


# Машинное обучение и анализ данных

Воронцов Константин Вячеславович  
(ФИЦ ИУ РАН • МФТИ • Форексис)

Научный семинар ВНИИА • 17 ноября 2016


- Статистический анализ данных (Statistical Data Analysis)
- Искусственный интеллект (Artificial Intelligence) — 1955
- Распознавание образов (Pattern Recognition)
- **Машинное обучение (Machine Learning)** — 1959
- Статистическое обучение (Statistical Learning)
- Интеллектуальный анализ данных (Data Mining) — 1989
- Knowledge Discovery in Databases — 1989
- Бизнес-аналитика (Business Intelligence, Business Analytics)
- Предсказательная аналитика (Predictive Analytics) — 2007
- Большие данные (Big Data) — 2008
- Аналитика больших данных (Big Data Analytics)
- Науки о данных (Data Science) — 2011

# Предпосылки Data Science



<http://www.kdnuggets.com/2015/02/history-data-science-infographic.html>

# Структура смежных областей Data Science



- одна из ключевых технологий будущего
- наиболее успешное направление искусственного интеллекта, часто противопоставляемое инженерии знаний
- симбиоз математической статистики и численных методов оптимизации
- математическое моделирование в условиях, когда данных много, знаний мало
- проведение функции через заданные точки в сложно устроенных пространствах

Восстановление зависимости  $y(x)$  по точкам  $(x_i, y_i)$ ,  $i = 1, \dots, \ell$ .

**Дано:** выборка  $\ell$  объектов  $x_i = (f_1(x_i), \dots, f_n(x_i))$  и ответов  $y_i$ ,  
 $f_j(x)$  — признаки объекта  $x$ ,  $j = 1, \dots, n$

$$\begin{pmatrix} f_1(x_1) & \dots & f_n(x_1) \\ \dots & \dots & \dots \\ f_1(x_\ell) & \dots & f_n(x_\ell) \end{pmatrix} \xrightarrow{y} \begin{pmatrix} y_1 \\ \dots \\ y_\ell \end{pmatrix}$$

**Найти:** функцию  $a(x)$ , способную давать правильные ответы  
на тестовых объектах  $x'_i = (f_1(x'_i), \dots, f_n(x'_i))$ ,  $i = 1, \dots, k$ :

$$\begin{pmatrix} f_1(x'_1) & \dots & f_n(x'_1) \\ \dots & \dots & \dots \\ f_1(x'_k) & \dots & f_n(x'_k) \end{pmatrix} \xrightarrow{a?} \begin{pmatrix} a(x'_1) \\ \dots \\ a(x'_k) \end{pmatrix}$$

- ❶ Обучение с учителем (supervised learning)
  - классификация (classification)
  - регрессия (regression)
  - ранжирование (learning to rank)
  - прогнозирование (forecasting)
- ❷ Обучение без учителя (unsupervised learning)
  - кластеризация (clustering)
  - поиск ассоциативных правил (association rule learning)
  - восстановление плотности (density estimation)
  - одноклассовая классификация (anomaly detection)
- ❸ Частичное обучение (semi-supervised learning)
  - трансдуктивное обучение (transductive learning)
- ❹ Предварительная обработка (data preparation)
  - извлечение признаков (feature extraction)
  - отбор признаков (feature selection)
  - восстановление пропусков (missing values)

- ⑤ Обучение представлений (representation learning)
  - обучение признаков (feature learning)
  - обучение многообразий (manifold learning)
  - анализ главных компонент (principal component analysis)
  - матричные разложения (matrix factorization)
  - колаборативная фильтрация (collaborative filtering)
  - тематическое моделирование (topic modeling)
- ⑥ Обучение выявлению связей (relational learning)
- ⑦ Динамическое обучение (online/incremental learning)
- ⑧ Обучение с подкреплением (reinforcement learning)
- ⑨ Активное обучение (active learning)
- ⑩ Привилегированное обучение (privilege learning)
- ⑪ Обучение с переносом опыта (transfer learning)
- ⑫ Мета-обучение (meta-learning)

## 1 СИМВОЛИЗМ

- Decision Tree, Rule Induction

## 2 коннекционизм

- BackPropagation, Deep Belief Nets, Deep Learning

## 3 эволюционизм

- Genetic Algorithms, Genetic Programming

## 4 байесионизм

- Naive Bayes, Bayesian Networks, Graphical Models

## 5 аналогизм

- kNN, RBF, SVM, Kernel Regression, Kernel Density Estimation

## 6 композиционизм (+)

- Weighted Voting, Boosting, Bagging, Stacking, Random Forest, Яндекс.MatrixNet, xgboost



---

Домингос П. Верховный алгоритм. 2016. 336 с.

- минимизация эмпирического риска  
MVR, Linear Regression, Logistic Regression
- регуляризация эмпирического риска  
SVM, RLR, ElasticNet, LASSO, Least Angle Regression
- метрические методы  
kNN, RBF, Kernel Regression, Kernel Density Estimation
- логические методы и отбор признаков  
DT, DL, DF, Rule Induction, Add, Add-Del, BFS, МГУА, СПА, GA
- байесовские методы  
Naive Bayes, Linear Discriminant, Bayesian Networks
- нейросетевые методы  
BackPropagation, Deep Belief Nets, Deep Learning
- композиционные методы  
Boosting, Bagging, Stacking, Random Forest, Яндекс.MatrixNet


## Данные...

- разнородные (признаки измерены в разных шкалах)
- неполные (измерены не все, имеются пропуски)
- неточные (измерены с погрешностями)
- противоречивые (объекты одинаковые, ответы разные)
- избыточные (сверхбольшие, не помещаются в память)
- недостаточные (объектов меньше, чем признаков)
- неструктурированные (нет признаковых описаний)

## Заказчик...

- не знает точно, чего хочет
- не имеет чётких критериев качества (KPI)
- не заботится о качестве своих данных
- не понимает роль математики и ожидает чуда

CRISP-DM (1999) — межотраслевой стандарт Data Mining



- понимание задачи и данных
- предобработка данных и изобретение признаков
- построение модели
- сведение обучения к оптимизации
- решение проблем оптимизации и переобучения
- оценивание качества решения
- внедрение и эксплуатация

Экосистемы машинного обучения:

- Python + SciPy + SciKit-Learn
- Java + Weka + RapidMiner
- R
- Deductor — аналитическая платформа BaseGroup Labs

Инструменты для хранения и обработки больших данных:

- Hadoop — распределённое хранение данных
- Spark — распределённые вычисления

Инструменты для обучения нейронных сетей:

- TensorFlow
- Theano
- Torch

- Распознавание, классификация, принятие решений ( $y \in \mathbb{N}$ ):
  - $x$  — пациент;  $y$  — диагноз, рекомендуемая терапия;
  - $x$  — заёмщик;  $y$  — вероятность дефолта;
  - $x$  — геологич. объект;  $y$  — наличие полезного ископаемого;
  - $x$  — абонент;  $y$  — вероятность ухода к другому оператору;
  - $x$  — текстовое сообщение;  $y$  — спам / не спам;
  - $x$  — документ;  $y$  — категория в рубрикаторе;
  - $x$  — фрагмент белка;  $y$  — тип вторичной структуры;
  - $x$  — фрагмент ДНК;  $y$  — функция: промотор / ген;
  - $x$  — фотопортрет;  $y$  — идентификатор личности;
- Регрессия и прогнозирование ( $y \in \mathbb{R}$  или  $\mathbb{R}^m$ ):
  - $x$  — история продаж;  $y$  — прогноз объёма продаж;
  - $x$  — пара  $\langle$ клиент, товар $\rangle$ ;  $y$  — рейтинг товара;
  - $x$  — параметры технолого. процесса;  $y$  — свойство продукции;
  - $x$  — структура хим. соединения;  $y$  — его свойство;
  - $x$  — характеристики недвижимости;  $y$  — цена;

**Объект** — пациент в определённый момент времени.

**Классы** — диагноз или способ лечения или исход заболевания.

**Примеры признаков:**

- **бинарные**: пол, головная боль, слабость, тошнота, и т. д.
- **порядковые**: тяжесть состояния, желтушность, и т. д.
- **количественные**: возраст, пульс, артериальное давление, содержание гемоглобина в крови, доза препарата, и т. д.

**Особенности задачи:**

- обычно много «пропусков» в данных;
- как правило, недостаточный объём данных;
- нужен интерпретируемый алгоритм классификации;
- нужна оценка вероятности (болезни | успеха | исхода).

**Объект** — геологический район (рудное поле).

**Классы** — есть или нет полезное ископаемое.

**Примеры признаков:**

- **бинарные:** присутствие крупных зон смятия и рассланцевания, и т. д.
- **порядковые:** минеральное разнообразие; мнения экспертов о наличии полезного ископаемого, и т. д.
- **количественные:** содержания сурьмы, присутствие в рудах антимонита, и т. д.

**Особенности задачи:**

- проблема «малых данных» — для редких типов месторождений объектов много меньше, чем признаков.

## Идентификация по отпечаткам пальцев



## Идентификация по радужной оболочке глаза



## Особенности задач:

- нетривиальная предобработка для извлечения признаков;
- высочайшие требования к точности.

**Объект** — заявка на выдачу банком кредита.

**Классы** — bad или good.

**Примеры признаков:**

- **бинарные**: пол, наличие телефона, и т. д.
- **номинальные**: место проживания, профессия, работодатель, и т. д.
- **порядковые**: образование, должность, и т. д.
- **количественные**: возраст, зарплата, стаж работы, доход семьи, сумма кредита, и т. д.

**Особенности задачи:**

- нужно оценивать вероятность дефолта  $P(\text{bad})$
- и риск всего кредитного портфеля банка

**Объект** — абонент в определённый момент времени.

**Классы** — уйдёт или не уйдёт в следующем месяце.

**Примеры признаков:**

- **бинарные**: корпоративный клиент, включение услуг, и т. д.
- **номинальные**: тарифный план, регион проживания, и т. д.
- **количественные**: длительность разговоров (входящих, исходящих, СМС, и т. д.), частота оплаты, и т. д.

**Особенности задачи:**

- сложно идентифицировать факт ухода;
- нужно оценивать вероятность ухода;
- сверхбольшие выборки;
- не ясно, какие признаки вычислять по «сырым» данным.

**Объект** — текстовый документ.

**Классы** — рубрики иерархического тематического каталога.

**Примеры признаков:**

- **номинальные:** автор, издание, год, и т. д.
- **количественные:** для каждого термина — частота в тексте, в заголовках, в аннотации, и т. д.

**Особенности задачи:**

- лишь небольшая часть документов имеют метки  $y_i$ ;
- документ может относиться к нескольким рубрикам;
- в каждом ребре дерева свой классификатор на 2 класса.

Объект — квартира в Москве.

Примеры признаков:

- **бинарные**: наличие балкона, лифта, мусоропровода, охраны, и т. д.
- **номинальные**: район города, тип дома (кирпичный/панельный/блочный/монолит), и т. д.
- **количественные**: число комнат, жилая площадь, расстояние до центра, до метро, возраст дома, и т. д.

Особенности задачи:

- выборка неоднородна, стоимость меняется со временем;
- разнотипные признаки;
- для линейной модели нужны преобразования признаков.

# Задача прогнозирования объемов продаж


Объект — тройка  $\langle$ товар, магазин, день $\rangle$ .

Примеры признаков:

- бинарные: выходной день, праздник, промоакция, и т. д.
- количественные: объемы продаж в предшествующие дни.

Особенности задачи:

- функция потерь не квадратична и даже не симметрична;
- разреженные данные.



**Объект** — место для открытия нового ресторана.

**Предсказать** — прибыль от ресторана через год.

**Примеры признаков:**

- демографические данные района;
- цены на недвижимость поблизости;
- маркетинговые данные: наличие школ, офисов и т.д.

**Особенности задачи:**

- мало объектов, много признаков;
- разнотипные признаки;
- есть выбросы;
- разнородные объекты (возможно, имеет смысл строить разные модели для мелких и крупных городов).

**Объект** — пара **⟨запрос, документ⟩**.

**Классы** — асессорские оценки релевантности.

**Примеры признаков:**

- **количественные:**

частота слов запроса в документе,

число ссылок на документ,

число кликов на документ: всего, по данному запросу,

- **номинальные:**

ID пользователя, ID региона, язык запроса.

**Особенности задачи:**

- оптимизируется не число ошибок, а качество ранжирования;
- сверхбольшие выборки;
- проблема конструирования признаков по сырым данным.

## 1 Анализ данных жидкостной хроматографии

$$z(t, \lambda) = \sum_i X_i(t) Y_i(\lambda)$$

**дано:**  $z(t, \lambda)$  — выход сканирующего УФ-детектора;

**найти:**  $X_i(t)$  — хроматограмма  $i$ -го вещества,  $t$  — время  
 $Y_i(\lambda)$  — спектр  $i$ -го вещества,  $\lambda$  — длина волны.

## 2 Анализ данных ДНК-микрочипов

$$I(p, k) = \sum_g a_{pg} C_{gk}$$

**дано:**  $I(p, k)$  — интенсивность свечения  $p$ -й пробы на  $k$ -м чипе;

**найти:**  $a_{pg}$  — коэффициент сродства  $p$ -й пробы  $g$ -му гену,

$C_{gk}$  — концентрация  $g$ -го гена на  $k$ -м чипе.

## 3 Рекомендательные системы

$$R_{iu} = \sum_t p_i(t)q_u(t)$$

**дано:**  $R_{iu}$  — рейтинги товаров  $i$ , поставленные пользователем  $u$ ;

**найти:**  $p_i(t)$  — профиль интересов товара  $i$ ;

$q_u(t)$  — профиль интересов пользователя  $u$ .

## 4 Тематическое моделирование текстовых коллекций

$$p(w|d) = \sum_t p(w|t)p(t|d)$$

**дано:**  $p(w|d) = \frac{n_{dw}}{n_d}$  — частоты слов  $w$  в документах  $d$ ;

**найти:**  $\phi_{wt} = p(w|t)$  — распределения слов  $w$  в темах  $t$ ,

$\theta_{td} = p(t|d)$  — распределения тем  $t$  в документах  $d$ .

**дано:**  $p(w|d) = \frac{n_{dw}}{n_d}$  — доля расходов клиента  $d$  по категории  $w$ ;

**найти:**  $\phi_{wt} = p(w|t)$  — распределения категорий  $w$  в темах  $t$ ,

$\theta_{td} = p(t|d)$  — распределения тем  $t$  у клиента  $d$ .

**Объект** — пара **⟨длинный запрос, документ⟩**.

**Предсказать** — тематическую близость документа запросу.

**Примеры приложений:**

- поиск и мониторинг научно-технической информации,
- выявление эпидемий по поисковым логам,
- выявление социальной напряжённости по данным соцсетей.

**Особенности задачи:**

- темы скрыты, их надо сначала выявить;
- лишь небольшая часть документов может быть размечена;
- плохо формализуемые критерии качества;
- необходимость продвинутой визуализации.

**Объект** — пара  $\langle$  клиент, товар  $\rangle$   
(товары — книги, фильмы, музыка).

**Предсказать** — вероятность покупки или рейтинг товара.

**Примеры признаков:**

- **количественные:**

рейтинг схожих товаров для данного клиента;

рейтинг данного товара для схожих клиентов;

оценки интересов клиента;

оценки интересов товара;

**Особенности задачи:**

- сверхбольшие разреженные данные;
- интересы скрыты, их надо сначала выявить.

**Объект** — тройка  $\langle$ пользователь, объявление, баннер $\rangle$ .

**Предсказать** — кликнет ли пользователь по контекстной рекламе, которую показали в ответ на его запрос на avito.ru.

**Сырые данные:**

- все действия пользователя на сайте,
- профиль пользователя (браузер, устройство и т. д.),
- история показов и кликов других пользователей по баннеру,
- ... всего 10 таблиц данных.

**Особенности задачи:**

- признаки надо придумывать;
- данных много — сотни миллионов показов;
- основной критерий качества — доход рекламной площадки;
- несколько дополнительных критериев и ограничений.

- [www.MachineLearning.ru](http://www.MachineLearning.ru) — русскоязычная вики
- [www.kdnuggets.com](http://www.kdnuggets.com) — главный сайт датамайнеров
- [www.datasciencecentral.com](http://www.datasciencecentral.com) — 72 000 датамайнеров
- [www.kaggle.com](http://www.kaggle.com) — конкурсы анализа данных
- [archive.ics.uci.edu/ml](http://archive.ics.uci.edu/ml) — UCI ML Repository (349 datasets)
- [ru.coursera.org/learn/machine-learning](http://ru.coursera.org/learn/machine-learning) — курс Эндрю Ына
- [ru.coursera.org/learn/vvedenie-mashinnoe-obuchenie](http://ru.coursera.org/learn/vvedenie-mashinnoe-obuchenie)  
— курс Воронцова от ВШЭ и ШАД Яндекс
- [ru.coursera.org/specializations/machine-learning-data-analysis](http://ru.coursera.org/specializations/machine-learning-data-analysis)  
— специализация от МФТИ и ШАД Яндекс

- Домингос П. Верховный алгоритм. 2016. 336 с.
- Коэльо Л. П., Ричарт В. Построение систем машинного обучения на языке Python. 2016. 302 с.
- Мерков А. Б. Распознавание образов. Введение в методы статистического обучения. 2011. 256 с.
- Мерков А. Б. Распознавание образов. Построение и обучение вероятностных моделей. 2014. 238 с.
- Машинное обучение (курс лекций, К. В. Воронцов). [www.MachineLearning.ru](http://www.MachineLearning.ru). 2004–2016.
- Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning. Springer, 2014. 739 p.
- Bishop C. M. Pattern Recognition and Machine Learning. - Springer, 2006. 738 p.