
Оглавление

Отзывы о книге «Google BigQuery. Всё о хранилищах данных, аналитике и машинном обучении»	13
Предисловие	15
Для кого написана эта книга?.....	16
Условные обозначения	16
Использование примеров программного кода	17
Благодарности	17
От издательства.....	18
Глава 1. Что такое Google BigQuery?.....	19
Архитектуры обработки данных	19
Система управления реляционными базами данных.....	20
Фреймворк MapReduce.....	22
BigQuery: бессерверный распределенный движок SQL.....	23
Работа с BigQuery.....	25
Анализ наборов данных.....	25
ETL, EL и ELT	26
Эффективная аналитика	28
Простота управления	30
История появления BigQuery.....	31
Что позволило создать BigQuery?.....	34
Отделение вычислений от хранилища	35
Хранилище и сетевая инфраструктура.....	36
Управляемое хранилище.....	37
Интеграция с платформой Google Cloud	39
Безопасность и соответствие требованиям	40
Выводы	41

Глава 2. Основы запросов	42
Простые запросы.....	44
Извлечение записей с помощью SELECT	44
Создание псевдонимов столбцов с помощью AS	46
Фильтрация с WHERE	48
SELECT *, EXCEPT, REPLACE.....	49
Подзапросы с WITH	50
Сортировка с ORDER BY.....	50
Агрегирование.....	51
Агрегирование с GROUP BY	51
Подсчет записей с COUNT	52
Фильтрация сгруппированных значений с HAVING	53
Поиск уникальных значений с DISTINCT	54
Краткое руководство по массивам и структурам.....	55
Создание массивов с помощью ARRAY_AGG.....	57
Массив структур STRUCT	59
Кортежи	60
Работа с массивами	60
Развёртывание массива	61
Соединение таблиц	62
Основы соединения таблиц.....	63
Оператор внутреннего соединения INNER JOIN.....	66
Оператор перекрестного соединения CROSS JOIN.....	67
Оператор внешнего соединения OUTER JOIN.....	69
Сохранение и совместное использование	70
История запросов и кеширование	70
Сохранение запросов	72
Представления и общедоступные запросы.....	73
Выводы	74
Глава 3. Типы данных, функции и операторы.....	75
Числовые типы и функции.....	76
Математические функции	77
Стандартное вещественное деление.....	78

Функции SAFE	78
Сравнение	79
Точные десятичные вычисления с NUMERIC	80
Тип BOOL	81
Логические операции	81
Условные выражения	83
Обработка NULL с помощью COALESCE.....	84
Явное и неявное приведение типов	85
Использование COUNTIF, чтобы избежать приведения логических значений	87
Строковые функции.....	88
Интернационализация	89
Формирование и парсинг строк.....	91
Функции для обработки строк.....	91
Функции преобразования	92
Регулярные выражения	92
Краткие итоги по строковым функциям	94
Операции со значениями TIMESTAMP	95
Парсинг и форматирование отметок времени	95
Извлечение календарных данных.....	97
Арифметические операции с временными метками.....	98
DATE, TIME и DATETIME	99
Функции для работы с географическими координатами	100
Выводы	101
Глава 4. Загрузка данных в BigQuery.....	104
Основы.....	104
Загрузка из локального источника	105
Корректировка схемы.....	112
Копирование в новую таблицу	116
Управление данными (DDL и DML)	116
Эффективная загрузка данных	118
Федеративные запросы и внешние источники данных	121
Как использовать федеративные запросы.....	121
Когда использовать федеративные запросы и внешние источники данных.....	125

Интерактивное исследование и запрос данных из Google Sheets	132
Запросы SQL для выборки данных из Cloud Bigtable.....	141
Передача и экспорт данных.....	147
Служба передачи данных Data Transfer Service.....	147
Экспортирование журналов Stackdriver	153
Использование Cloud Dataflow для чтения/записи в BigQuery	154
Перемещение локальных данных.....	159
Методы миграции данных	159
Выводы	162
Глава 5. Разработка с BigQuery	163
Программный доступ	163
Доступ к BigQuery через REST API.....	163
Google Cloud Client Library.....	171
Доступ к BigQuery из инструментов исследования данных	188
Блокноты в Google Cloud Platform	188
Работа с BigQuery, pandas и Jupyter.....	193
Работа с BigQuery из R.....	198
Cloud Dataflow	199
Драйверы JDBC/ODBC.....	202
Внедрение данных из BigQuery в Google Slides (в G Suite)	203
Bash-скрипты для BigQuery.....	205
Создание наборов данных и таблиц	205
Выполнение запросов	208
Объекты BigQuery	210
Выводы	212
Глава 6. Архитектура BigQuery	213
Архитектура высокого уровня	213
Жизненный цикл запроса	213
Обновление BigQuery	218
Система обработки запросов (Dremel).....	219
Архитектура Dremel.....	221
Выполнение запроса	226
Хранилище.....	241
Хранение данных	241

Метаданные	248
Выводы	258
Глава 7. Оптимизация производительности и затрат	259
Принципы производительности	259
Ключевые составляющие производительности.....	260
Управление затратами.....	260
Измерение производительности и поиск проблем	262
Определение скорости выполнения запроса с помощью REST API.....	263
Определение скорости выполнения запроса с помощью BigQuery Workload Tester	265
Выявление проблем в рабочих нагрузках с помощью Stackdriver	267
Чтение плана запроса	269
Увеличение скорости выполнения запросов	274
Минимизация ввода/вывода	275
Кеширование результатов предыдущих запросов	280
Эффективное выполнение соединений	284
Исключение перегрузки рабочих серверов	293
Использование приближенных функций агрегирования.....	296
Оптимизация хранения данных и доступа к ним.....	299
Минимизация сетевых издержек	300
Выбор эффективного формата хранения	303
Секционирование таблиц для уменьшения объема сканирования	313
Кластеризация таблиц на основе ключей с большой мощностью множества	316
Случаи использования, нечувствительные ко времени	321
Пакетные запросы	321
Загрузка файлов	323
Выводы	324
Контрольный список	324
Глава 8. Продвинутые запросы	326
Многократные запросы	326
Параметризованные запросы.....	327
Пользовательские функции SQL	332
Повторное использование частей запросов	337

Продвинутый SQL.....	341
Работа с массивами.....	342
Оконные функции.....	351
Метаданные таблиц	356
Язык определения данных и язык манипулирования данными.....	360
За пределами SQL.....	365
Пользовательские функции на JavaScript.....	366
Скрипты.....	367
Продвинутые функции.....	375
Геоинформационная система BigQuery.....	375
Полезные статистические функции.....	383
Алгоритмы хеширования	385
Выводы	389
Глава 9. Машинное обучение в BigQuery	390
Что такое машинное обучение?.....	390
Формулировка задачи машинного обучения.....	391
Типы задач машинного обучения.....	392
Построение регрессионной модели	396
Выбор метки	396
Выбор признаков в наборе данных.....	397
Создание обучающего набора данных	401
Обучение и оценка модели	402
Получение прогнозов с помощью модели	404
Исследование весов модели	407
Более сложные регрессионные модели	409
Создание модели классификации	414
Обучение.....	415
Оценка.....	416
Прогнозирование	417
Выбор порога.....	418
Настройка механизма машинного обучения в BigQuery	420
Управление делением данных.....	420
Балансировка классов	422
Регуляризация.....	422

Кластеризация методом k-средних.....	423
Выбор признаков для кластеризации.....	424
Кластеризация пунктов проката велосипедов	425
Кластеризация.....	426
Исследование кластеров.....	427
Принятие решений на основе данных	429
Рекомендательные системы	430
Набор данных MovieLens.....	430
Разложение матрицы	432
Получение рекомендаций	434
Включение информации о пользователях и фильмах.....	436
Нестандартные модели машинного обучения в GCP.....	443
Настройка гиперпараметров	444
AutoML	448
Поддержка TensorFlow.....	450
Выводы	453
Глава 10. Администрирование и безопасность BigQuery.....	455
Защищенность инфраструктуры	455
Управление идентификацией и доступом	457
Идентификация.....	457
Роль	458
Ресурс	461
Администрирование BigQuery.....	462
Управление заданиями	462
Авторизация пользователей	463
Восстановление удаленных записей и таблиц	463
Непрерывная интеграция/непрерывное развертывание	464
Экспорт биллинга — получение информации о расходах.....	467
Оперативные панели, мониторинг и журналы аудита.....	470
Доступность, восстановление после отказа и шифрование	471
Зоны, регионы и объединения регионов	471
BigQuery и обработка отказов	472
Сохранность, резервное копирование и восстановление после аварий.....	476
Конфиденциальность и шифрование.....	477

Соответствие требованиям законодательств	478
Местоположение данных.....	478
Ограничение доступа к подмножествам данных.....	480
Удаление всех сделок, связанных с конкретным физическим лицом	483
Предотвращение потери данных	487
СМЕК.....	488
Защита от утечки данных.....	490
Выводы	491
Об авторах	493
Об обложке	494