«Базы данных»

МГУ им. Н.П. Огарева, 2018 год

(18 часов лекций + экзамен)

«Базы данных»

МГУ им. Н.П. Огарева, 2017 год

(18 часов лекций + экзамен)

Андрей Владимирович Попов

доцент кафедры фундаментальной информатики

http://andpop.ru

Лекция 1. Часть 1.

Базы данных: введение

Базы данных: введение

1. Значение и классификация данных.
2. Базы данных как часть технологий работы с данными.

Что такое данные?

Что такое данные?

Дословно: Data (англ. *данные*) = «данность», «факт».

ISO, 1996: Формы представления информации, с которыми имеют дело информационные системы и их пользователи.

ISO, 2015: Поддающееся многократной интерпретации представление информации в формализованном виде, пригодном для передачи, связи, или обработки.

Данные – факты, текст, графики, картинки, звуки, аналоговые или цифровые видео-сегменты, представленные в форме, пригодной для хранения, передачи и обработки.

Для чего нужны данные?

Для чего нужны данные?

Основная задача обработки данных:

- получение из данных **информации**
  - из информации – **знаний**
    - из знаний – **мудрости**

Для чего нужны данные?

Основная задача обработки данных:

- получение из данных **информации**
  - из информации – **знаний**
    - из знаний – **мудрости**

Знание – понимание того, ЧТО мы должны делать в определенный момент времени и КАК это нужно делать.

Мудрость – предвидение возможного развития событий.

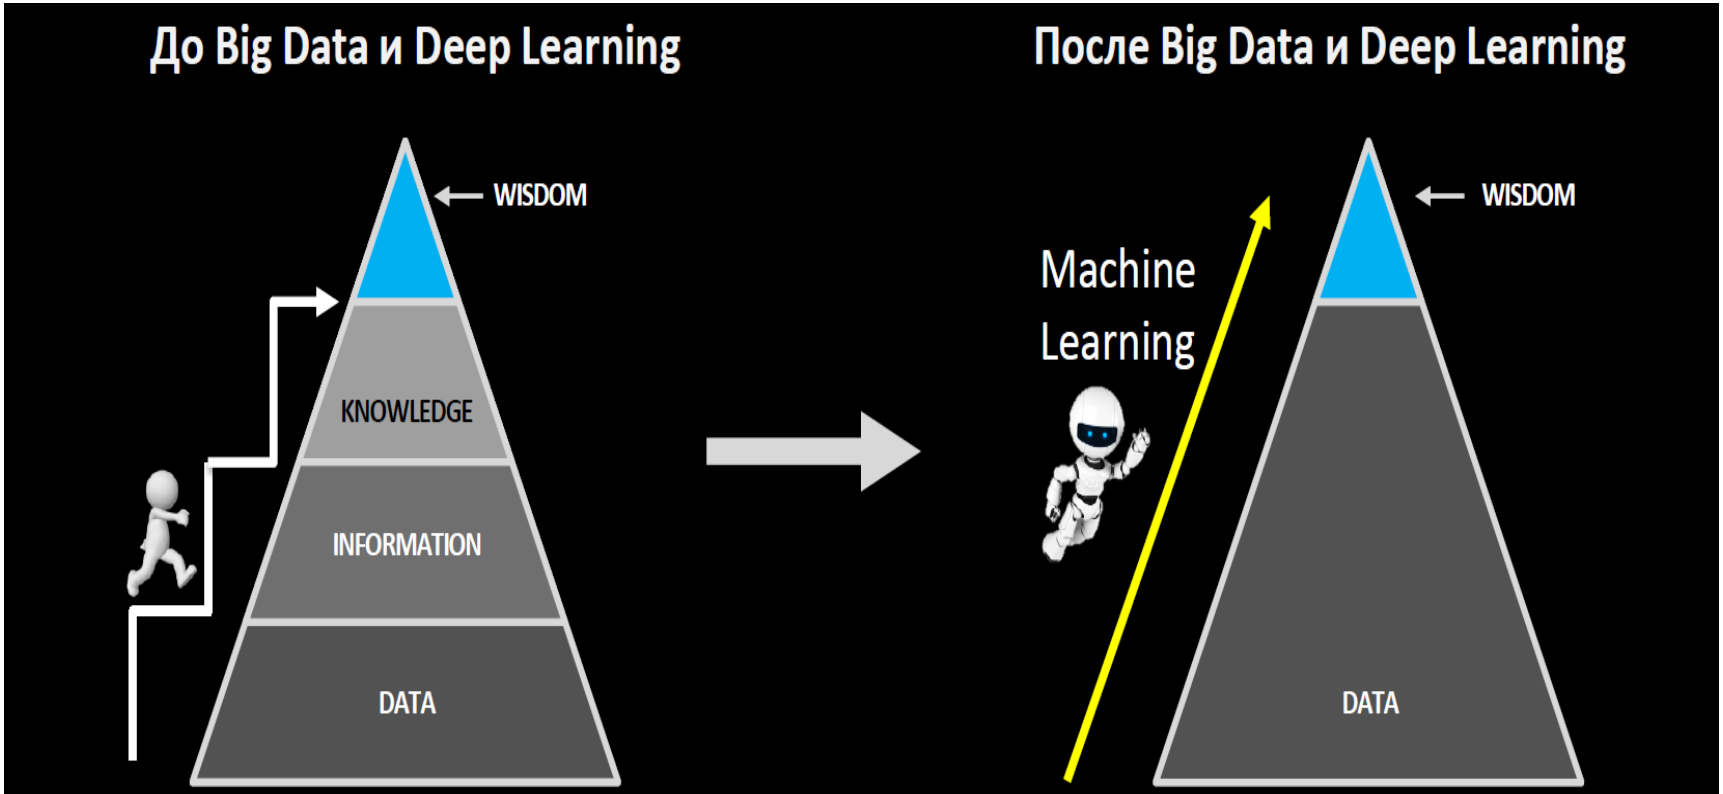

С ростом объёма данных и появлением технологий Big Data, сократился путь от данных к мудрости за счет развития технологий машинного обучения

Где используются данные?

Процессы, использующие данные

Цель – замена человека машиной

- **Механизация** – замена физического труда человека машинным.

Процессы, использующие данные

Цель – замена человека машиной

- **Механизация** – замена физического труда человека машинным.

- **Автоматизация** – замена управленческого труда человека (машина реализует некоторую программу, алгоритм управления).

Процессы, использующие данные

Цель – замена человека машиной

- **Механизация** – замена физического труда человека машинным.
- **Автоматизация** – замена управленческого труда человека (машина реализует некоторую программу, алгоритм управления).
- **Кибернетизация** – замена человека в сфере принятия решений.

Данные и базы данных используются в процессах автоматизации и кибернетизации.

Данные – новая нефть

Данные = сырье для создания ценности.

Разные данные – для разных задач.

Какие задачи решаются с помощью анализа данных?

Задачи, решаемые с помощью анализа данных

Классические

- формирование отчетностей
- учетные системы
- описательная аналитика

Современные

- воспроизведение связей между событиями и результатом (machine learning)
- таргетированные коммуникации
- распознавание образов (лиц)
- классификация

Задачи, решаемые с помощью анализа данных

Классические

- формирование отчетностей
- учетные системы
- описательная аналитика

Современные

- воспроизведение связей между событиями и результатом (machine learning)
- таргетированные коммуникации
- распознавание образов (лиц)
- классификация

Данные – это важнейший актив, так как из них можно автоматически получать знание.

Знания из данных дают модели и аналитика

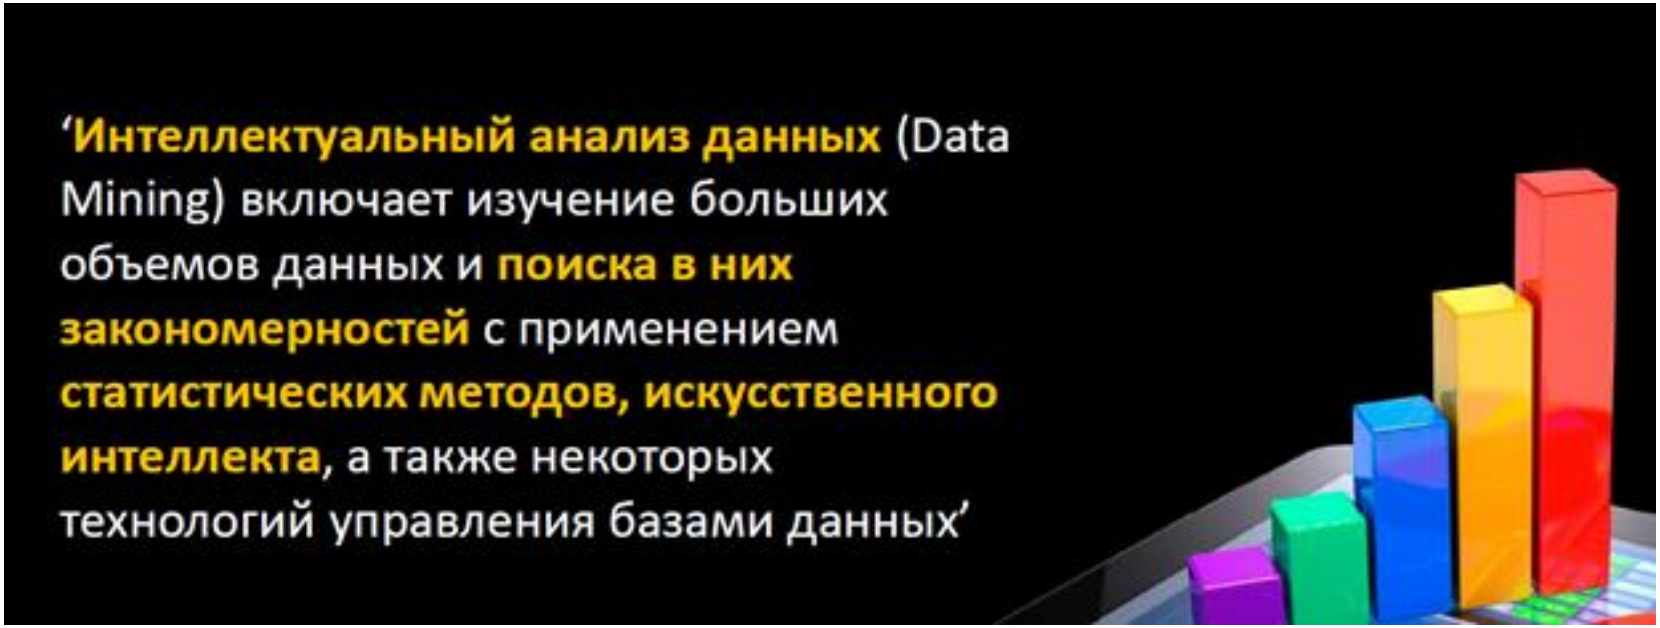

Машинное обучение

Глубинное обучение

Данные без технологий - бесполезны

‘Сегодня углубленная аналитика применяется все чаще. **Рост вычислительных мощностей, улучшенная инфраструктура данных, появление новых алгоритмов создали для этого технические возможности**, а с резким увеличением объемов данных их качественный детальный анализ превратился в средство обеспечения значительных конкурентных преимуществ’

Алан Ньюджент, Марсия Кауфман, Джудит Гурвиц, Ферн Халпер «Просто о больших данных»

Задачи технологий работы с данными

Базы данных и СУБД – часть технологий для работы с данными.

Используются на этапах **загрузки**, **сохранения** и **обработки данных**.

Откуда берутся данные?

Откуда берутся данные?

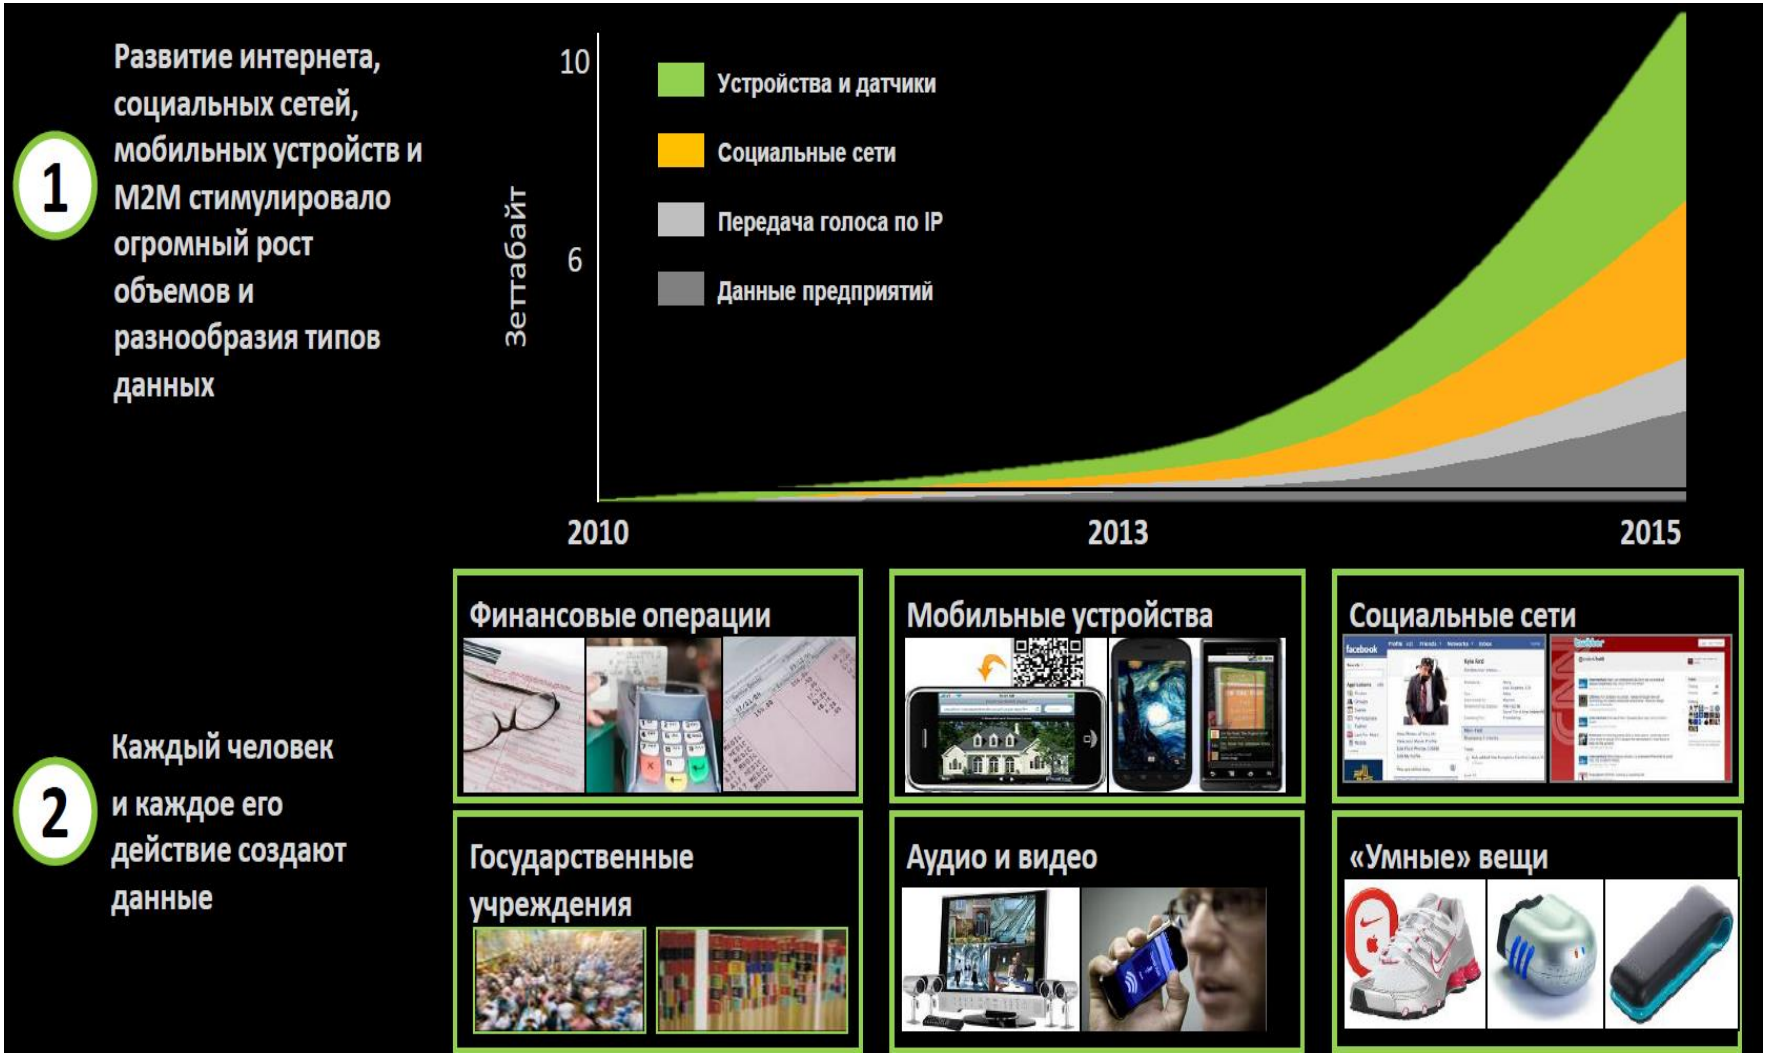

Классификация данных

Тип носителя	Цифровые	Аналоговые	Цифровой или аналоговый носитель данных
Место генерации	Внутренние	Внешние	Данные формируются внутри или вовне организации
Способ генерации	Машина	Человек	Данные создаются машиной или человеком
Объем[1]	Малый	Большой	Гб/Тб. Малые - пригодны к обработке на ПК. Большие требуют решений класса Big Data[1]
Доступность[2]	Низкая	Высокая	Показатель доступности
Качество	Низкое	Высокое	Показатель качества
Структурированность	Низкая	Высокая	Простота классификации данных по атрибутам
Однородность	Низкая	Высокая	Число различных форматов данных
Связность	Низкая	Высокая	Возможность сопоставить данные между собой

...

[1] Малые данные – те, на которых можно анализировать на современном ПК (до 16 Гб) (Том Андерсон, Большие данные – нужны ли они в маркетинговых исследованиях)

[2] Одни и те же данные могут быть доступными для одного пользователя и не доступными для другого

Какое значение имеют базы данных?

Обработка данных: от сырья к результату

Обработка данных: от сырья к результату

Базы данных – это инструменты, средства достижения конечного результата (месторождения, буровые установки, насосы и нефтеочистительные заводы).

Развитие технологий баз данных

Год	Событие	Данные	Анали-тика	Техно-логии
1881	**Первая машина, работающая на перфокартах**		+	+
1928	**Создана магнитная лента**	+		+
1956	**Первые магнитные диски (IBM)**	+		+
1963	**Чарльз Бахман разработал первую СУБД Integrated Data Store**			+
1965	**Первый дата-центр в США**	+		+
1970	**Реляционная модель данных**			+
1976	**Компьютер стал использоваться в повседневных целях**	+		
1991	**Появился Интернет. Анализ и загрузка данных онлайн**	+		+
1997	**Google запустил поисковую систему**			+
2001	**Google создал файловую систему GFS**			+
2005	**Apache создал Hadoop**			+
2005	**Появляются промышленные NoSQL СУБД**			+
2010	**За два дня создается столько данных, сколько люди создали с начала цивилизации до 2003 года**	+		+
2014	**80% директоров компаний заявляют, что анализ Big Data – высший приоритет**		+	