



Лекция “Данные современного мира и актуальные способы их хранения”



A background image showing a group of students in a library. A young man is smiling and looking at a laptop, while a young woman with glasses looks on. Another student is partially visible in the foreground. Bookshelves filled with books are in the background.

Ваш лектор: Доцент РТУ-МИРЭА Смирнов Михаил

E-mail: mikhaelsmirnov@gmail.com

ОПРЕДЕЛИМ ПРЕДМЕТ ДИСКУССИИ



Данные.

Форма представления информации в виде фактов.

Факты можно изучать, классифицировать, по ним можно делать выводы и получать новые знания.

Благодаря данным с вашего Apple Watch я могу узнать практически все о вашем образе жизни. И даже спрогнозировать, что вы будете завтра... или через неделю.

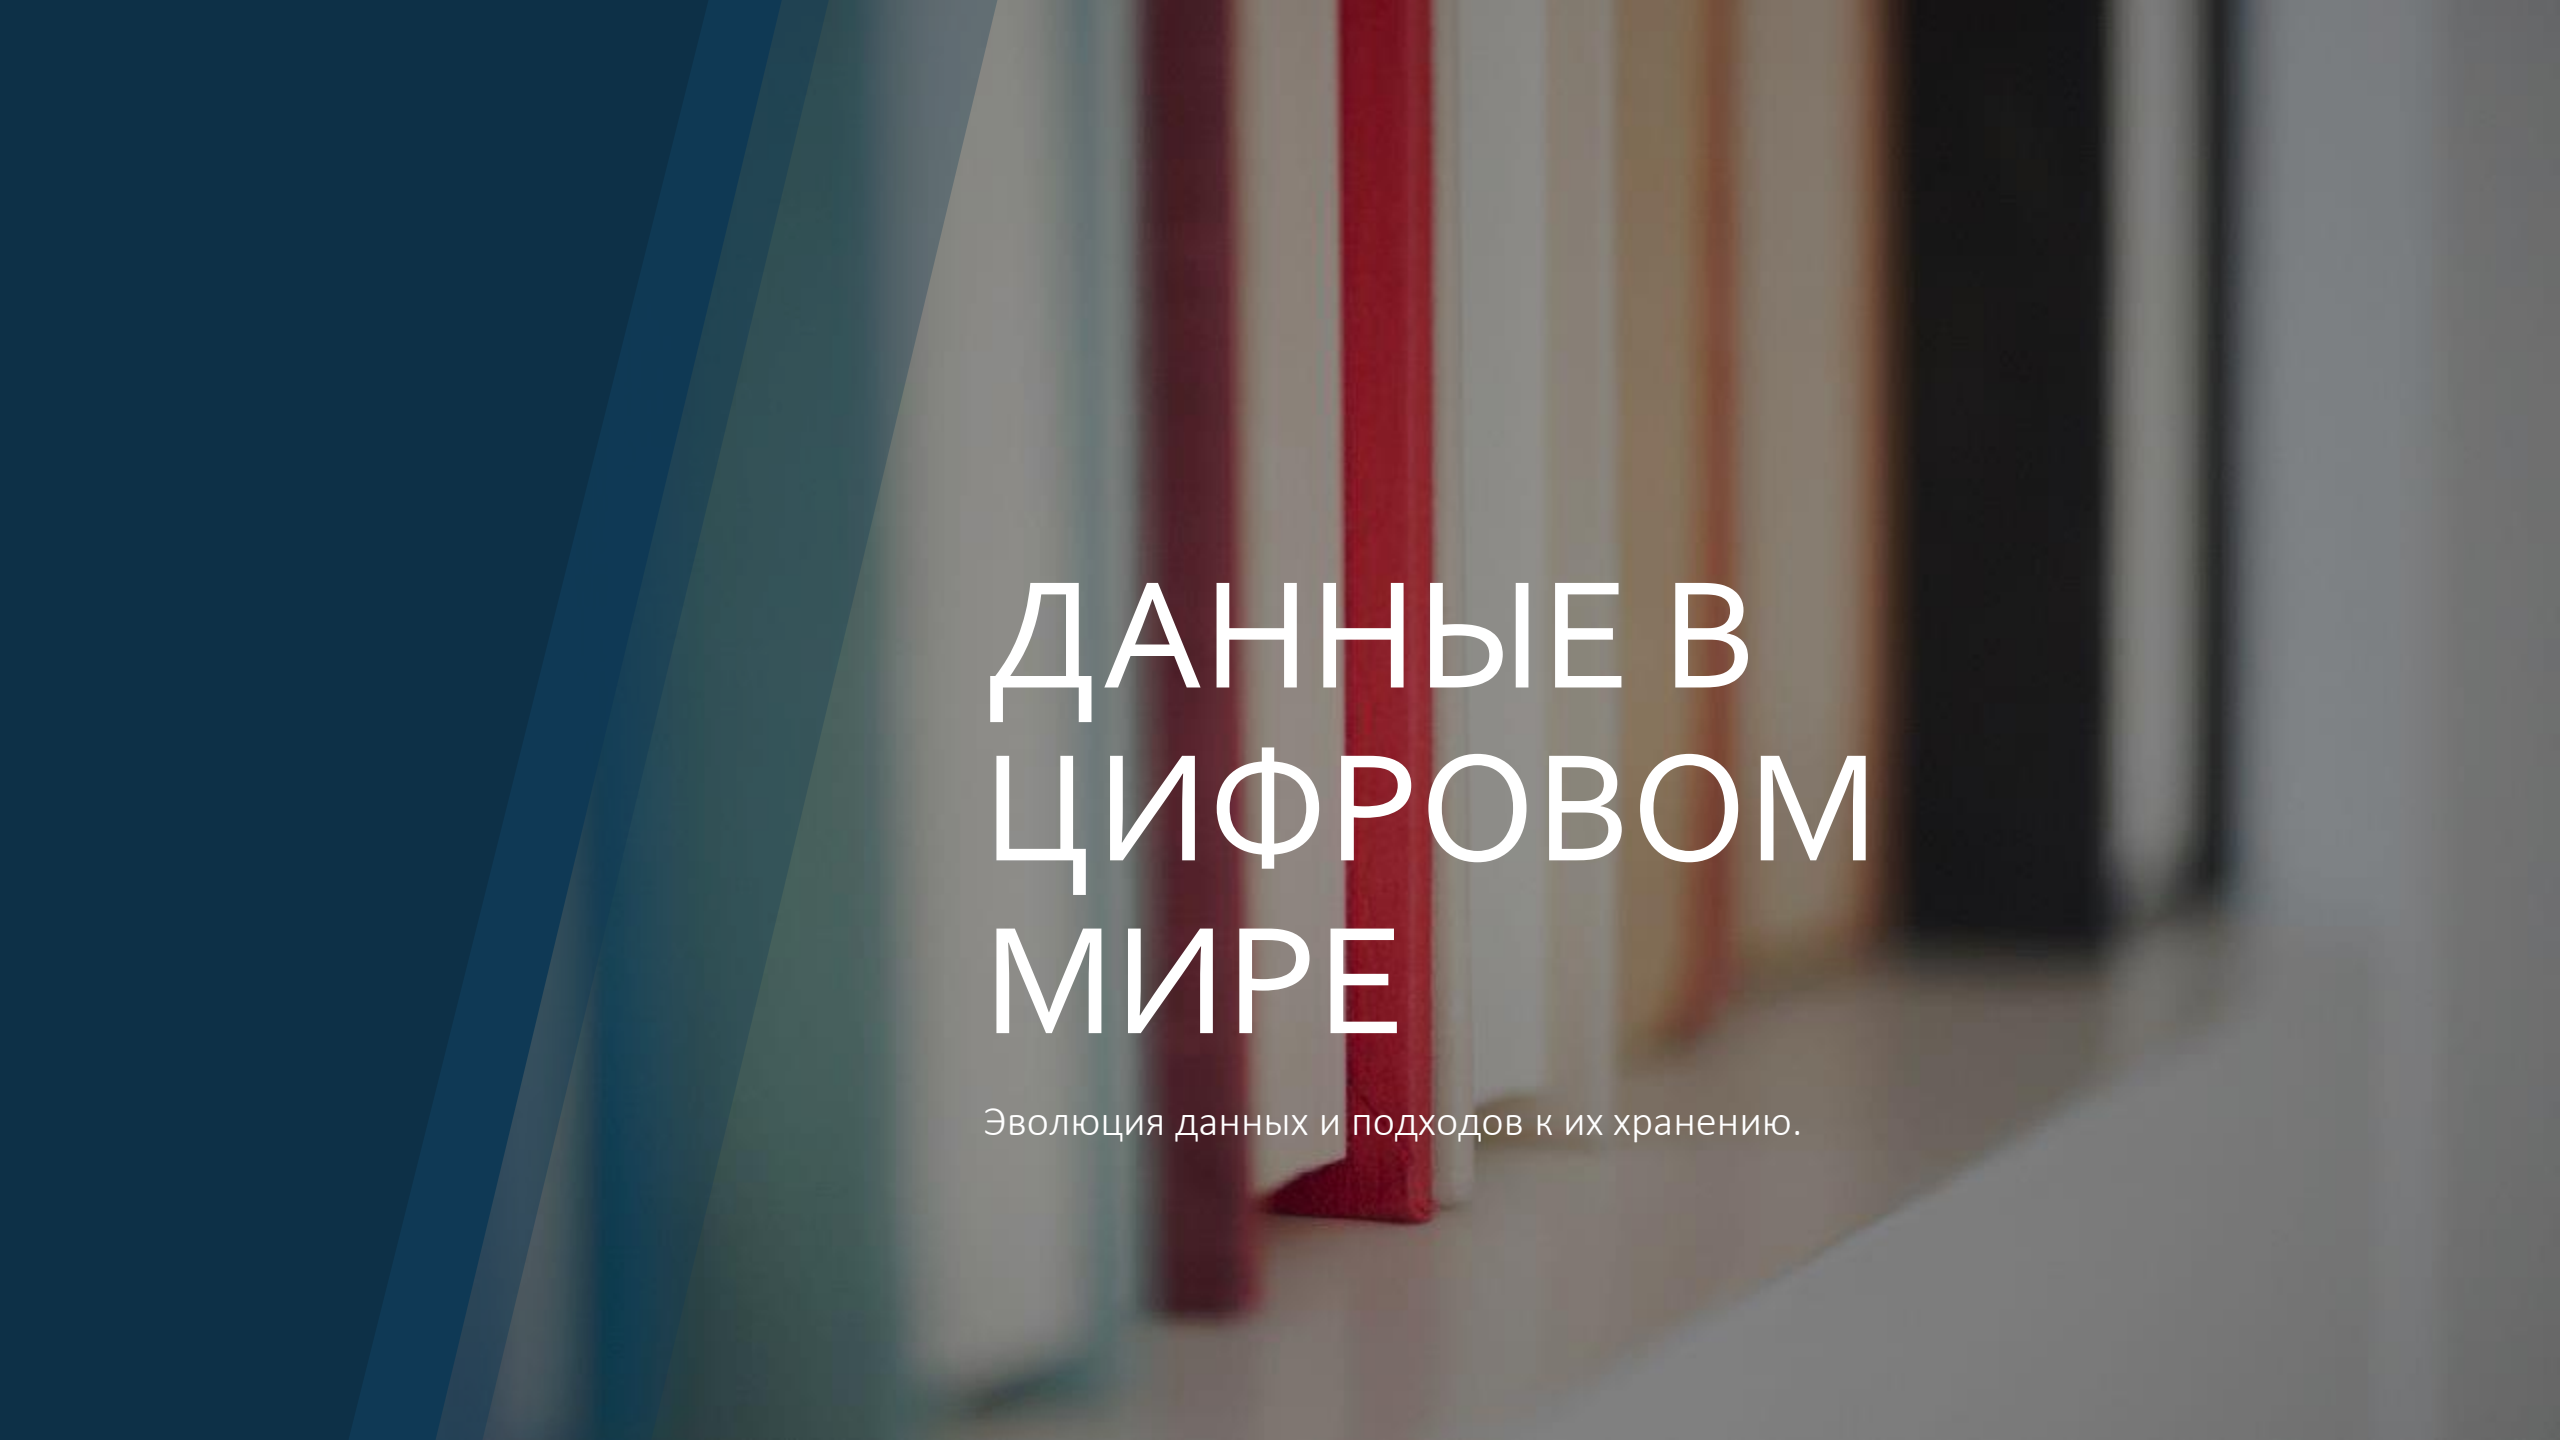


Базы данных.

Программное обеспечение, фреймворки, технологии, главной задачей которых является обеспечение возможности безопасного хранения данных.

Их ОЧЕНЬ много.






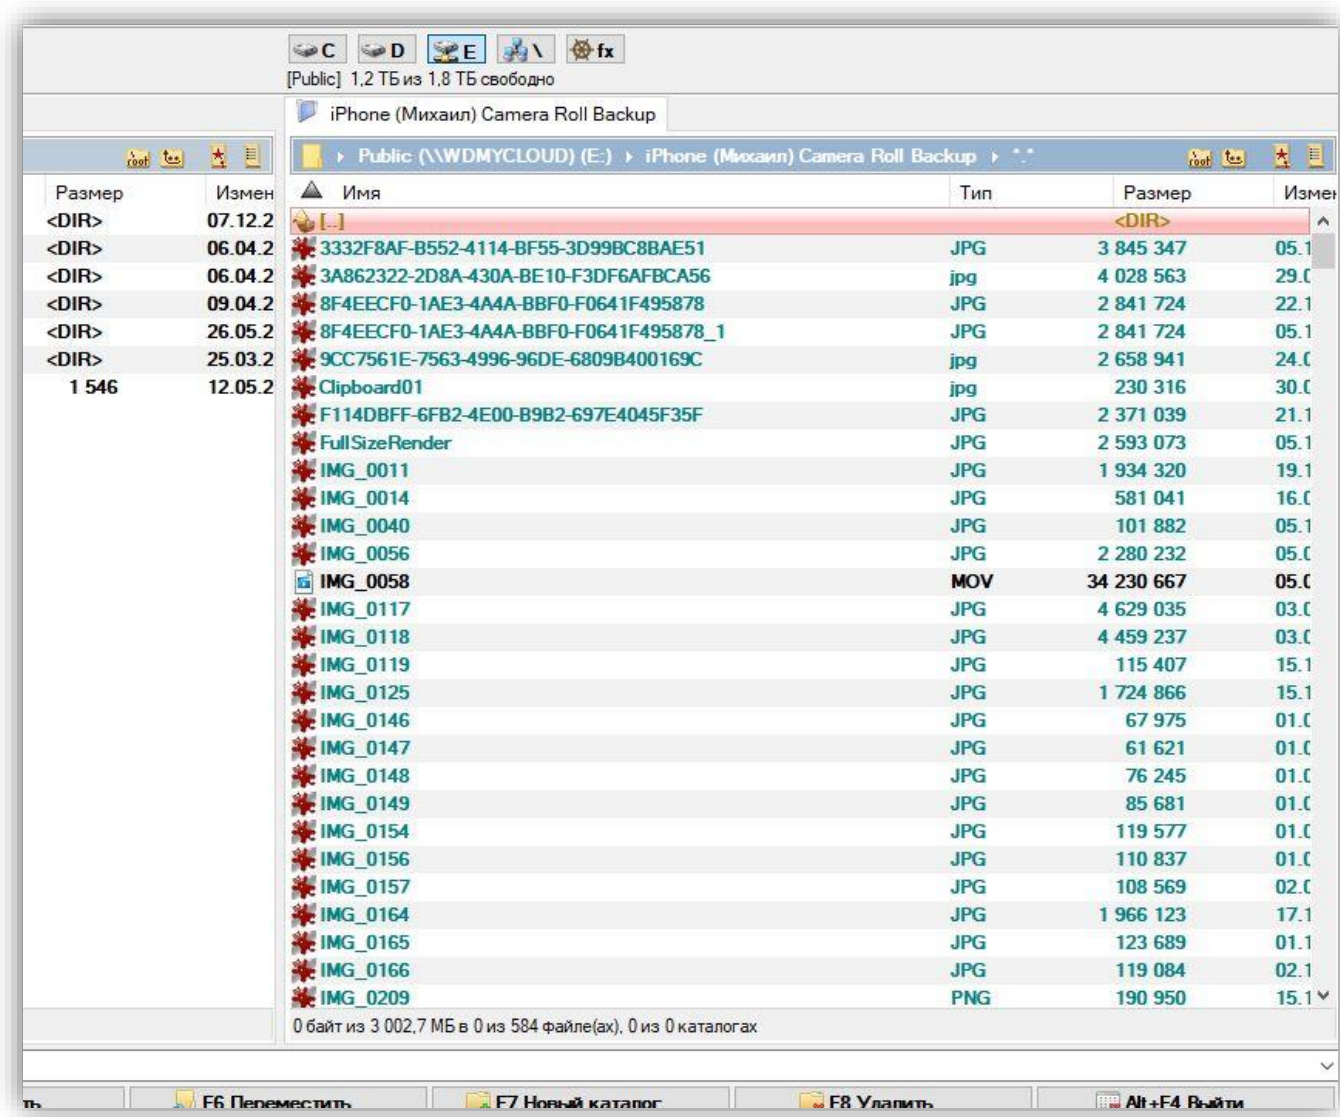
ДАННЫЕ В ЦИФРОВОМ МИРЕ

Эволюция данных и подходов к их хранению.

КАК ВСЕ НАЧИНАЛОСЬ. РУЧЕЕК ДАННЫХ.



ДАННЫЕ В ВИДЕ ФАЙЛОВ.



НУ, ЭТО ЖЕ НЕ ПРОБЛЕМА?



**И ТАК
СОЙДЕТ!**

ДАННЫХ ВСЕ БОЛЬШЕ. РЕКА ДАНЫХ.



РЕЛЯЦИОННЫЙ ПОРЯДОК В ДАННЫХ. РЫБАЛКА ЛИНКА.

Озеро Дейа


ДАТА	КОЛ-ВО	РЫБА
17.05.2021	412	Муранья
03.07.2021	84	Сладкая рыба-пастух
03.07.2021	9	Лорд Чапу-Чапу
03.07.2021	117	Веселый карп

Рыба Муранья


ДАТА	КОЛ-ВО	ВОДОЕМ
17.05.2021	412	Озеро Дейа
03.07.2021	84	Озеро Джаррах
03.07.2021	9	Озеро Кора
03.07.2021	117	Озеро Нирвата



НАДЕЖНО, НО... НЕБЫСТРО.



ЭПОХА СОЦСЕТЕЙ И ЦИФРОВИЗАЦИИ. ВОДОПАД ДАННЫХ.



ТОЧКИ ПРИЛОЖЕНИЯ ДАННЫХ В СОВРЕМЕННОМ МИРЕ

Государство

Мобильные
приложения

Компьютерные
игры

Социальные
сети

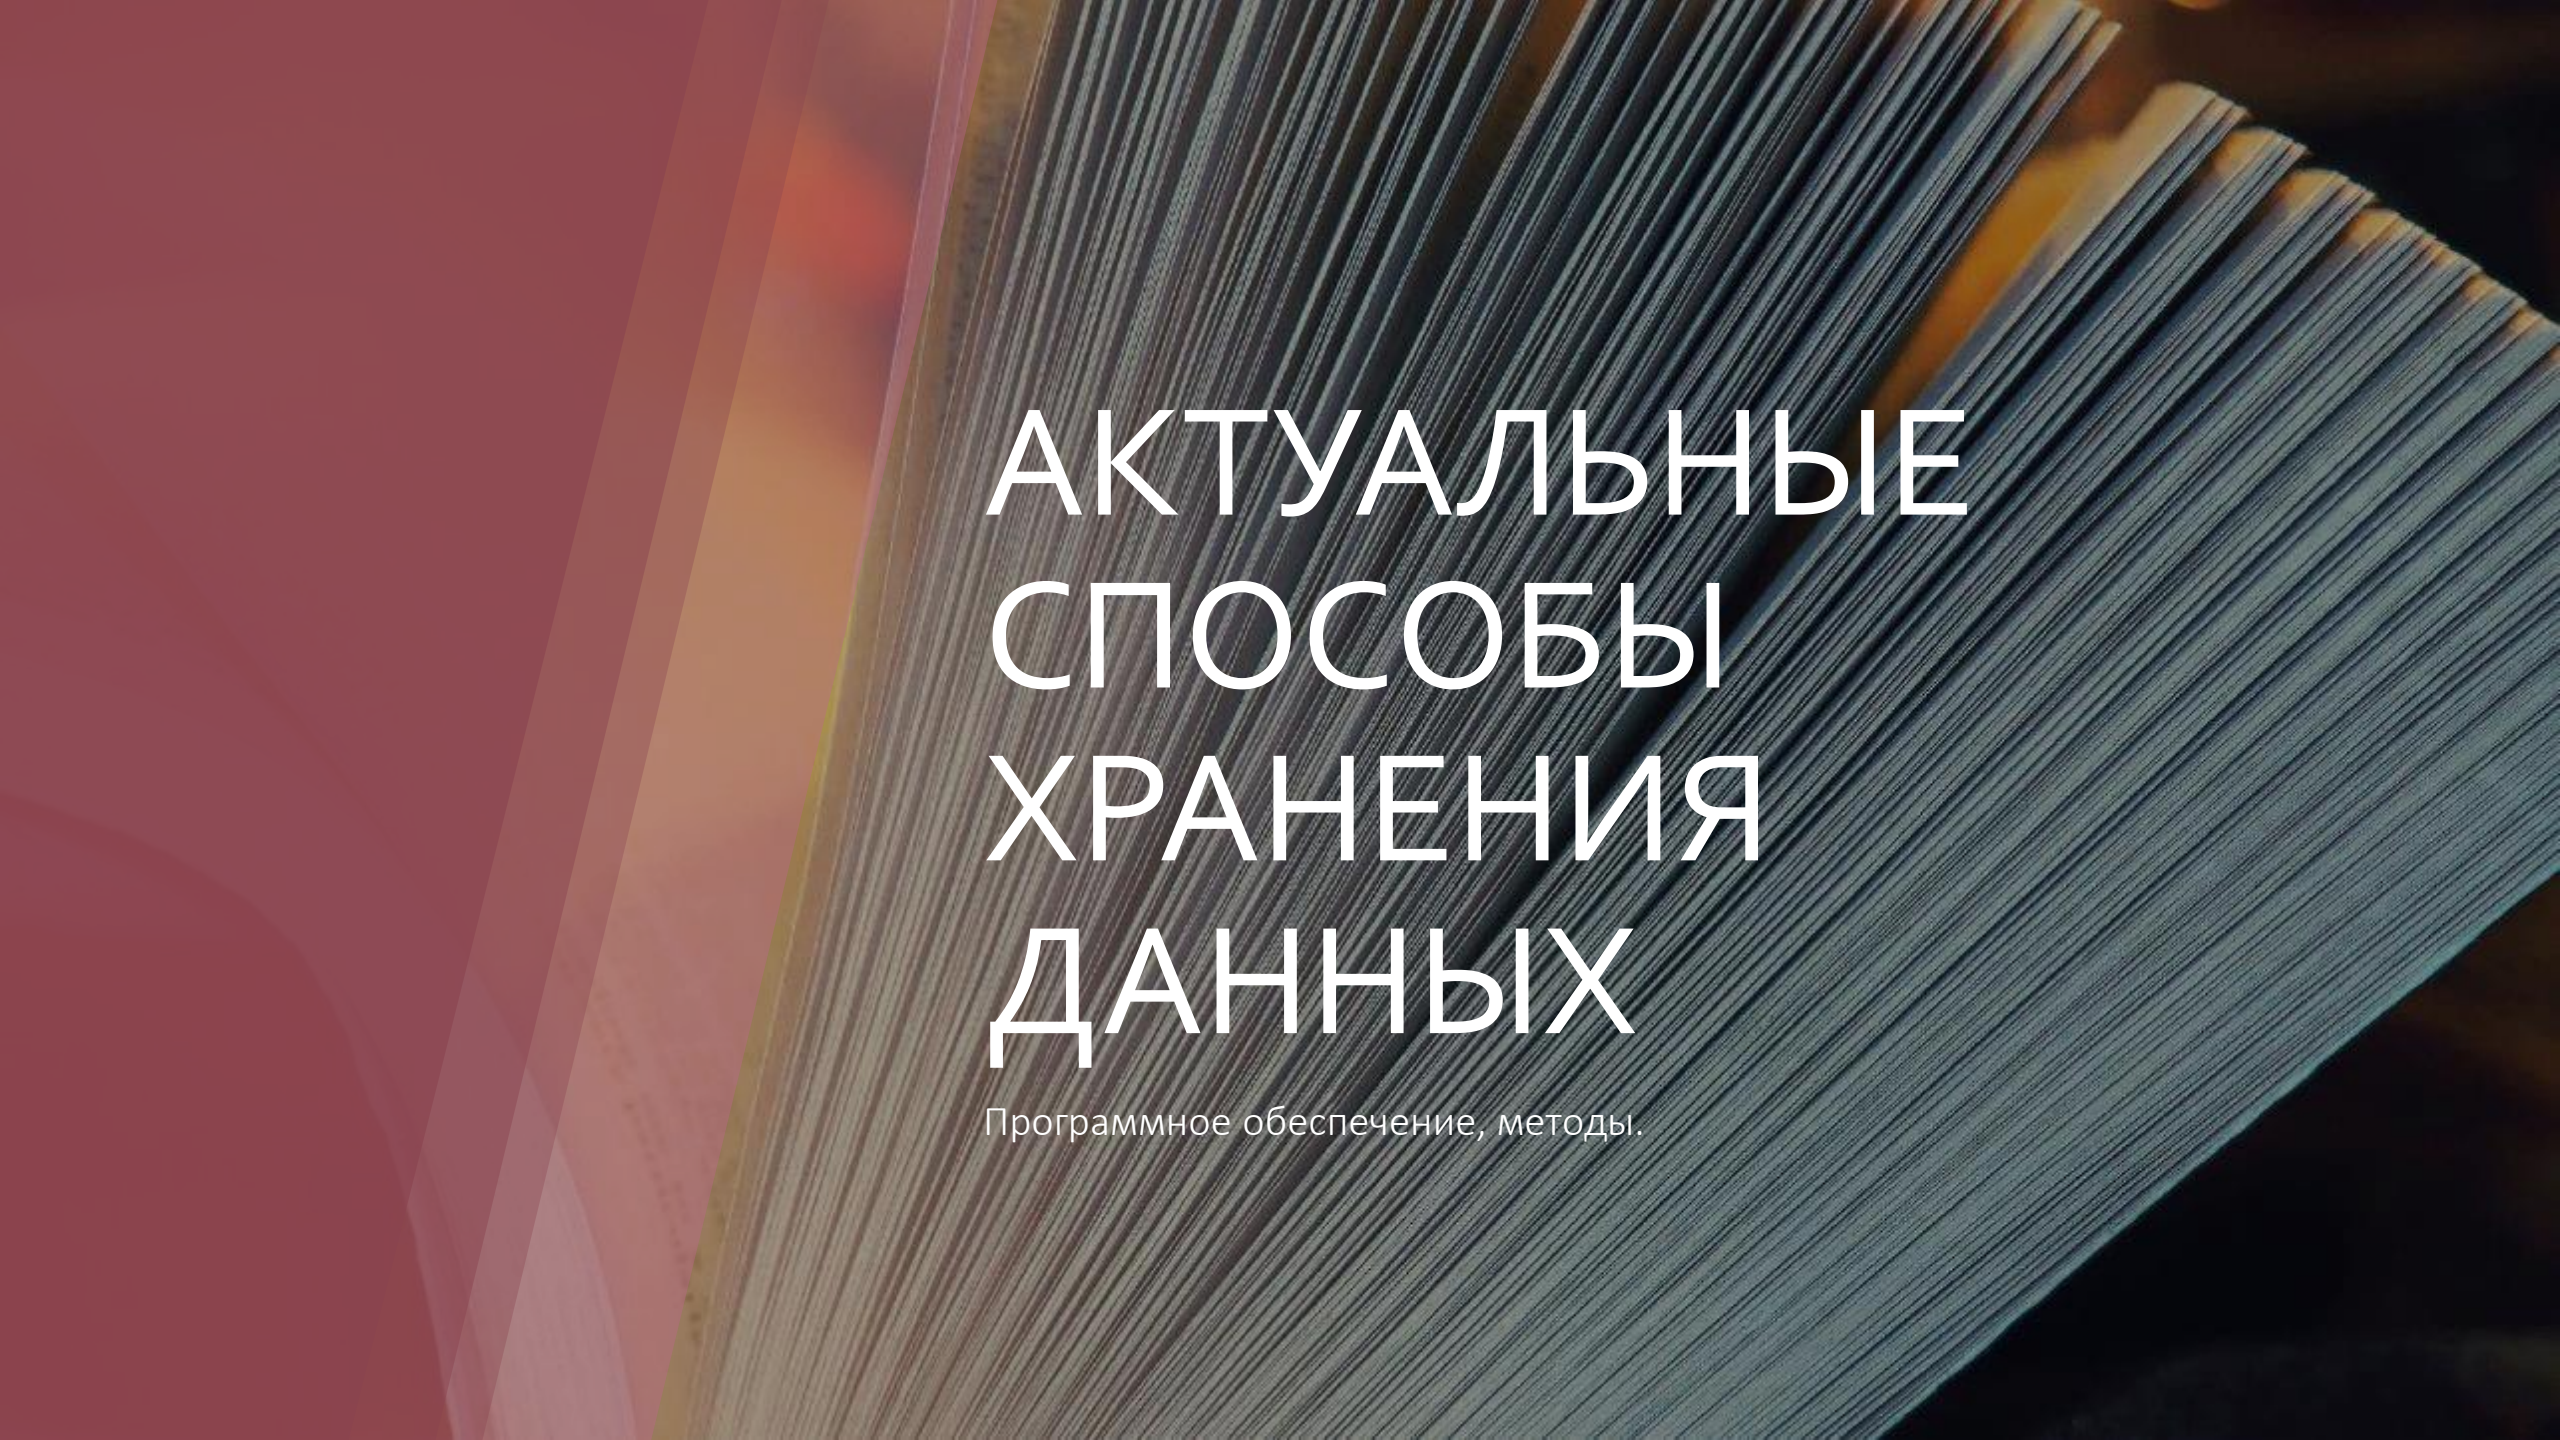
Интернет
магазины

Интернет
вещей

Десктопные
приложения

Корпорации

Банки и
финучреждения



АКТУАЛЬНЫЕ СПОСОБЫ ХРАНЕНИЯ ДАННЫХ

Программное обеспечение, методы.

РЕЛЯЦИОННЫЕ И ПОСТРЕЛЯЦИОННЫЕ БАЗЫ ДАННЫХ



Реляционные базы данных и хранилища данных.

Все упорядочено по строгим правилам.

Дружелюбный, похожий на естественный язык программирования (SQL).

Гарантирует правильность и целостность данных. Всегда. Не даст совершить ошибку.

Долгая подготовка, дорогие изменения.



Постреляционные базы данных и хранилища данных.

Упорядочим потом. Как-нибудь. Но это неточно.

Много скобочек. Разных. Очень много! (JSON).

Гарантирует правильность данных. Когда-нибудь. Но это неточно.

Короткая подготовка. Моментальные изменения.




РЕЛЯЦИОННЫЕ И ПОСТРЕЛЯЦИОННЫЕ БАЗЫ ДАННЫХ

Реляционная модель хранения



Постреляционная модель хранения



ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ РЕЛЯЦИОННОЙ ПАРАДИГМЫ



ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ ПОСТРЕЛЯЦИОННОЙ ПАРАДИГМЫ

Хранилище
“ключ-значение”

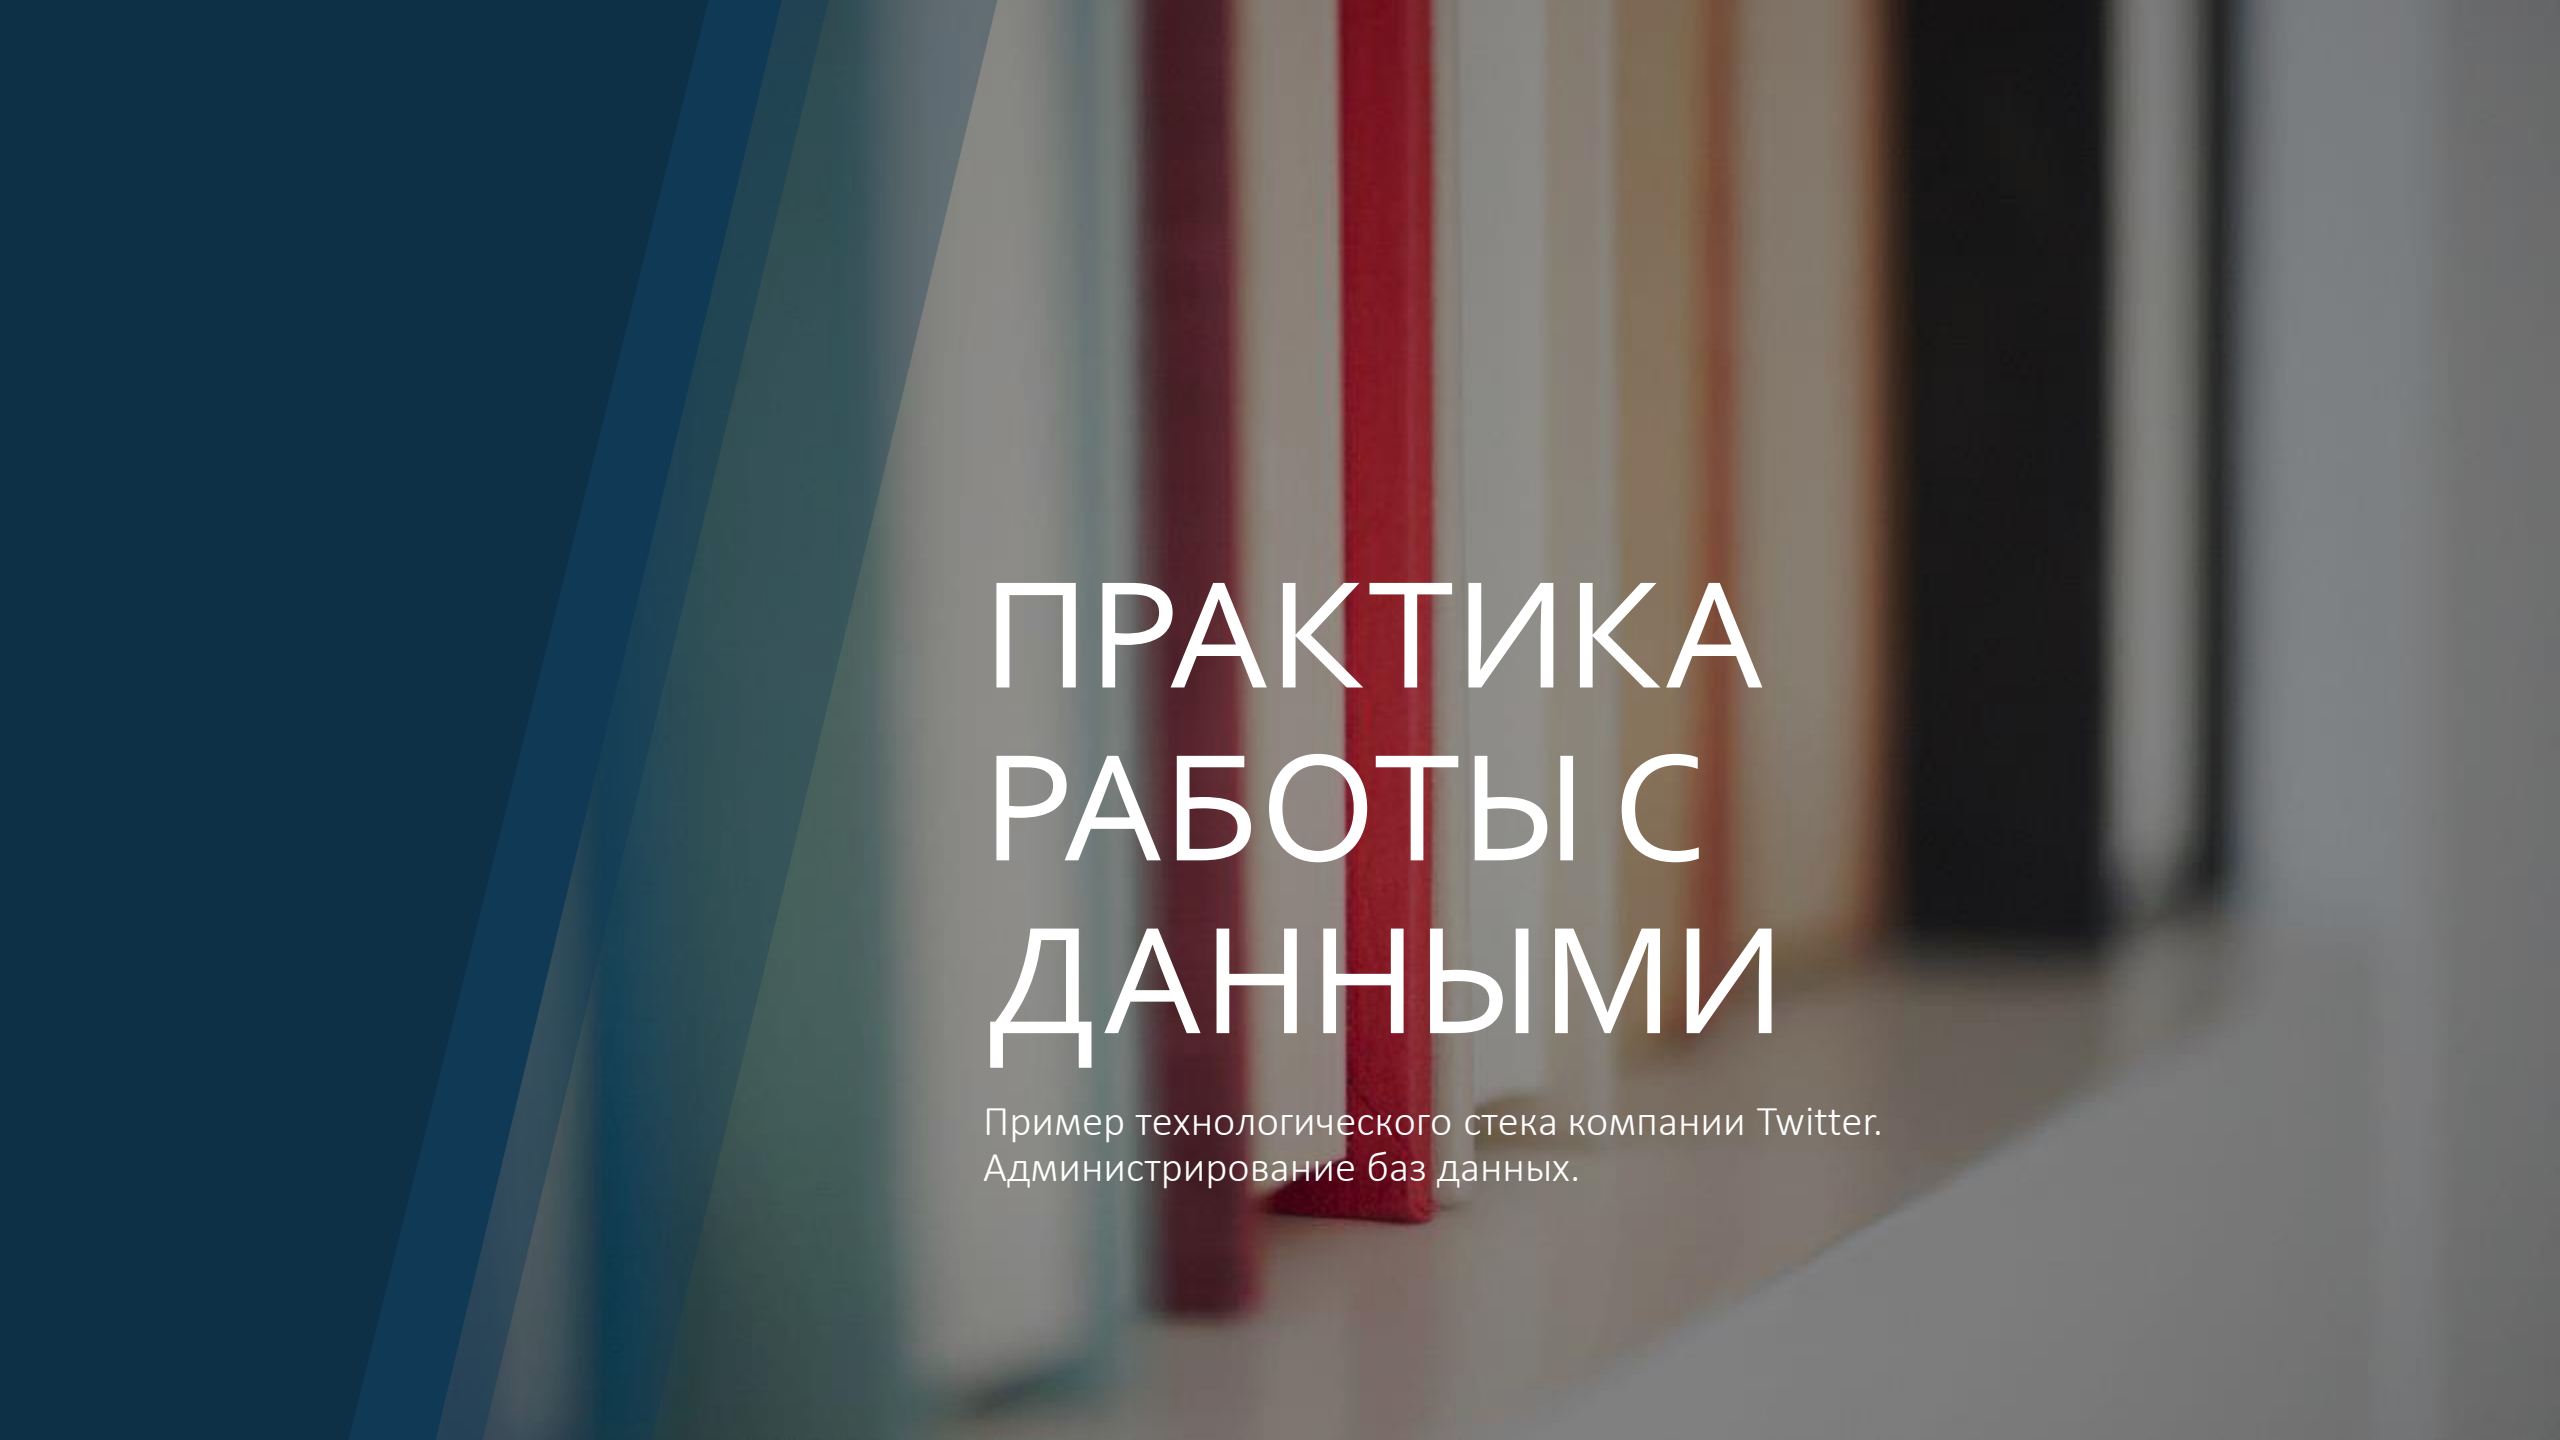


Хранилище семейств
колонок



Документо-ориентированная
СУБД





ПРАКТИКА РАБОТЫ С ДАННЫМИ

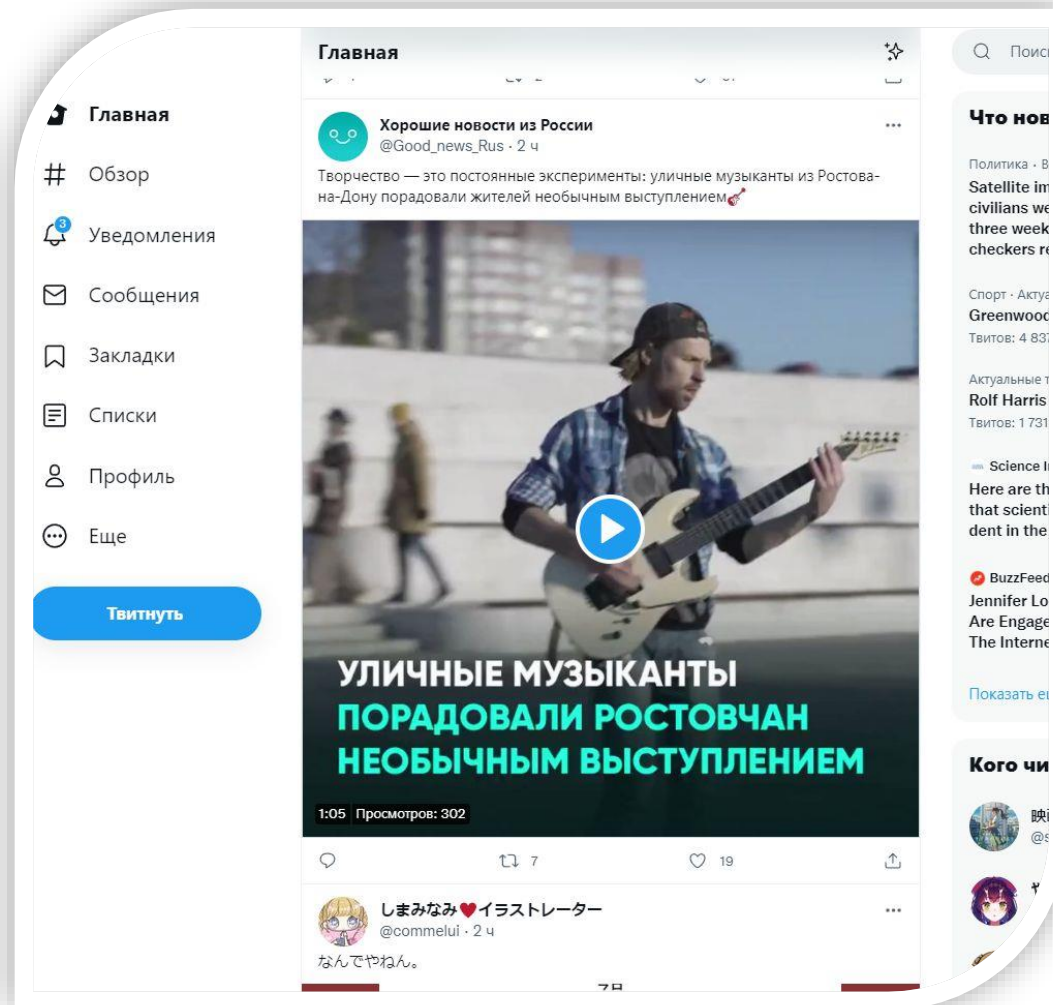
Пример технологического стека компании Twitter.
Администрирование баз данных.



ОПЫТ КОМПАНИИ TWITTER.

Десятилетний опыт построения действительно огромной и комплексной базы данных для удовлетворения нужд огромной аудитории сервиса.

ВЕБ-ПРИЛОЖЕНИЕ (СОЦИАЛЬНАЯ СЕТЬ) TWITTER




ПРАКТИЧЕСКИЕ ЗАДАЧИ, СТОЯВШИЕ ПЕРЕД СПЕЦИАЛИСТАМИ TWITTER



- За годы работы суммарный объем данных, накопленный на серверах (без мультимедиа) – около 500 петабайт (квадриллион байт, google it (с)). Где и как хранить то, что уже есть... а главное – где и как хранить то, новое, что приходит бешеными темпами?
- Обработка оперативной информации – твиты, личные сообщения, должна происходить моментально. Учитывая их количество, это десятки миллионов QPS по всему миру (в СЕКУНДУ, КАРЛ!!)
- Управление системой рекомендаций (что почитать, на кого подписаться...). Социальный граф огромного размера!
- Мультимедиа пользователей (сотни миллиардов картинок, видеороликов) – куда это девать?
- Чем кэшировать метаинформацию (действия пользователей, таймлайны) для моментального доступа клиентских приложений к ней?
- Где хранить финансовую, рекламную и другую информацию строгой отчетности? Потеряется твит или личное сообщение – пользователь будет недоволен, но это не критично? Потеряется оплаченная реклама – это огромный удар по репутации компании!

https://blog.twitter.com/engineering/en_us/topics/infrastructure/2017/the-infrastructure-behind-twitter-scale

СТРУКТУРА ТЕХНОЛОГИЧЕСКОГО СТЕКА TWITTER ДЛЯ ХРАНЕНИЯ ДАННЫХ (ПОСТОЯННО ЭВОЛЮЦИОНИРУЕТ)



1. Кластеры Hadoop для вычислений и HDFS.
2. Кластеры Manhattan для всех хранилищ key-value с малой задержкой.
3. Хранилища Graph для шардированных кластеров MySQL.
4. Кластеры Blobstore для всех крупных объектов (видео, изображения, бинарные файлы...).
5. Кластеры кэширования.
6. Кластеры обмена сообщениями.
7. Реляционные хранилища (MySQL, PostgreSQL и Vertica).

https://blog.twitter.com/engineering/en_us/topics/infrastructure/2017/the-infrastructure-behind-twitter-scale



А ЧТО С ЭКСПЛУАТАЦИЕЙ ГОТОВЫХ БАЗ ДАННЫХ?

Задачи администраторов программного обеспечения баз данных.

ЗАДАЧИ АДМИНИСТРАТОРОВ БАЗ ДАННЫХ



Чтобы все работало.

Постоянная проверка данных.

Мониторинг правильности работы интерфейсов и программного обеспечения.

Автоматизация задач всем доступными способами, чтобы можно было попить кофейку и посмотреть сериальчик, пока хорошо отлаженная система работает (прохладная история про мастера PERL скриптов из комьюнити).



Чтобы все работало максимально хорошо.

Эволюция программного обеспечения.

Эволюция программного кода.

Оптимизация работы компонентов системы хранения данных.



Чтобы никто это не сломал.

Мероприятия, связанные с постоянной защитой данных пользователей (зачастую не приводящие к положительному результату, но все-таки необходимые).



ЛИКБЕЗ НА ТЕМУ ПЕРСПЕКТИВ РАЗВИТИЯ БАЗ ДАННЫХ



СПАСИБО

....



Смирнов Михаил



mikhaelsmirnov@gmail.com



<http://msuniversity.ru>