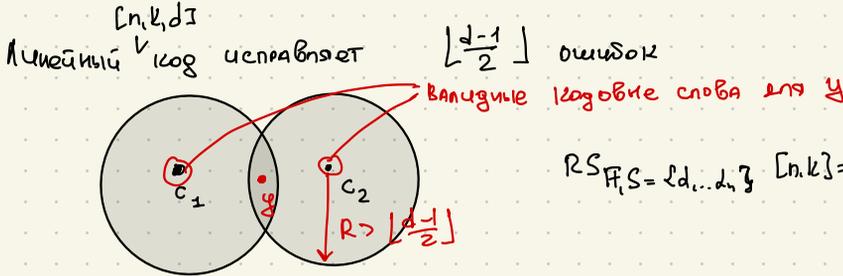


# Лекция №9

## Списочное декодирование Приложение теории кодирования в вычислительной биологии

### I. Списочное декодирование



$$RS_{\mathbb{F}_q, S} = \{d_1, \dots, d_n\} \quad [n, k] = \{ (p(d_1) \dots p(d_n)) \in \mathbb{F}^n \mid p \in \mathbb{F}[x], \deg p \leq k-1 \}$$

ЗАДАЧА ПОИСКА ДВУХ МНОГОЧЛЕНОВ: Положим  $p_1(x), p_2(x) \in \mathbb{F}[x]$ ,  $\deg p_1(x) = \deg p_2(x) = k-1$ ;  $n \geq 4k$  - чётное;  $d_1, \dots, d_n$  - различны.

$\exists T \subset \{1, \dots, n\}$ ,  $|T| = \frac{n}{2}$ . Далее, пусть нам даны  $y \in \mathbb{F}^n$

$$y_i = \begin{cases} p_1(d_i) & , i \in T \\ p_2(d_i) & , i \in \{1, \dots, n\} \setminus T \end{cases}$$

ЗАДАЧА состоит в вычислении  $p_1(x), p_2(x)$  по данным парам  $\{(d_i, y_i)\}_{i \in n}$

Связь с декодированием RS:  $(y_i)_{i \in n}$  - полученное слово, полагая что  $p_1(x)$  - исходное сообщение. Однако,  $p_1(x)$  не совпадает с  $y$  на  $\frac{n}{2}$

значениях;  $\frac{n}{2} > \frac{d-1}{2} = \lfloor \frac{n-k+1-1}{2} \rfloor = \lfloor \frac{n-k}{2} \rfloor$ . Поэтому обычные

алгоритмы декодирования когда RS не подходят.

Идея списочного декодирования  $(y_i - p_1(d_i))(y_i - p_2(d_i)) = 0 \quad \forall i$

Положим, moreover  $Q(x, y) = (y - p_1(x))(y - p_2(x)) = y^2 - \underbrace{(p_1(x) + p_2(x))}_{B(x)} y + \underbrace{p_1(x) \cdot p_2(x)}_{C(x)}$

$$= y^2 - B(x)y + C(x), \quad \text{где } \begin{cases} \deg B(x) = k-1 \\ \deg C(x) = 2(k-1) \end{cases}$$

$Q(d_i, y_i) = 0 \quad \forall i \in n.$

## Алгоритм

### Шаг 1

Составить систему л.н. ур-ий из  $Q(d_i, y_i) = 0$ ;  
 $\{b_0, \dots, b_{k-1}, c_0, \dots, c_{2(k-1)}\}$   $y$  - неизвестные; и  $n$  ур-ий. Т.к.  $n \geq 4k$ ,  
коэф-ты  $B(x)$  коэф-ты  $C(x)$

система будет иметь решение. Получим  $B(x), C(x)$  в явном виде

Сложность:  $O(n^{\omega})$ ,  $2 < \omega \leq 3$

### Шаг 2

Факторизуем м.н.  $Q(x, y) = (y - f_1(x))(y - f_2(x))$ .  
Верны  $f_1(x), f_2(x)$ .

Сложность: факторизация м.н. об. от двух переменных степени  $d$   
на  $\mathbb{F}$ :  $O(d^5 \cdot \lg |F|)$

### Корректность

На шаге I мы всегда отыщем какие-либо  $B(x), C(x)$ ,  $\exists$   
решение  $B(x) = p_1(x) + p_2(x)$ ,  $C(x) = p_1(x) \cdot p_2(x)$ .

Докажем, что на IIм шаге мы получим корректные  $p_1(x), p_2(x)$

### Лемма

$\forall Q(x, y)$ , полученного на шаге I, справедливо

$$(y - p_1(x)) \mid Q(x, y) \text{ и } (y - p_2(x)) \mid Q(x, y)$$

$\triangleleft$  Док-м утверждение для  $p_1(x)$

Заметим, что  $Q(x, y)$  - унитарный (от  $y$ ) м.н. Для того, чтобы показать,

что  $(y - \beta)$  делит  $Q$ , достаточно показать, что  $\beta$  - корень  $Q \Rightarrow$

$Q(\beta) = 0$ . Чтобы показать,  $y - p_1(x) \mid Q(x, y)$ , покажем, что

$$Q(x, p_1(x)) = 0$$

$$\neq R(x) := Q(x, p_1(x)), \quad \deg R(x) \leq 2(k-1)$$

$$\stackrel{||}{=} p_1(x)^2 - (p_1(x) + p_2(x)) \cdot p_1(x) + p_1(x) p_2(x)$$

Заметим, что  $\exists \frac{n}{2} \geq 2k$   $d_i$ , т.ч.  $p_1(d_i) = y_i$ . Для таких  $d_i$ , справедливо:

$R(d_i) = Q(d_i, p_1(d_i)) = Q(d_i, y_i) = 0 \Rightarrow$  мы нашли  $\frac{n}{2} \geq 2k$  корней м.н.на

степени  $\leq 2(k-1) \Rightarrow R(x) \equiv 0$ .

# II ЗАДАЧА: ГРУППОВОЕ ТЕСТИРОВАНИЕ (group testing)

Пример Даны  $N$  человек,  $s \ll N$  из которых заражены.  
 ЗАДАЧА: выявить заражённых за min. число тестов

Тривиальное решение сделать  $N$  тестов может быть дорогим.

МОЖНО ЛИБО СМЕШАТЬ ОБРАЗЦЫ КРОВИ ТАК, ЧТОБЫ МОЖНО БЫЛО ВЫЯВИТЬ БОЛЬНЫХ / ЗДОРОВЫХ ЗА МЕНЬШЕЕ ЧИСЛО ТЕСТОВ

## ИДЕЯ

- Ассоциируем с каждым человеком кодовое слово  $c \in RS_{\mathbb{F}_5, S} [n, k]$
- имеем  $n \cdot |\mathbb{F}|$  кодов / тестов, сформированных в матрицу  $|\mathbb{F}| \times n$ , где столбцы пронумерованы  $\{c_i\}$ :
- образцы крови человека, ассоциированного с кодовым словом  $c$ , помещаются в коды  $(c[i], c_i)$
- $d = n - k + 1$  - min. расстояние RS  $\Rightarrow \forall$  два  $c_i, c_j$  отличаются на как min  $d$  позиций.

Пример  $RS_{\mathbb{F}_5}$ ,  $n=5, k=3, d=3, s \leq 2$ ;  $|RS_{\mathbb{F}_5}| = 5^3 = 125 \Rightarrow$  макс. 125 человек

$$c^* = (c_0^*, c_1^*, c_2^*, c_3^*, c_4^*) = (2, 0, 2, 1, 4) -$$

- заражённый №1

$$c^* = (1, 2, 0, 3, 3) -$$

заражённый №2

$$c = (1, 0, 2, 4, 3) -$$

здоровый

| $\mathbb{F}_5$ | $c_0$ | $c_1$ | $c_2$ | $c_3$ | $c_4$ |
|----------------|-------|-------|-------|-------|-------|
| 0              | 0     | 5     | 10    | 15    | 20    |
| 1              | 1     | 6     | 11    | 16    | 21    |
| 2              | 2     | 7     | 12    | 17    | 22    |
| 3              | 3     | 8     | 13    | 18    | 23    |
| 4              | 4     | 9     | 14    | 19    | 24    |

клетка - код (всего 25)

Если  $s=1 \Rightarrow \exists$  3 негативных теста для  $\forall$  здорового;

Если  $s=2 \Rightarrow \exists$  1 негативный тест — || —

## Замечание

можно показать, что для  $1 \leq s \ll N$ , такое групповое тестирование работает корректно, если число тестов удовлетворяет

$$T = O\left(s^2 \cdot \left(\frac{1}{s}\right)^2\right)$$