

МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное учреждение
высшего образования

**«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ИМЕНИ Н. Г. ЧЕРНЫШЕВСКОГО»**

Кафедра математической кибернетики и компьютерных наук

**ПРИМЕНЕНИЕ OLAP-ТЕХНОЛОГИИ ПРИ РАЗРАБОТКЕ
АНАЛИТИЧЕСКОЙ ИНФОРМАЦИОННОЙ СИСТЕМЫ**

АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ

студента 5 курса 551 группы
направления 09.03.04 — Программная инженерия
факультета КНиИТ
Багрова Ильи Юрьевича

Научный руководитель
старший преподаватель

М. И. Сафрончик

Заведующий кафедрой
к. ф.-м. н. доцент

С. В. Миронов

Саратов 2022

ВВЕДЕНИЕ

В настоящее время бизнесу постоянно требуется производить анализ данных, получаемых в ходе его деятельности. Поскольку приходится обрабатывать значительные объемы данных, возникает необходимость вынесения аналитической информации из оперативной базы данных.

Целью настоящей выпускной квалификационной работы является разработка веб-сервиса для анализа данных с применением технологий оперативной аналитической обработки данных (OLAP). Для достижения данной цели поставлены следующие задачи:

- рассмотреть концепцию OLAP;
- изучить основы языка MDX;
- выбрать датасет для анализа содержащейся в нем информации;
- спроектировать хранилище данных для этой информации;
- построить ETL-процесс для переноса данных из датасета в хранилище;
- построить OLAP-куб;
- разработать аналитические запросы к полученному кубу;
- разработать веб-интерфейс для отображения результатов выполнения этих запросов.

Для разработки приложения были использованы следующие инструменты:

- Microsoft SQL Server Developer Edition — сервер баз данных;
- SQL Server Integration Services — службы, позволяющие организовать процесс переноса данных;
- Pentaho Mondrian — OLAP-клиент для Java;
- Spring Boot — Java фреймворк для разработки веб-приложений;
- React — библиотека для построения пользовательских интерфейсов.

КРАТКОЕ СОДЕРЖАНИЕ РАБОТЫ

Первый раздел «Обзор концепции хранения и анализа больших объемов данных» посвящен описанию основных концепций хранения и анализа больших объемов данных.

В подразделе 1.1 приведено описание многомерной модели данных [1].

Подраздел 1.2 посвящен архитектуре OLAP-систем.

В подразделе 1.2.1 описывается реляционный OLAP.

В подразделе 1.2.1 описывается многомерный OLAP, дается 12 основных принципов определяющих многомерную OLAP.

В подразделе 1.3 посвящен обзору языка MDX для доступа к многомерным структурам данных.

Второй раздел «Реализация хранилища данных» посвящен описанию реализации хранилища данных.

В подразделе 2.1 описывается проектирование хранилища данных на основе полей датасета содержащем информацию о поездках такси города Нью-Йорка.

Датасет представляет собой набор файлов формата `.parquet` и содержит следующую информацию о поездках желтых и зеленых такси:

- `Trip_pickup_datetime` — время и дата, когда включился таксометр;
- `Trip_dropoff_datetime` — время и дата, когда выключился таксометр;
- `Passenger_count` — количество пассажиров (вводится водителем);
- `Trip_distance` — длина поездки в милях согласно показаниям таксометра;
- `PULocationID` — ID зоны, в которой включился таксометр;
- `DOLocationID` — ID зоны, в которой выключился таксометр;
- `RateCodeID` — код вида поездки;
 - 1 — стандартный тариф;
 - 2 — поездка в аэропорт JFK;
 - 3 — поездка в Ньюарк;
 - 4 — Нассо или Уэстчестер;
 - 5 — договорная цена;
 - 6 — групповая поездка;
- `Payment_type` — код, обозначающий способ оплаты поездки;
 - 1 — кредитная карта;

- 2 — оплата наличными;
- 3 — бесплатно;
- 4 — спорная ситуация;
- 5 — неизвестно;
- 6 — аннулированная поездка;
- Fare_amount — стоимость поездки, рассчитанная таксометром;
- Extra — различные надбавки к стоимости поездки. Включает в себя надбавки в 0.5\$ и 1\$ в час пик и ночные надбавки;
- MTA_tax — 0.5\$ налога для MTA, которая автоматически срабатывает на основе показаний счетчика;
- Improvement_surcharge — минимальная стоимость поездки в 0.3\$, взимаемая с 2015 года;
- Tip_amount — чаевые, заполняются только для поездок с оплатой по кредитной карте. Чаевые, выданные наличными, не учитываются;
- Tolls_amount — сумма всех пошлин в поездке;
- Total_amount — итоговая сумма поездки, взятая с пассажиров. Не учитывает наличные чаевые;
- Trip_type — тип поездки: было ли такси поймано на улице или вызвано через оператора.

Подраздел 2.2 посвящен разработке ETL процесса для загрузки данных в хранилище [2].

Процесс загрузки данных в хранилище представлен тремя основными шагами:

1. Извлечение данных из внешних источников.
2. Трансформация данных.
3. Непосредственная загрузка преобразованных данных в хранилище.

Третий раздел «Разработка аналитического Web-приложения» посвящен описанию разработки Web-приложения, позволяющего визуализировать полученную из хранилища информацию.

В подразделе 3.1 описывается разработка серверной части. Было разработано Web-приложение, позволяющее визуализировать полученную из хранилища информацию. Данное приложение является клиент-серверным: в роли клиента выступает браузер; сервер реализован при помощи фреймворка Spring [3].




Рисунок 1 – Схема хранилища данных




Рисунок 2 – Поток управления ETL процесса для загрузки данных датасета в хранилище

В подразделе 3.1.1 описание модели OLAP-куба. Для построения OLAP-куба и выполнения запросов к нему была использована библиотека Mondrian. Данная библиотека позволяет описать куб при помощи XML-файла, который называется схемой куба. Основными элементами схемы являются элементы <Cube/>, <Dimension/>, <Hierarchy/>, <Level/> и <Measure/>, описывающие соответственно куб, измерение, иерархию, уровень и меру. Так, для разработанного хранилища данных была написана схема приведенная в приложении.

Построенный OLAP-куб имеет 4 измерения <Dimension/>:

- <Pickup Location/> — район из которого началась поездка;
- <Pickup Date/> — дата начала поездки;
- <Pickup Time/> — время начала поездки;
- <Dropoff Location/> — район окончания поездки;
- <Payment Type/> — тип оплаты.

В подразделе 3.2.1 представлена разработка API для получения данных из куба.

Для выполнения запросов к кубу из браузера было разработано API, конечные точки которого приведены в таблице 1.

Таблица 1 – Конечные точки API для доступа к кубу

URL	Описание
/date/year	Возвращает список годов
/date/holidays	Возвращает для заданного месяца в заданном году список праздничных и выходных дней.
/stat/average-cost	Возвращает среднюю стоимость одной поездки
/stat/total-cost	Возвращает общую стоимость всех поездок за все время
/stat/payment-type/distribution	Возвращает доли количества поездок по способам оплаты
/stat/location/start-distribution	Возвращает доли районов, в которых начинались поездки

/trip/count	Возвращает для заданной даты количество поездок в эту дату. Если дата не задана, возвращается количество поездок для каждого года. Если задан только год, возвращается количество поездок для каждого месяца этого года. Если заданы год и месяц, возвращается количество поездок для каждого дня этого месяца. Если заданы год, месяц и день, то возвращается количество поездок по часам в этом дне.
/trip/count/total	Возвращает количество всех поездок за все время
/trip/count/zone/pickup	Возвращает распределение количества поездок по районам. Каждой зоне города ставится в соответствие число от 0 до 1, показывающее, насколько количество поездок в этой части города близко к максимуму.

Для получения данных из куба, при помощи Mondrian к нему отправляются запросы на языке MDX — языке доступа к многомерным базам данных.

Так, для получения количества поездок за все время был написан следующий запрос:

```
SELECT [Measures].[Trip Count] ON COLUMNS FROM [TaxiTrips];
```

Данный запрос возвращает единственную ячейку, в которой содержится значение меры [Measures].[Trip Count], взятое по всему кубу.

Для получения долей поездок, приходящихся на способы оплаты, был написан следующий запрос:

```

1 WITH MEMBER Measures.[Total Trip Count] AS
2 100 * SUM([Payment Type].[Type].CurrentMember,
3 Measures.[Trip Count]) / SUM([Payment Type].[Type].members,
4 Measures.[Trip Count])
5 SELECT Measures.[Total Trip Count] ON COLUMNS,
6 [Payment Type].[Type].members ON ROWS
7 FROM [TaxiTrips];

```

Данный запрос получает искомые проценты путем деления количества поездок с каждым способом оплаты на общее количество поездок.

Метод, обрабатывающий данный запрос, выглядит следующим образом:

```

1 @GetMapping("stat/payment-type/distribution")
2 public TableResult getPaymentTypeDistribution() throws SQLException {
3     final String query = "WITH MEMBER Measures.[Total Trip Count] AS 100 *
4         ↪ SUM([Payment Type].[Type]." +
5         "CurrentMember, Measures.[Trip Count]) / SUM([Payment
6         ↪ Type].[Type].members, Measures.[Trip Count]) " +
7         "SELECT Measures.[Total Trip Count] ON COLUMNS," +
8         "[Payment Type].[Type].members ON ROWS FROM [TaxiTrips]";
9
10    // Объект запроса
11    OlapStatement statement = DBConfig.connection.createStatement();
12    // Исполнение запроса
13    CellSet cs = statement.executeOlapQuery(query);
14    // Возврат обертки над результатом запроса
15    return new TableResult(cs);
16 }

```

Подраздел 3.2 посвящен разработке клиентской части приложения.

Для разработки Web-интерфейса была использована библиотека React [4]. Для визуализации полученных с сервера данных была использована библиотека Chart.js. Данная библиотека предоставляет набор компонентов для отрисовки различных графиков. Для получения данных с сервера используется модуль Axios.

Вид разработанного приложения представлен на рисунке 3.

На данном рисунке представлены агрегированные данные о всех поездках — общее количество поездок, средняя стоимость поездки, а также суммарная стоимость всех поездок. Под этими данными отрисован график количества




Рисунок 3 – Интерфейс разработанного приложения

поездок по годам.

На карте, приведенной на рисунке, показаны районы, которые выделены разными цветами в зависимости от количества начинающихся в них поездок. Районы, в которых начинается меньше всего поездок, обозначаются зеленым цветом. Чем больше поездок, тем более красным цветом выделен район.

Для отрисовки данной карты была использована JavaScript-библиотека @pbe/react-yandex-maps, представляющая собой React-обертку над API сервиса «Яндекс Карты» [5]. Яндекс Карты позволяют отрисовывать объекты, заданные в формате GeoJSON. Однако, исходные данные для отрисовки частей города Нью-Йорк, представленные на сайте с датасетом, были представлены в формате Shapefile. Для преобразования данных из Shapefile в GeoJSON была использована программа QGIS версии 3.22.7. Данное приложение позволяет конвертировать географические данные в различные форматы, изменив систему координат. Система координат, поддерживаемая Яндекс Картами — WGS 84.

Далее, для преобразования полученных из куба чисел от 0 до 1 в цвет от зеленого до красного были написаны две следующие функции:

```

1  // Преобразует цвет из формата HSL в RGB
2  const HSLToRGB = (h, s, l) => {
3      s /= 100;
4      l /= 100;
5      const k = n => (n + h / 30) % 12;
6      const a = s * Math.min(1, 1 - l);
7      const f = n =>
8          l - a * Math.max(-1, Math.min(k(n) - 3, Math.min(9 - k(n), 1)));
9      return [255 * f(0), 255 * f(8), 255 * f(4)];
10 };
11
12 function numberToColorHsl(i) {
13     var hue = (-i * 120) + 120;
14     // преобразование HSL в RGB с параметрами насыщенности 100 и яркости в 50
15     ↪ процентов
16     var rgb = HSLToRGB(hue, 100, 50);
17     // форматирование результата
18     return `rgb(${rgb[0]}, ${rgb[1]}, ${rgb[2]})`;
19 }

```

По карте видно, что большинство поездок начинается в районах Манхэттена. Следующими по популярности районами начала поездок являются аэропорт Джона Кеннеди и аэропорт Ла-Гуардия.




Рисунок 4 – Распределение поездок по районам

ЗАКЛЮЧЕНИЕ

В ходе выполнения выпускной квалификационной работы было разработано Web-приложение, позволяющее получать аналитическую информацию из многомерной базы данных. В процессе разработки было создано и заполнено хранилище данных, создан OLAP-куб и написаны различные аналитические запросы. Для тестирования приложения был использован датасет поездок в такси Нью-Йорка, объем которого составляет 156 ГБ и 1.4 миллиарда строк. При таких объемах данных время обработки одного запроса составило порядка 30 секунд.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

- 1 *Барсегян, А. А.* Анализ данных и процессов / А. А. Барсегян, М. С. Куприянов, И. И. Холод, М. Д. Тесс, С. И. Елизаров. — Санкт-Петербург: БХВ-Петербург, 2009.
- 2 *Сарка, Д.* Microsoft SQL Server 2012. Реализация хранилищ данных / Д. Сарка, М. Лах, Г. Йеркич. — Москва: Русская редакция, 2014.
- 3 *Гутьеррес, Фелипе.* Spring Boot 2 лучшие практики для профессионалов / Фелипе Гутьеррес. — Санкт-Петербург: Питер, 2020.
- 4 *Томас, Марк Тиленс.* React в действии / Марк Тиленс Томас. — Санкт-Петербург: Питер, 2019.
- 5 *ApiYandexMap* [Электронный ресурс]. — URL: <https://yandex.ru/dev/maps/?p=realty> (Дата обращения 15.05.2022). Загл. с экр. Яз. англ.