

# Введение: AI и байесовский вывод

Сергей Николенко

Академический Университет, весна 2011

# Outline

- 1 Искусственный интеллект и машинное обучение**
  - Краткая история AI
  - Что использует AI
  - Машинное обучение: суть
- 2 Вспоминаем теорию вероятностей**
  - Понятие вероятности, прямые и обратные задачи
  - Вывод скрытых параметров
  - Сравнение моделей
- 3 Гипотезы максимального правдоподобия**
  - Определение
  - Поиск скрытых параметров в гауссианах
  - Важные распределения

## Первые мысли об искусственном интеллекте

- Гефест создавал себе роботов–андроидов, например, гигантского человекоподобного робота Талоса.
- Пигмалион оживлял Галатею.
- Иегова и Аллах — куски глины.
- Особо мудрые раввины могли создавать големов.
- Альберт Великий изготовил искусственную говорящую голову (чем очень расстроил Фому Аквинского).
- Начиная с доктора Франкенштейна, дальше AI в литературе появляется постоянно...

# Тест Тьюринга

- AI как наука начался с *теста Тьюринга* (1950).
- Компьютер должен успешно выдать себя за человека в (письменном) диалоге между судьёй, человеком и компьютером.
- Правда, исходная формулировка была несколько тоньше и интереснее...

# Тест Тьюринга

- Здесь уже очевидно, сколько всего надо, чтобы сделать AI:
  - обработка естественного языка;
  - представление знаний;
  - выводы из полученных знаний;
  - обучение на опыте (собственно machine learning).

## Дартмутский семинар

- Термин AI и формулировки основных задач появились в 1956 на семинаре в Дартмуте.
- Его организовали Джон Маккарти (John McCarthy), Марвин Мински (Marvin Minsky), Клод Шеннон (Claude Shannon) и Натаниэль Рочестер (Nathaniel Rochester).
- Это была, наверное, самая амбициозная грантозаявка в истории информатики.

## Дартмутский семинар

*Мы предлагаем исследование искусственного интеллекта сроком в 2 месяца с участием 10 человек летом 1956 года в Дартмутском колледже, Гановер, Нью-Гемпшир. Исследование основано на предположении, что всякий аспект обучения или любое другое свойство интеллекта может в принципе быть столь точно описано, что машина сможет его симулировать. Мы попытаемся понять, как обучить машины использовать естественные языки, формировать абстракции и концепции, решать задачи, сейчас подвластные только людям, и улучшать самих себя. Мы считаем, что существенное продвижение в одной или более из этих проблем вполне возможно, если специально подобранная группа учёных будет работать над этим в течение лета.*

## 1956-1960: большие надежды

- Оптимистическое время. Казалось, что ещё немного, ещё чуть-чуть...
- Allen Newell, Herbert Simon: *Logic Theorist*.
  - Программа для логического вывода.
  - Смогла передоказать большую часть *Principia Mathematica*, кое-где даже изящнее, чем сами Рассел с Уайтхедом.

## 1956-1960: большие надежды

- Оптимистическое время. Казалось, что ещё немного, ещё чуть-чуть...
- General Problem Solver – программа, которая пыталась думать как человек;
- Много программ, которые умели делать некоторые ограниченные вещи (microworlds):
  - Analogy (IQ-тесты на «выберите лишнее»);
  - Student (алгебраические словесные задачи);
  - Blocks World (переставляла 3D-блоки).

## 1970-е: knowledge-based systems

- Суть: накопить достаточно большой набор правил и знаний о предметной области, затем делать выводы.
- Первый успех: MYCIN – диагностика инфекций крови:
  - около 450 правил;
  - результаты как у опытного врача и существенно лучше, чем у начинающих врачей.

## 1980-е: коммерческие применения; индустрия AI

- Началось внедрение.
- Первый AI-отдел был в компании DEC (Digital Equipment Corporation);
- К 1986 году он сэкономил DEC \$10 млн. в год;
- Бум закончился к концу 80-х, когда многие компании не смогли оправдать завышенных ожиданий.

## 1990-2010: data mining, machine learning

- В последние десятилетия основной акцент сместился на машинное обучение и поиск закономерностей в данных.
- Особенно — с развитием интернета.
- Сейчас про AI в смысле трёх законов робототехники уже не очень вспоминают.
- // Но роботика — процветает и пользуется machine learning на каждом шагу.

# AI как междисциплинарный проект

- Искусственный интеллект использует огромное количество методов из самых разных наук.
  - 1 Математика.
  - 2 Биология.
  - 3 Экономика.
  - 4 Философия.
  - 5 Психология.
  - 6 Лингвистика.
  - 7 ...

## Определение

- Что значит — обучающаяся машина? Как определить «обучаемость»?

## Определение

- Что значит — обучающаяся машина? Как определить «обучаемость»?

### Определение

*Компьютерная программа обучается по мере накопления опыта относительно некоторого класса задач  $T$  и целевой функции  $P$ , если качество решения этих задач (относительно  $P$ ) улучшается с получением нового опыта.*

- Определение очень (слишком?) общее.
- Какие конкретные примеры можно привести?


## Самообучающиеся агенты

- В чём отличие самообучающегося от обычного интеллектуального агента?
- Обычный агент реагирует на информацию извне, а самообучающийся — не просто реагирует, а со временем реагирует всё лучше и лучше.

## Самообучающиеся агенты

- Интеллектуальные агенты действуют в условиях неполной информации.
- Предсказать исход невозможно, но нужно научиться действовать оптимальным образом.
- Если бы можно было предсказать, обучение было бы не нужно, только вычислительные мощности.

## Схема самообучающегося агента



## Чем мы будем заниматься

- Мы, конечно, не будем разрабатывать готовых агентов.
- Мы будем рассматривать разные алгоритмы, которые решают ту ли иную задачу, причём решают тем лучше, чем больше начальных (тестовых) данных ему дадут.
- Сейчас мы перейдём к общей теории байесовского вывода, в которую обычно можно погрузить любой алгоритм машинного обучения.

# Outline

- 1 Искусственный интеллект и машинное обучение
  - Краткая история AI
  - Что использует AI
  - Машинное обучение: суть
- 2 Вспоминаем теорию вероятностей
  - Понятие вероятности, прямые и обратные задачи
  - Вывод скрытых параметров
  - Сравнение моделей
- 3 Гипотезы максимального правдоподобия
  - Определение
  - Поиск скрытых параметров в гауссианах
  - Важные распределения

# Вероятностное пространство

## Definition

*Вероятностное пространство* — это тройка  $(\Omega, \mathcal{F}, p)$ , где

- $\Omega$  — множество, элементы которого называются элементарными событиями, исходами или точками;
- $\mathcal{F}$  — сигма-алгебра подмножеств  $\Omega$ , называемых (случайными) событиями;
- $P$  — вероятностная мера или вероятность, т.е. такая  $\sigma$ -аддитивная конечная мера, что  $p(\Omega) = 1$ .

## Definition

*Случайная величина*  $X : \Omega \rightarrow \mathbb{R}$  индуцирует *распределение случайной величины*  $X$  на борелевских  $P^X(B) = P(X \in B)$ .

## Операции над вероятностями

- Совместная вероятность  $p(x, y)$ ,  $x \in \Omega_X$ ,  $y \in \Omega_Y$  определяется на прямом произведении  $\Omega_X \times \Omega_Y$ .
- Маргинализация из совместной вероятности:

$$p(x = a) = \sum_{y \in \Omega_Y} p(x = a, y).$$

- Условная вероятность:

$$p(x = a | y = b) = \frac{p(x = a, y = b)}{p(y = b)}, \text{ если } p(y = b) \neq 0.$$

## Об условных вероятностях

- В жизни на самом деле все вероятности условные.
- Всегда есть какие-то предположения, без которых, вообще говоря, и понятие «вероятность» будет не очень-то определено.
- Например, когда мы говорим «вероятность орла на честной монетке равна  $\frac{1}{2}$ », это вероятность в предположении, что монетка честная.
- В нашем курсе вероятности тоже будут обычно условными.

## Общие правила

- Правило произведения:

$$p(x, y|H) = p(x|y, H)p(y|H) = p(y|x, H)p(x|H).$$

- Правило суммирования:

$$p(x|H) = \sum_y p(x, y|H) = \sum_y p(x|y, H)p(y|H).$$

- Теорема Байеса:

$$p(y|x, H) = \frac{p(x|y, H)p(y|H)}{p(x|H)} = \frac{p(x|y, H)p(y|H)}{\sum_{y'} p(x|y', H)p(y'|H)}.$$

- *Независимость* определим просто: две случайные переменные  $X$  и  $Y$  независимы, если

$$p(x, y) = p(x)p(y).$$

## О болезнях и вероятностях

- Приведём классический пример из классической области применения статистики — медицины.
- Пусть некий тест на какую-нибудь болезнь имеет вероятность успеха 95% (т.е. 5% — вероятность как позитивной, так и негативной ошибки).
- Всего болезнь имеется у 1% респондентов (отложим на время то, что они разного возраста и профессий).
- Пусть некий человек получил позитивный результат теста (тест говорит, что он болен). С какой вероятностью он действительно болен?

## О болезнях и вероятностях

- Приведём классический пример из классической области применения статистики — медицины.
- Пусть некий тест на какую-нибудь болезнь имеет вероятность успеха 95% (т.е. 5% — вероятность как позитивной, так и негативной ошибки).
- Всего болезнь имеется у 1% респондентов (отложим на время то, что они разного возраста и профессий).
- Пусть некий человек получил позитивный результат теста (тест говорит, что он болен). С какой вероятностью он действительно болен?
- Ответ: 16%.

## Доказательство

- Обозначим через  $t$  результат теста, через  $d$  — наличие болезни.
- $p(d = 1) = p(d = 1|t = 1)p(t = 1) + p(d = 1|t = 0)p(t = 0)$ .
- Используем теорему Байеса:

$$\begin{aligned} p(d = 1|t = 1) &= \\ &= \frac{p(t = 1|d = 1)p(t = 1)}{p(d = 1|t = 1)p(t = 1) + p(d = 1|t = 0)p(t = 0)} = \\ &= \frac{0.95 \times 0.01}{0.95 \times 0.01 + 0.05 \times 0.99} = 0.16. \end{aligned}$$

## Вывод

- Вот такие задачи составляют суть вероятностного вывода (probabilistic inference).
- Поскольку они обычно основаны на теореме Байеса, вывод часто называют байесовским (Bayesian inference).
- Но не только поэтому.

## Вероятность как частота

- Обычно в классической теории вероятностей, происходящей из физики, вероятность понимается как предел отношения количества определённого результата эксперимента к общему количеству экспериментов.
- Стандартный пример: бросание монетки.

## Вероятность как степень доверия

- Мы можем рассуждать о том, «насколько вероятно» то, что
  - Дмитрий Медведев будет избран на второй срок;
  - «Одиссею» написала женщина;
  - Керенский бежал за границу в женском платье;
  - ...
- Но о «стремящемся к бесконечности количестве экспериментов» говорить бессмысленно — эксперимент здесь ровно один.

## Вероятность как степень доверия

- Здесь вероятности уже выступают как *степени доверия* (degrees of belief). Это байесовский подход к вероятностям (Томас Байес так понимал).
- К счастью, и те, и другие вероятности подчиняются одним и тем же законам, а если не подчиняются — значит, не вероятности и были.

## Прямые и обратные задачи

- Прямая задача: в урне лежат 10 шаров, из них 3 чёрных. Какова вероятность выбрать чёрный шар?
- Или: в урне лежат 10 шаров с номерами от 1 до 10. Какова вероятность того, что номера трёх последовательно выбранных шаров дадут в сумме 12?
- Обратная задача: перед нами две урны, в каждой по 10 шаров, но в одной 3 чёрных, а в другой — 6. Кто-то взял из какой-то урны шар, и он оказался чёрным. Насколько вероятно, что он брал шар из первой урны?
- Заметьте, что в обратной задаче вероятности сразу стали байесовскими (хоть здесь и можно переформулировать через частоты).

## Прямые и обратные задачи

- Иначе говоря, прямые задачи теории вероятностей описывают некий вероятностный процесс или модель и просят подсчитать ту или иную вероятность (т.е. фактически по модели предсказать поведение).
- Обратные задачи содержат *скрытые переменные* (в примере — номер урны, из которой брали шар). Они часто просят по известному поведению построить вероятностную модель.
- Задачи машинного обучения обычно являются задачами второй категории.

## Определения

- Запишем теорему Байеса:

$$p(x|y, H) = \frac{p(x)p(y|x, H)}{p(y|H)}.$$

- Здесь  $p(x)$  — *априорная вероятность* (prior probability),  $p(y|x, H)$  — *правдоподобие* (likelihood),  $p(x|y)$  — *апостериорная вероятность* (aposterior probability),  $p(y|H)$  — *вероятность данных* (evidence).
- Вообще, *функция правдоподобия* имеет вид

$$a \mapsto p(y|x = a)$$

для некоторой случайной величины  $y$ .

## Постановка задачи

- Простая задача вывода: дана нечестная монетка, она подброшена  $N$  раз, имеется последовательность результатов падения монетки. Надо определить её «нечестность» и предсказать, чем она выпадет в следующий раз.

## Первые замечания

- Если у нас есть вероятность  $p_h$  того, что монетка выпадет решкой (вероятность орла  $p_t = 1 - p_h$ ), то вероятность того, что выпадет последовательность  $s$ , которая содержит  $n_h$  решек и  $n_t$  орлов, равна

$$p(s|p_h, H_1) = p_h^{n_h} (1 - p_h)^{n_t}.$$

- Сделаем предположение: будем считать, что монетка выпадает равномерно, т.е. у нас нет априорного знания  $p_h$ .
- Теперь нужно использовать теорему Байеса и вычислить скрытые параметры.

## Применение теоремы Байеса

- $p(p_h|s, H_1) = \frac{p(s|p_h, H_1)p(p_h|H_1)}{p(s|H_1)}$ .
- Здесь  $p(p_h)$  следует понимать как непрерывную случайную величину, сосредоточенную на интервале  $[0, 1]$ , коей она и является. Наше предположение о равномерном распределении в данном случае значит, что априорная вероятность  $p(p_h|H) = 1, p_h \in [0, 1]$  (т.е. априори мы не знаем, насколько нечестна монетка, и предполагаем это равновероятным). А  $p(s|p_h, H_1)$  мы уже знаем.
- Итого получается:

$$p(p_h|s, H_1) = \frac{p_h^{n_h}(1 - p_h)^{n_t}}{p(s|H_1)}.$$

## Применение теоремы Байеса

- Итого получается:

$$p(p_h|s, H_1) = \frac{p_h^{n_h}(1 - p_h)^{n_t}}{p(s|H_1)}.$$

- Осталось подсчитать  $p(s|H_1)$ ; её нужно маргинализовать из функции правдоподобия:

$$\begin{aligned} p(s|H_1) &= \int_0^1 p_h^{n_h}(1 - p_h)^{n_t} dp_h = \\ &= \frac{\Gamma(n_h + 1)\Gamma(n_t + 1)}{\Gamma(n_h + n_t + 2)} = \frac{n_h!n_t!}{(n_h + n_t + 1)!}. \end{aligned}$$

## А теперь предскажем следующий исход

- Чтобы предсказать следующий исход, нужно вычислить  $p(\text{heads}|s)$ :

$$\begin{aligned} p(\text{heads}|s) &= \int_0^1 p(\text{heads}|p_h) p(p_h|s, H_1) dp_h = \\ &= \int_0^1 \frac{p_h^{n_h+1} (1-p_h)^{n_t}}{p(s)} dp_h = \\ &= \frac{(n_h+1)! n_t!}{(n_h+n_t+2)!} \cdot \frac{(n_h+n_t+1)!}{n_h! n_t!} = \frac{n_h+1}{n_h+n_t+2}. \end{aligned}$$

- Это называется *правилом Лапласа*.

## Постановка задачи

- Мы использовали предположение  $H_1$  о равномерном априорном распределении  $p_h$ .
- Это было нашей моделью ситуации.
- Можно использовать другие модели; например, можно априори предположить, что монетка падает решкой с вероятностью  $1/3$ , т.е.  $p_h = 1/3$ . Обозначим через  $H_0$
- Как сравнить, какая из моделей  $H_i$  лучше описывает данные?

## Теорема Байеса

- Снова теорема Байеса:

$$p(H_1|s) = \frac{p(s|H_1)p(H_1)}{p(s)}, \quad p(H_0|s) = \frac{p(s|H_0)p(H_0)}{p(s)}.$$

- Нужно как-то оценить априорные вероятности  $p(H_0)$  и  $p(H_1)$ ; можно просто положить их равными  $1/2$ .
- Теперь можно составить отношение:

$$\frac{p(H_1|s)}{p(H_0|s)} = \frac{p(s|H_1)p(H_1)}{p(s|H_0)p(H_0)} = \frac{n_h!n_t!}{(n_h + n_t + 1)!} \cdot \frac{1}{(1/3)^{n_h}(2/3)^{n_t}}.$$

- Это отношение можно использовать для сравнения моделей.

# Outline

- 1 Искусственный интеллект и машинное обучение
  - Краткая история AI
  - Что использует AI
  - Машинное обучение: суть
- 2 Вспоминаем теорию вероятностей
  - Понятие вероятности, прямые и обратные задачи
  - Вывод скрытых параметров
  - Сравнение моделей
- 3 Гипотезы максимального правдоподобия
  - Определение
  - Поиск скрытых параметров в гауссианах
  - Важные распределения

## Суть

- Мы наконец-то подходим к тому, что мы будем делать всё время на протяжении нашего курса.
- Мы сейчас определим цель, которую пытается достичь любой алгоритм машинного обучения.
- Некоторые её достигают, некоторые только приближаются — но в любом случае это «золотой стандарт».

## Определения

### Definition

*Гипотеза максимального правдоподобия* (maximum likelihood hypothesis) — это набор параметров  $\theta$ , который максимизирует функцию правдоподобия

$$p(D|\theta, H),$$

где  $D$  — имеющаяся информация (тестовые примеры).

- Гипотеза максимального правдоподобия — гипотеза, которая лучше всего описывает имеющиеся данные  $D$  в текущих предположениях  $H$ .

## Зачем это нужно

- Гипотезы получают численные оценки, которые можно сравнивать; не просто «соответствует данным», а «лучше/хуже соответствует».
- Каждый наблюдаемый случай может увеличить или уменьшить вероятность гипотезы (а не просто отвергнуть или не отвергнуть её).
- Можно использовать гипотезы с вероятностными утверждениями.
- Новые случаи можно классифицировать, объединяя несколько гипотез.
- Рассуждения достаточно строгие, много можно доказать математически.

## Поиск скрытых параметров

- Очень многие задачи машинного обучения можно представить как *поиск скрытых параметров*.
- Есть некоторое предположение о структуре задачи, т.е. о виде распределений, которыми набрасываются тестовые данные.
- Требуется найти наиболее правдоподобные неизвестные параметры этих распределений.

# Гауссиан

- Начнём с нормального (гауссовского) распределения. У него два параметра:

$$p(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

- Функция правдоподобия данных  $x_1, \dots, x_n$ :

$$p(x_1, \dots, x_n | \mu, \sigma) = \frac{1}{(\sigma\sqrt{2\pi})^n} e^{-\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}}.$$

## Гауссиан: достаточные статистики

- Заметим, что функция эта зависит от двух параметров, а не от  $n$ :

$$p(x_1, \dots, x_n | \mu, \sigma) = \frac{1}{(\sigma\sqrt{2\pi})^n} e^{-\frac{S+n(\bar{x}-\mu)^2}{2\sigma^2}},$$

где

$$\bar{x} = \frac{x_1 + \dots + x_n}{n}, \quad S = \sum_{i=1}^n (\bar{x} - x_n)^2.$$

- Параметры  $\bar{x}$  и  $S$  называются *достаточными статистиками* (sufficient statistics).

## Гауссиан: ГМП

- Какие параметры лучше всего описывают данные?
- Перейдём, как водится, к логарифму:

$$\ln p(x_1, \dots, x_n | \mu, \sigma) = -n \ln(\sigma \sqrt{2\pi}) - \frac{S + n(\bar{x} - \mu)^2}{2\sigma^2}.$$

- Как выяснить, при каких параметрах функция правдоподобия максимизируется?

## Гауссиан: ГМП

- Какие параметры лучше всего описывают данные?
- Перейдём, как водится, к логарифму:

$$\ln p(x_1, \dots, x_n | \mu, \sigma) = -n \ln(\sigma \sqrt{2\pi}) - \frac{S + n(\bar{x} - \mu)^2}{2\sigma^2}.$$

- Как выяснить, при каких параметрах функция правдоподобия максимизируется?
- Взять частные производные и приравнять нулю.

## Гауссиан: ГМП

- По  $\mu$ :

$$\frac{\partial \ln p}{\partial \mu} = -\frac{n}{\sigma^2}(\mu - \bar{x}).$$

- То есть в гипотезе максимального правдоподобия  $\mu = \bar{x}$ , независимо от  $S$ .
- Теперь нужно найти  $\sigma$  из гипотезы максимального правдоподобия.
- Для этого мы продифференцируем по  $\ln \sigma$  — полезный приём на будущее. Кстати,  $\frac{dx^n}{d(\ln x)} = nx^n$ .

## Гауссиан: ГМП



$$\frac{\partial \ln p}{\partial \ln \sigma} = -n + \frac{\sum_{i=1}^n (x_i - \mu)}{\sigma^2}.$$

- Следовательно, в гипотезе максимального правдоподобия

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)}{n}}.$$

**Упражнение.** Оценить ошибку в полученных нами значениях (найти доверительные интервалы).

## Несколько гауссианов

- Теперь то же самое для нескольких гауссианов сразу.
- Даны несколько точек  $x_1, \dots, x_n$ , но они принадлежат смеси гауссианов с разными  $\mu_k$  (пусть  $\sigma$  будет одна и та же).
- Тогда распределение будет

$$p(x_1, \dots, x_n | \{\mu_k\}, \sigma) = \prod_{i=1}^n p(x_i | \{\mu_k\}, \sigma).$$

## Домашнее задание

**Упражнение.** Разработать алгоритм, который итеративно максимизировал бы функцию правдоподобия при данных тестовых примерах, т.е. находил бы  $\mu_k$ . За основу можно взять метод итераций Ньютона, который для максимизации функции  $f(x)$  итерирует её как

$$x \leftarrow x - \frac{f(x)}{\partial f / \partial x}.$$

- Что должно получиться?

## Что должно получиться

- Что значит «найти скрытые параметры смеси гауссианов»?
- Это значит — найти центры, вокруг которых чаще всего будут появляться точки, а также дисперсии (читай — диаметр областей, в которых более-менее вероятно обнаружить точки вокруг этих центров).
- Это в точности задача *кластеризации!*
- Когда вы сделаете упражнение, у вас должен получиться фактически вариант алгоритма  $k$ -средних для сферических кластеров.
- Но о кластеризации мы потом ещё будем говорить гораздо подробнее.

## Важные распределения


- Есть некоторое количество распределений, которые часто появляются в разных задачах и являются наиболее полезными на практике.
- Их полезно... ну, если не знать, то хотя бы быть знакомыми.
- Сейчас по ним и пробежимся.

## Биномиальное распределение

- *Биномиальное распределение* возникает, когда мы подбрасываем нечестную монетку (вероятность решки  $p$ )  $n$  раз и хотим найти вероятность появления  $r$  решек.

$$p(r|p, n) = \binom{n}{r} p^r (1-p)^{n-r}.$$

# Биномиальное распределение



## Пуассоново распределение


- *Распределение Пуассона* возникает, когда мы хотим подсчитать количество событий за фиксированный интервал, если нам дана средняя интенсивность этих событий.
- Если ожидается в среднем  $\lambda$  событий за этот интервал, то вероятность того, что произойдут ровно  $r$  событий, равна

$$p(r|\lambda) = e^{-\lambda} \frac{\lambda^r}{r!}.$$

- Распределение Пуассона – это предельный случай биномиального распределения. Если  $n$  очень велико, а  $p$  очень мало,  $\text{Binomial}(n, p)$  будет очень похоже на  $\text{Poisson}(np)$ .

**Упражнение.** Проверьте это.

# Пуассоново распределение




# Нормальное распределение

- Мы уже давно знаем нормальное распределение:

$$p(x|\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

- Очень многие процессы могут моделироваться нормальным (гауссовским) распределением; обычно возникает, когда есть некое среднее значение  $\mu$  и шум вокруг него.

# Нормальное распределение



## Распределение Стьюдента

- Распределение Стьюдента применяется, когда нужно искать доверительные интервалы на параметры нормального распределения.
- Величина  $T = \frac{\bar{x}_n - \mu}{S_n / \sqrt{n}}$  распределена по закону

$$f(t) = \frac{\Gamma(n/2)}{\sqrt{\pi(n-1)}\Gamma(\frac{n-1}{2})} \left(1 + \frac{t^2}{n-1}\right)^{-n/2}.$$

- Если мы выберем число  $A$  так, чтобы  $p(-A < T < A) = 1 - \alpha$ , то

$$\left[ \bar{x}_n - A \frac{S_n}{\sqrt{n}}, \bar{x}_n + A \frac{S_n}{\sqrt{n}} \right]$$

будет доверительным интервалом для  $\mu$  с вероятностью ошибки  $\alpha$ .

## Экспоненциальное распределение


- Обычно возникает в ответах на вопрос «сколько надо ждать события».
- Дискретный вариант: вероятность того, что выпадения орла на нечестной монетке придётся ждать ровно  $r$  шагов, равна

$$p(r|p) = p^r (1 - p) = (1 - p)e^{-\lambda r}, \text{ где } \lambda = \ln \frac{1}{p}.$$

- Непрерывный вариант: если мы ждём события, которое происходит в среднем каждые  $1/\lambda$  единиц времени (в пуассоновском процессе с интенсивностью  $\lambda$ ), то распределение времени ожидания

$$p(x|\lambda) = \lambda e^{-\lambda x}.$$

## Экспоненциальное распределение




## Гамма-распределение

- Может возникать как сумма нескольких экспоненциальных распределений.
- Плотность распределения

$$p(x|k, \theta) = x^{k-1} \frac{e^{-x/\theta}}{\theta^k \Gamma(k)}, \quad x > 0.$$

# Гамма-распределение




## Бета-распределение

- Бета-распределение определяется над вероятностями, т.е. на интервале  $[0, 1]$ .
- Может служить априорным распределением для каких-либо вероятностей; является апостериорным распределением для испытаний Бернулли после

$$\text{Beta}(x|\alpha, \beta) = \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1}, \quad B(\alpha, \beta) = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha + \beta)}.$$

- $\text{Beta}(i, j)$  — это распределение  $i$ -й по величине случайной величины из  $i + j - 1$  случайных величин, распределённых равномерно на  $[0, 1]$ .

# Бета-распределение



## Порядковые статистики

- Бета-распределение — частный случай *порядковой статистики* (order statistics).
- Если  $n$  случайных величин  $X_1, \dots, X_n$  распределены одинаково с функцией распределения  $F$ , то  $k$ -я порядковая статистика  $Y_k^{(n)}(y)$  — это функция распределения  $k$ -й сверху величины из этих  $n$  величин.
- Например, очевидно, что

$$Y_1^{(n)}(y) = F(y)^{n-1}.$$

**Упражнение.** Вывести формулу для второй порядковой статистики  $Y_2^{(n)}$ .

## Распределение Дирихле

- Обобщение бета-распределения на многомерный случай.
- На  $k$ -мерном симплексе  $\{x \mid \sum_{i=1}^k x_i = 1\}$  плотность распределения Дирихле с параметром  $\alpha = (\alpha_1, \dots, \alpha_k)$  равна

$$p(x|\alpha) = \frac{1}{B(\alpha)} \prod_{i=1}^k x_i^{\alpha_i-1}, \quad B(\alpha) = \frac{\prod_{i=1}^k \Gamma(\alpha_i)}{\Gamma\left(\sum_{i=1}^k \alpha_i\right)}.$$

Thank you!

**Спасибо за внимание!**