

Виды индексов:

- В-деревья
- Реверсивный индекс
- Полнотекстовый (инвертированный) индекс
- Hash-индексы
- Индексы на основе битовых карт
- Пространственные индексы

Индексы в СУБД

	MySQL	PostgreSQL	MS SQL	Oracle
B-Tree index	Есть	Есть	Есть	Есть
Поддерживаемые пространственные индексы(Spatial indexes)	R-Tree с квадратичным разбиением	R-tree с линейным разбиением	Grid-based spatial index	R-Tree с квадратичным разбиением
Hash index	Только в таблицах типа Memory	Есть	Нет	Нет
Bitmap index	Нет	Есть	Нет	Есть
Reverse index	Нет	Нет	Нет	Есть
Inverted index	Есть	Есть	Есть	Есть
Partial index	Нет	Есть	Есть	Нет
Function based index	Нет	Есть	Есть	Есть

Поиск с использованием индекса

- SELECT * FROM customers WHERE email_address='vassya@spbu.ru' +
- SELECT * FROM customers WHERE email_address > 'v' +
- SELECT * FROM customers WHERE email_address LIKE 'vassya' +
- SELECT * FROM customers WHERE email_address LIKE '%@spbu.ru' -

Reverse index

- `SELECT email_address FROM customers
WHERE email_address LIKE '%@yahoo.com'.`
- `CREATE INDEX test_indexi
ON customers (email_address) REVERSE;`
- `SELECT email_address FROM customers
WHERE reverse(email_address) LIKE
reverse('%@yahoo.com');
(moc.oohay@%)`

Reverse index

- Reverse index – это тоже B-tree индекс но с реверсированным ключом, используемый в основном для монотонно возрастающих значений (например, автоинкрементный идентификатор) в OLTP системах с целью снятия конкуренции за последний листовый блок индекса, т.к. благодаря переворачиванию значения две соседние записи индекса попадают в разные блоки индекса. Он не может

Reverse index

Поле в таблице(bin)	Ключ reverse-индекса(bin)
00000001	10000000
...	...
00001001	10010000
00001010	01010000
00001011	11010000

Поиск документов по содержащимся в них словам

- `WHERE Field1 like 'алгоритм%'`
Использует индекс
- `WHERE Field1 like '%алгоритм%'`
Полное сканирование таблицы

Inverted index

- Документ (текстовое поле) – это последовательность слов
- D1: w1 w2 w3 w1 w4 w2
- D2: w1 w7 w8 w9 w5
- D3: w1 w7 w3 w2 w8

Поиск документов по содержащимся в них словам

- W1: d1 d2 d3
- W2: d1 d3
- W3: d1
- W5: d2

Для FULL TEXT индекса

- Выбрать столбцы таблицы или индексированного представления
- Построить для таблицы индекс по **одному** полю, которое не позволяет дубликатов и нулевых значений
- Построить каталог
- А потом уже строить полнотекстовый индекс...

Полнотекстовый индекс FULLTEXT

- В полнотекстовый индекс включается один или несколько символьных столбцов в таблице.
- Эти столбцы могут иметь тип данных:
 - `char`, `varchar`, `nchar`, `nvarchar`, `text`, `ntext`, `image`, `xml` и `varbinary(max)`.
- Каждому столбцу может соответствовать определенный язык (из 50-ти возможных).
 - Английский 1033,
 - Русский 1049.

Процесс индексирования

- Создание полнотекстового каталога
- Создание полнотекстового индекса
- Заполнение полнотекстового индекса

Создание каталога

- `CREATE FULLTEXT CATALOG catalog_name`
- Полнотекстовый каталог — это логическое понятие, обозначающее группу полнотекстовых индексов.

Создание полнотекстового каталога

- Полнотекстовый каталог — это логическое понятие, обозначающее группу полнотекстовых индексов.
- `CREATE FULLTEXT CATALOG test_catalog`
- `CREATE UNIQUE INDEX ui_1 ON customers (id)`
индекс с одним уникальным столбцом,
`NOT NULL`

Создание полнотекстового индекса

- CREATE FULLTEXT INDEX ON
customers (email_address)
KEY INDEX ui_1 ON test_catalog

Создание FULL TEXT индекса

```
CREATE FULLTEXT INDEX ON table_name  
  [ ( { column_name  
      [ TYPE COLUMN type_column_name ]  
      [ LANGUAGE language_term ]  
      [ STATISTICAL_SEMANTICS ]  
    } [ ,...n ]  
  ) ]  
KEY INDEX index_name
```


Создание полнотекстового индекса

- CREATE FULLTEXT INDEX ON
customers (
email_address language 1033
, cust_name language 1049)
KEY INDEX ui_1 ON test_catalog
WITH
CHANGE_TRACKING MANUAL|AUTO
, STOPLIST = OFF|SYSTEM|My_stop_list

Полнотекстовый индекс

Полнотекстовые индексы	Обычные индексы SQL Server
Для одной таблицы разрешен только один полнотекстовой индекс.	Для одной таблицы разрешено несколько обычных индексов.
Добавление данных к полнотекстовым индексам (<i>заполнение</i>) может быть запрошено явно, выполняться по расписанию либо автоматически при добавлении новых данных.	Обновляются автоматически при создании, вставке, обновлении или удалении данных, на которых они созданы.
Группируются в той же базе данных в один или несколько	Не группируются.

Процесс полнотекстового индексирования

- Фильтрацию, разбиение по словам
- Удаление стоп-слов и нормализация токенов
- Преобразует конвертированные данные в инвертированный список слов
- Заполнение полнотекстового индекса.

Заполнение индекса значениями (обновление)

- MANUAL – вручную
ALTER FULLTEXT INDEX ON customers
START FULL POPULATION
- AUTO
автоматически, но это не значит, что они
будут немедленно отражаться в
полнотекстовом индексе.

Список стоп-слов

- По умолчанию индекс сопоставляется с системным стоп-листом “system”, по этому стоп-листу не будут находиться , например, числовые значение(раз, два и т.д.)
- ```
alter fulltext index on MyTable1
set stoplist= myStoplist
```

# СПИСОК СТОП-СЛОВ

- `CREATE FULLTEXT STOPLIST myStoplist [FROM SYSTEM STOPLIST];`
- `ALTER FULLTEXT STOPLIST MyStoplist ADD 'en' LANGUAGE 'Spanish';`
- `ALTER FULLTEXT STOPLIST MyStoplist ADD 'en' LANGUAGE 'French';`

# Обработка полнотекстовых запросов

- разбиение по словам
- расширение тезауруса
- морфологический поиск
- обработка стоп-слов
- поиск в индексе
- ранжирование

# Поиск в полнотекстовом индексе

- В полнотекстовых запросах не учитывается регистр букв.
- Все полнотекстовые запросы используют предикаты (CONTAINS и FREETEXT) и функции (CONTAINSTABLE и FREETEXTTABLE)



# Запросы с полнотекстовым ИНДЕКСОМ:

- Самый простой способ – это использование `freetext` и `CONTAINS`
- `select * from Production.ProductDescription where freetext(Description,'bike')`
- `select * from Production.ProductDescription where CONTAINS (Description,'bike')`

# CONTAINS

Предикат, используемый в предложении WHERE для и проверки точного или нечеткого совпадения с отдельными словами, расстояния между словами или взвешенных совпадений.

CONTAINS ( { column\_name | \* } , 'condition')

- слова или фразы;
- префикса слова или фразы;
- слова около другого слова;

# FREETEXT

Этот предикат используется в предложении WHERE для поиска значений, которые соответствуют условию поиска по смыслу, а не написанию.

FREETEXT ( { column\_name | \* } , 'string' )

- Разбивает строку на отдельные слова
- Формирует словоформы.
- Определяет список расширений или замен на основании совпадений в тезаурусе.

# Виды запросов

- Простое выражение.
- Префиксные выражения.
- Производное выражение.
- Выражения с учетом расположения.
- Синонимы.
- Взвешенное выражение.

# *Простое выражение*

- Одно или несколько конкретных слов или фраз в одном или нескольких столбцах.

{ AND | & } | { AND NOT | &! } | { OR | | }

```
SELECT Comments FROM ProductReview
WHERE CONTAINS(Comments, 'ужасно');
... CONTAINS(Comments, 'ужасно OR плохо');
...CONTAINS((Absract,Article), 'indexing');
```

# Префиксные выражения

- Слова, начинающиеся заданным текстом, или фразы с такими словами.

... ~~CONTAINS(Comments, 'ужасн\*');~~

... CONTAINS(Comments, ' "ужасн\*" ');

...CONTAINS(Name, '"chain\*" OR "full\*"');

...CONTAINS(Name, '"C#" AND NOT "JAVA " ');

...CONTAINS(Name, '"C#" AND NOT "JAVA " ');

# *Префиксные выражения*

- Если параметр является фразой, то каждое содержащееся во фразе слово считается отдельным префиксом.
- "local wine\*"  
=> «local winery», «locally wined and dined»

# *Выражения с учетом расположения*

- Слова или фразы, находящиеся рядом с другими словами или фразами.
- CONTAINS(\*,'NEAR (значение, выражения)')
- CONTAINS(\*,'NEAR ((значение, выражения),1)')



# Выражения с учетом расположения

- NEAR  
( { *search\_term* [ ,...*n* ] | (*search\_term* [ ,...*n* ] )  
[,<maximum\_distance> [,<match\_order> ] ]
- CONTAINS(column\_name, 'NEAR ((Monday,,  
Wednesday), MAX, TRUE)')
- CONTAINS(column\_name, 'NEAR ((Monday,,  
Wednesday), 5)')

# *FREETEXT*

- Разбивает строку на отдельные слова согласно границам слов (пословное разбиение).
- Формирует словоформы (а также производит выделение основы слова).
- Определяет список расширений или замен для термов на основании совпадений в тезаурусе.

# *FREETEXT*

- Словоформы конкретного слова.
- Синонимические формы конкретного слова.
- `SELECT * FROM t3 WHERE freetext(s,'пама')`

# *Взвешенное выражение*

- Слова или фразы со взвешенными значениями ( )

```
SELECT * from CONTAINSTABLE (
table3 –имя таблицы
, * – имена столбцов для поиска
, 'ISABOUT (drive WEIGHT(0.9)
 , auto WEIGHT(0.1)) ', 10)
ORDER BY RANK;
```

Результат: ранжированная таблица (ключ, ранг)

# Полнотекстовый индекс FULLTEXT

- Загрузка данных в таблицу, уже имеющую индекс FULLTEXT, будет более медленной.

# Индексы на основе битовых карт

- Подходят для столбцов с низкой избирательностью.
- Создаются быстро.
- Занимают мало места.
- Размер индекса на основе битовых карт существенно зависит от распределения данных.

# Индексы на основе битовых карт

- create bitmap index ind\_4 on table\_1(field1)
- В индекс входят:
  - Для каждого значения индексируемого столбца – одна строка, состоящая из значения столбца и битовой последовательности
  - битовая последовательность имеет длину по количеству строк таблицы, в которой 1 означает, что в данной строке атрибут принимает заданное значение

# Индексы на основе битовых карт

| Имя    | Цвет глаз | Цвет волос | Рост    |
|--------|-----------|------------|---------|
| Аня    | карие     | блондинка  | средний |
| Даша   | зеленые   | блондинка  | средний |
| Катя   | голубые   | шатенка    | высокий |
| Таня   | серые     | рыжая      | средний |
| Наташа | карие     | брюнетка   | средний |
| Марина | карие     | блондинка  | средний |
| Даша   | серые     | брюнетка   | высокий |
| С      |           |            | у       |



create bitmap index ind\_4 on  
table\_1(пост):

- Высокий 0010001000
- Средний 1101110100
- Ниже среднего 0000000011

create bitmap index ind\_5 on  
table\_1(Цвет волос):

- Блондинка      1100010000
- Шатенка      0010000100
- Брюнетка      0000101001
- Рыжая      0001000010

# Блондинка среднего роста:

- Блондинка                    1100010000
- Средний                    1101110100
- Побитовое умножение    1100010000

# Появилась Мальвина:

- Блондинка 1100010000
- Шатенка 0010000100
- Брюнетка 0000101001
- Рыжая 0001000010
- Голубые волосы 000000000001

# Индексы на основе битовых карт


- Индексы на основе битовых карт обычно выбираются стоимостным оптимизатором, если для выполнения запроса можно использовать несколько таких индексов.
- Изменения столбцов, входящих в индексы на основе битовых карт, а также вставки и удаления данных могут вызывать существенные конфликты блокировок.
- Изменения столбцов, входящих в индексы на основе битовых карт, а также вставки и удаления данных могут весьма существенно "ухудшать" индексы.

# Hash-индекс

- Выбираем количество участков, в которых будем размещать записи.
- Подбираем функцию перемешивания, которая от ключевого столбца будет выдавать номер участка.
- В памяти храним таблицу адресов участков

# Создание hash-индекса

```
CREATE INDEX имя_индекса
 USING HASH
 ON имя_таблицы (имя_столбца)
```






# Hash-индекс

- Для размещения таблицы отводится заданное количество участков
- Есть функция  $\text{hash}(\text{key})=n$ , где  $n$  – номер участка
- В памяти хранится таблица адресов участков
- Доступ к данным за одно обращение к диску

# Недостатки hash-индексов

- Таблица адресов участков может быть слишком велика
- Если в один участок попало слишком много записей, придется выделять дополнительный блок.
- Проблема – неравномерность размещения записей, возникновение коллизий

# Коллизии



# Функции Hash

- Деление
- Мультипликативный метод

# Функции Hash деление

- Размер таблицы `hashTableSize` - простое число.
- Хеширующее значение `hashValue`, изменяющееся от 0 до  $(\text{hashTableSize} - 1)$ , равно остатку от деления ключа на размер хеш-таблицы.
- Увеличиваем число участков в два раза

# Функции Hash

## МУЛЬТИПЛИКАТИВНЫЙ МЕТОД


- Размер таблицы `hashTableSize` есть степень  $2^n$ .
- Значение `key` умножается на константу, затем от результата берется  $n$  бит.
- В качестве такой константы Кнут рекомендует золотое сечение  $(\sqrt{5} - 1)/2 = 0.6180339887499$ .

# Функции Hash

## для строк переменной длины

- Аддитивный метод – преобразовываем слова в числа, складываем и берем остаток деления по модулю 256.
- Метод ИЛИ

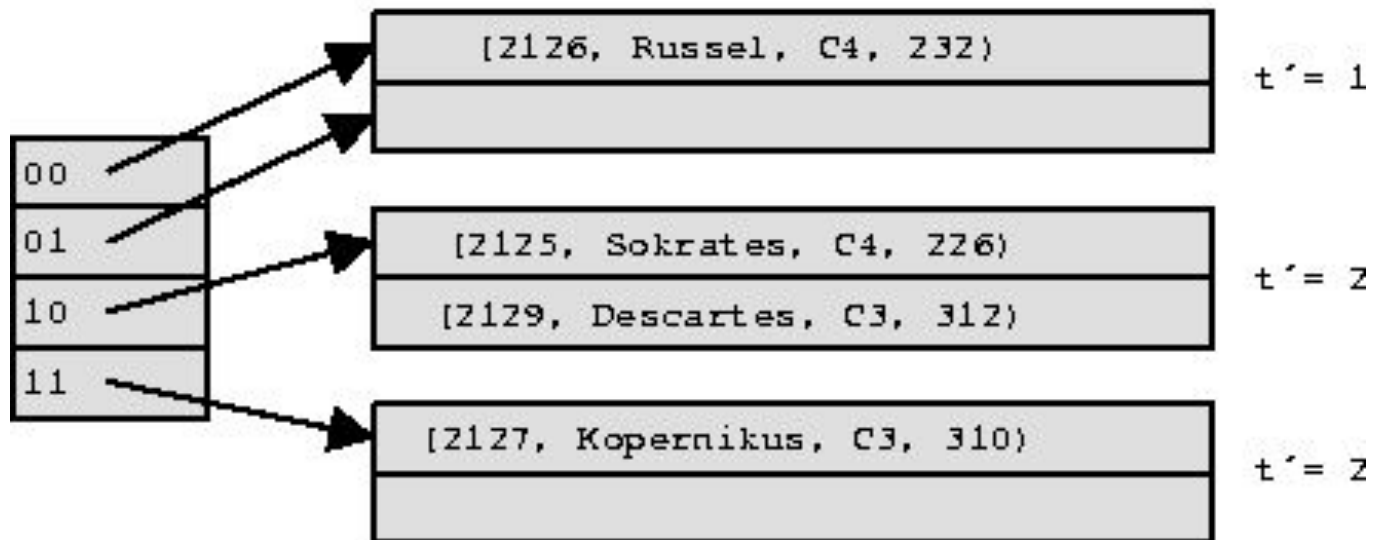
| x    | h(x) |             |
|------|------|-------------|
|      | d    | p           |
| 2125 | 1    | 01100100001 |
| 2126 | 0    | 11100100001 |
| 2127 | 1    | 11100100001 |



$t = 1$



| x    | h(x) |            |
|------|------|------------|
|      | d    | p          |
| 2125 | 10   | 1100100001 |
| 2126 | 01   | 1100100001 |
| 2127 | 11   | 1100100001 |
| 2129 | 10   | 0010100001 |



t = 2

# Пространственные типы данных



- **geometry** используется для планарных или евклидовых данных
- **geography**, который используется для хранения эллиптических данных, таких как координаты GPS широты и долготы

# Пространственные типы данных

- **geometry** используется для планарных или евклидовых данных
- **geography**, который используется для хранения эллиптических данных, таких как координаты GPS широты и долготы
- объекты **geography** должны помещаться в одном полушарии, расстояние обычно вычисляется в метрах


# Пространственные типы данных

- Point
- MultiPoint
- LineString
- MultiLineString
- Polygon





# R-дерево

- Избавляемся от формы – окружаем фигуру  $\min$  ограничивающим прямоугольником  
(*oid*, *Rectangle*), *oid* – ссылка на запись





# Иерархия R-дерева

- Окружаем фигуры ограничивающими прямоугольниками
- (*ср, Rectangle*)
- При переполнении делим пополам



# R-дерево




# R-дерево - недостатки

- Не удастся избежать перекрытий – необходим просмотр нескольких веток




# Критерии разделения узла

- Минимальная площадь
- Минимальное перекрытие
- Минимальные границы




- MBR узла
- MBR объекта
- Объект

# Минимальная площадь




Так плохо




А вот так уже лучше

# Минимальное перекрытие



Так плохо




А вот так уже лучше

# Минимальные границы




Так плохо



А вот так уже лучше

# Spatial grid



# Spatial grid

- CREATE SPATIAL INDEX
  - GEOMETRY\_GRID | GEOGRAPHY\_GRID
  - BOUNDING\_BOX (для GEOMETRY\_GRID)  
xmin, ymin, xmax, ymax
  - GRIDS - плотность сетки на каждом уровне  
LEVEL\_1 - LEVEL\_4

# Spatial grid

- 4 уровня вложенности

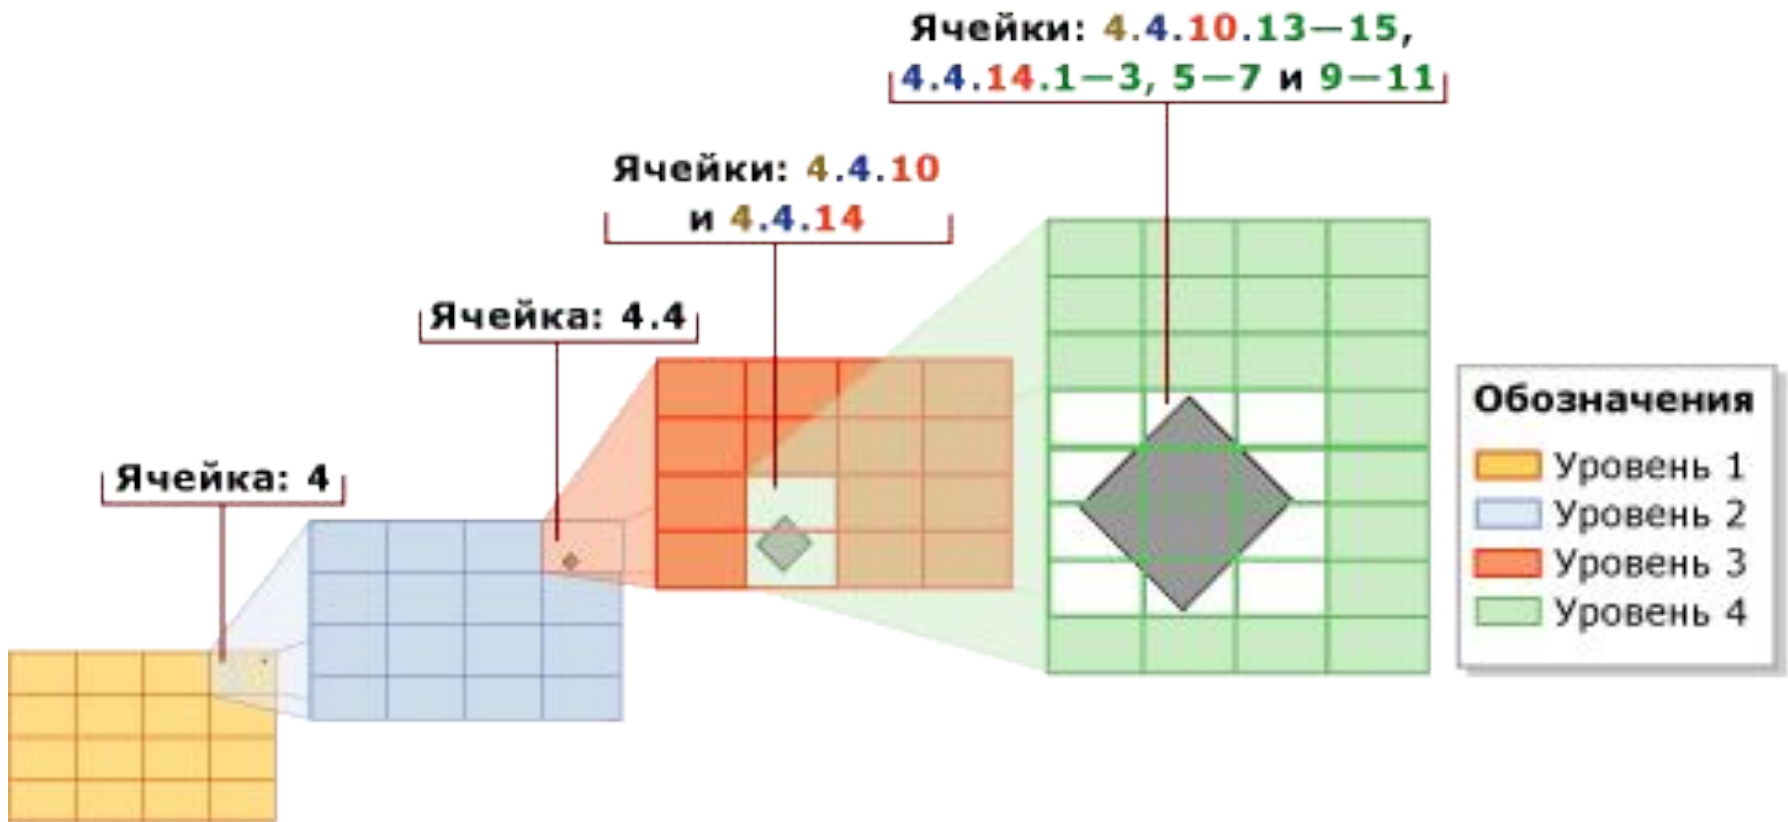
| Ключевое слово | Конфигурация сетки | Число ячеек |
|----------------|--------------------|-------------|
| LOW            | 4X4                | 16          |
| MEDIUM         | 8X8                | 64          |
| HIGH           | 16X16              | 256         |

# Spatial grid

```
CREATE SPATIAL INDEX SIndx
ON SpatialTable(geometry_col)
WITH (
 BOUNDING_BOX = (0, 0, 500, 200),
 GRIDS = (LEVEL_4 = HIGH, LEVEL_3=MEDIUM));
```



# Spatial grid



# Тесселяция

- Декомпозиция индексированного пространства в сеточную иерархию
- Считывание данных для пространственного объекта по строкам
- Вставка объекта в сеточную иерархию (тесселяция)
- Устанавливая связь между объектом и набором сеточных ячеек

# Тесселяция

- Накрытая ячейка
- Ограничение кол-ва ячеек на объект
- Правило самой глубокой ячейки – записываем объект только туда

