Полная программа

ClickHouse для инженеров и архитекторов БД

Подробная программа для инженеров и архитекторов БД

Длительность курса: 16 часов

Модуль 1. Знакомство с ClickHouse

Тема 1.
Архитектура ClickHouse

Теория: как работает колоночная СУБД, почему она быстрая на аналитических запросах и чем отличается от OLTP-систем.

Практика: развернуть ClickHouse в Docker, подключиться через clickhouse-client и выполнить первые запросы.

Дополнительно: обзор официальной документации, полезные ресурсы сообщества, обсуждение типовых задач, с которыми приходят к ClickHouse.

Тема 2.
Типы данных и движки таблиц

Теория: числовые, строковые, временные типы, Nullable, LowCardinality, Array, Tuple, Map, Enum. Семейство движков MergeTree: ReplacingMergeTree, SummingMergeTree, AggregatingMergeTree, CollapsingMergeTree, VersionedCollapsingMergeTree.

Практика: создать таблицы с разными движками, вставить данные и сравнить поведение при слиянии кусков.

Дополнительно: рекомендации по выбору типов данных, влияние типов на размер данных и скорость запросов.

Тема 3.
Вставка данных: форматы и способы

Теория: форматы TabSeparated, CSV, JSONEachRow, Native, Parquet. Буферизация вставок, асинхронные вставки, ограничения на размер и частоту вставок.

Практика: загрузить данные из CSV и JSON-файлов, настроить асинхронные вставки, проверить, как ведут себя мелкие и крупные батчи.

Дополнительно: обзор clickhouse-local для разовой обработки файлов без сервера, работа с данными из stdin.

Тема 4.
Основы SELECT: фильтрация, сортировка, агрегация

Теория: WHERE, ORDER BY, LIMIT, GROUP BY, HAVING. Агрегатные функции, комбинаторы -If, -Array, -State, -Merge. Оконные функции.

Практика: написать аналитические запросы к учебному датасету, сравнить производительность разных подходов к агрегации.

Дополнительно: разбор типовых ошибок новичков, полезные настройки сессии.

Модуль 2. Работа с ClickHouse

Тема 1.
Язык запросов ClickHouse SQL и его диалекты

Теория: стандартный SQL и расширения ClickHouse. Лямбда-функции, массивные функции, работа с вложенными структурами. Подзапросы и CTE.

Практика: написать сложные аналитические запросы с использованием массивов, лямбд и подзапросов.

Дополнительно: сравнение с другими диалектами SQL, на что обратить внимание при переносе запросов.

Тема 2.
Работа с JSON и Tuple

Теория: хранение и извлечение данных, вывод типов, ограничения и производительность.

Практика: загрузить данные с вложенными JSON-документами, извлечь нужные поля, сравнить производительность.

Дополнительно: сравнение с другими подходами к работе с JSON в аналитических СУБД.

Тема 3.
Импорт и экспорт данных

Теория: форматы для импорта и экспорта, работа с файлами, потоками и внешними источниками.

Практика: загрузить данные из файла, выгрузить результат запроса в другом формате.

Дополнительно: обзор clickhouse-local для разовой обработки файлов без сервера.

Тема 4.
Работа с внешними данными: словари и JOIN

Теория: словари (dictionaries), их источники и способы обновления. Типы JOIN, их особенности и ограничения. Когда словарь лучше JOIN.

Практика: подключить словарь из внешнего источника, использовать его в запросах, сравнить с JOIN.

Дополнительно: рекомендации по выбору между словарем и JOIN в типовых задачах.

Тема 5.
Словари

Теория: подключение внешних источников данных, обновление словарей.

Практика: создать словарь из внешнего источника, использовать его в запросах.

Дополнительно: рекомендации по выбору между словарем и JOIN в типовых задачах.

Тема 6.
Работа с материализованными представлениями

Теория: принцип работы, триггерная природа, ограничения, типичные ошибки.

Практика: создать материализованное представление, проверить его работу на потоке данных.

Дополнительно: обзор TO-варианта и его преимуществ.

Модуль 3. Масштабирование и манипуляции с данными

Тема 1.
Репликация и шардирование: теория и настройка кластера

Теория: ReplicatedMergeTree, ClickHouse Keeper, шардирование, распределённые таблицы, консистентность и отказоустойчивость.

Практика: развернуть кластер из нескольких узлов, настроить репликацию и шардирование, проверить поведение при отказе узла.

Дополнительно: типичные ошибки при эксплуатации кластера, мониторинг состояния.

Тема 2.
Мутации, партиции и другие операции над данными

Теория: мутации и их ограничения, партиционирование, операции с партициями, TTL.

Практика: выполнить мутацию, работать с партициями, настроить автоматическое удаление старых данных.

Дополнительно: влияние мутаций на производительность, альтернативные подходы.

Тема 3.
Резервное копирование и восстановление

Теория: стратегии бэкапов, инструменты, восстановление отдельных партиций и таблиц.

Практика: настроить регулярное резервное копирование, восстановить данные из бэкапа.

Дополнительно: обзор clickhouse-backup и других инструментов.

Тема 4.
Оптимизация производительности запросов

Теория: как ClickHouse выполняет запрос, EXPLAIN, профилирование, узкие места.

Практика: найти медленные запросы, проанализировать их план, оптимизировать.

Дополнительно: чек-лист оптимизации, типичные паттерны ускорения.

Тема 5.
Мониторинг и работа с системными таблицами

Теория: system.*, query_log, метрики, алерты.

Практика: настроить сбор метрик, найти проблемные запросы через system.query_log.

Дополнительно: обзор готовых дашбордов для Grafana.

Тема 6.
Безопасность и управление доступом

Теория: пользователи, роли, квоты, профили настроек, сетевой доступ, шифрование.

Практика: настроить ограничения для разных пользователей, проверить, что они работают.

Дополнительно: рекомендации по безопасной конфигурации для продакшена.

Тема 7.
Обновление кластера и миграции схемы

Теория: стратегии обновления без простоя, совместимость версий, миграции схемы.

Практика: обновить кластер с минимальным временем недоступности, откатить изменения схемы.

Дополнительно: чек-лист перед обновлением, типичные проблемы.

Модуль 4. Управление ресурсами

Тема 1.
Квоты, профили настроек и ограничения

Теория: пользователи, роли, профили настроек, квоты. Ограничения на время выполнения, память, количество строк, частоту запросов. Иерархия профилей.

Практика: настроить профили для разных групп пользователей, проверить, что ограничения срабатывают.

Дополнительно: рекомендации по выбору ограничений для продакшена.

Тема 2.
Управление ресурсами: workloads и приоритеты

Теория: workloads и ресурсы, приоритеты, справедливое распределение, ограничения.

Практика: настроить workload для разных типов запросов, проверить, как они конкурируют за ресурсы.

Дополнительно: сравнение с другими подходами к управлению ресурсами.

Тема 3.
Профилирование и анализ медленных запросов

Теория: как ClickHouse выполняет запрос, EXPLAIN, профилирование, узкие места.

Практика: найти медленные запросы, проанализировать их план, оптимизировать.

Дополнительно: чек-лист оптимизации, типичные паттерны ускорения.

Тема 4.
Мониторинг и работа с системными таблицами

Теория: system.*, query_log, метрики, алерты.

Практика: настроить сбор метрик, найти проблемные запросы через system.query_log.

Дополнительно: обзор готовых дашбордов для Grafana.

Тема 5.
Обновление кластера и миграции схемы

Теория: стратегии обновления без простоя, совместимость версий, миграции схемы.

Практика: обновить кластер с минимальным временем недоступности, откатить изменения схемы.

Дополнительно: чек-лист перед обновлением, типичные проблемы.

Модуль 5. Популярные интеграции

Тема 1.
Kafka и ClickHouse: Table Engine и ClickPipes

Теория: как работает движок Kafka, материализованные представления как конвейер, ClickPipes.

Практика: настроить загрузку данных из Kafka, проверить работу конвейера.

Дополнительно: обработка ошибок, мониторинг потребителей.

Тема 2.
Интеграция с Kafka и внешними потоками данных

Теория: Kafka Engine, материализованные представления как конвейер, ClickPipes.

Практика: настроить загрузку данных из Kafka, проверить работу конвейера.

Дополнительно: обработка ошибок, мониторинг потребителей.

Тема 3.
Интеграция с BI-инструментами и JDBC/ODBC

Теория: протоколы HTTP, Native, JDBC, ODBC. Подключение Grafana, Superset, Metabase, DBeaver.

Практика: настроить подключение из BI-инструмента, построить дашборд.

Дополнительно: типичные проблемы подключения и их решения.

Тема 4.
Работа с внешними источниками данных

Теория: движки для чтения внешних данных, табличные функции, их ограничения.

Практика: прочитать данные из внешнего источника, сравнить с загрузкой в ClickHouse.

Дополнительно: когда оставлять данные снаружи, а когда загружать.

Тема 5.
Интеграция с Kafka

Теория: как работает движок Kafka, материализованные представления как конвейер, ClickPipes.

Практика: настроить загрузку данных из Kafka, проверить работу конвейера.

Дополнительно: обработка ошибок, мониторинг потребителей.

Тема 6.
Интеграция с BI-инструментами и JDBC/ODBC

Теория: протоколы HTTP, Native, JDBC, ODBC. Подключение Grafana, Superset, Metabase, DBeaver.

Практика: настроить подключение из BI-инструмента, построить дашборд.

Дополнительно: типичные проблемы подключения и их решения.

Модуль 6. ClickHouse для задач AI

Тема 1.
Векторный поиск в ClickHouse

Теория: типы данных для векторов, функции расстояний, индексы для приближённого поиска, ограничения.

Практика: загрузить эмбеддинги, построить индекс, выполнить поиск ближайших соседей.

Дополнительно: сравнение с специализированными векторными базами, когда ClickHouse подходит, а когда нет.

Тема 2.
Интеграция с LLM-приложениями: RAG и семантический поиск

Теория: архитектура RAG-приложения, роль векторного поиска, гибридный поиск (векторы + фильтры).

Практика: собрать простое RAG-приложение с ClickHouse в качестве хранилища.

Дополнительно: обзор готовых фреймворков и подходов.

Тема 3.
Подготовка данных для обучения моделей

Теория: выгрузка больших объёмов данных, форматы, производительность.

Практика: выгрузить данные в Parquet, загрузить в pandas, сравнить скорость с другими способами.

Дополнительно: типичные задачи подготовки данных для ML.

Модуль 7. Проектная работа

Тема 1.
Постановка задачи и проектирование схемы данных

Теория: выбор типов данных, движков и ключей сортировки под конкретную задачу.

Практика: спроектировать схему данных для своего проекта, обосновать выбор.

Дополнительно: разбор типовых ошибок при проектировании схемы.

Тема 2.
Разработка и оптимизация запросов

Теория: подходы к написанию эффективных аналитических запросов.

Практика: написать и оптимизировать запросы для своего проекта.

Дополнительно: чек-лист оптимизации, типичные паттерны ускорения.

Тема 3.
Тестирование и подготовка к продакшену

Теория: стратегии тестирования, нагрузочное тестирование, чек-лист готовности к продакшену.

Практика: протестировать свой проект, подготовить его к продакшену.

Дополнительно: типичные проблемы при переходе в продакшен.

Тема 4.
Презентация

Подготовка и защита проектной работы.

Дополнительно: рекомендации по структуре презентации, типичные ошибки при защите.

Тема 5.
Защита проектных работ и подведение итогов курса

Каждый студент защищает готовый проект перед группой и преподавателем. Разбор решений, обсуждение альтернатив, общие выводы по курсу.

Дополнительно: рекомендации по структуре презентации, типичные ошибки при защите.