

# Информатика

Лекция 3

Дискретные источники

# Дискретные источники без памяти

- ◆ Дискретный источник без памяти (ДИБП) полностью задается таблицей распределения вероятностей:

$$X = \begin{pmatrix} x_1 & x_2 & \dots & x_N \\ p_1 & p_2 & \dots & p_N \end{pmatrix}$$

- ◆ Информационные характеристики ДИБП:

Энтропия  $H(X) = -\sum_{i=1}^N p_i \log p_i$ ; максимальная энтропия  $H_{\max} = \log N$

Избыточность  $D = H_{\max} - H(X)$ ;

Относительная избыточность  $D_0 = \frac{D}{H_{\max}} = \frac{H_{\max} - H(X)}{H_{\max}}$ ;

Средняя длительность выдачи одного символа  $\tau_{cp} = \sum_{i=1}^N p_i \tau_i$ ;

Производительность источника  $\bar{I}(X) = \frac{H(X)}{\tau_{cp}}$ .

# Дискретные источники с памятью

Дискретный источник с памятью  $r$  и алфавитом  $x_1, x_2, \dots, x_N$  задается множеством состояний  $\{S_1, S_2, \dots, S_M\}$ ,  $M = N^r$ ; вероятностями  $p^{(j)}(i)$  появления символа  $x_i$  в состоянии  $S_j$ ; графом перехода из состояния  $S[n] = (x[n-r], x[n-r+1], \dots, x[n-1])$  в  $S[n+1] = (x[n-r+1], x[n-r+2], \dots, x[n])$  после появления очередного символа  $x[n]$ ; начальным распределением состояний  $\mathbf{p}_0 = (p_0(1), p_0(2), \dots, p_0(M))$ .

Будем предполагать стационарность (независимость от начала отсчета времени) и эргодичность (однотипность всех возможных последовательностей символов). Любой стационарный источник можно представить как несколько эргодических источников, различающихся режимами работы.

Совместные энтропии возрастающих последовательностей символов:

$H(X_1X_2)$ ,  $H(X_1X_2X_3)$ , дают в среднем на один символ энтропию

$$H_L(X) = \frac{1}{L} H(X_1X_2 \dots X_L).$$

Условная энтропия  $L$ -го символа  $H(X_L | X_1X_2 \dots X_{L-1})$ .

Теорема.  $\lim_{L \rightarrow \infty} H(X_L | X_1X_2 \dots X_{L-1}) = \lim_{L \rightarrow \infty} H_L(X) = H_\infty(X)$ .

# Цепи Маркова

Математической моделью ДИСП является цепь Маркова. Это последовательность состояний  $S[1], S[2], \dots, S[n], \dots$ , каждое из которых принадлежит множеству  $\{S_1, S_2, \dots, S_M\}$ , и заданные вероятности перехода  $\pi_{n_2 n_1}(j_2 | j_1) = P(S[n_2] = S_{j_2} | S[n_1] = S_{j_1})$ .

Они должны удовлетворять следующим свойствам:

1.  $\sum_{j_2=1}^M \pi_{n_2 n_1}(j_2 | j_1) = 1$  (полная группа);
2.  $\pi_{n_3 n_1}(j_3 | j_1) = \sum_{j_2=1}^M \pi_{n_3 n_2}(j_3 | j_2) \cdot \pi_{n_2 n_1}(j_2 | j_1)$  (равенство Колмогорова-Чэпмена).

Для стационарного ДИСП (независимого от начала отсчета времени) достаточно задать

$\pi_{n_1+l, n_1}(j_2 | j_1) = P(S[n_1 + l] = S_{j_2} | S[n_1] = S_{j_1})$ , то есть матрицу

$$\Pi = \begin{pmatrix} \pi_{n+1, n}(1|1) & \pi_{n+1, n}(2|1) & \boxtimes & \pi_{n+1, n}(M|1) \\ \pi_{n+1, n}(1|2) & \pi_{n+1, n}(2|2) & \boxtimes & \pi_{n+1, n}(M|2) \\ \boxtimes & \boxtimes & \boxtimes & \boxtimes \\ \pi_{n+1, n}(1|M) & \pi_{n+1, n}(2|M) & \boxtimes & \pi_{n+1, n}(M|M) \end{pmatrix},$$

тогда по равенству Колмогорова-Чэпмена,

$$\mathbf{p}_n = (p_n(1), p_n(2) \boxtimes p_n(M)) = \mathbf{p}_0 \cdot \Pi^n, \text{ где } \mathbf{p}_0 = (p_0(1), p_0(2) \boxtimes p_0(M)).$$

Из эргодичности ДИСП следует регулярность цепи Маркова, т.е.

существование предела  $\Pi_\infty = \lim_{n \rightarrow \infty} \Pi^n$ . Тогда все строки матрицы  $\Pi_\infty$

равны предельному распределению  $\mathbf{p}_\infty = (p_\infty(1), p_\infty(2) \boxtimes p_\infty(M))$ ,

являющемуся собственным вектором:  $\mathbf{p}_\infty = \mathbf{p}_\infty \Pi$ .


Энтропия в этом случае равна  $H_\infty(X) = \sum_{j=1}^M p_\infty(j) H(X | S_j)$ , где

$$H(X | S_j) = -\sum_{i=1}^N p^{(j)}(i) \cdot \log p^{(j)}(i).$$

**Пример.** Двоичный источник имеет память  $r = 2$  и вероятности появления символов для каждого состояния даны в таблице:

$S_1 = (00)$	0	1	$S_2 = (11)$	0	1
$p^{(1)}$	0	1	$p^{(2)}$	$\frac{1}{2}$	$\frac{1}{2}$
$S_3 = (01)$	0	1	$S_4 = (10)$	0	1
$p^{(3)}$	$\frac{2}{3}$	$\frac{1}{3}$	$p^{(4)}$	$\frac{3}{4}$	$\frac{1}{4}$

Граф состояний:



Матрица переходных вероятностей:

$$\mathbf{\Pi} = \begin{pmatrix} 0 & 0 & 1 & 0 \\ 0 & \frac{1}{2} & 0 & \frac{1}{2} \\ 0 & \frac{1}{3} & 0 & \frac{2}{3} \\ \frac{3}{4} & 0 & \frac{1}{4} & 0 \end{pmatrix}$$

Предельная матрица  $\Pi_\infty = \lim_{n \rightarrow \infty} \Pi^n = \frac{1}{41} \begin{pmatrix} 9 & 8 & 12 & 12 \\ 9 & 8 & 12 & 12 \\ 9 & 8 & 12 & 12 \\ 9 & 8 & 12 & 12 \end{pmatrix}$ , значит

$\mathbf{P}_\infty = \left( \frac{9}{41} \quad \frac{8}{41} \quad \frac{12}{41} \quad \frac{12}{41} \right)$ . Энтропии для каждого состояния:

$$H(X | S_1) = 0; H(X | S_2) = 1; H(X | S_3) = 0,918; H(X | S_4) = 0,811.$$

Энтропия всего источника

$$H_\infty(X) = 0 \cdot \frac{9}{41} + 1 \cdot \frac{8}{41} + 0,918 \cdot \frac{12}{41} + 0,811 \cdot \frac{12}{41} = 0,701.$$

Если не принимать во внимание различие состояний, то есть считать этот источник источником без памяти, то

$$P(0) = 0 \cdot \frac{9}{41} + \frac{1}{2} \cdot \frac{8}{41} + \frac{2}{3} \cdot \frac{12}{41} + \frac{3}{4} \cdot \frac{12}{41} = \frac{21}{41};$$

$$P(1) = 1 \cdot \frac{9}{41} + \frac{1}{2} \cdot \frac{8}{41} + \frac{1}{3} \cdot \frac{12}{41} + \frac{1}{4} \cdot \frac{12}{41} = \frac{20}{41} \text{ и } H(X) = 0,999.$$

# Информационные характеристики ДИСП:

Объем памяти  $r$ ; Энтропия  $H_{\infty}(X) = \sum_{j=1}^M p_{\infty}(j) H(X | S_j)$ ;

Максимальная энтропия  $H_{\max} = \log N$ ;

Избыточность  $D = H_{\max} - H_{\infty}(X)$ ;

Относительная избыточность  $D_0 = \frac{D}{H_{\max}} = \frac{H_{\max} - H_{\infty}(X)}{H_{\max}}$ ;

Средняя длительность выдачи одного символа  $\tau_{cp} = \sum_{i=1}^N p_i \tau_i$ ,

где  $p_i = \sum_{j=1}^M p_{\infty}(j) p^{(j)}(i)$ ;

Производительность источника  $\bar{I}(X) = \frac{H_{\infty}(X)}{\tau_{cp}}$ .