

# Заметки к курсу „Теория информации“. Лекции 1-6

А. Смаль

9 февраля 2020 г.

## **Аннотация**

Курс посвящён изучению подходов к определению понятия „количество информации“. Последовательность изложения материала данного курса основана на классической статье Колмогорова „Три подхода к определению понятия количества информации“ (1965).

В курсе будет рассмотрено три подхода к определению „количества информации“: комбинаторный (информация по Хартли), вероятностный (энтропия Шеннона) и алгоритмический (Колмогоровская сложность). Кроме этого мы поговорим про различные применения аппарата теории информации в различных областях компьютерных наук: в криптографии, в коммуникационной сложности, в теории кодирования, в теории конечных автоматов, в теории сложности вычислений и некоторых других.

## Содержание

<b>1. Комбинаторный подход</b>	<b>3</b>
1.1. Информация по Хартли . . . . .	3
1.2. Применение: игра в 10 вопросов . . . . .	4
1.3. Цена информации . . . . .	4
<b>2. Вероятностный подход</b>	<b>5</b>
2.1. Энтропия Шэннона . . . . .	5
2.2. Взаимная информация . . . . .	9
<b>3. Кодирование</b>	<b>10</b>
3.1. Однозначно декодируемые коды . . . . .	10
3.2. Код Шеннона-Фано . . . . .	12
3.3. Код Хаффмана . . . . .	13
3.4. Арифметическое кодирование . . . . .	13
3.5. Блочные коды с ошибками . . . . .	14
<b>4. Свойства распределений</b>	<b>16</b>
4.1. Энтропийные профили . . . . .	16
4.2. Неравенства о тройках . . . . .	22
4.3. Условное неравенство о четвёрке . . . . .	24

# 1. Комбинаторный подход

## 1.1. Информация по Хартли

Пусть задано некоторое конечное множество  $A$  — *множество исходов*.

**Определение 1.1** (1928). Определим *количество информации в  $A$*  как  $\chi(A) = \log_2 |A|$  (мы будем измерять количество информации в битах, поэтому все логарифмы будут по основанию 2, для измерения в байтах нужно выбрать основание 256).

Если про некоторый  $x \in A$  стало известно, что  $x \in B$ , то теперь для идентификации  $x$  нам достаточно  $\chi(A \cap B) = \log |A \cap B|$  битов, т.е. нам сообщили  $\chi(A) - \chi(A \cap B)$  битов информации.

*Пример 1.1.* Предположим, что мы хотим узнать некоторое неизвестное упорядочение множества  $\{a_1, a_2, \dots, a_5\}$ . Нам стало известно, что  $a_1 > a_2$  или  $a_3 > a_4$ . Сколько битов информации мы узнали? Множество  $A$  состоит из 5! перестановок, множество  $B$  — из перестановок, которые удовлетворяют новому условию. Легко проверить, что  $|B| = 90$ . Итого мы узнали  $\log 120 - \log 90 = \log(4/3)$  битов.

Пусть  $A \subset \{0, 1\}^* \times \{0, 1\}^*$ . Обозначим через  $\pi_1(A)$  и  $\pi_2(A)$  проекции множества  $A$  на первую и вторую координату соответственно, а  $\chi_1(A) = \log |\pi_1(A)|$  и  $\chi_2(A) = \log |\pi_2(A)|$  — количество информации в них по Хартли.

**Теорема 1.1.**  $\chi(A) \leq \chi_1(A) + \chi_2(A)$ .

**Определение 1.2.** Количество информации в второй координате  $A \subset \{0, 1\}^* \times \{0, 1\}^*$  при известной первой

$$\chi_{2|1} = \log \left( \max_{a \in \pi_1(A)} |\{x \mid (a, x) \in A\}| \right).$$

**Теорема 1.2.**  $\chi(A) \leq \chi_1(A) + \chi_{2|1}(A)$ .

**Теорема 1.3.** Для  $A \subset \{0, 1\}^* \times \{0, 1\}^* \times \{0, 1\}^*$

$$2 \cdot \chi(A) \leq \chi_{12}(A) + \chi_{13}(A) + \chi_{23}(A).$$

**Следствие 1.1.** Квадрат объёма трёхмерного тела не превосходит произведение площадей его проекций на координатные плоскости.

**Утверждение 1.1.** Если  $f : X \rightarrow Y$

1. является сюръекцией, то  $\chi(Y) \leq \chi(X)$ ,
2. является инъекцией, то  $\chi(X) \leq \chi(Y)$ .

## 1.2. Применение: игра в 10 вопросов

Сколько вопросов на ДА/НЕТ нужно задать, чтобы определить загаданное число от 1 до  $N$ , если (а) можно задавать вопросы адаптивно; (б) вопросы нужно написать на бумажке заранее.

Оценка  $\lceil \log N \rceil$  достигается в обоих случаях, если задавать вопросы про биты двоичного представления загаданного числа.

Докажем нижнюю оценку. Пусть  $A = [N]$ . Множество  $Q = \{(q_1, q_2, \dots, q_k)\}$  — множество протоколов (ответы на вопросы). Можно рассматривать  $A$  и  $Q$  как проекции некоторого множества исходов игры  $S$  на разные координаты. Тогда верны следующие неравенства:

- $\chi_Q(S) = \chi(Q) \leq \chi_1(Q) + \chi_2(Q) + \dots + \chi_k(Q) \leq k$ ,
- $\chi_A(S) = \chi(A) \leq \chi(S) \leq \chi_Q(S) + \chi_{A|Q}(S) \leq k + 0 = k$ .

Таким образом получаем, что  $\log N = \chi(A) \leq k$ .

## 1.3. Цена информации

Пусть загадано некоторое целое число от 1 до  $n$  (где  $n \geq 2$ ). Разрешается задавать любые вопросы с ответами ДА/НЕТ. При ответе ДА мы заплатим 1 рубль, а при ответе НЕТ — два рубля. Сколько необходимо и достаточно заплатить для отгадывания числа?

**Верхняя оценка.** Будем задавать вопросы так, чтобы отрицательные ответы приносили в два раза больше информации, чем положительные. Тогда за каждый бит информации мы заплатим некоторое константное количество рублей  $c$ . Пусть все вопросы будут вида „ $x \in T$ ?“. Потребуем, чтобы

$$2 \cdot (\log |X| - \log |X \cap T|) = \log |X| - \log |X \cap \bar{T}|.$$

Пусть  $|X \cap T| = \alpha |X|$ , тогда  $|X \cap \bar{T}| = (1 - \alpha) |X|$ , таким образом получается уравнение

$$2 \log(1/\alpha) = \log(1/(1 - \alpha)),$$

эквивалентное квадратному уравнению

$$\alpha^2 = 1 - \alpha.$$

Из двух корней нас интересует тот, что меньше 1, т.е.  $\alpha = (\sqrt{5} - 1)/2$ . Следовательно при любом ответе мы заплатим  $c = 1/(-\log \alpha) \approx 1.44$  рублей за бит, а в целом —  $c \log n$  рублей.

В этой оценке мы полностью проигнорировали вопросы округления. Действительно, у нас никогда получится разделить множество из  $n$  элементов на два в отношении

$\alpha : (1 - \alpha)$ , т.к.  $\alpha$  — иррациональное. Поэтому на каждом вопросе будет накапливаться некоторая ошибка округления. Давайте вместо вопросов принадлежности некоторому подмножеству  $T$  множества  $X$  будем задавать вопрос о принадлежности отрезку с вещественными координатами. Начнём с отрезок  $S = [1, n]$  и будем каждый раз уменьшать его в  $1/\alpha$  раз, т.е. первым вопросом спросим, принадлежит ли  $x$  отрезку  $S' = [1, 1 + \alpha(n - 1)]$ . Длина отрезка  $S'$  в  $1/\alpha$  раз меньше длины отрезка  $S$ . Продолжим действовать так же до тех пор, пока длина отрезка не станет меньше 1 — в этом случае  $x$  определено однозначно. После каждого вопроса длина отрезка уменьшается максимум в  $1/(1 - \alpha) = 1/\alpha^2$ , поэтому длина последнего отрезка не меньше  $\alpha^2$ . Таким образом длина отрезка сократится не более, чем в  $(n - 1)/\alpha^2$  раз. Поскольку мы каждый раз выбирали отрезки так, чтобы платить  $c$  рублей за уменьшение  $\log |S|$  на 1, то в сумме заплатим не более

$$c \log((n - 1)/\alpha^2) = c \log(n - 1) - 2c \log \alpha = c \log(n - 1) + 2.$$

При любом исходе мы заплатим целое число рублей, поэтому эту оценку можно уточнить до  $\lceil c \log(n - 1) \rceil + 2$ .

**Нижняя оценка.** Применим рассуждение про злонамеренного противника (adversary argument). Пусть противник выбирает ответ ДА/НЕТ в зависимости от того, какое из двух значений  $1/(\log |X| - \log |X \cap T|)$  и  $2/(\log |X| - \log |X \cap \bar{T}|)$  больше. При любых  $X$ ,  $T$  одно из этих значений не меньше  $c = 1/(-\log \alpha)$ . Таким образом мы заставляем алгоритм платить не менее  $c$  рублей за бит, а значит любой алгоритм в худшем случае заплатит  $\lceil c \log n \rceil$  рублей.

## 2. Вероятностный подход

### 2.1. Энтропия Шэннона

Энтропия Шэннона определяет количество информации  $H(\alpha)$  в распределении вероятностей для некоторой случайной величины  $\alpha$ . Пусть  $\alpha$  принимает значения из множества  $\{a_1, a_2, \dots, a_k\}$  с вероятностями  $\{p_1, p_2, \dots, p_k\}$ ,  $p_i \geq 0$ ,  $\sum_i p_i = 1$ .

Нам бы хотелось, чтобы это определение согласовывалось с определением Хартли, т.е. имеют место следующие „граничные условия“:

- если  $p_1 = \dots = p_k$ , то  $H(\alpha) = \log k$ ,
- если  $p_1 = 1, p_2 = \dots = p_k = 0$ , то  $H(\alpha) = 0$ .

Будем искать  $H(\alpha)$  в виде математического ожидания информации, которую мы получаем от каждого исхода.

$$H(\alpha) = \sum_i p_i \cdot (\text{информация в } a_i).$$

Как оценить, сколько информации в исходе  $a_i$ ? Пусть  $U$  — всё пространство элементарных исходов, все исходы которого равновероятны. Тогда событию  $\alpha = a_i$  соответствует множеству элементарных исходов меры  $p_i$ . Соответственно, если случилось событие  $\alpha = a_i$ , то размер множества согласованных с этим событием исходов уменьшается с  $|U|$  до  $p_i|U|$ , т.е. событие  $\alpha = a_i$  сообщает нам  $\log |U| - \log(p_i|U|) = \log \frac{1}{p_i}$  битов информации. Пусть теперь элементарные исходы не равновероятны. В этом случае событие  $\alpha = a_i$  сообщает нам информацию, которая уменьшает меру множества возможных исходов в  $1/p_i$  раз, т.е. опять получаем  $\log 1 - \log p_i = \log \frac{1}{p_i}$ . Это приводит нас к следующему определению.

**Определение 2.1** (1948). Энтропия Шеннона случайной величины  $\alpha$

$$H(\alpha) = \sum_{i=1}^k p_i \cdot \log \frac{1}{p_i}.$$

(По непрерывности доопределим  $0 \cdot \log \frac{1}{0} = 0$ .)

Можно вывести это соотношение из определения информации по Хартли другим способом. Пусть  $W_n$  — это множество всех слов длины  $n$  состоящих из букв  $\{a_1, a_2, \dots, a_k\}$ , где каждая буква  $a_i$  встречается ровно  $n_i = p_i \cdot n$  раз (будем считать, что вероятности  $p_i$  рациональны, и что множество  $W_n$  определено только тогда, когда все  $n_i$  целые). Информация по Хартли в  $W_n$

$$\chi(W_n) = \log |W_n| = \log \frac{n!}{n_1! n_2! \dots n_k!}.$$

Это выражение можно оценить при помощи формулы Стирлинга.

$$\begin{aligned} \chi(W_n) &= \log \frac{\text{poly}(n) \cdot (n/e)^n}{\text{poly}(n) \cdot (n_1/e)^{n_1} \cdot (n_2/e)^{n_2} \dots (n_k/e)^{n_k}} = \\ &= \log \left( \left( \frac{n}{n_1} \right)^{n_1} \cdot \left( \frac{n}{n_2} \right)^{n_2} \dots \left( \frac{n}{n_k} \right)^{n_k} \right) + O(\log n) = \\ &= \log \left( \left( \frac{1}{p_1} \right)^{p_1 \cdot n} \cdot \left( \frac{1}{p_2} \right)^{p_2 \cdot n} \dots \left( \frac{1}{p_k} \right)^{p_k \cdot n} \right) + O(\log n) = \\ &= n \cdot \sum_{i=1}^k p_i \cdot \log \frac{1}{p_i} + O(\log n). \end{aligned}$$

В среднем на один символ приходится  $\chi(W_n)/n$  битов информации. В пределе получаем

$$\lim_{n \rightarrow \infty} \frac{\chi(W_n)}{n} = \sum_{i=1}^k p_i \cdot \log \frac{1}{p_i} = H(\alpha)$$

(предел нужно брать по бесконечной подпоследовательности натуральных чисел  $n$  таких, для которых все  $\{n_i\}$  — целые).

**Лемма 2.1.** Для энтропии Шеннона выполняются следующие соотношения.

- $H(\alpha) \geq 0$ , причём  $H(\alpha) = 0 \iff$  распределение  $\alpha$  вырождено.
- $H(\alpha) \leq \log k$ , причём  $H(\alpha) = \log k \iff$  величина  $\alpha$  распределена равномерно.

Для доказательства нам потребуется следующая теорема.

**Теорема 2.1** (Неравенство Йенсена). Пусть функция  $f(x)$  является вогнутой на некотором промежутке  $\mathcal{X}$  и числа  $q_1, q_2, \dots, q_n > 0$  таковы, что  $q_1 + \dots + q_n = 1$ . Тогда для любых  $x_1, x_2, \dots, x_n$  из промежутка  $\mathcal{X}$  выполняется неравенство:

$$\sum_{i=1}^n q_i f(x_i) \leq f\left(\sum_{i=1}^n q_i x_i\right).$$

*Доказательство леммы 2.1.* Первое свойство следует напрямую из определения: каждый член суммы  $H(\alpha)$  неотрицателен и равен нулю только в случае, если  $p_i = 0$  или  $p_i = 1$ .

Для доказательства второго неравенства перенесём всё в левую часть и применим неравенство Йенсена:

$$H(\alpha) - \log k = \sum_{i=1}^k p_k \cdot \log \frac{1}{p_i} - \sum_{i=1}^k p_i \cdot \log k = \sum_{i=1}^k p_k \cdot \log \frac{1}{p_i k} \leq \log \left( \sum_{i=1}^k p_i \frac{1}{p_i k} \right) = \log 1 = 0.$$

□

Энтропию совместного распределения пары случайных величин  $\alpha$  и  $\beta$  будем обозначать  $H(\alpha, \beta)$ .

**Лемма 2.2.** Выполняются следующие свойства:

- $H(\alpha, \beta) \leq H(\alpha) + H(\beta)$ , причём равенство достигается тогда и только тогда, когда случайные величины независимы;
- $H(\alpha) \leq H(\alpha, \beta)$ , причём равенство достигается тогда и только тогда, когда  $\beta$  полностью определяется значением  $\alpha$ , т.е.  $\beta = f(\alpha)$ .

*Доказательство.* Введём обозначения для вероятностей событий совместного распределения вероятностей  $(\alpha, \beta)$ . Пусть пара  $(a_i, b_j)$  имеет вероятность  $p_{i,j}$ , событие  $[\alpha = a_i]$  имеет вероятность  $p_{i,*} = p_{i,1} + \dots + p_{i,n}$ , а событие  $[\beta = b_j]$  — вероятность  $p_{*,j} = p_{1,j} + \dots + p_{k,j}$ . В этих обозначениях неравенство  $H(\alpha, \beta) \leq H(\alpha) + H(\beta)$  переписывается как

$$\sum_{i,j} p_{i,j} \cdot \log \frac{1}{p_{i,j}} \leq \sum_i \sum_j p_{i,j} \cdot \log \frac{1}{p_{i,*}} + \sum_j \sum_i p_{i,j} \cdot \log \frac{1}{p_{*,j}}.$$

Перенесём всё в левую часть и применим неравенство Йенсена.

$$\begin{aligned} \sum_{i,j} p_{i,j} \cdot \log \frac{p_{i,*} \cdot p_{*,j}}{p_{i,j}} &\leq \log \left( \sum_{i,j} p_{i,j} \cdot \frac{p_{i,*} \cdot p_{*,j}}{p_{i,j}} \right) = \log \left( \sum_{i,j} p_{i,*} \cdot p_{*,j} \right) = \\ &= \log \left( \underbrace{\left( \sum_i p_{i,*} \right)}_1 \cdot \underbrace{\left( \sum_j p_{*,j} \right)}_1 \right) = 0. \end{aligned}$$

Равенство в неравенстве Йенсена для  $f(x) = \log(x)$  достигается только, если все точки равны, т.е. для любых  $i, j$   $\frac{p_{i,*} p_{*,j}}{p_{i,j}} = c$  для некоторой константы  $c$ . Несложно заметить, что  $c = 1$ , т.к. выполняется следующее равенство  $\sum_{i,j} p_{i,*} p_{*,j} = c \sum_{i,j} p_{i,j}$  в котором обе суммы равны 1. Таким образом в случае равенства  $\alpha$  и  $\beta$  независимы.

Доказательство второго свойства мы получим как следствие из свойств условной энтропии.  $\square$

**Определение 2.2.** Энтропия  $\alpha$  при условии  $\beta = b_j$

$$H(\alpha \mid \beta = b_j) = \sum_i \Pr[\alpha = a_i \mid \beta = b_j] \cdot \log \frac{1}{\Pr[\alpha = a_i \mid \beta = b_j]}.$$

**Определение 2.3.** Условная (относительная) энтропия  $\alpha$  относительно  $\beta$

$$H(\alpha \mid \beta) = \sum_j \Pr[\beta = b_j] \cdot H(\alpha \mid \beta = b_j).$$

Другими словами

$$H(\alpha \mid \beta) = \mathbb{E}_{b_j \leftarrow \beta} [H(\alpha \mid \beta = b_j)].$$

Если подставить определение 2.2, то можно получить выражение для условной энтропии через отдельные вероятности событий.

$$H(\alpha \mid \beta) = \sum_j \Pr[\beta = b_j] \cdot \sum_i \Pr[\alpha = a_i \mid \beta = b_j] \cdot \log \frac{1}{\Pr[\alpha = a_i \mid \beta = b_j]} = \sum_{i,j} p_{i,j} \cdot \log \frac{p_{*,j}}{p_{i,j}}.$$

**Лемма 2.3.** Условная энтропия обладает следующими свойствами.

- $H(\alpha \mid \beta) \geq 0$ .
- $H(\alpha \mid \beta) = 0 \iff \alpha$  однозначно определяется по  $\beta$ .
- $H(\alpha, \beta) = H(\beta) + H(\alpha \mid \beta) = H(\alpha) + H(\beta \mid \alpha)$ .



*Доказательство.* Первое свойство выполняется, т.к. условная энтропия это матожидание неотрицательной случайной величины. Второе свойство объясняется тем, что для любого  $j$  распределение  $\langle \alpha \mid \beta = b_j \rangle$  имеет нулевую энтропию, т.е. распределение вырождено и каждому  $b_j$  соответствует ровно один  $a_i$ . Третье свойство следует из следующего равенства.

$$\sum_{i,j} p_{i,j} \cdot \log \frac{1}{p_{i,j}} = \sum_{i,j} p_{i,j} \cdot \log \frac{1}{p_{*,j}} + \sum_{i,j} p_{i,j} \cdot \log \frac{p_{*,j}}{p_{i,j}}.$$

(Нужна аккуратность, если есть строки, которые состоят из одних нулей, т.е.  $p_{*,j} = 0$  — такие строки не нужно включать в эти суммы.)  $\square$

**Следствие 2.1.**  $H(\alpha, \beta) \geq H(\alpha)$ , причём равенство достигается тогда и только тогда, когда  $\beta = f(\alpha)$ .

*Доказательство.*  $H(\alpha, \beta) - H(\alpha) = H(\beta \mid \alpha) \geq 0$ . По второму свойству условной энтропии равенство достигается тогда и только тогда, когда  $\beta = f(\alpha)$ .  $\square$

## 2.2. Взаимная информация

**Определение 2.4.** *Информация в  $\alpha$  о величине  $\beta$*  определяется следующим соотношением:

$$I(\alpha : \beta) = H(\beta) - H(\beta \mid \alpha).$$

Эту величину так же называют *взаимной информацией случайных величин  $\alpha$  и  $\beta$* .

**Лемма 2.4.** *Для взаимной информации выполняются следующие соотношения.*

1.  $I(\alpha : \beta) \leq H(\alpha)$ .
2.  $I(\alpha : \beta) \leq H(\beta)$ .
3.  $I(\alpha : \alpha) = H(\alpha)$ .
4.  $I(\alpha : \beta) = I(\beta : \alpha)$ .
5.  $I(\alpha : \beta) = H(\alpha) + H(\beta) - H(\alpha, \beta)$ .

**Определение 2.5.** Пусть  $\alpha, \beta, \gamma$  — случайные величины. Определим *взаимную информацию в  $\alpha$  о  $\beta$  при условии  $\gamma$* .

1.  $I(\alpha : \beta \mid \gamma) = H(\beta \mid \gamma) - H(\beta \mid \alpha, \gamma)$ .
2.  $I(\alpha : \beta \mid \gamma) = \sum_{\ell} I(\alpha : \beta \mid \gamma = c_{\ell}) \cdot \Pr[\gamma = c_{\ell}]$ .
3.  $I(\alpha : \beta \mid \gamma) = H(\alpha \mid \gamma) + H(\beta \mid \gamma) - H(\alpha, \beta \mid \gamma)$ .
4.  $I(\alpha : \beta \mid \gamma) = H(\alpha, \gamma) + H(\beta, \gamma) - H(\alpha, \beta, \gamma) - H(\gamma)$ .

**Лемма 2.5.** *Все определения условной взаимной информации эквивалентны.*

*Доказательство.* (3)  $\iff$  (4).

$$(3) = H(\alpha | \gamma) + H(\beta | \gamma) - H(\alpha, \beta | \gamma) = H(\alpha, \gamma) - H(\gamma) + H(\beta, \gamma) - H(\gamma) - H(\alpha, \beta, \gamma) + H(\gamma).$$

□

**Утверждение 2.1** (chain rule for mutual information). *Имеют место следующие соотношения:*

1.  $I((\alpha, \beta) : \gamma) = I(\alpha : \gamma) + I(\beta : \gamma | \alpha)$ .
2.  $I((\alpha, \beta) : \gamma | \delta) = I(\alpha : \gamma | \delta) + I(\beta : \gamma | \alpha, \delta)$ .

### 3. Кодирование

#### 3.1. Однозначно декодируемые коды

**Определение 3.1.** Будем называть *кодом* функцию  $C : \{a_1, a_2, \dots, a_n\} \rightarrow \{0, 1\}^*$ , сопоставляющую буквам некоторого алфавита *кодовые слова*. Если любое сообщение, которое получено применением кода  $C$ , декодируется однозначно (т.е. только единственным образом разрезается на образы  $C$ ), то такой код называется *однозначно декодируемым*.

**Определение 3.2.** Код называется *префиксным* (*беспрефиксным*, *prefix-free*), если никакое кодовое слово не является префиксом другого кодового слова.

**Теорема 3.1** (Неравенство Крафта-Макмилана). *Для любого однозначно декодируемого кода со множеством кодовых слов  $\{c_1, c_2, \dots, c_n\}$  выполняется следующее неравенство:*

$$\sum_{i=1}^n 2^{-|c_i|} \leq 1.$$

**Лемма 3.1.** *Для префиксных кодов верно неравенство Крафта-Макмилана.*

*Доказательство.* Рассмотрим дерево префиксного кода и посчитаем суммарную меру поддеревьев, которые соответствуют кодовым словам. □

**Утверждение 3.1.** *Для префиксных кодов верно и обратное: если есть набор целых чисел  $\{\ell_1, \ell_2, \dots, \ell_n\}$ , удовлетворяющие неравенству Крафта-Макмилана*

$$\sum_{i=1}^n 2^{-\ell_i} \leq 1,$$

*то существует префиксный код с кодовыми словами  $\{c_1, c_2, \dots, c_n\}$ , где  $|c_i| = \ell_i$ .*

*Доказательство.* Отсортируем  $\ell_i$  по возрастанию и будем развешивать их в бесконечном двоичном дереве, выбирая каждый раз самый левый свободный узел соответствующей меры. Можно заметить, что мы всегда сможем найти такой узел. □

**Следствие 3.1.** Для любого однозначно декодируемого кода существует префиксный код с теми же длинами кодовых слов.

*Доказательства теоремы 3.1.* Сопоставим кодовым словам  $\{c_i\}$  мономы  $\{p_i\}$  от переменных  $x$  и  $y$  таким образом, что каждый '0' в кодовом слове соответствует  $x$ , а каждая '1' —  $y$ :

$$c_i = 0110101 \implies p_i(x, y) = xyuxyxy.$$

Рассмотрим следующее выражение для некоторого  $L$ .

$$\left( \sum_{i=1}^n p_i(x, y) \right)^L = \sum_{\ell=L}^{\max |c_i| \cdot L} M_\ell(x, y),$$

где  $M_\ell$  обозначает сумму всех получившихся мономов степени  $\ell$ . Заметим, что в каждом  $M_\ell$  не более  $2^\ell$  мономов: в противном случае код не был бы однозначно декодируемым — каждый моном (без учёта коммутативности и ассоциативности) мог получиться не более одного раза.

Теперь рассмотрим значение этого выражения при  $x = y = \frac{1}{2}$ .

$$\left( \sum_{i=1}^n p_i\left(\frac{1}{2}, \frac{1}{2}\right) \right)^L = \sum_{\ell=L}^{\max |c_i| \cdot L} M_\ell\left(\frac{1}{2}, \frac{1}{2}\right) \leq \sum_{\ell=L}^{\max |c_i| \cdot L} (2^{-\ell} \cdot 2^\ell) \leq L \cdot \max |c_i| = O(L). \quad (1)$$

Предположим теперь, что неравенство Крафта-Макмилана не выполняется, т.е.

$$q = \sum_{i=1}^n p_i(1/2, 1/2) = \sum_{i=1}^n 2^{-|c_i|} > 1.$$

Сравнивая это с (1) получаем противоречие:  $q^L = O(L)$  (левая часть растёт экспоненциально, а правая — линейно).  $\square$

Пусть для каждого символа алфавита задана вероятность  $p_i$ . Нас будут интересовать самые короткие в среднем коды, т.е. такие, что

$$\sum_{i=1}^n p_i \cdot |c_i| \rightarrow \min.$$

**Теорема 3.2** (Шеннон). Для любого однозначно декодируемого кода выполняется

$$\sum_{i=1}^n p_i \cdot |c_i| \geq \sum_{i=1}^n p_i \cdot \log \frac{1}{p_i}.$$

*Доказательство.* Перенесём всё в правую часть и применим неравенство Йенсена:

$$\sum_{i=1}^n p_i \cdot \log \frac{2^{-|c_i|}}{p_i} \leq \log \sum_{i=1}^n \left( p_i \frac{2^{-|c_i|}}{p_i} \right) = \log \sum_{i=1}^n 2^{-|c_i|} \leq \log 1 = 0.$$

$\square$

**Теорема 3.3** (Шеннон). Для любого распределения вероятностей  $\{p_1, p_2, \dots, p_n\}$  существует однозначно декодируемый/префиксный код  $\{c_1, c_2, \dots, c_n\}$ , такой что

$$\sum_{i=1}^n p_i \cdot |c_i| \leq \sum_{i=1}^n p_i \cdot \log \frac{1}{p_i} + 1.$$

*Замечание 3.1.* От '+1' в правой части никак не избавиться: например, если у нас только два символа в алфавите, то  $\sum p_i \cdot |c_i| = 1$ , в то время как  $\sum p_i \log \frac{1}{p_i}$  может быть сколько угодно близко к нулю.

*Доказательство.* Покажем, что найдутся  $\{c_1, c_2, \dots, c_n\}$  такие, что  $|c_i| = \lceil \log \frac{1}{p_i} \rceil$ . Код существует, т.к. для длин  $c_i$  выполняется неравенство Крафта-Макмилана:

$$\sum_{i=1}^n 2^{-|c_i|} = \sum_{i=1}^n 2^{-\lceil \log \frac{1}{p_i} \rceil} \leq \sum_{i=1}^n 2^{-\log \frac{1}{p_i}} = \sum_{i=1}^n p_i = 1.$$

Теперь оценим среднюю длину кода:

$$\sum_{i=1}^n p_i \cdot |c_i| = \sum_{i=1}^n p_i \cdot \lceil \log \frac{1}{p_i} \rceil < \sum_{i=1}^n p_i \cdot (\log \frac{1}{p_i} + 1) = \left( \sum_{i=1}^n p_i \cdot \log \frac{1}{p_i} \right) + 1.$$

□

### 3.2. Код Шеннона-Фано

Упорядочим вероятности символов по убыванию:  $p_1 \geq p_2 \geq \dots \geq p_n$ . Уложим на прямой без пропусков отрезки длиной  $p_1, p_2, \dots, p_n$  и обозначим  $i$ -ый отрезок через  $S_i$ , а их объединение — через  $S$ . Коды тех букв  $a_i$ , для которых отрезок  $S_i$  попал в левую половину  $S$ , будут начинаться с '0', а коды тех букв, для которых отрезок  $S_i$  попал в правую часть  $S$  — с '1'. Центральный отрезок может не попасть целиком в одну из половин  $S$ . Если центральный отрезок является первым или последним, то начнём его код, соответственно, с '0' или '1'. В противном случае отнесём его в произвольную половину  $S$ . Далее применяем эту стратегию отдельно для букв из левой половины  $S$  и отдельно для правой половины  $S$ . Повторяем так пока не получим уникальные коды для всех символов.

**Определение 3.3.** Будем называть кодирование, при котором для некоторой константы  $c$  и для всех  $i$  выполняется  $|c_i| \leq -\log p_i + c$ , *сбалансированным*.

**Теорема 3.4** (Шеннон). Средняя длина кода Шеннона-Фано близка к энтропии, но не обязательно оптимальна:

$$\sum_{i=1}^n p_i \cdot |c_i| = H + O(1).$$

### 3.3. Код Хаффмана

**Определение 3.4.** Будем строить код Хаффмана по индукции. При  $n = 2$  коды  $c_1 = \langle 0 \rangle$ ,  $c_2 = \langle 1 \rangle$ . При  $n > 2$  будем предполагать, что вероятности упорядочены по убыванию  $p_1 \geq p_2 \geq \dots \geq p_n$ . Заменяем символы  $a_{n-1}$  и  $a_n$  на символ  $a'_{n-1}$  с вероятностью  $p'_{n-1} = p_{n-1} + p_n$ . Построим код Хаффмана для  $n - 1$  символа. Для символов  $a_{n-1}$  и  $a_n$  возьмём коды  $c_{n-1} = c'_{n-1}0$  и  $c_n = c'_{n-1}1$ .

**Лемма 3.2.** Средняя длина кодового слова для кода Хаффмана оптимальна, т.е. не превосходит средней длины любого другого префиксного кода (а значит и любого однозначно декодируемого).

**Следствие 3.2.** Для кода Хаффмана выполняется неравенство из теоремы Шеннона 3.3.

*Замечание 3.2.* На энтропию случайной величины иногда удобно смотреть как на среднюю длину кода Хаффмана.

### 3.4. Арифметическое кодирование

Мы построим код со следующим ограничением на среднюю длину:

$$\sum_{i=1}^n p_i \cdot |c_i| \leq \sum_{i=1}^n p_i \cdot \log \frac{1}{p_i} + 2,$$

что хуже, чем в теореме Шеннона.


**Определение 3.5.** Будем называть полуинтервал *стандартным*, если он имеет вид  $[0.v0_2, 0.v1_2)$ , где  $v$  — это некоторая последовательность битов, а числа записаны в двоичной системе счисления. Будем сопоставлять каждому стандартному интервалу  $[0.v0_2, 0.v1_2)$  код  $v0$ .

Для первой буквы кода на отрезке  $[0,1]$  мы отложим слева направо непересекающиеся интервалы длины  $p_i$ . Пусть первая буква блока — это  $a_{i_1}$ , тогда для второй буквы кода мы внутри интервала соответствующего  $p_{i_j}$  повторим эту операцию (отложим непересекающиеся интервалы), но длины интервалов будут уже масштабированы с коэффициентом  $p_i$ . Повторим эту операцию  $k$  раз. Получившемуся интервалу в качестве его кода сопоставим код наибольшего стандартного интервала, который полностью содержится внутри него.

**Утверждение 3.2.** В интервале  $[a, b)$  всегда найдётся стандартный интервал длины  $2^{-k}$ , где  $\frac{b-a}{4} < 2^{-k} \leq \frac{b-a}{2}$ , т.е. длина кода любого интервала при арифметическом кодировании не превосходит  $\log \frac{4}{b-a} = \log \frac{1}{p} + 2$ , где  $p$  — вероятность соответствующего блока.

*Замечание 3.3.* В случае Марковской цепи можно строить код с соответствующими условными вероятностями.

Упражнение 3.1. Пусть Марковская цепь задана графом.



Определим  $h_p = \lim_{n \rightarrow \infty} \frac{H(\alpha_1, \alpha_2, \dots, \alpha_n)}{n}$ . Найти  $\max_p h_p$ .

### 3.5. Блочные коды с ошибками

Пусть  $\alpha_1, \alpha_2, \dots, \alpha_n$  — независимые одинаково распределённые на  $\{a_1, a_2, \dots, a_k\}$  случайные величины с вероятностями  $p_1, p_2, \dots, p_k$ . Рассмотрим блочное кодирование, заданное функциями  $E_n$  и  $D_n$ :

$$E_n : \{a_1, a_2, \dots, a_k\}^n \rightarrow \{0, 1\}^{L_n},$$

$$D_n : \{0, 1\}^{L_n} \rightarrow \{a_1, a_2, \dots, a_k\}^n,$$

**Определение 3.6.** Вероятность ошибки  $\varepsilon_n$  — это вероятность следующего события:  $[(\alpha_1, \alpha_2, \dots, \alpha_n) = (a_{i_1}, a_{i_2}, \dots, a_{i_n}) \mid D_n(E_n(a_{i_1}, a_{i_2}, \dots, a_{i_n})) \neq (a_{i_1}, a_{i_2}, \dots, a_{i_n})]$ .

**Теорема 3.5** (Шеннон). При блочном кодировании допускающем ошибки выполняются следующие соотношения.

1. Если  $h > H(\alpha) = \sum_{i=1}^k p_i \log \frac{1}{p_i}$ , то существует функции  $(E_n, D_n)$  для  $L_n = \lceil h \cdot n \rceil$ , такие что  $\varepsilon_n \rightarrow 0$  при  $n \rightarrow \infty$ .
2. Если  $h < H(\alpha) = \sum_{i=1}^k p_i \log \frac{1}{p_i}$ , то для любых функций  $(E_n, D_n)$  для  $L_n = \lceil h \cdot n \rceil$  вероятность ошибки  $\varepsilon_n \rightarrow 1$  при  $n \rightarrow \infty$ .

**Определение 3.7.** Будем называть слово  $w = \langle a_{i_1}, a_{i_2}, \dots, a_{i_n} \rangle$   $\delta$ -типичным, если каждая буква  $a_j$  встречается в нём  $t_j$  раз, причём

$$\begin{cases} t_j \leq (p_j + \delta) \cdot n, \\ t_j \geq (p_j - \delta) \cdot n. \end{cases}$$

**Лемма 3.3.** Для  $\delta = n^{-0.49} = \frac{n^{0.01}}{\sqrt{n}}$  вероятность не  $\delta$ -типичного не превосходит  $\varepsilon_n$ , для  $\varepsilon_n \rightarrow 0$ .

*Доказательство.* Применить неравенство Чебышева

$$P[|X - \mu| \geq \delta n] \leq \frac{\sigma^2}{(\delta n)^2} = \frac{np_i(1-p_i)}{\delta^2 n^2} = O(n^{-0.02}).$$

□

**Лемма 3.4.** Для  $\delta = n^{-0.49}$  количество  $\delta$ -типичных слов не превосходит  $2^{h \cdot n}$  (при достаточно больших  $n$ ).

*Доказательство.* Давайте для начала рассмотрим слова определённого типа, в которых буква  $i$  встречается  $n_i$  раз,  $n_1 + n_2 + \dots + n_k = n$ . Сначала оценим количество слов типа, в котором  $n_i = n \cdot p_i$ . Таких слов

$$\frac{n!}{n_1! n_2! \dots n_k!}.$$

По формуле Стирлинга  $n! \sim \sqrt{2\pi n} \left(\frac{n}{e}\right)^n \cdot (1 + o(1))$ .

$$\begin{aligned} \log \frac{n!}{n_1! n_2! \dots n_k!} &\approx \log \frac{\text{poly}(n) \left(\frac{n}{e}\right)^n}{\text{poly}(n) \left(\frac{n_1}{e}\right)^{n_1} \dots \left(\frac{n_k}{e}\right)^{n_k}} = \\ &= \log \left(\frac{n}{n_1}\right)^{n_1} \dots \left(\frac{n}{n_k}\right)^{n_k} + O(\log n) = \sum_{i=1}^k \underbrace{np_i}_{n_i} \cdot \log \frac{1}{p_i} + O(\log n) < h \cdot n. \end{aligned} \quad (2)$$

Последнее неравенство выполняется асимптотически, т.к. по предположению  $h > H(\alpha)$ . Мы оценили это только для конкретного типа слов. Давайте оценим для произвольного  $\delta$ -типичного слова с  $n_i = n \cdot (p_i + \Delta_i)$ , где  $|\Delta_i| \leq \delta$ . Тогда (2) изменится следующим образом:

$$\dots = \sum_{i=1}^k n(p_i + \Delta_i) \cdot \log \frac{1}{p_i + \Delta_i} + O(\log n) = n \cdot \sum_{i=1}^k p_i \cdot \log \frac{1}{p_i} + O(\log n) + n \cdot O(\delta) < h \cdot n.$$

(Действительно, энтропия — это непрерывная функция, а значит при небольшом отклонении она изменяется на  $c \cdot \max_i \Delta_i$ , где  $c$  зависит от производной функции энтропии.) Итого общее количество  $\delta$ -типичных слов можно оценить как количество типов умноженное на количество  $\delta$ -типичных слов одного типа:

$$\text{poly}(n) \cdot 2^{n \cdot H(\alpha) + n \cdot O(\delta) + O(\log n)} < 2^{h \cdot n}.$$

□

*Доказательство теоремы 3.5.*

1. Если мы будем кодировать только  $\delta$ -типичные слова, то по лемме 3.4 нам будет достаточно длины кода  $L_n$ , а вероятность всех не типичных слов будет стремиться к нулю.
2. Обозначим за  $\hat{\epsilon}_n$  вероятность ошибки при декодировании  $\delta$ -типичных слов. Мы хотим показать, что  $\hat{\epsilon}_n \rightarrow 1$ . Давайте рассмотрим конкретное  $\delta$ -типичное слово  $w = \langle a_{i_1}, a_{i_2}, \dots, a_{i_n} \rangle$ . Пусть  $p'_1, p'_2, \dots, p'_k$  — это частоты букв  $a_1, a_2, \dots, a_n$  в слове  $w$ . Оценим вероятность появления  $w$ :

$$\Pr[\langle \alpha_{i_1}, \alpha_{i_2}, \dots, \alpha_{i_n} \rangle = w] = p_1^{p'_1 \cdot n} \cdot \dots \cdot p_k^{p'_k \cdot n} = 2^{-(\sum_i p'_i \log \frac{1}{p_i}) \cdot n} \leq 2^{-(\sum_i p_i \log \frac{1}{p_i}) \cdot n + O(\delta_n \cdot n)}.$$

Всего мы можем корректно закодировать не более  $2^{L_n}$   $\delta$ -типичных слов, т.е. вероятность корректно декодировать  $\delta$ -типичное слово

$$1 - \hat{\varepsilon}_n \leq 2^{L_n} \cdot 2^{-H(\alpha) \cdot n + O(\delta_n \cdot n)} \leq 2^{h \cdot n + 1} \cdot 2^{-H(\alpha) \cdot n + O(\delta_n \cdot n)} \rightarrow 0.$$

Таким образом  $\hat{\varepsilon}_n \rightarrow 1$ . Вместе с леммой 3.3 получаем, что  $\varepsilon_n \rightarrow 1$ .

□

*Замечание 3.4.* Используя предыдущую теорему можно, например, получить альтернативное доказательство неравенства  $H(\alpha, \beta) \leq H(\alpha) + H(\beta)$ . В левой части стоит асимптотическая средняя длина кода при блоковом кодировании  $(\alpha, \beta)$ , а справа сумма средних длин кодов при блоковом кодировании  $\alpha$  и  $\beta$  отдельно друг от друга. Т.к. мы можем рассмотреть кодирование  $(\alpha, \beta)$  как конкатенацию кодов для  $\alpha$  и  $\beta$ , то неравенство выполняется.

## 4. Свойства распределений

### 4.1. Энтропийные профили

**Утверждение 4.1.** Для любого  $h \geq 0$  существует распределение  $\alpha$ :  $H(\alpha) = h$ .

*Доказательство.* Возьмём некоторое целое  $n$ :  $0 \leq h \leq \log n$ . Искомое распределение — это линейная комбинация распределений с вероятностями  $(1, 0, \dots, 0)$  и  $(\frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n})$ . □

Каким может быть совместное распределение двух случайных величин  $\alpha$  и  $\beta$ ? Рассмотрим как может быть устроен *энтропийный профиль*  $(H(\alpha), H(\beta), H(\alpha, \beta))$ .

**Утверждение 4.2.** Для любых чисел  $h_1, h_2, h_{12} \geq 0$ , которые удовлетворяют следующим соотношениям

$$\begin{cases} h_{12} \leq h_1 + h_2 & \iff t_0 = I(\alpha : \beta) \geq 0, \\ h_2 \leq h_{12} & \iff t_1 = H(\alpha | \beta) \geq 0, \\ h_1 \leq h_{12} & \iff t_2 = H(\beta | \alpha) \geq 0. \end{cases}$$

существует пара случайных величин  $(\alpha, \beta)$  с энтропийным профилем  $(h_1, h_2, h_{12})$ .

*Доказательство.* Пусть  $\xi_0, \xi_1, \xi_2$  — независимые случайные величины с энтропиями  $t_0, t_1, t_2$  соответственно. Тогда  $\alpha = (\xi_0, \xi_1)$  и  $\beta = (\xi_0, \xi_2)$  будут искомыми величинами.

$$\begin{cases} H(\xi_0) = t_0 = h_1 + h_2 - h_{12}, \\ H(\xi_1) = t_1 = h_{12} - h_2, \\ H(\xi_2) = t_2 = h_{12} - h_1. \end{cases} \quad \alpha \left( \begin{array}{ccc} & \xi_1 & \xi_2 \\ & \cap & \cap \\ \xi_0 & & \end{array} \right) \beta$$

□



Давайте попробуем разобраться с аналогичным вопросом для троек случайных величин. Энтропийный профиль для тройки  $(\alpha, \beta, \gamma)$  будет задаваться 7 числами:

$$(H(\alpha), H(\beta), H(\gamma), H(\alpha, \beta), H(\alpha, \gamma), H(\beta, \gamma), H(\alpha, \beta, \gamma)).$$


Для случайных величин  $(\alpha, \beta, \gamma)$  можно записать 9 независимых неравенств.

$$\begin{aligned} H(\alpha | \beta, \gamma) &\geq 0, & I(\alpha : \beta) &\geq 0, & I(\alpha : \beta | \gamma) &\geq 0, \\ H(\beta | \gamma, \alpha) &\geq 0, & I(\beta : \gamma) &\geq 0, & I(\beta : \gamma | \alpha) &\geq 0, \\ H(\gamma | \alpha, \beta) &\geq 0, & I(\gamma : \alpha) &\geq 0, & I(\gamma : \alpha | \beta) &\geq 0. \end{aligned}$$

**Определение 4.1.** Определим общую информацию трёх случайных величин

$$I(\alpha : \beta : \gamma) = I(\alpha : \beta) - I(\alpha : \beta | \gamma).$$

Соотношения на информационные величины имеют удобную геометрическую интерпретацию. Давайте нарисуем три круга Эйлера и сопоставим площади каждой из получившихся замкнутых области некоторую информационную величину.



Мы можем проверить, что в результате получится корректное представление. Так, например, площадь круга  $\alpha$  будет соответствовать

$$H(\alpha) = H(\alpha | \beta, \gamma) + I(\alpha : \beta | \gamma) + I(\alpha : \gamma | \beta) + I(\alpha : \beta : \gamma),$$

а пересечение кругов  $\alpha$  и  $\beta$

$$I(\alpha : \beta) = I(\alpha : \beta | \gamma) + I(\alpha : \beta : \gamma).$$


В дальнейшем мы будем использовать эту геометрическую интерпретацию для доказательства соотношений на информационные величины.

**Утверждение 4.3.** *Общая информация трёх случайных величин может быть отрицательной.*

*Доказательство.* Пусть  $\alpha$  и  $\beta$  будут независимыми равномерно распределёнными на  $\{0, 1\}$  случайными величинами. Случайная величина  $\gamma$  будет принимать значение из  $\{0, 1\}$  в соответствии со следующим соотношением:

$$\alpha \oplus \beta \oplus \gamma = 0.$$

Мы получим следующую картину:




□

**Утверждение 4.4.** *Других неравенств для троек нет.*


**Утверждение 4.5.** *Есть профили, которые не реализуются никакими распределениями, но их мера 0.*

*Упражнение 4.1.* Доказать, что следующий профиль реализуется только при  $h = \log n$  для некоторого целого  $n$ .



**Утверждение 4.6.**  $2H(\alpha, \beta, \gamma) \leq H(\alpha, \beta) + H(\alpha, \gamma) + H(\beta, \gamma)$ .

*Доказательство.* Отметим сколько раз каждая область входит в левую/в правую часть неравенства.



Таким образом утверждение упрощается до  $0 \leq I(\beta : \gamma) + I(\alpha : \beta \mid \gamma) + I(\alpha : \gamma \mid \beta)$ .  $\square$

**Следствие 4.1** (Теорема 1.3). Для  $A \subset \{0, 1\}^* \times \{0, 1\}^* \times \{0, 1\}^*$

$$2\chi(A) \leq \chi_{12}(A) + \chi_{13}(A) + \chi_{23}(A).$$

*Доказательство.* Пусть  $(\alpha, \beta, \gamma)$  равномерно распределены на  $A$  (т.е. случайные величины — это координаты точек в множестве  $A$ ).

$$2\chi(A) = 2H(\alpha, \beta, \gamma) \leq \underbrace{H(\alpha, \beta)}_{\leq \chi_{12}(A)} + \underbrace{H(\alpha, \gamma)}_{\leq \chi_{13}(A)} + \underbrace{H(\beta, \gamma)}_{\leq \chi_{23}(A)}.$$

$\square$

Можно рассмотреть обобщение этой теоремы на произвольное число координат.

**Теорема 4.1** (Лемма Ширера). Пусть  $X$  — случайная величина, распределённая на  $\{0, 1\}^n$ . Для любого распределения  $S$  на подмножествах  $[n]$ , при котором  $\Pr[i \in S] \geq \mu$ , выполняется  $\mathbb{E}[H(X_S)] \geq \mu \cdot H(X)$ .

*Доказательство.* Для любого множества  $T = \{i_1, i_2, \dots, i_k\} \subset [n]$ ,  $i_1 < i_2 < \dots < i_k$  выполняется

$$H(X_T) = H(X_{i_1}) + H(X_{i_2} \mid X_{i_1}) + \dots + H(X_{i_k} \mid X_{i_1}, \dots, X_{i_{k-1}}).$$

Воспользуемся тем, что  $H(X_{i_t} \mid X_{i_1}, \dots, X_{i_{t-1}}) \geq H(X_{i_t} \mid X_{<i_t})$ , тогда

$$H(X_T) \geq H(X_{i_1} \mid X_{<i_1}) + H(X_{i_2} \mid X_{<i_2}) + \dots + H(X_{i_k} \mid X_{<i_k}).$$

Теперь применим этот факт к распределению  $S$ .

$$\begin{aligned} \mathbb{E}_S[H(X_S)] &\geq \mathbb{E}_S \left[ \sum_{i \in S} H(X_i \mid X_{<i}) \right] = \sum_{i \in [n]} \Pr[i \in S] \cdot H(X_i \mid X_{<i}) \\ &\geq \mu \sum_{i \in [n]} H(X_i \mid X_{<i}) = \mu \cdot H(X). \end{aligned}$$

$\square$

У леммы Ширера имеется множество применений.

*Пример 4.1* (Подсчёт треугольников в графе). Пусть  $G = (V, E)$  — неориентированный граф с  $t$  треугольниками, и пусть  $\ell = |E|$ . Покажем, что  $t \leq (2\ell)^{3/2}/6$ .

*Доказательство.* Пусть тройка случайных величин  $(\alpha, \beta, \gamma)$  равномерно распределена на вершинах треугольников, и пусть  $X = (\alpha, \beta, \gamma)$ . Тогда  $H(X) = H(\alpha, \beta, \gamma) = \log(6t)$ , т.к. каждый треугольник случается шестью различными перестановками. Рассмотрим распределение  $S$ , равномерное на подмножествах  $\{1, 2, 3\}$  размера 2. Тогда  $\Pr[i \in S] = 2/3$ . По лемме Ширера

$$\mathbb{E}_S[H(X_S)] \geq \frac{2}{3} \log(6t),$$

т.е. существует  $T \subset \{1, 2, 3\}$ , для которого  $H(X_T) \geq \frac{2}{3} \log(6t)$ . С другой стороны  $X_T$  — это распределение на рёбрах графа, то есть  $\log(2\ell) \geq H(X_T)$ . Из этого получаем, что  $2\ell \geq (6t)^{2/3}$ .  $\square$


Обобщение для вложения произвольных графов см. в [10].

**Утверждение 4.7.** Для любых  $\alpha, \beta$  и  $\gamma$  выполняется следующее неравенство

$$H(\gamma) \leq H(\gamma | \alpha) + H(\gamma | \beta) + I(\alpha : \beta).$$

Если  $H(\gamma | \alpha) = H(\gamma | \beta) = 0$  (т.е.  $\gamma$  однозначно определяется и по  $\alpha$  и по  $\beta$ ), то  $H(\gamma) \leq I(\alpha : \beta)$ .

*Доказательство.* Отметим сколько раз каждая область входит в левую/в правую часть неравенства.




Таким образом неравенство упрощается до  $0 \leq H(\gamma | \alpha, \beta) + I(\alpha : \beta | \gamma)$ .  $\square$

*Упражнение 4.2.* Пусть  $\alpha \rightarrow \beta \rightarrow \gamma$  образуют Марковскую цепь, т.е. распределение  $\langle \gamma | \beta \rangle = \langle \gamma | \alpha, \beta \rangle$ . Докажите, что  $I(\alpha : \gamma) \leq I(\alpha : \beta)$  и  $I(\alpha : \gamma) \leq I(\beta : \gamma)$ .

*Упражнение 4.3.* Пусть  $\alpha \rightarrow \beta \rightarrow \gamma \rightarrow \delta$  образуют Марковскую цепь. Докажите, что  $I(\alpha : \beta) \leq I(\beta : \gamma)$ .

*Упражнение 4.4.* Пусть  $\alpha, \beta$  и  $\gamma$  имеют следующий профиль.



Докажите, что существует случайная величина  $\delta$ , такая что

$$\begin{cases} H(\delta | \alpha) = 0, \\ H(\delta | \beta) = 0, \\ H(\delta | \gamma) = 0, \\ H(\delta) = I(\alpha : \beta : \gamma). \end{cases}$$

И при этом  $I(\alpha : \beta | \delta) = I(\alpha : \gamma | \delta) = I(\beta : \gamma | \delta) = 0$ .

*Упражнение 4.5.* Возьмём в качестве  $x, y, a, b$  случайные величины из предыдущего упражнения:  $x = \alpha, y = \beta, a = \gamma, b = \delta$ . Покажите, что для любых таких  $(a, b, x, y)$  из условия  $I(x : y | a) = I(x : a | y) = I(y : a | x) = 0$  следует

$$I(a : b) \leq I(a : b | x) + I(a : b | y) + I(x : y).$$

[Указание: примените неравенство из утверждения 4.7.]

*Упражнение 4.6.* Возьмём в качестве  $x, y, a, b$  случайные величины из упражнения 4.4:  $x = \alpha, y = \beta, a = \gamma, b = \delta$ . Покажите, что существуют такие  $(a, b, x, y)$ , для которых

$$I(a : b) \not\leq I(a : b | x) + I(a : b | y) + I(x : y).$$

(Т.е. условие в предыдущем упражнении было необходимо.)

**Утверждение 4.8** (Неравенство для 5 случайных величин).

$$I(a : b) \leq I(a : b | x) + I(a : b | y) + I(x : y) + I(a : b | z) + I(a : z | b) + I(b : z | a).$$

**Следствие 4.2** (Zhang, Yeung, 1998). *Неравенство для 4 случайных величин, которое не выражается через базисные неравенства.*

$$I(a : b) \leq 2I(a : b | x) + I(a : b | y) + I(x : y) + I(a : x | b) + I(b : x | a).$$

**Утверждение 4.9.** *Для 4 случайных величин существует бесконечно много неравенств, которые независимы в совокупности.*

## 4.2. Неравенства о тройках

Будем в различных предположениях доказывать следующее утверждение


$$H(a | x) + H(a | y) \leq H(a).$$

**Утверждение 4.10.** Если  $a, x, y$  такие, что

$$\begin{cases} H(a | y, x) = 0, \\ I(x : y | a) = 0. \end{cases}$$

то  $H(a | x) + H(a | y) \leq H(a)$ .

*Доказательство.* Получается, что нам нужно доказать неотрицательность  $h$ .



Т.к.  $I(x : y | a) = 0$ , то  $h = I(x : y) \geq 0$ . □

**Утверждение 4.11.** Если  $a, x, y$  такие, что  $H(a | y, x) = 0$  и

$$\begin{cases} A_i \sim X_j \\ A_i \sim Y_k \end{cases} \implies A_i \sim (X_j, Y_k),$$

то  $H(a | x) + H(a | y) \leq H(a)$ . (Обозначение  $A_i \sim X_j \iff \Pr[a = A_i \wedge x = X_j] > 0$ .)

*Замечание 4.1.* Условие  $H(a | x, y) = 0$  можно интерпретировать так:  $a = f(x, y)$ .

*Доказательство.* Построим новое распределение  $(a', x', y')$ :

- $a'$  имеет то же распределение, что и  $a$ ,
- условное распределение  $x'$  при условии  $a'$  совпадает с условным распределением  $x$  при условии  $a$ ,
- условное распределение  $y'$  при условии  $a'$  совпадает с условным распределением  $y$  при условии  $a$ ,
- $x'$  и  $y'$  независимы.

$$\Pr[a' = A_i, x' = X_j, y' = Y_k] = \Pr[a' = A_i] \cdot \Pr[x' = X_j \mid a' = A_i] \cdot \Pr[y' = Y_k \mid a' = A_i].$$

Таким образом

$$H(a', x', y') = H(a') + H(x' \mid a') + H(y' \mid a') - \underbrace{I(x' : y' \mid a')}_0.$$

С другой стороны

$$H(a', x', y') \leq H(x') + H(y') + H(a' \mid x', y').$$

Кроме того, мы может стереть штрихи почти везде.

$$H(x) + H(y) + H(a' \mid x', y') \geq H(a', x', y') = H(a) + H(x \mid a) + H(y \mid a).$$

Покажем, что  $H(a' \mid x', y') = 0$ , т.е.  $a' = f(x', y')$ . Действительно: если тройка  $(A_i, X_j, Y_k)$  в новом распределении встречается с положительной вероятностью, то и в исходном распределении она так же встречалась с положительной вероятностью, следовательно  $a' = f(x', y')$ . Получаем:  $H(a) + H(x \mid a) + H(y \mid a) \leq H(x) + H(y)$ . Прибавим  $H(a)$  к обеим частям неравенства:

$$H(x, a) + H(y, a) \leq H(x) + H(y) + H(a) \implies H(a \mid x) + H(a \mid y) \leq H(a).$$

□

*Задача 4.1* (Верещагин, [8]). Рассмотрим двудольный граф с вершинами  $(L, R)$  с цветными рёбрами. Все рёбра инцидентные одной вершине разноцветные, степень в левой доле не меньше  $n$ , в правой — не меньше  $m$ . Пусть известно, что для пары вершин  $(x \in L, y \in R)$  есть не более одного общего цвета. Докажите, что количество цветов хотя бы  $n \cdot m$ .

Заметим, что одноцветные рёбра образуют паросочетания. Для каждого цвета  $c$  соединим все согласованные с  $c$  вершины слева с согласованными с  $c$  вершинами справа. Получим биклику из рёбер цвета  $c$ .

Рассмотрим распределение на тройках  $(a, x, y)$  (цвет, вершина из левой доли, вершина из правой доли): выбираем цвет пропорционально размеру (количеству рёбер) соответствующей биклики и выбираем случайное ребро этого цвета. Можно проверить, что выполняется следующее соотношение:

$$\begin{cases} A_i \sim X_j, \\ A_i \sim Y_k, \end{cases} \implies A_i \sim (X_j, Y_k).$$

Теперь применим:  $\underbrace{H(a \mid x)}_{\geq \log n} + \underbrace{H(a \mid y)}_{\geq \log m} \leq H(a) \leq \log(\# \text{ цветов}).$

### 4.3. Условное неравенство о четвёрке

**Утверждение 4.12.** Если для случайных величин  $a, b, x, y$  выполняется

$$\begin{cases} I(x : y | a) = 0, \\ H(a | x, y) = 0, \end{cases}$$

то  $I(a : b) \leq I(a : b | x) + I(a : b | y) + I(x : y)$ .

*Доказательство.* Построим новое распределение  $(a', b', x', y')$ : сначала выберем значение  $(a', b') \sim (a, b)$ . При фиксированном значении  $(a', b')$  выбираем независимо  $x'$  и  $y'$  так, чтобы условные распределения вероятностей относительно  $a'$  были такими же, как у  $x$  и  $y$  относительно  $a$ .

$$\begin{aligned} H(a', b', x', y') &= H(a', b') + H(x | a', b') + H(y | a', b') - \underbrace{I(x' : y' | a', b')}_0 = \\ &= H(a, b) + H(x | a, b) + H(y | a, b). \end{aligned}$$

С другой стороны

$$\begin{aligned} H(a', b', x', y') &\leq H(b') + H(x' | b') + H(y' | b') + H(a' | x', y') = \\ &= H(b) + H(x | b) + H(y | b) + H(a' | x', y'). \end{aligned}$$

Покажем, что  $H(a' | x', y') = 0$ . В исходном распределении это выполнялось по условию. Пусть  $[a' = A_i, x' = X_j, y' = Y_k]$  в новом распределении случается с положительной вероятностью. Следовательно и в исходном распределении это случается с положительной вероятностью (при фиксированном  $a'$  величины  $x'$  и  $y'$  независимы), а значит сохраняется соответствующее свойство функциональной зависимости  $a'$  от  $(x', y')$ .

В результате получаем

$$H(a, b) + H(x | a, b) + H(y | a, b) \leq H(b) + H(x | b) + H(y | b).$$

Распишем это неравенство в безусловных энтропиях:

$$H(a, b) + H(x, a, b) - H(a, b) + H(y, a, b) - H(a, b) \leq H(b) + H(x, b) - H(b) + H(y, b) - H(b).$$

Упрощаем и получаем:

$$H(x, a, b) + H(y, a, b) + H(b) \leq H(x, b) + H(y, b) + H(a, b). \quad (3)$$

Проделаем то же самое с  $I(a : b) \leq I(a : b | x) + I(a : b | y) + I(x : y)$ .


$$\begin{aligned} H(a) + H(b) - H(a, b) &\leq H(a, x) + H(b, x) - H(a, b, x) - H(x) + \\ &H(a, y) + H(b, y) - H(a, b, y) - H(y) + \\ &H(x) + H(y) - H(x, y). \end{aligned}$$



Упрощаем и получаем:

$$H(a, b, x) + H(a, b, y) + H(b) + H(x, y) \leq \frac{H(b, x) + H(b, y) + H(a, b) + H(a, x) + H(a, y) - H(a)}{2} \quad (4)$$

Заметим, что нам осталось доказать лишь  $H(x, y) \leq H(a) + H(x | a) + H(y | a)$ . Сложив это неравенство с (3) мы получим (4). Отметим сколько раз каждая область входит в левую/в правую часть неравенства.



Т.е. оно эквивалентно  $H(a | x, y) + I(x : y | a) \geq 0$ . □

Вопросы на подумать. Придумать интерпретацию для этого неравенства. Zhang и Yeung в 97 году доказали это же неравенство в предположении  $I(x : y) = I(x : y | a) = 0$ . Есть ли комбинаторная интерпретация у этого утверждения?

## Список литературы

- [1] Н.К. Верещагин, Е.В. Щепин. *Информация, кодирование, предсказание*, МЦНМО, 2012.
- [2] Н.К. Верещагин. *Коммуникационная сложность*, Computer Science клуб, 2017. <http://compsciclub.ru/courses/communicationcomplexity/2017-spring/>
- [3] А.Е. Ромащенко. *Введение в теорию информации*, Computer Science клуб, 2015. <http://compsciclub.ru/courses/informationtheory/2015-spring/>
- [4] А.Е. Ромащенко. *Краткий конспект лекций курса “Введение в теорию информации”*, 2014. <http://www.mcsme.ru/~anromash/courses/lecture-notes-it-2014.pdf>
- [5] В.А. Успенский, Н.К. Верещагин, А.Шень. *Введение в колмогоровскую сложность*. МЦНМО, 2012.
- [6] А. Шень. *Алгоритмическая теория информации*, Computer Science клуб, 2008. <http://compsciclub.ru/courses/algo-information-theory/2008-autumn/>

- [7] D. Gavinsky, O. Meir, O. Weinstein, A. Wigderson. *Toward better formula lower bounds: an information complexity approach to the KRW composition conjecture*. STOC 2014.
- [8] T.Kaced, A.E. Romashchenko, N.K.Vereshchagin, *A Conditional Information Inequality and Its Combinatorial Applications*. IEEE Trans. Information Theory, 2018.
- [9] E. Nisan, N. Kushilevitz. *Communication complexity*, 1997.
- [10] A. Rao. *Notes for CSE533: Information Theory in Computer Science*, 2010.  
<https://homes.cs.washington.edu/~anuprao/pubs/CSE533Autumn2010/>