

# **Введение**

Не точные определения, для понимания.

- **Искусственный Интеллект (ИИ) Artificial Intellect (AI)** - область науки и технологии, целью которой является создание "умных машин", а так же "умных программ".
- **Большие данные Big data** - методы и подходы для работы с большими массивами данных, которые не поддаются обработке на одной машине.
- **Data science (наука о данных)** - анализ обработка и представление данных.
- **Машинное обучение machine learning** - подраздел ИИ, целью которого является создание алгоритмов, которые способны "обучаться".
- **Искусственные нейронные сети Artificial Neural Networks** - класс алгоритмов машинного обучения.
- **Глубокое обучение deep learning** - раздел машинного обучения изучающий нейронные сети.
- **Классическое машинное обучение, классические алгоритмы машинного обучения, "классика"** - машинное обучение без нейронных сетей.

## **Как работает машинное обучение**

Программу (алгоритм) пишет не человек. Человек выбирает модель и подает модели данные, после чего модель обучается и выдает алгоритм.

Связанные области из математики:

- Математическая статистика
- Методы оптимизации
- Линейная алгебра

Типы машинного обучения:

1. Обучение с учителем
2. Обучение без учителя
3. Обучение с подкреплением
4. ...

## **Обучение с учителем** supervised learning

*Пусть:*

- Генеральная совокупность -  $\hat{X}$ . Все объекты в мире (может быть бесконечным).
- Все возможные ответы -  $\hat{Y}$ .

*У нас есть:*

- $\overline{X}$  - подвыбока реальных объектов. Пусть размер выборки (кол-во объектов в ней):  $N$ .
- $\overline{Y}$  - ответы на нашей выборке. Для каждого элемента из  $\overline{X}$  есть соответствующий элемент  $\overline{Y}$ .

Мы хотим разработать алгоритм, вычисляющий ответ для заданного объекта.

Представим это в виде некоторой функции:

$$f : \hat{X} \rightarrow \hat{Y}$$

## **Обучение без учителя unsupervised learning**

У нас нет ответов.

Наша цель найти некую внутренние взаимосвязи между существующими объектами (инсайды).

## **Признаковое описание объекта**

С объектами из реального мира сложно работать без математического описания.  
Для этого описания мы используем признаки.

Мы можем измерить характеристику  $j$ -ю характеристику любого объекта из генеральной совокупности:

$$f_j(\hat{X}_i) = x_{ij}, \text{ где } \hat{X}_j \in \hat{X}$$

Измерив  $M$  характеристик объектов из нашего набора данных  $\overline{X}$  мы получим матрицу  $X$ :

$$\begin{bmatrix} f_1(X_1) & f_2(X_1) & f_3(X_1) & \dots & f_M(X_1) \\ f_1(X_2) & f_2(X_2) & f_3(X_2) & \dots & f_M(X_2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ f_1(X_N) & f_2(X_N) & f_3(X_N) & \dots & f_M(X_N) \end{bmatrix}$$

$$\begin{bmatrix} x_{11} & x_{12} & x_{13} & \dots & x_{1M} \\ x_{21} & x_{22} & x_{23} & \dots & x_{2M} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & x_{N3} & \dots & x_{NM} \end{bmatrix}$$

$X$  называется матрицей признаков. Договоримся, что как только у нас есть выборка объектов, то у нас есть и матрица признаков и будем считать. Будем их считать синонимами:

выборка объектов = матрица признаков  
Об объектах мы будем думать как об их признаковом описании.

**Типы признаков**  $f_j : \hat{X}_i \rightarrow D_j$ :

- $|D_i| = \{0, 1\}$  - бинарный признак (пол: мужской/женский)
- $|D_i| < \inf$  - категориальный признак (погода: пасмурно, солнечно, ветренно)
- $|D_i| < \inf$  - категориальный признак и при этом есть отношение порядка над  $D_i$ , то это порядковый признак (воинские звания, уровень образования)
- $|D_i| = \mathbb{R}$  - прочие числовые признаки(рост, уровень давления)

## **Типы задач (ответов) в обучении с учителем**

### **Классификация**

$$|Y| < \inf$$

- $|Y| = \{+1, -1\}$  – бинарная классификация
- $|Y| = \{1, \dots, K\}$  – классификация на  $K$ , причем каждый объект относится к какому-то одному классу
- $|Y| = \{0, 1\}^K$  – классификация на  $K$ , причем каждый объект относится к нескольким классам (тегирование)

### **Регрессия**

$$|Y| = \mathbb{R}^m \text{ где } m \geq 1$$

Если  $Y$ - бесконечное упорядченное множество. Такой тип задач называется ранжированием и может относиться как к обучению с учителем, так и к обучению без учителя.

## **Основные типы задач в обучении без учителя**

Кластеризация - объект делится на непересекающиеся множества, которые называются кластерами. объекты из одного ласса должны "быть похожи" друг на друга, и отличаться от другого кластера.

Нахождение ассоциативных правил - нахождение признаков, которые идут как правило, вместе (пример: составление потребительской корзины).

Заполнение пропущенных данных – значения для каких то признаков и даже объектов могут быть пропущены, нам надо их как нибудь заполнить.

Сокращение размерности - исходные данные представлены в виде признаковой матрицы и число признаков может быть большим. Задача: представить эти данные в пространстве меньшей размерности, возможно с потерей информации.

**Строгие определения. Обобщающая способность, качество обобщения.**

## Определения

Модель - параметрическое множество функций

$$\mathbb{A} = \{g(x, \theta) \mid \theta \in \Theta\} \text{ where } g : \hat{X} * \Theta \rightarrow \hat{Y}$$

Метод обучения - отображение вида:

$$\mu : (\hat{X} * \hat{Y})^l \rightarrow \mathbb{A}$$

$(\hat{X} * \hat{Y})^l = (x_i, y_i)_{i=1}^l$  - выборка размера  $l$ , sample

$\alpha \in \mathbb{A}$  - алгоритм

В обучении с учителем две фазы:

1. Обучение(Train) - способ обучения  $\mu$  по объектам  $(\hat{X} * \hat{Y})^l$  строит алгоритм  
 $\alpha = \mu((\hat{X} * \hat{Y})^l)$
2. Тестирование(Test) - алгоритм  $\alpha$  для (новых) объектов  $x \in \hat{X}$   
предсказывает ответ(ы)  $\alpha(x)$

Функция потерь, (loss function):

$L(\alpha, x)$  - мера ошибки алгоритма  $\alpha \in \mathbb{A}$  на объекте  $x \in \hat{X}$ .

**Определение** функция  $y$  по  $x \in X$  возвращает ответ для  $x$  из  $Y$ .

например для классификации:

$L(\alpha, x) = [\alpha(x) \neq y(x)]$  где  $[True] = 1$  и  $[False] = 0$

Для регрессии:

$L = |\alpha(x) - y(x)|$  - абсолютная ошибка.

$L = (\alpha(x) - y(x))^2$  - квадратичная ошибка.

Эмпирический риск(empirical risk(ER)) - функционал качества алгоритма на выборке:

$$Q(\alpha, \hat{X}^l) = \frac{1}{l} \sum_{i=1}^l L(\alpha, x_i)$$

$Q(\alpha, \hat{X}^l) \rightarrow \min$  - чем меньше, тем лучше

Минимизация эмпирического риска - метод обучения

$$\mu(\hat{X}) = \operatorname{argmin}_{\alpha \in \mathbb{A}} Q(\alpha, \hat{X}^l)$$

У нас есть:  $X, Y$  - объекты и ответы на них.

Мы выбираем:  $\mathbb{A}(\Theta)$

Найти:  $\alpha' = \mu(X)$

$$\mu(X) = \min_{\alpha \in \mathbb{A}} Q(\alpha, X) =$$

$$\min_{\theta \in \Theta} Q(\mathbb{A}(\theta), X) =$$

$$\min_{\theta \in \Theta} Q(g(x, \theta), X) =$$

$$\min_{\theta \in \Theta} \frac{1}{l} \sum_{i=1}^l L(g(x, \theta), x_i)$$



Например, для метода наименьших квадратов, МНК (ordinary least squares, OLS):

$$\min_{\theta \in \Theta} \frac{1}{l} \sum_{i=1}^l (g(x, \theta) - y_i)^2$$

В результате, для задач машинного обучения мы получаем минимизационную задачу

## **Обобщающая способность, качество обучения**

Мы нашли "закон природы" или просто настроились на какой-то частный случай, подогнали  $g(x, \theta)$  под заданные параметры? Будет ли полученный алгоритм аппроксимировать желаемую функцию на всей генеральной совокупности? Хорошо ли алгоритм будет работать на новых данных? Не переобучились (overfit) ли мы?

Пусть  $\hat{X}^l$  - обучающая выборка,  $\hat{X}^k$  - тестовая выборка. Если

$$Q(\mu(\hat{X}^l), \hat{X}^k) \gg Q(\mu(\hat{X}^l), \hat{X}^l)$$

значит алгоритм переобучен.

## **Как избежать переобучения?**

Проверяем на отложенной выборке (hold-out):

$$HO(\mu, X_{train}, X_{test}) = Q(\mu(X_{train}), X_{test}) \rightarrow \min$$

Перекрестная проверка (cross-validation):

$$CV(\mu, X^{l+k}) = \frac{1}{|n|} \sum_{i \in n} Q(\mu(X_i^l), X_i^k)$$

Теоретическая оценка эмпирического риска:

$$E [ Q(\mu(X_i^l), X_i^k) ] \rightarrow \min$$

$E$  - мат ожидание.

**Почему** мы можем переобучиться?

- большая сложность пространства параметров  $\Theta$
- Переобучение будет всегда если мы оптимизируем параметры не для генеральной совокупности.

Что делать? Избавиться совсем нельзя, можно минимизировать.

- минимизировать одну из теоретических оценок
- накладывать ограничения на  $\theta$  (регуляризация)
- минимизировать НО или CV

## **Особенности некоторых задач**

- Требуется интерпретируемость алгоритма
- Требуется предсказывать вероятность ошибки
- "Большой" размер объектов
- Пропуски в данных
- "Сырые данные", сложности в выборке и построении признаков
- Данные могут быть устаревшими
- Не размеченные и плохо размеченные данные
- Малое количество обучающих примеров
- Типы информации различны: текст + звук + видео
- Нужен высокопроизводительный алгоритм
- Разные функции потерь
- ...

## **Примеры задач**

## **Задача кредитного скоринга**

Выдать или нет кредит по заявке.

Объект: клиент (его заявка на выдачу кредита)

Возможные признаки: пол, возраст, место проживания, профессия, зарплата, стаж работы, сумма кредита, образование, наличие в собственности квартиры, машины, семейное положение.

### **Задача категоризации новостей**

Разбить новостные статьи по категориям (возможна иерархия)

Объект: Статья (текст)

Возможные признаки: издание, автор, частота в тексте(заголовке) того или иного признака.

### **Задача ранжирования поисковой выдачи (вычитка научных статей)**

Выдать последовательность сайтов по запросу. Подходит не подходит документ под запрос, и в какой по порядку.

Объект: пара запрос, документ (веб страница)

Возможные признаки: частота слов запроса в документе, число ссылок на документ, число кликов на документ (просмотров) вообще и по данному запросу.

## **Задача прогнозируемости стоимости квартиры**

Определить стоимость квартиры в конкретный момент.

Объект: квартира

Возможные признаки: район города, число комнат, жилая площадь, общая площадь, высота потолков, расстояние до центра, до метро, этаж, наличие балкона, лифта, мусоропровода, возраст дома, тип постройки (кирпич, панель, монолит...)

## **Задачи компьютерного зрения, на фото видео спецоборудовании**

- Распознавание объекта
- Детектирование объекта
- Определения свойств объекта
- ...

## **На основе звука**

- Те же что и в задачах компьютерного зрения
- Распознавание слов, цифр, текстов, команд
- ...

## **Задачи медицины и биологии**

- Медицинское диагностирование
- Исследования на уровне генома
- ...

## **Игры**

- GO
- На бирже
- ...

## **Задачи продавцов, магазинов**

- Кластеризация покупателей для эффективных рекламных акций.
- Предсказание оттока клиентов.
- Прогнозирование объемов продаж.
- Контекстная реклама
- ...

## **Хранение больших объемов информации**

- поиск наиболее информативных, или интересных признаков
- ...

**Линейная регрессия как пример модели алгоритма. Градиентный спуск и аналитическое решение.**

Линейная регрессия - это модель алгоритмов которая выглядит как:

$$\mathbb{A} = \{g(x, \theta) \mid \theta \in \Theta\}$$

где  $g(x, \theta) = \theta_0 + \theta_1 * x_1 + \theta_2 * x_2 + \dots + \theta_l * x_l$  и

$$\theta = [\theta_0, \theta_1, \theta_2, \dots, \theta_l]$$

Дано:

$$X * \theta = Y_{predict}$$

Функция потерь  $L = (\alpha(x) - y(x))^2$  - квадратичная ошибка.

Минимизация эмперического риска -> методу наименьших квадратов

$$Q \rightarrow min_{\theta}$$

$$\sum(\alpha(x) - y(x))^2 \rightarrow min_{\theta}$$

$$(Y_{predict} - Y)^T * (Y_{predict} - Y) \rightarrow min_{\theta}$$

$$(X * \theta - Y)^T * (X * \theta - Y) \rightarrow min_{\theta}$$

**Аналитическое решение**

$$(X^T * X) * \theta = X^T * Y \Rightarrow \theta = (X^T * X)^{-1} * X^T * Y$$

$(X^T * X)^{-1} * X^T$  - псевдообратная матрица

Аналитическое решение сложное по вычислениям.

Поэтому используем **градиентный спуск**

итеративный метод:

$$\theta_k^{(j+1)} := \theta_k^{(j)} - \gamma * \frac{\partial}{\partial \theta_k^{(j)}} Q$$

Для МНК:

$$Q = \frac{1}{2l} \sum_{i=1}^l ((\alpha(x_i) - y_i)^2)$$
$$\frac{\partial}{\partial_k \theta} Q = \frac{1}{l} \sum_{i=1}^l ((\alpha(x_i) - y_i) * x_{ik})$$

повторяем пока не сойдется:


$$\theta_k^{(j+1)} := \theta_k^{(j)} - \gamma * \frac{1}{l} * \sum_{i=1}^l ((\alpha(x_i) - y_i) * x_{ik})$$

в матричной форме:



$$\theta^{(j+1)} := \theta^{(j)} - \gamma * \frac{1}{l} * (X^T * (X * \theta^{(j)} - Y))$$

## **Особенности градиентного спуска**


**normalize features**



## choosing learning rate



**several minimus**



## **градиентный спуск**

- подобрать параметры
  - learning rate
  - максимальное число итераций
  - условие сходимости
  - стартовые параметры (сетка)
- легко реализуем
- хорошо работает на больших выборках
- нет уверенности в том что выдал minimum функции

Подходит для большинства моделей.

Используется (с некоторыми усовершенствованиями) в том числе нейронных сетях.

## **Резюме**

- Основные понятия машинного обучения: Обучение с учителем, без учителя, объект, ответ, признак, алгоритм, модель алгоритмов, метод обучения, эмпирический риск, переобучение, кластеризация, классификация, восстановление регрессии, ранжирование.

Этапы решения задач машинного обучения:

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

Градиентный спуск.