

Современная теория информации

Лекция 3. Энтропия на сообщение дискретного источника.

Префиксные коды.

Беляев Евгений Александрович

eabelyaev@itmo.ru

1. Энтропия на сообщение дискретного источника.
2. Префиксные коды.
3. Неравенство Крафта.
4. Прямая и обратная теоремы побуквенного кодирования.
5. Код Хаффмана.

Рассмотрим $\mathbf{x} = (x_1, x_2, \dots, x_n)$ из $X_1 X_2 \dots X_n = X^n$.

Энтропия $H(X_1 X_2 \dots X_n) = H(X^n)$ называется *n-мерной энтропией* процесса.

Энтропия на символ для последовательности длины n определяется как:

$$H_n(X) = \frac{H(X^n)}{n}.$$

Другой способ:

$$H(X_n | X_1, \dots, X_{n-1}) = H(X | X^{n-1}).$$

Энтропия на сообщение:

$$\lim_{n \rightarrow \infty} H_n(X) \text{ и } \lim_{n \rightarrow \infty} H(X | X^n).$$

Теорема. Для дискретного стационарного процесса (источника):

- A. $H(X|X^n)$ не возрастает с увеличением n ;
- B. $H_n(X)$ не возрастает с увеличением n ;
- C. $H_n(X) \geq H(X|X^{n-1})$;
- D. $\lim_{n \rightarrow \infty} H_n(X) = \lim_{n \rightarrow \infty} H(X|X^n)$.

Доказательство.

A. Следует из невозрастания энтропии с увеличением числа условий.

$$\begin{aligned} \text{C. } H(X^n) &= H(X) + H(X|X^1) + \dots + H(X|X^{n-1}) \geq \\ &\geq nH(X|X^{n-1}) \geq nH(X|X^n) \end{aligned}$$

$$\text{B. } H(X^{n+1}) \stackrel{(a)}{=} H(X_1 \dots X_n X_{n+1})$$

$$\stackrel{(b)}{=} H(X_1 \dots X_n) + H(X_{n+1} | X_1, \dots, X_n)$$

$$\stackrel{(c)}{\leq} nH_n(X) + H_n(X)$$

$$\stackrel{(d)}{=} (n+1)H_n(X).$$

$$H(X^{n+1}) \leq (n+1)H_n(X).$$

$$\Rightarrow \frac{H(X^{n+1})}{n+1} = H_{n+1}(X) \leq H_n(X)$$

Доказательство.

Д1. $H_n(X)$ и $H(X|X^n)$ ограничены снизу (≥ 0) и не возрастают, т.е., существуют пределы $\lim_{n \rightarrow \infty} H_n(X)$ и $\lim_{n \rightarrow \infty} H(X|X^n)$.

Из С следует, что: $\lim_{n \rightarrow \infty} H_n(X) \geq \lim_{n \rightarrow \infty} H(X|X^n)$.

Д2. Для $m < n$:

$$\begin{aligned} H(X^n) &= H(X_1 \dots X_n) = \\ &\stackrel{(a)}{=} H(X_1 \dots X_m) + H(X_{m+1}|X_1, \dots, X_m) + \dots + H(X_n|X_1, \dots, X_{n-1}) \\ &\stackrel{(b)}{\leq} {}^1 m H_m(X) + (n - m) H(X|X^m). \end{aligned}$$

После деления на n : $\lim_{n \rightarrow \infty} H_n(X) \leq H(X|X^m)$, для любого m .

Устремляем $m \rightarrow \infty$: $\lim_{n \rightarrow \infty} H_n(X) \leq \lim_{m \rightarrow \infty} H(X|X^m)$.

¹В правой части учитываем m предыдущих символов, вместо n

Обозначим $H_\infty(X) = \lim_{n \rightarrow \infty} H_n(X)$, $H(X|X^\infty) = \lim_{n \rightarrow \infty} H(X|X^n)$, тогда

$$H_\infty(X) = H(X|X^\infty)$$

Два способа кодирования:

- ▶ Расширение алфавита: буквы это последовательности исходных букв длины n .
- ▶ Учёт зависимости текущей буквы от n предшествующих букв.

- ▶ $H(X_1 \dots X_n) = H(X_1) + \dots + H(X_n)$.
- ▶ $H(X^n) = nH(X)$.
- ▶ $H_n(X) = H(X)$,
- ▶ $H_\infty(X) = H(X)$.
- ▶ $H(X|X^n) = H(X_{n+1}|X_1, \dots, X_n) = H(X)$,
- ▶ $H(X|X^\infty) = H(X)$.

Отсюда не следует, что для такого источника нужно кодировать каждую букву независимо от других.

$$\blacktriangleright H(X|X^n) = H(X_{n+1}|X_1, \dots, X_n) = H(X_{n+1}|X_{n-s+1}, \dots, X_n) = H(X|X^s).$$

$$\blacktriangleright H(X|X^\infty) = H(X|X^s).$$

$$\blacktriangleright H(X^n) = H(X_1 \dots X_s X_{s+1} \dots X_n)$$

$$= H(X_1 \dots X_s) + H(X_{s+1} \dots X_n | X_1, \dots, X_s).$$

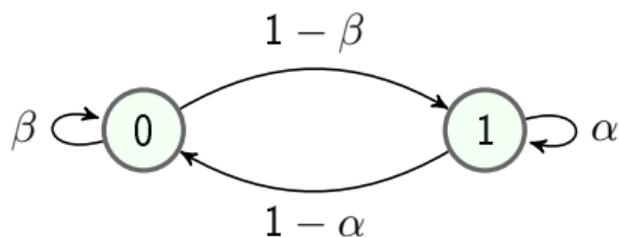
$$\blacktriangleright H(X_{s+1} \dots X_n | X_1, \dots, X_s) = H(X_{s+1} | X_1, \dots, X_s) +$$

$$+ H(X_{s+2} | X_2, \dots, X_{s+1}) + \dots$$

$$+ H(X_n | X_{n-s}, \dots, X_{n-1})$$

$$= (n-s)H(X|X^s).$$

$$\blacktriangleright \frac{H(X^n)}{n} = \frac{sH_s(X)}{n} + \frac{(n-s)H(X|X^s)}{n}$$



$$\Pi = \begin{bmatrix} \beta & 1 - \beta \\ 1 - \alpha & \alpha \end{bmatrix}, \begin{cases} p_0 = \frac{(1-\alpha)}{2-\beta-\alpha}, \\ p_1 = \frac{(1-\beta)}{2-\beta-\alpha}. \end{cases}$$

▶ $H(X) = -p_0 \log p_0 - p_1 \log p_1 = \eta(p_0) = \eta(p_1).$

▶ $H(X|X) =$

$$= - \sum_{x_1 \in X} \left(p(x_1) \sum_{x_2 \in X} p(x_2|x_1) \log p(x_2|x_1) \right) = - \sum_{x_1=0}^1 \left(p(x_1) \sum_{x_2=0}^1 p(x_2|x_1) \log p(x_2|x_1) \right) =$$

$$- p_0 p(0|0) \log p(0|0) - p_0 p(1|0) \log p(1|0) - p_1 p(0|1) \log p(0|1) - p_1 p(1|1) \log p(1|1) =$$

$$- p_0 \beta \log \beta - p_0 (1 - \beta) \log(1 - \beta) - p_1 \alpha \log \alpha - p_1 (1 - \alpha) \log(1 - \alpha) = p_0 \eta(\beta) + p_1 \eta(\alpha).$$

▶ $H_2(X) = \frac{H(X)+H(X|X)}{2}$, $H_3(X) = \frac{H(X)+2H(X|X)}{3}$, $H_n(X) = \frac{H(X)+(n-1)H(X|X)}{n}.$

- ▶ Информационная производительность дискретного источника без памяти определяется его энтропией $H(X)$.
- ▶ $H(X) \leq \log |X|$, равенство когда все символы равновероятны.
- ▶ Энтропия на символ дискретного стационарного источника определяется как
$$\lim_{n \rightarrow \infty} H_n(X) = \lim_{n \rightarrow \infty} H(X|X^n)$$
- ▶ Наилучшее сжатие может быть достигнуто либо кодированием длинных блоков символов, либо с учётом длинной предыстории для каждого символа.

Рассмотрим дискретный источник без памяти.

- ▶ $X = \{1, \dots, M\}$, $\{p_1, \dots, p_M\}$. $C = \{c_1, \dots, c_M\}$, кодовые слова длины l_1, \dots, l_M .
- ▶ Средняя длина кодового слова:

$$\bar{l} = E[l_i] = \sum_{i=1}^M p_i l_i$$

$H(X)$ – нижняя граница для \bar{l} .

| Буква | Кодовое слово |
|-------|---------------|
| е | · |
| а | ·— |
| j | · — — — |
| q | — — ·— |

Декодировать: · — — — ·—

| Буква | Кодовое слово |
|-------|---------------|
| е | · |
| а | ·— |
| j | · — — — |
| q | — — ·— |

Декодировать: · — — — ·— → *aq* или *ja* ?

Для однозначного декодирования кода необходимы разделители (“паузы”) между кодовыми словами.

Пример: $X = \{a, b, c, d\}$

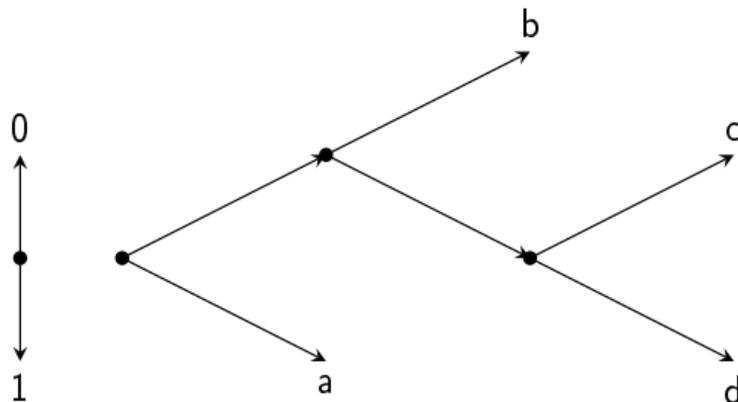


Рис.: Пример двоичного кодового дерева

| Буква | Кодовое слово |
|-------|---------------|
| a | 1 |
| b | 00 |
| c | 010 |
| d | 011 |

Декодировать: 0101001010 ...

Свойства:

- ▶ Код называется *префиксным*, если ни одно кодовое слово не является началом другого кодового слова.
- ▶ Префиксный код является однозначно декодируемым.
- ▶ Если только листья двоичного дерева соответствуют кодовым словам, то код является префиксным.
- ▶ Однозначно декодируемый код не обязательно является префиксным.
- ▶ Древовидный код является префиксным.

$$X = \{0, 1, 2, 3\}$$

Какой код является

- ▶ префиксным?
- ▶ однозначно декодируемым?

1. $C_1 = \{00, 01, 10, 11\}$;

2. $C_2 = \{1, 01, 001, 000\}$;

3. $C_3 = \{1, 10, 100, 000\}$;

4. $C_4 = \{0, 1, 10, 01\}$;

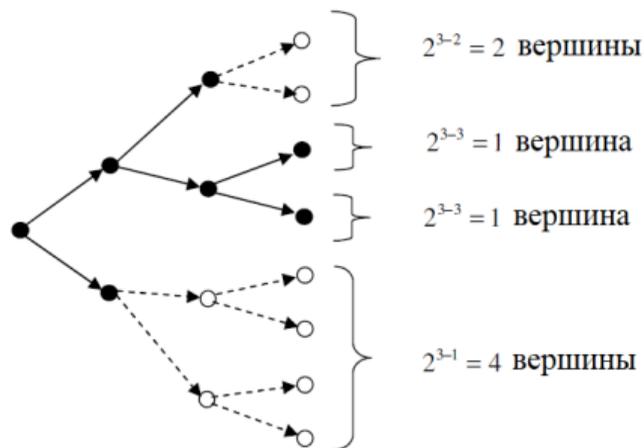
5. $C_5 = \{0, 1, 12, 31\}$;

Теорема. Необходимым и достаточным условием существования префиксного кода объёмом M с длинами кодовых слов l_1, \dots, l_M является выполнение неравенства:

$$\sum_{i=1}^M 2^{-l_i} \leq 1.$$

Неравенство верно для любого префиксного кода.

Выберем L , такое что $L \geq \max_i l_i$. Концевая вершина исходного дерева, расположенная на глубине l_i , имеет 2^{L-l_i} потомков на глубине L . Причем, множества концевых потомков не пересекается.



$$\sum_{i=1}^M 2^{L-l_i} \leq 2^L.$$

- ▶ Сортируем $\{l_i\}$ по убыванию.
- ▶ Из всего числа вершин на ярусе l_1 выберем любую и закрепим её за первым кодовым словом. Продолжим оставшиеся вершины до яруса l_2 . На этом ярусе будет свободно $2^{l_2} - 2^{l_2-l_1}$ вершин. Умножив $\sum_{i=1}^M 2^{-l_i} \leq 1$ для $M = 2$ на 2^{l_2} , получим $2^{l_2} - 2^{l_2-l_1} \geq 1$, то есть как минимум одна свободная вершина есть.
- ▶ $2^{l_3} - 2^{l_3-l_2} - 2^{l_3-l_1} \geq 1$.
- ▶ ...
- ▶ $2^{l_M} - 2^{l_M-l_{M-1}} - 2^{l_M-l_{M-2}} - \dots - 2^{l_M-l_1} \geq 1$

Теорема. Для любого однозначно декодируемого двоичного кода объёмом M с длинами кодовых слов l_1, \dots, l_M справедливо неравенство:

$$\sum_{i=1}^M 2^{-l_i} \leq 1.$$

Теорема. Для ансамбля $X = \{x, p(x)\}$ с энтропией $H(X) = H$ существует побуквенный неравномерный префиксный код со средней длиной кодовых слов $\bar{l} < H + 1$.

Доказательство.

1. Пусть $l_i = \lceil -\log p_i \rceil$. Тогда $\sum_{i=1}^M 2^{-l_i} = \sum_{i=1}^M 2^{-\lceil -\log p_i \rceil} \leq \sum_{i=1}^M 2^{\log p_i} = 1 \Rightarrow$ такой префиксный код существует.
2. $\bar{l} = \sum_{m=1}^M p_m l_m < \sum_{m=1}^M p_m (-\log p_m + 1) < H + 1$.

Теорема. Для любого однозначно декодируемого кода для дискретного источника $\{X, p(x)\}$ с энтропией H , $\bar{l} \geq H$.

Доказательство.

$$\begin{aligned} H - \bar{l} &= - \sum_{x \in X} p(x) \log p(x) - \sum_{x \in X} p(x) l(x) \\ &= \sum_{x \in X} p(x) \log \frac{2^{-l(x)}}{p(x)} \leq \log e \sum_{x \in X} p(x) \left(\frac{2^{-l(x)}}{p(x)} - 1 \right) \\ &\leq \log e \left(1 - \sum_{x \in X} p(x) \right) = 0 \end{aligned}$$

1. Вероятности символов сортируются по убыванию вероятностей и затем разбиваются на два множества с почти равной вероятностью.
2. Каждое подмножество кодируется 0 или 1 в двоичном дереве.
3. Каждое из полученных множеств разбивается еще на два аналогичным образом.
4. Этот процесс продолжается до тех пор, пока каждое подмножество не будет содержать только один символ².

| x | $p(x)$ | $c(x)$ |
|-----|--------|--------|
| a | 0.35 | 00 |
| b | 0.20 | 01 |
| c | 0.15 | 100 |
| d | 0.1 | 101 |
| e | 0.1 | 110 |
| f | 0.1 | 111 |

²R.M. Fano, Technical Report No. 65, The Research Laboratory of Electronics, M.I.T., 1949.

Свойства оптимального кода:

1. Если $p_i < p_j$, то $l_i \geq l_j$.
2. Не менее двух кодовых слов имеют одинаковую длину $l_M = \max_m l_m$. Если у нас имеется только одно кодовое слово максимальной длины, то код не оптимален, так как мы можем убрать последний символ такого кодового слова.
3. Среди кодовых слов длиной $l_M = \max_m l_m$ найдутся два слова, различающиеся только в одном последнем символе.

Этими свойствами обладает код Хаффмана³.

³D.Huffman, A Method for the Construction of Minimum-Redundancy Codes, *Proceedings of the IRE*, 1952

Свойства оптимального кода:

4. Пусть $p_1 \geq p_2 \geq \dots \geq p_M$.

- ▶ Для ансамбля $X = \{1, \dots, M\}$ и кода C , удовлетворяющего свойствам 1–3, введем ансамбль $X' = \{1, \dots, M-1\}$, сообщениям которого приписаны вероятности $\{p'_1, \dots, p'_{M-1}\}$ так, что

$$\begin{aligned}p'_1 &= p_1, \\p'_2 &= p_2, \\p'_{M-1} &= p_{M-1} + p_M.\end{aligned}$$

- ▶ Из кода C построим код C' для ансамбля X' , приписав сообщениям x'_1, \dots, x'_{M-2} те же кодовые слова, что и в коде C , т.е. $c'_i = c_i$, а сообщению x'_{M-1} слово c'_{M-1} , как общую часть слов c_{M-1} и c_M .
- ▶ Тогда, если C' оптимален для X' , то код C оптимален для X .

Из свойства 3 следует, что:

$$l_m = \begin{cases} l'_m & \text{для } m \leq M-2, \\ l'_{M-1} + 1 & \text{для } m = M-1, M. \end{cases}$$

Тогда средняя длина кодового слова:

$$\begin{aligned} \bar{l} &= \sum_{m=1}^M p_m l_m = \sum_{m=1}^{M-2} p_m l_m + p_{M-1} l_{M-1} + p_M l_M = \\ &= \sum_{m=1}^{M-2} p_m l_m + (p_{M-1} + p_M)(l'_{M-1} + 1) = \\ &= \sum_{m=1}^{M-2} p'_m l'_m + p'_{M-1} l'_{M-1} + p_{M-1} + p_M = \\ &= \sum_{m=1}^{M-1} p'_m l'_m + p_{M-1} + p_M = \bar{l}' + p_{M-1} + p_M. \end{aligned}$$

где $\bar{l}' = \sum_{m=1}^{M-1} p'_m l'_m$ – среднее длина кодового слово кода C' .

a 0.35

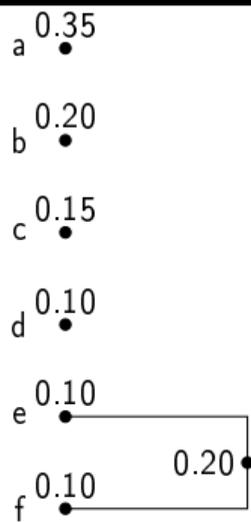
b 0.20

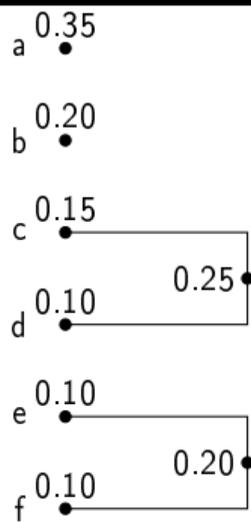
c 0.15

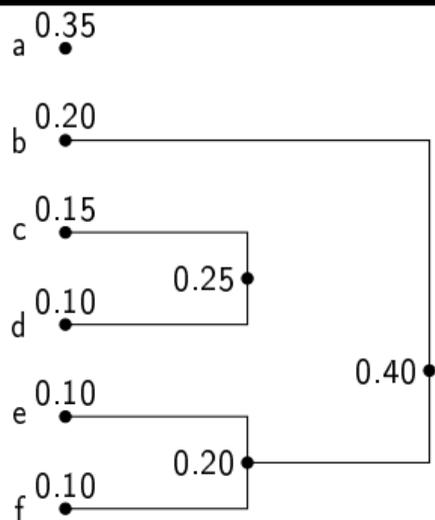
d 0.10

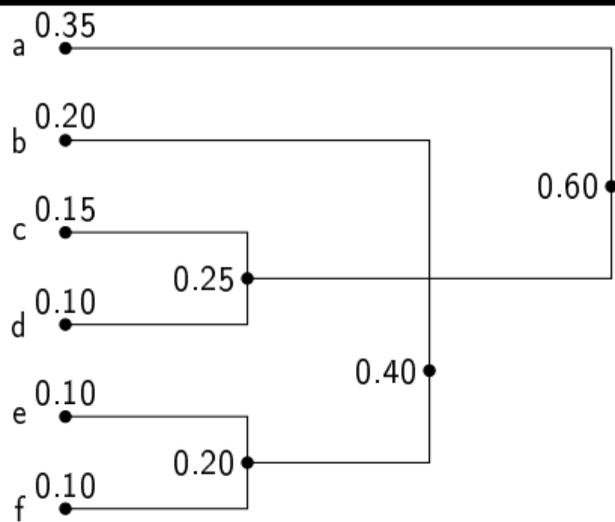
e 0.10

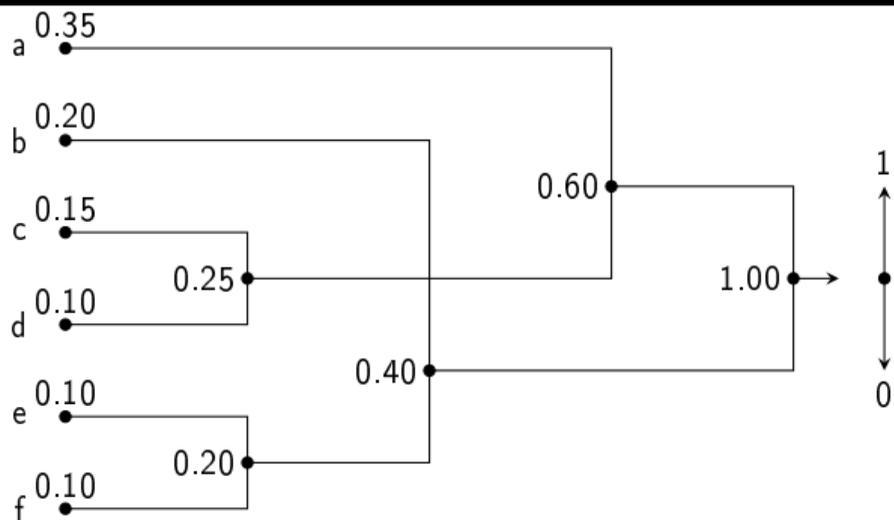
f 0.10



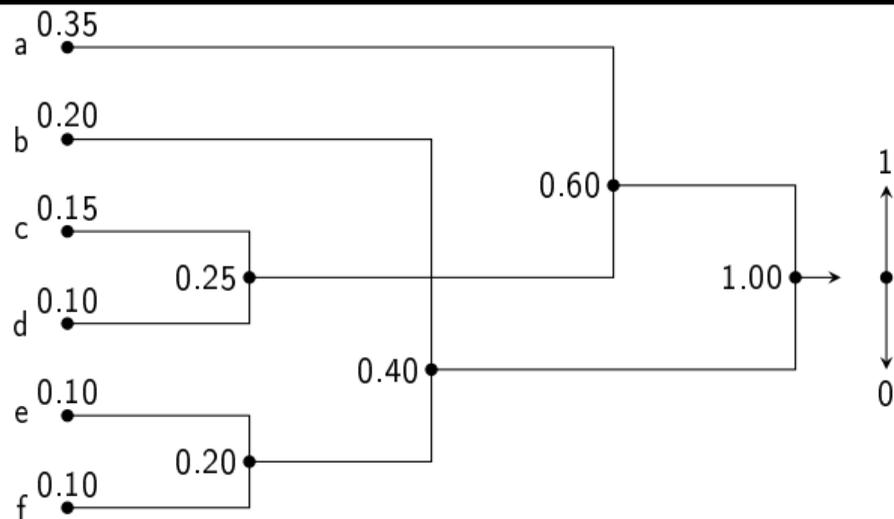






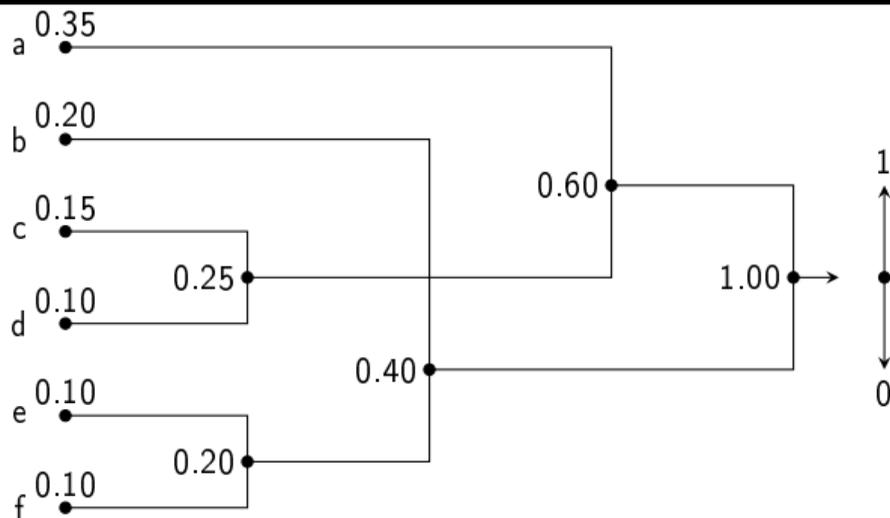


| | |
|---|-----|
| a | 11 |
| b | 01 |
| c | 101 |
| d | 100 |
| e | 001 |
| f | 000 |



| | |
|---|-----|
| a | 11 |
| b | 01 |
| c | 101 |
| d | 100 |
| e | 001 |
| f | 000 |

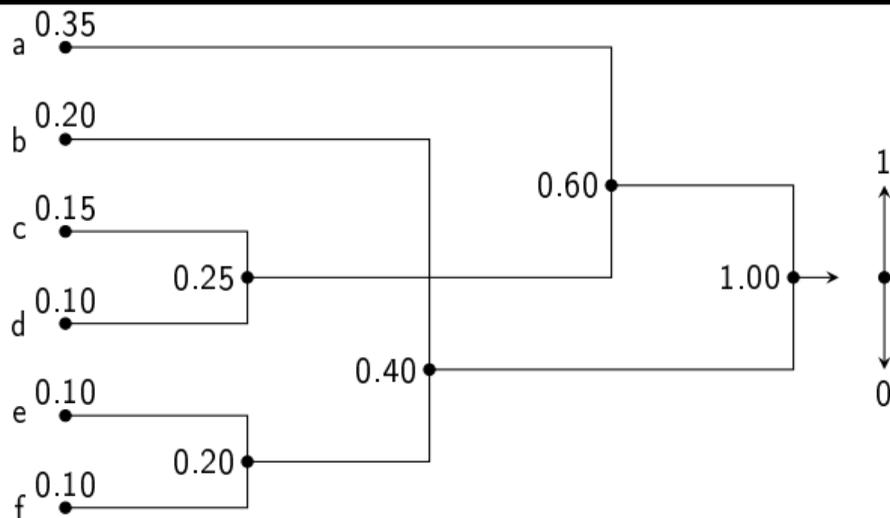
$$H = - \sum_x p(x) \log p(x) = 2.4016$$



| | |
|---|-----|
| a | 11 |
| b | 01 |
| c | 101 |
| d | 100 |
| e | 001 |
| f | 000 |

$$H = - \sum_x p(x) \log p(x) = 2.4016$$

$$\bar{l} = \sum_x l(x) p(x) = 2.4500$$



| | |
|---|-----|
| a | 11 |
| b | 01 |
| c | 101 |
| d | 100 |
| e | 001 |
| f | 000 |

$$H = - \sum_x p(x) \log p(x) = 2.4016$$

$$\bar{l} = \sum_x l(x) p(x) = 2.4500$$

- ▶ P – матрица, в которой хранятся вероятности появления сообщений.
- ▶ L – матрица длин кодовых слов.
- ▶ C – матрица кодовых слов размером $M \times M$.
- ▶ T – матрица потомков узлов $M \times M$.

$$P = \begin{pmatrix} 0.5 \\ 0.25 \\ 0.125 \\ 0.125 \end{pmatrix}, C = \begin{pmatrix} - & - & - & - \\ - & - & - & - \\ - & - & - & - \\ - & - & - & - \end{pmatrix}, T = \begin{pmatrix} 0 & - & - & - \\ 1 & - & - & - \\ 2 & - & - & - \\ 3 & - & - & - \end{pmatrix}, L = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}.$$

1. Два сообщения x_2 и x_3 с минимальными вероятностями объединяются. Вероятность нового сообщения записывается во вторую строку P .
2. $C[2, L[2]] \leftarrow 0$, $C[3, L[3]] \leftarrow 1$.
3. Во вторую строку матрицы T записываются номера потомков объединенного узла, то есть все номера узлов, которые находились в строках 2 и 3.
4. $L[2] \leftarrow L[2] + 1$, $L[3] \leftarrow L[3] + 1$.

$$P = \begin{pmatrix} 0.5 \\ 0.25 \\ 0.25 \\ - \end{pmatrix}, C = \begin{pmatrix} - & - & - & - \\ - & - & - & - \\ 0 & - & - & - \\ 1 & - & - & - \end{pmatrix}, T = \begin{pmatrix} 0 & - & - & - \\ 1 & - & - & - \\ 2 & 3 & - & - \\ - & - & - & - \end{pmatrix}, L = \begin{pmatrix} 0 \\ 0 \\ 1 \\ 1 \end{pmatrix}.$$

- ▶ Объединяются x_1 и x_{23} .
- ▶ $C[1, L[1]] \leftarrow 0$, $C[2, L[2]] \leftarrow 1$, $C[3, L[3]] \leftarrow 1$.
- ▶ В $T[1][..]$ записываются номера потомков, которые находились в первой и второй строках.
- ▶ $L[T[1][..]] \leftarrow L[T[1][..]] + 1$.

$$P = \begin{pmatrix} 0.5 \\ 0.5 \\ - \\ - \end{pmatrix}, C = \begin{pmatrix} - & - & - & - \\ 0 & - & - & - \\ 0 & 1 & - & - \\ 1 & 1 & - & - \end{pmatrix}, T = \begin{pmatrix} 0 & - & - & - \\ 1 & 2 & 3 & - \\ - & - & - & - \\ - & - & - & - \end{pmatrix}, L = \begin{pmatrix} 0 \\ 1 \\ 2 \\ 2 \end{pmatrix}.$$

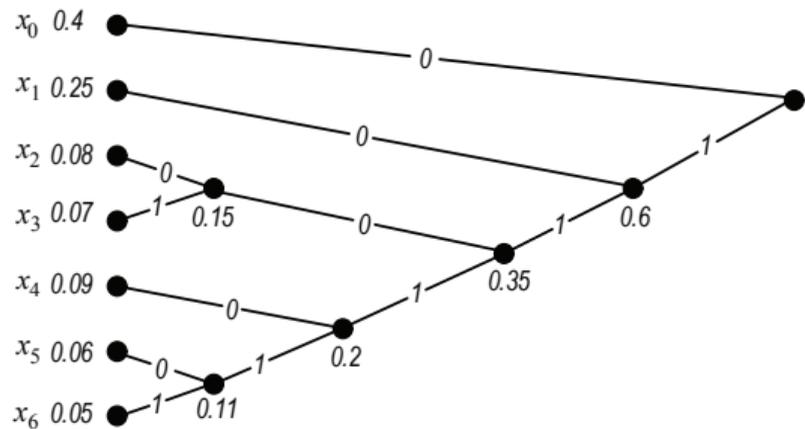
- ▶ Объединяются x_0 и x_{123} .
- ▶ $C[0, L[0]] \leftarrow 0$,
 $C[1, L[1]] \leftarrow 1$, $C[2, L[2]] \leftarrow 1$, $C[3, L[3]] \leftarrow 1$.
- ▶ В $T[0][..]$ записываются номера потомков, которые находились в нулевой и первой.
- ▶ $L[T[0][..]] \leftarrow L[T[0][..]] + 1$.

$$P = \begin{pmatrix} 1.0 \\ - \\ - \\ - \end{pmatrix}, C = \begin{pmatrix} 0 & - & - & - \\ 0 & 1 & - & - \\ 0 & 1 & 1 & - \\ 1 & 1 & 1 & - \end{pmatrix}, T = \begin{pmatrix} 0 & 1 & 2 & 3 \\ - & - & - & - \\ - & - & - & - \\ - & - & - & - \end{pmatrix}, L = \begin{pmatrix} 1 \\ 2 \\ 3 \\ 3 \end{pmatrix}.$$

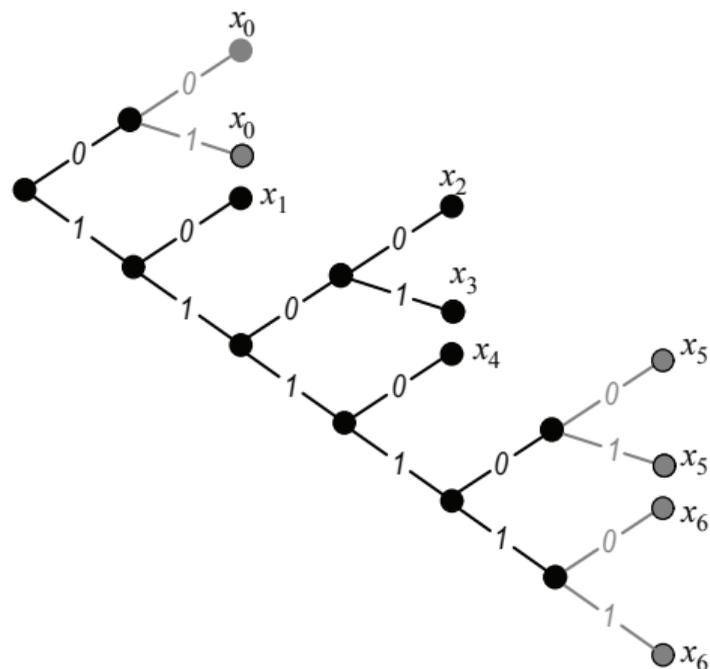
- ▶ Так как длина кодовых слов не кратна 8 битам, кодер должен использовать промежуточный буфер в 2-4 байта.
- ▶ На практике используется заранее подготовленная таблица декодирования.

Таблица: Пример однобитной таблицы декодирования для $X = \{x_0, x_1, x_2, x_3\}$ и $C = \{0, 10, 110, 111\}$

| Адрес, a | b_j | Адрес перехода, $A[a]$ | $x[a]$ |
|------------|-------|------------------------|--------|
| 0 | 0 | - | x_0 |
| 1 | 1 | 2 | - |
| 2 | 0 | - | x_1 |
| 3 | 1 | 4 | - |
| 4 | 0 | - | x_2 |
| 5 | 1 | - | x_3 |



| a | b_j | $A[a]$ | $x[a]$ |
|-----|-------|--------|--------|
| 0 | 0 | – | x_0 |
| 1 | 1 | 2 | – |
| 2 | 0 | – | x_1 |
| 3 | 1 | 4 | – |
| 4 | 0 | 6 | – |
| 5 | 1 | 8 | – |
| 6 | 0 | – | x_2 |
| 7 | 1 | – | x_3 |
| 8 | 0 | – | x_4 |
| 9 | 1 | 10 | – |
| 10 | 0 | – | x_5 |
| 11 | 1 | – | x_6 |



| a | $b_j b_{j+1}$ | $l[a]$ | $A[a]$ | $x[a]$ |
|-----|---------------|--------|--------|--------|
| 0 | 00 | 1 | – | x_0 |
| 1 | 01 | 1 | – | x_0 |
| 2 | 10 | 2 | – | x_1 |
| 3 | 11 | – | 4 | – |
| 4 | 00 | 4 | – | x_2 |
| 5 | 01 | 4 | – | x_3 |
| 6 | 10 | 4 | – | x_4 |
| 7 | 11 | – | 8 | – |
| 8 | 00 | 5 | – | x_5 |
| 9 | 01 | 5 | – | x_5 |
| 10 | 10 | 5 | – | x_6 |
| 11 | 11 | 5 | – | x_6 |



Спасибо за внимание!