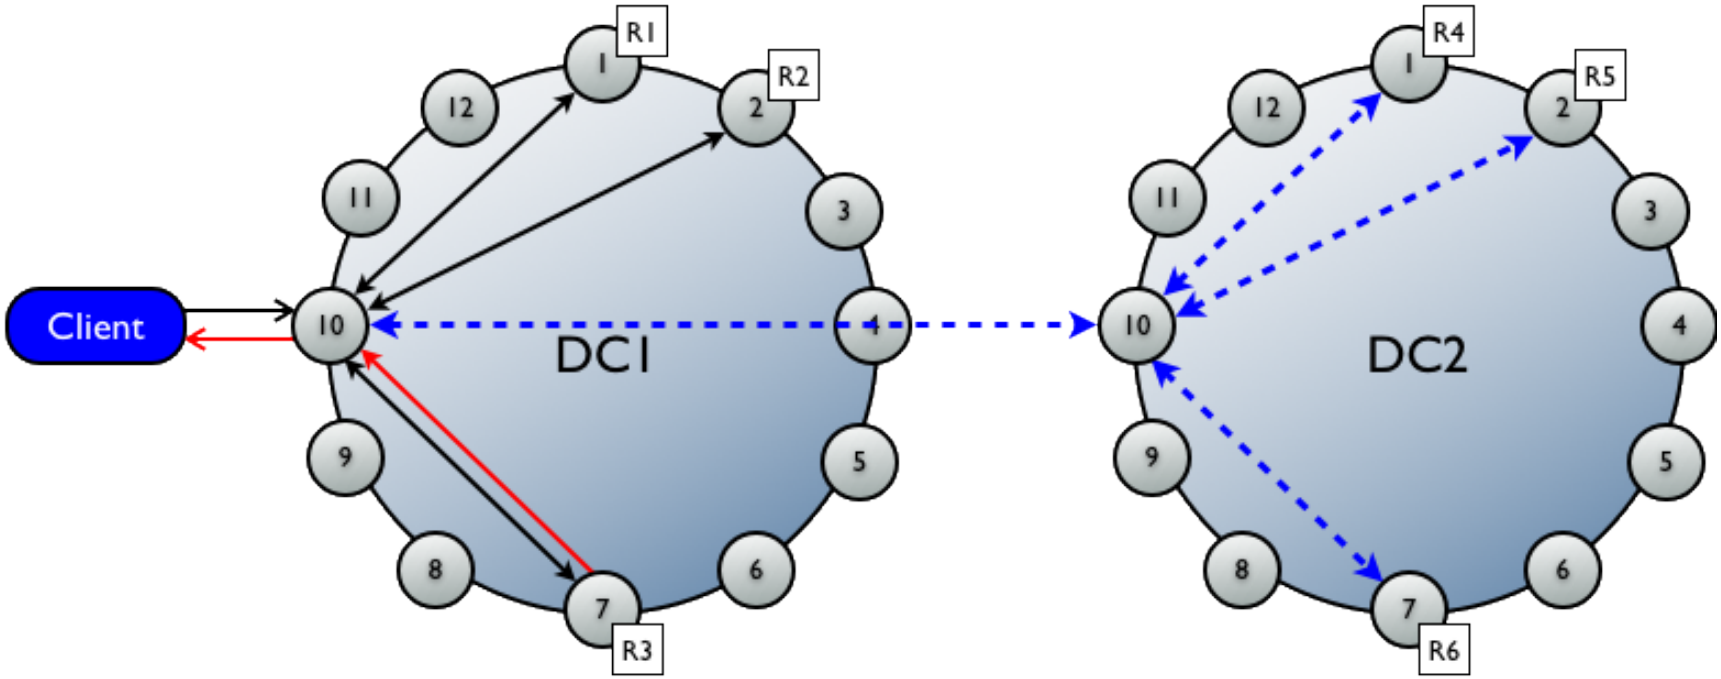

Write: ConsistencyLevel

- `ANY` — всегда успех (hinted handoff)
- `ONE` — в commit-log одного узла
- `TWO`
- `THREE`
- `QUORUM` — inter DC + нужен запас прочности
- `LOCAL_QUORUM` — быстрее, чем `QUORUM`
- `EACH_QUORUM` — выше консистентность
- `ALL` — WAT?

Не забываем

Даже при `ONE` и `LOCAL_QUORUM` запись пошлют всем репликам в т. ч. в других ДЦ

Read

Read-запросы от координатора репликам:

- Прямой запрос на чтение (в соответствии с `ConsistencyLevel`)
  - Самым «быстрым» репликам
  - Сравниваем ответы
  - Если не совпадают, то самая свежая (по timestamp) — клиенту
- Фоновый read repair (всем остальным репликам)
  - Для синхронизации «горячих» данных
  - `read_repair_chance` по умолчанию 0.1
  - Если не совпадают хэши, то перезаписываем

Read: Пример

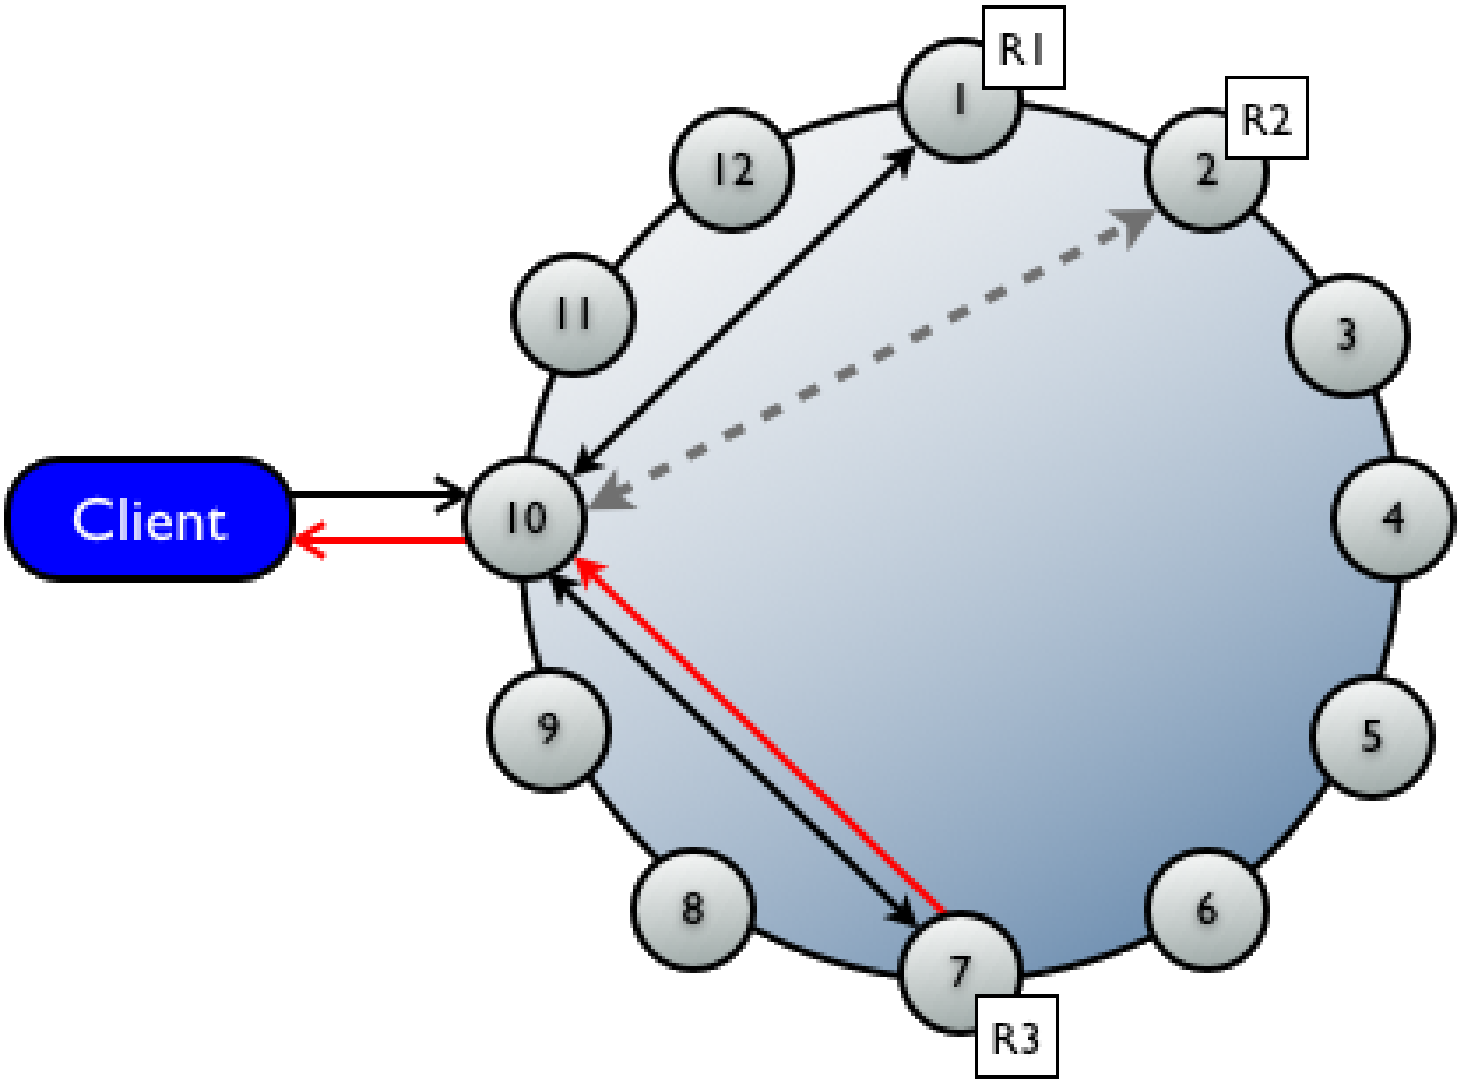

Read ConsistencyLevel

- `ONE` — ближайшая реплика, возможно, устаревшие данные
- `TWO`
- `THREE`
- `QUORUM` — inter DC + нужен запас прочности
- `LOCAL_QUORUM` — быстрее, чем `QUORUM`
- `EACH_QUORUM` — выше консистентность
- `ALL` — WAT?

Интерпретация

Возвращаем самое свежее значение из требуемого множества реплик

Quorum

Quorum

$$Quorum = \lfloor \frac{RF}{2} + 1 \rfloor$$

- $RF = 2 \Rightarrow Quorum = 2$ — нет запаса
- $RF = 3 \Rightarrow Quorum = 2$ — в запасе 1 узел
- $RF = 4 \Rightarrow Quorum = 3$ — в запасе 1 узел
- $RF = 5 \Rightarrow Quorum = 3$ — в запасе 2 узла

Consistency

$$R + W > RF$$

- $R = 2 + W = 2 > RF = 3$ — в запасе 1 узел

Клиентские запросы

Проблема

- Узел сбойнул: железо или (чаще) сеть
- А мы хотим на него записать
- Что делать?

Hinted Handoff

- Пусть известно (Gossip), что узел лежит, или узел не отвечает
- Координатор запоминает hint локально
- Когда обнаружится, что узел поднялся (Gossip), ему перешлют накопленные hints

Hint

Содержимое

- Кому предназначается
- Значение ключа
- Данные

Внимание

- Hints хранятся ограниченное время (по умолчанию 3 часа)
- Официально рекомендуется периодический запуск `repair`

Ограничения

- Hint засчитывается не на всех уровнях консистентности[12]: 2 узла (1 мёртв) + RF=1 + `ConsistencyLevel.ONE`
- Но **всегда работает**, если не выключен
- `ConsistencyLevel.ANY` — extreme write availability
- Если умрёт машина с hints, то мы их потеряем

[12] `http://www.datastax.com/dev/blog/modern-hinted-handoff`

Anti-entropy

Проблема

- Узел умер — пропустил удаление данных
- Вернулся к жизни — данные возродились

Anti-entropy

- Инициируем с помощью `nodetool repair`
- Запускаем readonly major compaction
- Строим Merkle Tree[a]
- Обмениваемся деревьями и ищем отличия
- Обмениваемся отличающимися сегментами

[a] `http://en.wikipedia.org/wiki/Merkle_tree`

Write Path

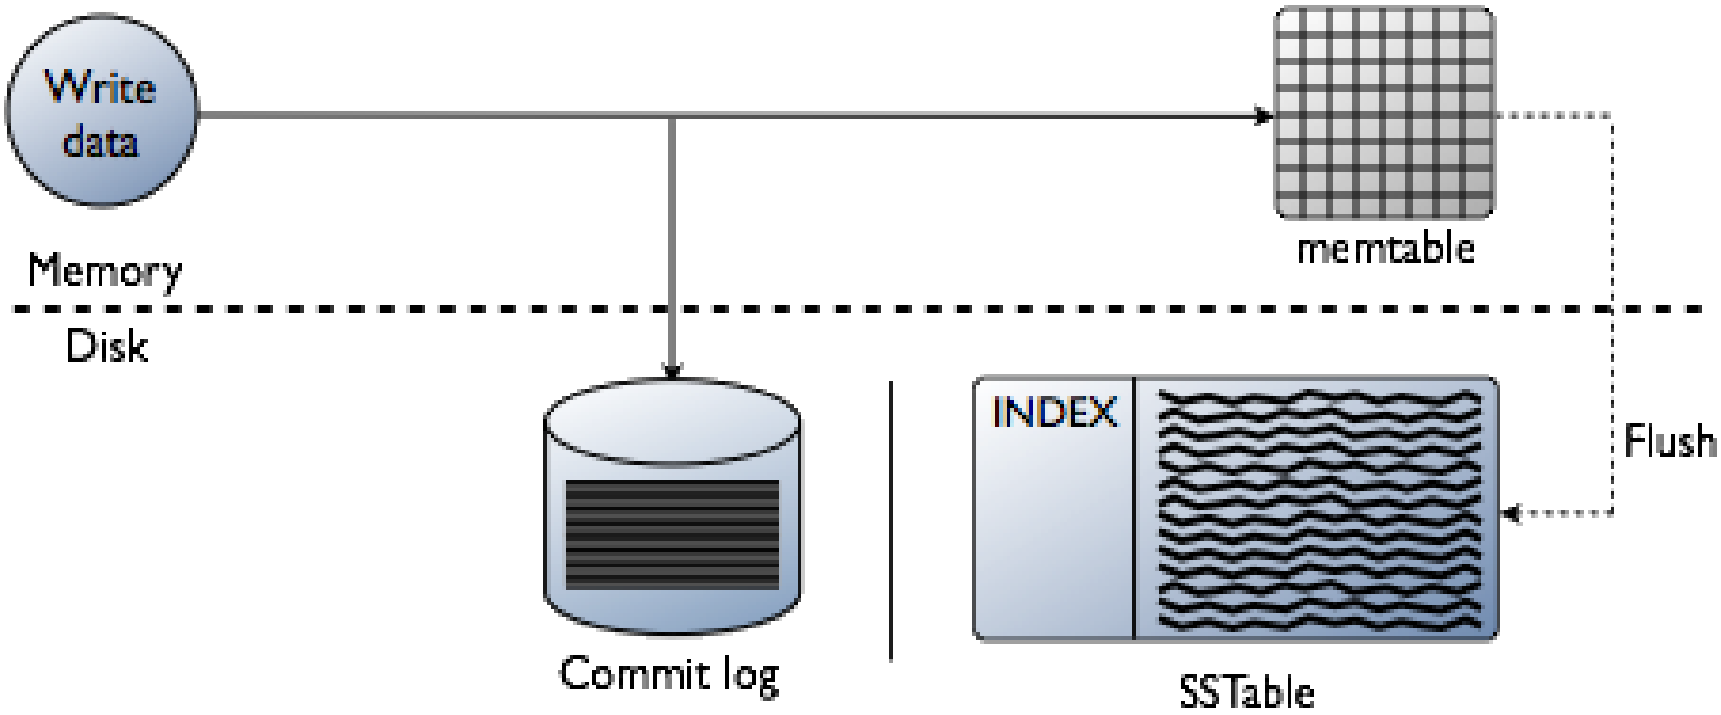
Write data
Memory
Disk
memtable
Flush
Commit log
INDEX
SSTable

Пояснения

- Memtables and SSTables per table
- Memtable — отсортирована
- **SSTable** — неизменяемая отсортированная ассоциативная таблица
- Обычно строка распределена по нескольким SSTable

Пример

Команды:

```
write (k1, c1:v1)
write (k2, c1:v1 c2:v2)
write (k1, c1:v4 c3:v3 c2:v2)
```

Commit-log:

```
k1, c1:v1
k2, c1:v1 c2:v2
k1, c1:v4 c3:v3 c2:v2
```

Memtable/SSTable:

```
k1 c1:v4 c2:v2 c3:v3
k2 c1:v1 c2:v2
```

Flush

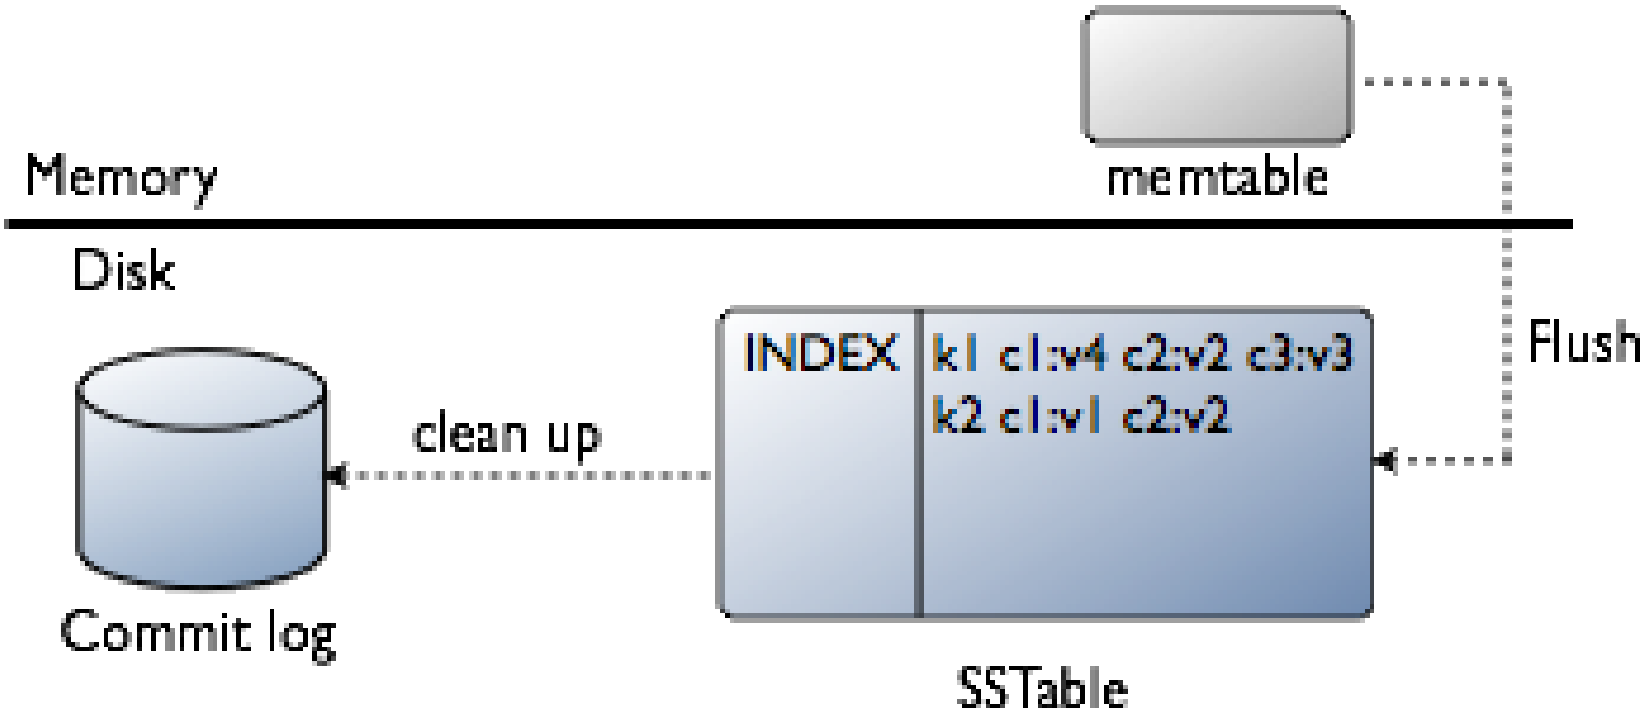
memtable
Memory
Disk
Flush
INDEX
k1 c1:v4 c2:v2 c3:v3
k2 c1:v1 c2:v2
clean up
Commit log
SSTable

Update Path

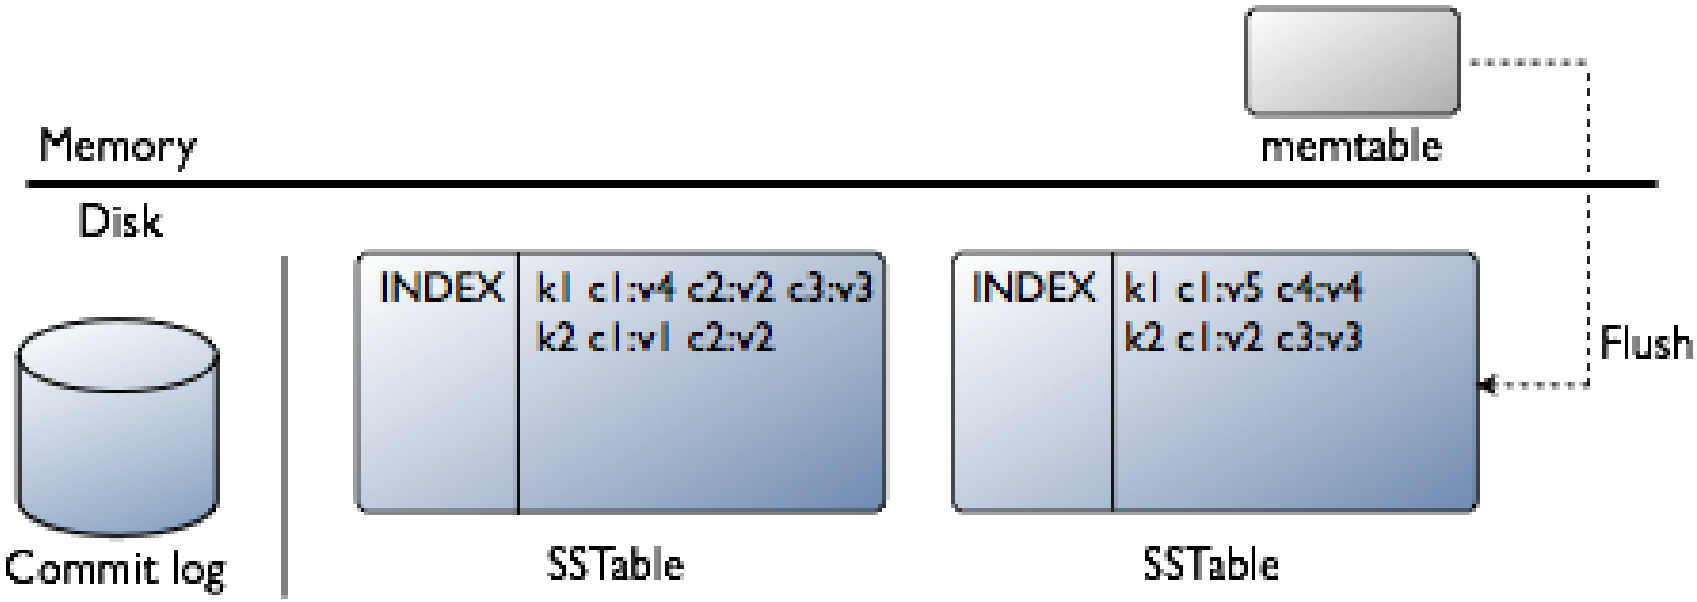
memtable
Memory
Disk
INDEX
k1 c1:v4 c2:v2 c3:v3
k2 c1:v1 c2:v2
INDEX
k1 c1:v5 c4:v4
k2 c1:v2 c3:v3
Flush
Commit log
SSTable
SSTable

Delete

- SSTable неизменяема
- Delete — tombstone marker
- Реальное удаление по истечении `gc_grace_seconds` во время compaction
- Удалённые данные могут возродиться (см. Anti-entropy)

Compaction

- Объединяет SSTable-файлы
  - Фрагменты строк
  - Протухшие tombstones
  - Перестраивает индексы
- SSTable отсортирована $\Rightarrow$ последовательный проход
- `SizeTieredCompactionStrategy` и `LeveledCompactionStrategy`[13][14]

[13] `http://www.datastax.com/dev/blog/when-to-use-leveled-compaction`

[14] `http://www.datastax.com/dev/blog/leveled-compaction-in-apache-cassandra`

Read

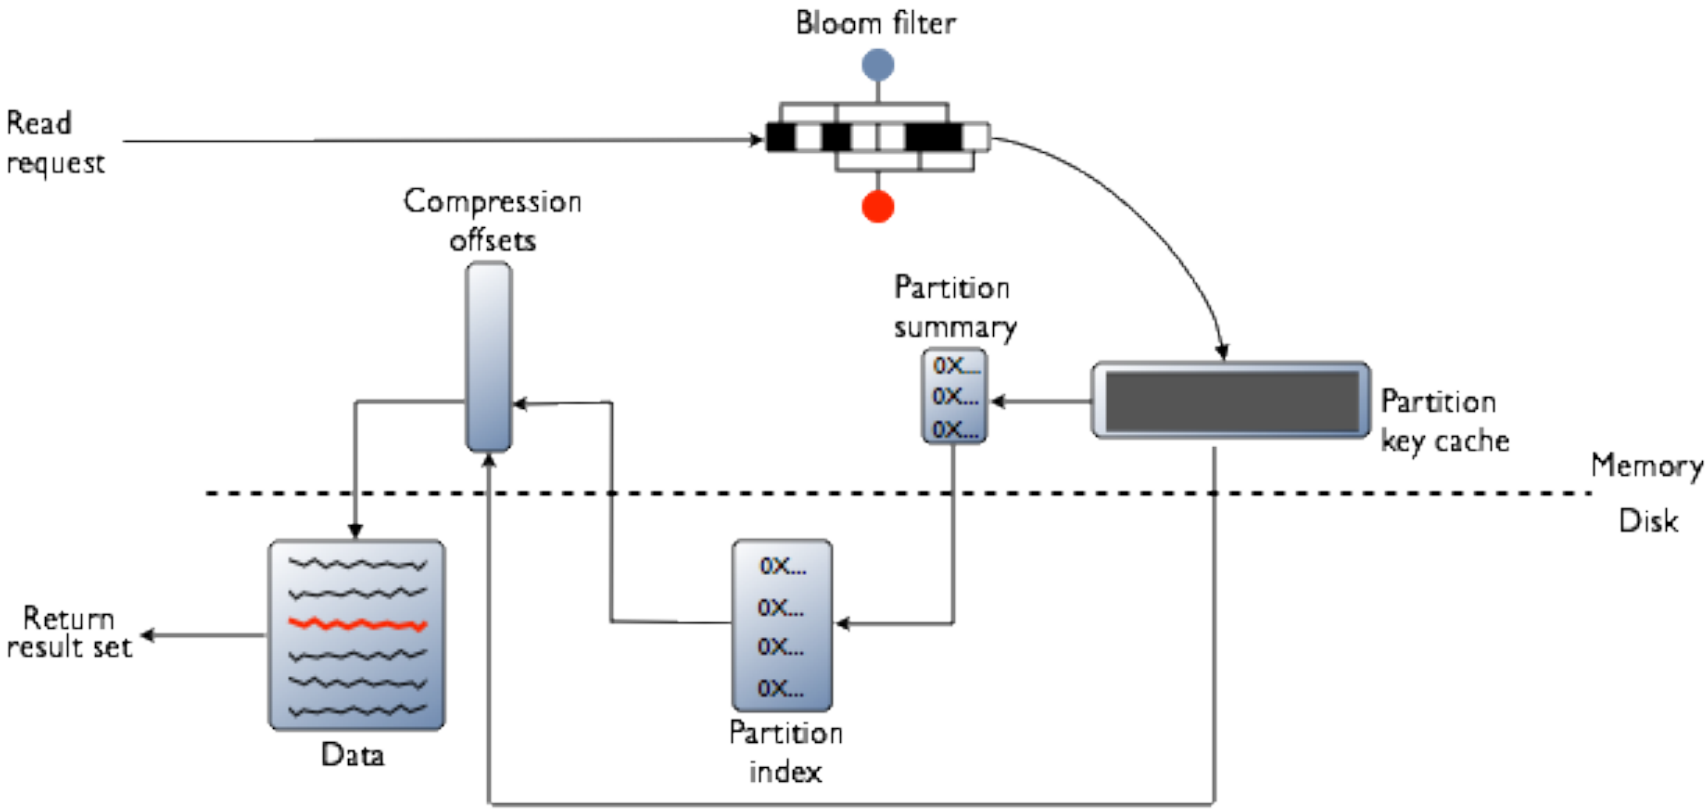
Bloom filter
Read request
Compression offsets
Partition summary
0X...
0X...
0X...
Partition key cache
Memory
Disk
Return result set
0X...
0X...
0X...
0X...
Data
Partition index

Комментарии

- Каждая SSTable имеет Bloom filter[15] — вероятность нахождения ключа в файле
- Если вероятность отлична от 0, идём в partition key cache
- Если нашли ключ в кэше, идём по смещению, находим сжатый блок и достаём данные
- Если не нашли ключ в кэше:
  - В partition summary примерно находим смещение на диске
  - Читаем последовательно блок с диска
  - Из compression offset map вынимаем индекс блока
  - Читаем сжатые данные и возвращаем клиенту

[15] http://en.wikipedia.org/wiki/Bloom_filter

Дополнительные структуры

- Bloom filter — 1-2 ГБ / млрд. ключей
- Partition summary — по умолчанию шаг 128
- Compression offset map — 1-3 ГБ / 1 ТБ сжатых данных

Read Path

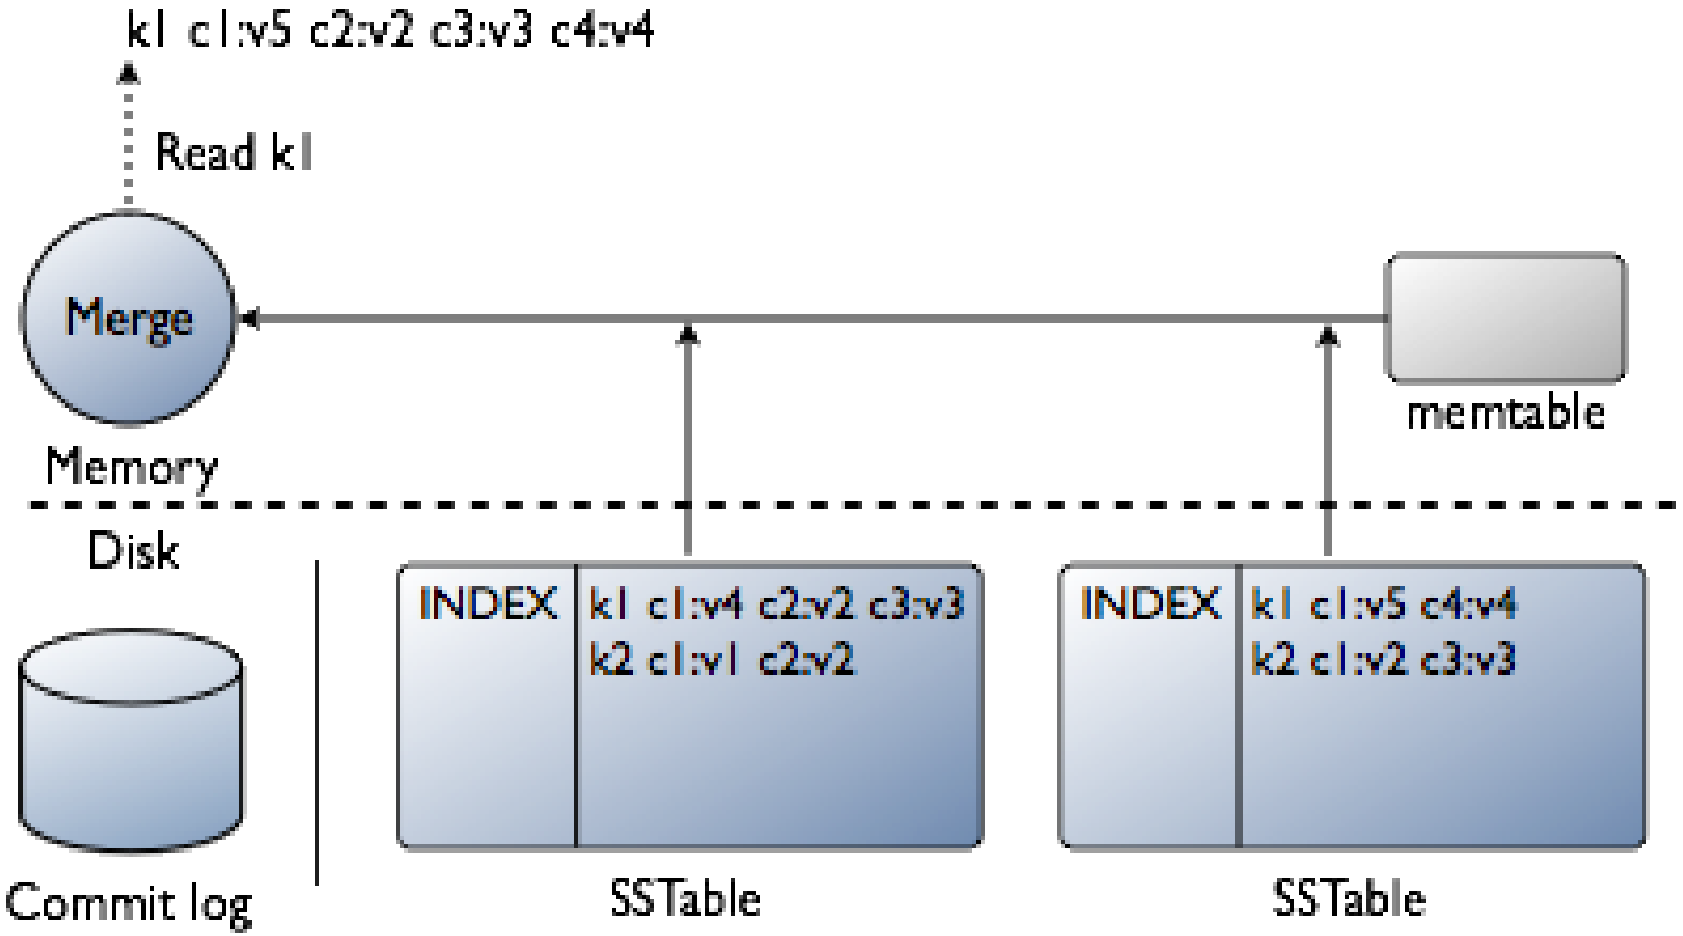
k1 c1:v5 c2:v2 c3:v3 c4:v4
Read k1
Merge
memtable
Memory
Disk
INDEX
k1 c1:v4 c2:v2 c3:v3
k2 c1:v1 c2:v2
INDEX
k1 c1:v5 c4:v4
k2 c1:v2 c3:v3
Commit log
SSTable
SSTable

Write-through Row Cache

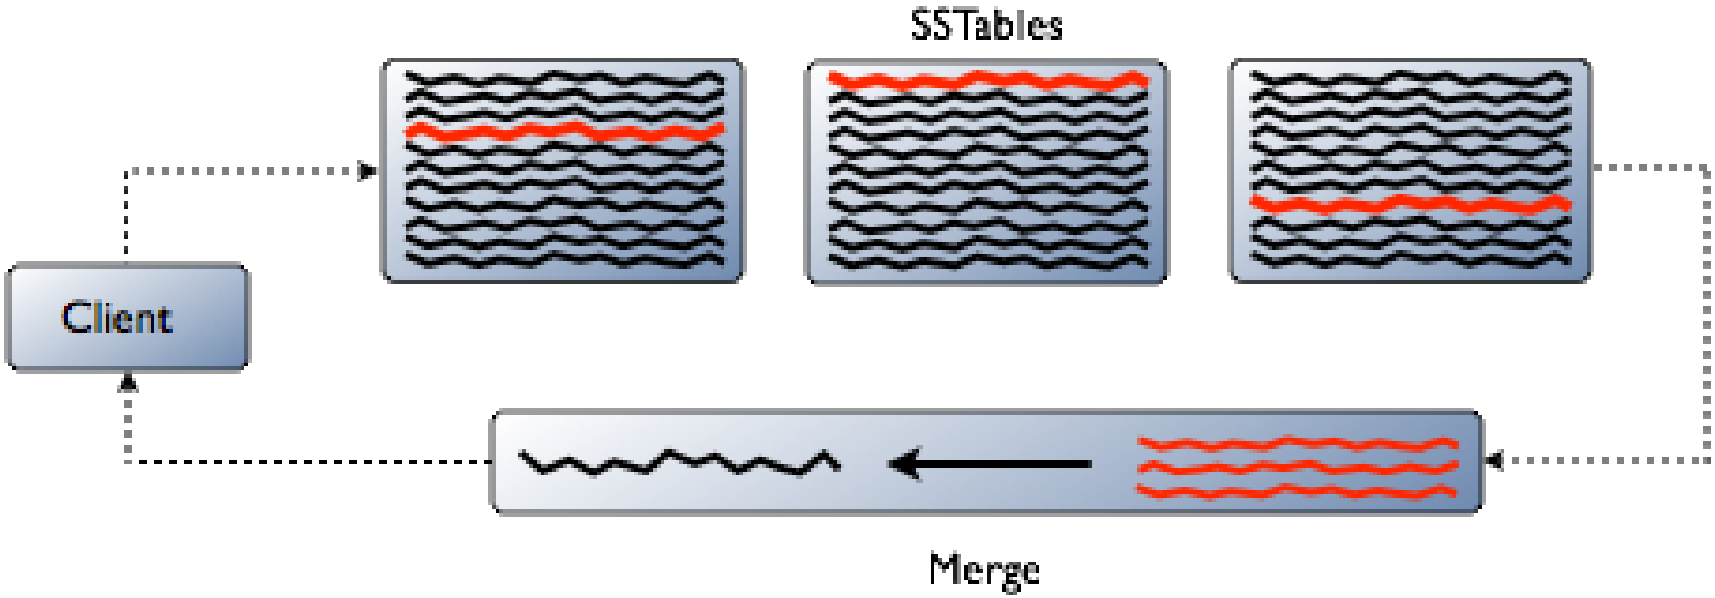

Key Cache + Row Cache

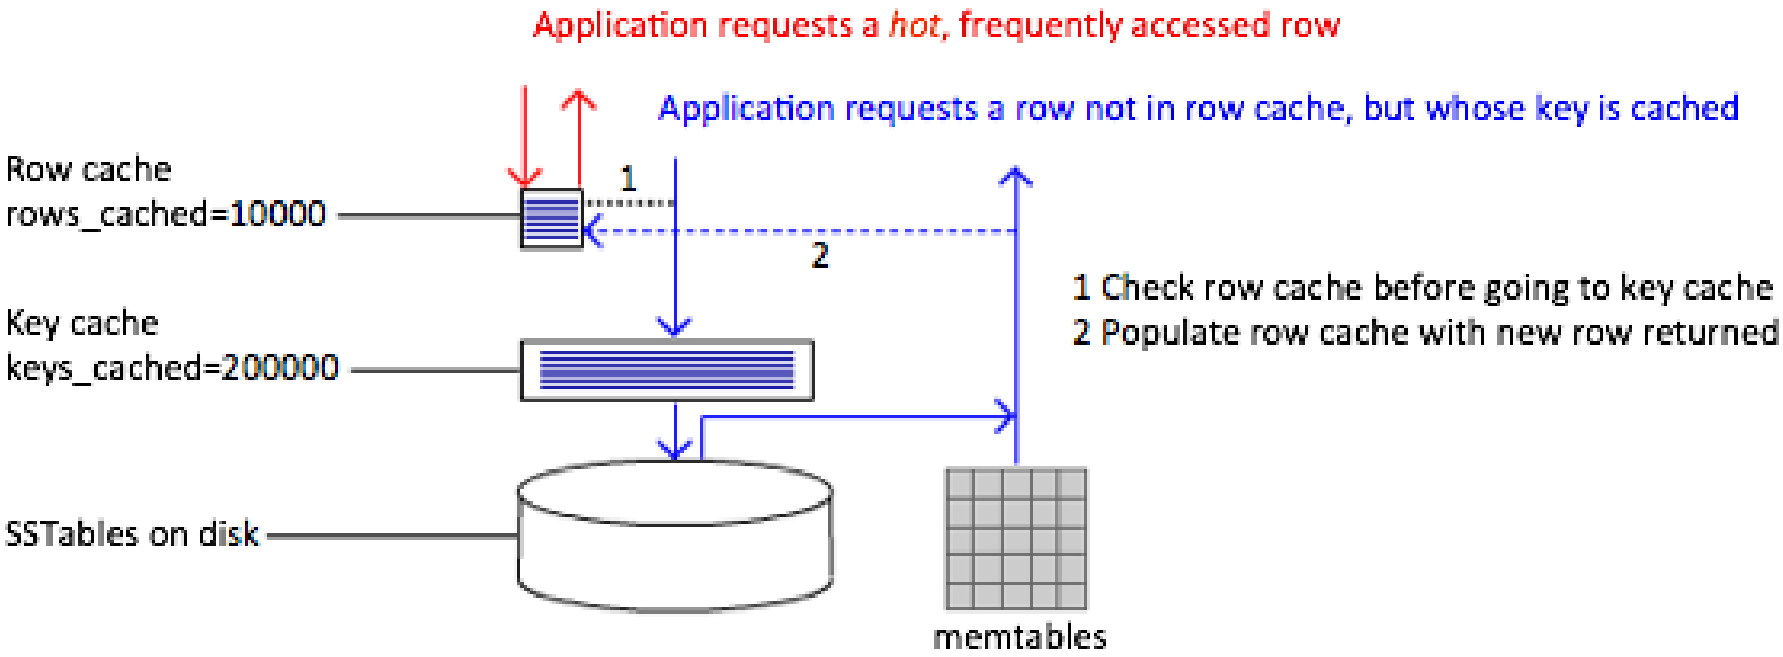

См. подробности[16].

[16] http://www.datastax.com/docs/1.1/operations/tuning

CQL

```
1 CREATE TABLE comments (
2     article_id uuid,
3     posted_at timestamp,
4     author text,
5     karma int,
6     content text,
7     PRIMARY KEY (article_id, posted_at))
```

Колонки

620e8...	1340000000:	
	1340000000:author	Alice
	1340000000:content	Nice article, thanks
	1340000000:karma	4
	1340130000:	
	1340130000:author	Bob
	1340130000:content	I agree with Alice, +1
	1340130000:karma	0

См. подробности[17].

[17] http://www.datastax.com/dev/blog/thrift-to-cql3

Wide vs Skinny Rows

- Wide Rows
  - (+) Колонки отсортированы — возможны трюки[18]
  - (+/-) Атомарность
  - (-) Row cache (скорее всего) не работает
- Skinny Rows
  - (+) Row cache
  - (+/-) Неатомарно, но меньше contention
  - (-) Больше записей — больше индексы, хуже работает Bloom Filter

[18] Класс!ная Cassandra: `http://javapoint.ru/talks/15/`

Опыт использования

- Из Hadoop можно «положить» кластер — ждём `CqlOutputFormat`
- Довольно много «ручек» для подкручивания
- Внимание к GC
- Развитые средства мониторинга
- Периодический `nodetool repair`

Осталось за кадром

- SEDA[19]
- Эксплуатация и тюнинг (JMX, `nodetool`)
- Масштабные примеры использования[20]
- См. блог разработчиков[21]

---

[19] `http://en.wikipedia.org/wiki/Staged_event-driven_architecture`

[20] `http://www.planetcassandra.org/blog/post/slideshare-presentations---cassandra-summit-2013`

[21] `http://www.datastax.com/dev/blog`

Следующая лекция

- MongoDB (приглашённый доклад)

Требования (ещё раз)

- Проект на `http://bitbucket.org` (Hg) / `http://github.com` (Git) + Issue Tracking
  - Открытый проект — ссылку мне на почту
  - Закрытый проект — мне админские права (`incubos`)
- **Обязательно**: Scala/Java + ScalaTest/JUnit + Maven/SBT
- **Обязательно**: `README` + `INSTALL`
- Команда 1-3 человека

Feature Request 0

- «Телефонная книга» (см. лекцию 01-intro[22] слайд #26)
- **Обязательный**
- Выдан 2013-09-16
- Сгорает **сегодня**

[22] http://incubos.org/2013/edu/db/01-intro.pdf

Зачёт хотят

- https://github.com/Elizaveta239/Storage_system_csc
- https://github.com/Feodorov/DB
- https://github.com/medvector/cscenter-databases13
- https://github.com/Noxoomo/DBCSC

WAT

?!

Feature Request 1

- «Big data» per node (см. лекцию 04-commit[23] слайд #64)
- Выдан 2013-09-23
- Сгорает **2013-10-14**

[23] http://incubos.org/2013/edu/db/04-commit.pdf

Кто всё-таки хочет участвовать

- FR1 заменяет FR0
- Становится **обязательным**
- Не засчитывается как дополнительный (не приносит балла)
- Всё так же сгорает **2013-10-14**

Не забывайте

Можно участвовать командой до 3 человек

Система оценивания

- Будет выдано не меньше 6 Feature Requests (FR)
- Для каждого FR — жёсткий срок (но не меньше 2 недель)
- За каждый FR — 0, 1 или 2 балла (за особое мастерство и креативность)
- Для зачёта нужно FR0/FR1 + 4 балла + отчёт
- Проверяю каждые выходные (по возможности чаще)
- Ценю равномерный прогресс
- Ведите стабильную и нестабильную ветки
- Обратная связь в виде issues
- Не все issues закрыты — не зачтено

FR2: Static Sharding

- Равноправные узлы
- Данные распределены по кластеру
- Статическая конфигурация (узлы и диапазоны ключей)
- Клиент знает конфигурацию и куда ходить
- **Тесты** + Testability
- Сгорает — **2013-10-14**

FR3: Master-Slave Replication

- Commit-log от master к slaves
- Статическая конфигурация
- Клиент знает конфигурацию — пишет в master, читает из slaves
- **Тесты** + Testability
- Сгорает — **2013-10-21**

FR4: Scalability

- Динамическая конфигурация (добавляем и удаляем ноды на лету)
- В простейшем случае 2PC новой конфигурации
- Graceful Degradation
- Consistent Hashing
- Миграция партиций при добавлении/удалении узлов
- **Тесты** + Testability
- Сгорает — **2013-10-28**

Вопросы?

- http://incubos.org/contacts/
- Общие вопросы — в Twitter: @incubos
- Вопросы по лекциям — в комментариях: http://incubos.org/blog/
- Частные вопросы — в почту vadim.tsesko@gmail.com