

# Теория информации

## Лекция 3

### Количество информации в случайной величине

В прошлой лекции было определено Шенноновское определение количества информации

$$h(x=a_i) = \log_2 \frac{1}{p_i}$$


и энтропия ансамбля

$$H(X) = \sum_i p_i \log_2 \frac{1}{p_i}$$

как мера среднего количества информации по ансамблю. Убедимся, что эти величины действительно характеризуют количество информации. Определенная в первой лекции двоичная энтропия

$$H_2(p) = p \log_2 \frac{1}{p} + (1-p) \log_2 \frac{1}{1-p}$$

это среднее количество информации для ансамбля из двух элементов  $A_x = \{a, b\}$  и распределением  $P_x = \{p, 1-p\}$ . Ниже показаны графики количества информации и двоичной энтропии.



Из графиков видно, что чем менее вероятным оказывается значение случайной

переменной, тем большее количество информации оно несет, а также что максимум энтропии соответствует равномерному распределению.

Обратим внимание на одно свойство функции  $\log_2 \frac{1}{p}$ . Если мы узнаем значение двух независимых переменных  $x$  и  $y$ , а поскольку они независимы  $P(x, y) = P(x)P(y)$ , то интуитивно ясно, что количество информации в этом случае должно быть аддитивной величиной. Этому свойству удовлетворяет функция  $\log_2 \frac{1}{p}$ :

$$h(x, y) = \log_2 \frac{1}{P(x, y)} = \log_2 \frac{1}{P(x)P(y)} = \log_2 \frac{1}{P(x)} + \log_2 \frac{1}{P(y)} = h(x) + h(y) \quad (3.1)$$

Легко показать, что для независимых переменных выполняется и равенство

$$H(X, Y) = H(X) + H(Y) \quad (3.2)$$

т.е. энтропия аддитивна для независимых переменных.

Рассмотрим игру в угадывание. Один игрок загадывает предмет, а другой задавая вопросы, ответ на которые либо да либо нет, угадывает за заданное число ходов. Упростим эту игру до отгадывания одного числа от 0 до 63. Всего 64 возможности и для того, чтобы угадать, достаточно задать следующие 6 вопросов:

1. Верно ли, что  $x \geq 32$  ?
2. Верно ли, что  $x \bmod 32 \geq 16$  ?
3. Верно ли, что  $x \bmod 16 \geq 8$  ?
4. Верно ли, что  $x \bmod 8 \geq 4$  ?
5. Верно ли, что  $x \bmod 4 \geq 2$  ?
6. Верно ли, что  $x \bmod 2 = 1$  ?

Здесь  $x \bmod y$  это остаток от целочисленного деления  $x$  на  $y$ , например  $35 \bmod 32 = 3$ . Если множество ответов на эти вопросы  $\{\text{да}, \text{нет}\}$  поставить в соответствие множеству  $\{1, 0\}$ , то собственно двоичная запись ответов и будет давать загаданное число. Например, число 35 даст набор ответов  $100011 = 1 \cdot 2^5 + 0 \cdot 2^4 + 0 \cdot 2^3 + 0 \cdot 2^2 + 1 \cdot 2^1 + 1 \cdot 2^0 = 32 + 2 + 1 = 35$ . Можно сказать, что наша последовательность вопросов кодирует загаданное число как двоичную последовательность (файл). Если предположить, что все числа от 0 до 63 равновероятны, тогда ответы на наши вопросы независимы и каждый ответ содержит информации

$$\log_2 \frac{1}{0.5} = 1 \text{ бит} ,$$

а полное Шенноновское количество информации 6 бит (по одному на каждый вопрос). Таким образом, количество информации это длина двоичного файла (последовательности) кодирующего переменную  $x$ . Остается убедиться в этом для ансамбля имеющие неравные вероятности в распределении  $P_x$ .

Рассмотрим для этого другую игру, похожую на морской бой, в которой всего один корабль из одной клетки на поле в  $8 \times 8 = 64$  клетки. Каждый выстрел формирует ансамбль, в котором  $A_x = \{\text{да}, \text{нет}\}$ . В самом начале игры

$$P(\text{да}) = \frac{1}{64}, \quad P(\text{нет}) = \frac{63}{64} .$$

Если первый выстрел был мимо, то на втором ходе

$$P(\text{да}) = \frac{1}{63}, \quad P(\text{нет}) = \frac{62}{63} ,$$

на третьем ходе (если первые два мимо)

$$P(\text{да}) = \frac{1}{62}, \quad P(\text{нет}) = \frac{61}{62}$$

и т.д., пока не будет попадания. Если игрок удачлив и попал с первого раза, то для такого события

$$h(x) = h_1(\text{да}) = \log_2 64 = 6 \text{ бит} .$$

Кажется странным, что однобитовое значение (единственное да) дало сразу 6 бит информации. Но игрок не только узнал, что на какой-то клетке есть «корабль», но и то, что на остальных 63-х клетках пусто.

Если же первый ход был промахом, то

$$h(x) = h_1(\text{нет}) = \log_2 \frac{1}{63/64} \approx 0.0227 \text{ бит} .$$

Что же означает количество информации в 0.0227 бит? Если сложить все количество информации соответствующее первым 32 промахам, то получим следующее:

$$h_1(\text{нет}) + h_2(\text{нет}) + \dots + h_{32}(\text{нет}) = \log_2 \frac{64}{63} + \log_2 \frac{63}{62} + \dots + \log_2 \frac{33}{32} = 1 \text{ бит} .$$

Что значит это круглое число? Если сравнить с предыдущей игрой, то можно увидеть, что за 32 неудачных хода отброшена половина гипотез, что и дало 1 бит информации. Это эквивалентно ответу на 1-ый вопрос в предыдущей игре. Если отбросить еще половину оставшихся гипотез, то на 48-ом неудачном ходу, количество информации будет

$$\log_2 \frac{64}{63} + \dots + \log_2 \frac{17}{16} = 2.0 \text{ бит} .$$

Если на 49-м ходу игрок найдет «корабль», то такой ход принесет  $\log_2 16 = 4.0$  бит информации. А всего информации вместе с 48-ю промахами будет 6 бит. Обобщая этот результат на нахождение «корабля» на том ходу, когда останется  $n$  непроверенных клеток, получим следующее выражение для количества информации:

$$\log_2 \frac{64}{63} + \dots + \log_2 \frac{n+1}{n} + \log_2 \frac{n}{1} = \log_2 \left( \frac{64}{63} \cdot \frac{63}{62} \cdot \dots \cdot \frac{n+1}{n} \cdot \frac{n}{1} \right) = \log_2 64 = 6 \text{ бит} .$$

Этот пример иллюстрирует то, что мера количества информации Шеннона  $h(x)$  годится и для случая неравномерного распределения вероятностей  $P_x$ .

## Сжатие данных

Рассмотрим для начала пример некоего искусственного языка, состоящего из  $2^{15} = 32768$  слов составленных из 5 случайно выбранных букв английского алфавита, а в качестве вероятности появления букв возьмем вероятности появления букв в реальном английском языке, в котором, например,  $P(a) \approx 0.0575$ , а  $P(z) \approx 0.001$ . Тогда в словаре из  $2^{15}$  слов будет около 1900 слов начинающихся на  $a$ , и около 32-х слов, начинающихся на  $z$ . Начинающихся на  $aa$  примерно 108, а на  $az$  всего 1 или 2.

Теперь предположим, что мы читаем документ на этом абстрактном языке. Если за раз прочитывается одно слово, то количество информации в одном слове  $\log_2 32768 = 15$  бит, при предположении, что все слова в этом языке используются равновероятно. Таким образом среднее число бит на символ  $15/5 = 3$  бита. Однако если мы читаем документ по одному символу, то буква  $a$  приносит  $\log_2(1/0.0575) \approx 4.12$  бит, а буква  $z$  приносит  $\log_2(1/0.001) \approx 9.96$  бит. То есть большая часть информации в случае слова, начинающегося на  $z$  сосредоточена в первой букве. Таким образом, чем более редкое сочетание в начале слова, тем с большей вероятностью можно угадать остаток слова. Все это

верно и для реального естественного языка. Например, слов, начинающихся с ло- (лотос, лодка, лопата, ...) в русском языке намного больше чем слов, начинающихся с йо- (йод, йог, йогурт).

Итак, подходим к идее сжатия данных. Маловероятное значение случайной переменной дает больше бит информации, чем вероятное. Если удастся какой-либо источник (текст например) закодировать в файл, размером  $L$  бит на символ, а затем надежно восстановить источник из этого файла, то можно будет с уверенностью сказать, что источник содержал информации не более  $L$  бит на символ. Простой пример это текстовый файл в кодировке ASCII, в котором, несмотря на 8-битовое представление символа, нужно только 7 бит. Значит, этот файл можно сжать с фактором 7/8.

Самый простой способ посчитать количество информации в случайной переменной это посчитать число возможных исходов, т.е.  $|A_x|$ . Если поставить соответствие между элементами множества  $A_x$  и двоичным числом, то длина этого числа в битах равна  $\log_2|A_x|$  если конечно  $|A_x|$  кратно 2. Таким образом, количество бит, необходимое для представления ансамбля  $X$  определим как

$$H_0(X) = \log_2|A_x| \quad (3.3)$$

Число  $H_0(X)$  это нижняя граница числа вопросов в игре в угадывание на множестве  $A_x$  для гарантированного угадывания. Из (3.3) ясно, что  $H_0(X)$  величина аддитивная. Для упорядоченной пары  $x, y$ , когда имеется  $|A_x| \cdot |A_y|$  возможных исходов

$$H_0(X, Y) = H_0(X) + H_0(Y) \quad (3.4)$$

Как мера информации в ансамбле, величина  $H_0(X)$  не учитывает вероятностные особенности  $A_x$ , а просто соответствует случаю отображения множества  $A_x$  в строку битов фиксированной длины. Очевидно, что нельзя реализовать алгоритм, сжимающий исходные данные из  $A_x$  в строку битов короче  $H_0(X)$ , так чтобы осуществить декомпрессию без ошибок. С другой стороны, возможно сжатие с потерями, которые являются приемлемыми. Сжатие с потерями широко используется при сжатии изображений или звуковых файлов.

Рассмотрим сжатие с потерями на примере. Пусть случайная величина принадлежит множеству  $A_x = \{a, b, c, d, e, f, g, h\}$  с распределением вероятностей  $P_x = \left\{ \frac{1}{4}, \frac{1}{4}, \frac{1}{4}, \frac{3}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64} \right\}$ . В этом случае  $H_0(X) = \log_2 8 = 3$  бита, то есть можно представить множество  $A_x$  3-битовыми строками как показано ниже в таблице.

$x$	$a$	$b$	$c$	$d$	$e$	$f$	$g$	$h$
$c(x)$	000	001	010	011	100	101	110	111

Обратим внимание на то, что  $P(x \in \{a, b, c, d\}) = \frac{15}{16}$ , а это значит, что если допустить вероятность того, что битовая строка не найдет подходящего символа из набора  $\delta = \frac{1}{16}$ , то можно оставить только половину множества  $A_x$ . Таким образом, для битового кодирования в данном случае понадобится только 2 бита:

$x$	$a$	$b$	$c$	$d$
$c(x)$	00	01	10	11

Это, в свою очередь, будет означать сжатие с потерями с фактором  $2/3$  и вероятностью ошибки  $1/16$ .