

## §3 符号

送信したい文章を2進数で送ることを考える。

例えば "math" という文を送るために、アルファベットの集合を

$$X = \{a, b, \dots, z\}$$

とすると  $|X| = 26$  で  $2^4 < 26 \leq 2^5$  より、

$$a: 00000, b: 00001, \dots, z: 11001 \quad \text{とすればよい。}$$

このように文字の集合に対し、2進数に対応させることを符号化  
という。

定義 3.1. 単射の写像  $\sigma: X \rightarrow \bigcup_{n \in \mathbb{N}} \{0, 1\}^n$  を

$X$  の符号という。

$$\tilde{\sigma}$$

$\sigma$  は自然に文の符号に拡張できる。例えば、

$$\tilde{\sigma}(ab) = \sigma(a)\sigma(b) = 0000000001$$

$$\tilde{\sigma}(\text{math}) = \underbrace{00110}_m \underbrace{00000}_a \underbrace{1001100111}_{t \quad h} \quad \text{である。}$$

符号化した文を元に戻すことを復号という。

命題 3.2. 符号  $\sigma$  が復号できるための必要十分条件は.

$\tilde{\sigma} : \bigcup_{n \in \mathbb{N}} X^n \rightarrow \bigcup_{n \in \mathbb{N}} \{0,1\}^n$  が単射であることである.

☺ 復号できる  $\Leftrightarrow$  文章をもとへ戻せる

$\Leftrightarrow \tilde{\sigma}$  も  $\tilde{\sigma} : \bigcup X^n \rightarrow \tilde{\sigma}(\bigcup X^n)$  と

制限したものに逆写像が存在

$\Leftrightarrow \tilde{\sigma}$  が単射

例 復号できない例として.

$\sigma : a \mapsto 0, b \mapsto 1, c \mapsto 01$  がある. このとき.

符号化された文 (符号語)  $01$  の復号は.  $ab$  か  $c$  かわからない!

$\leadsto \tilde{\sigma}(ab) = 01 = \tilde{\sigma}(c)$  より  $\tilde{\sigma}$  が単射でない.

以下では  $\tilde{\sigma}$  が単射なもののみ符号という.

定義 3.3.  $\sigma : X \rightarrow \bigcup_{n \in \mathbb{N}} \{0,1\}^n$  : 符号とす.  $x \in X$  に対し.

$\sigma(x) \in \{0,1\}^k$  であるとき,  $\sigma(x)$  の符号語長は  $k$  である  
としい.

$|\sigma(x)| = k$  で表す.  $\tilde{\sigma}$  についても同様に定義する.

### 定義 3.4.

$\forall x \in X$  に対し  $|\sigma(x)|$  が一定である符号を等長符号という.

### 命題 3.5.

等長符号は復号可能

①  $x = x_1 \cdots x_k, y = y_1 \cdots y_l \in \bigcup_{n \in \mathbb{N}} X^n$  とし  $\tilde{\sigma}(x) = \tilde{\sigma}(y)$  とする.

また  $|\sigma(x_i)| = m$  とする.

$|\tilde{\sigma}(x)| = mk, |\tilde{\sigma}(y)| = ml$  より  $k = l$ . さらに.

$$\tilde{\sigma}(x) = \sigma(x_1) \sigma(x_2) \cdots \sigma(x_k)$$

$$\text{より } \sigma(x_i) = \sigma(y_i)$$

$$\tilde{\sigma}(y) = \sigma(y_1) \sigma(y_2) \cdots \sigma(y_k)$$


$$\sigma \text{ は単射より } x_i = y_i \quad \therefore x = y \quad //$$

定義 3.6. どの符号語  $\sigma(x)$  も他の符号語  $\sigma(y)$  の

接頭語になっていないとき,  $\sigma$  を プレフィックス符号 という.

例  $\sigma(a) = 01$   $\sigma(b) = 011$  とすると  $\sigma(a)$  は  $\sigma(b)$  の  
接頭語になっている。

例 フォレツックス符号は次のように作れる。  $X = \{a, b, c, d, e\}$   
のと



のようにすれば フォレツックスになる。

例えば  $\sigma(d) = 110$  の接頭語は  $11$  と  $1$  だが。

これが他の符号語  $\sigma(x)$  になるには、樹形図の途中が

$x$  に対応するしかない。しかし、作り方からそれはない。

### 命題 3.7

フォレツックス符号は復号可能。

①  $x = x_1 \dots x_k, y = y_1 \dots y_l \in \bigcup_{n \in \mathbb{N}} X^n$ ,  $\tilde{\sigma}(x) = \tilde{\sigma}(y)$  とする。

$$\tilde{\sigma}(x) = \sigma(x_1) \sigma(x_2) \dots \sigma(x_k)$$

||

であるが、

$$\tilde{\sigma}(y) = \sigma(y_1) \sigma(y_2) \dots \sigma(y_l)$$

$|\sigma(x_1)| \neq |\sigma(y_1)|$  であれば、どちらかがもう一方の接頭語になり矛盾。

$\therefore |\sigma(x_1)| = |\sigma(y_1)| \quad \therefore \sigma(x_1) = \sigma(y_1)$  となり  $x_1 = y_1$ .

以下これを続けければ、 $x = y$  となる //

### 命題 3.8

$X = \{x_1, \dots, x_n\}$  とし、 $x_i$  が使用される確率を  $p_i$  とする。

このとき、符号語長の期待値  $L = \sum_{i=1}^n p_i |\sigma(x_i)|$  を。

$S_2(p) \leq L \leq S_2(p) - 1$  とする符号  $\sigma$  が存在する。  
ただし  $S_2(p) = \sum -p_i \log_2 p_i$

⊙  $p = (p_1, \dots, p_n)$  に  $\bar{x}$  とし、 $p_1 \geq p_2 \geq \dots \geq p_n > 0$  を仮定し、


$\frac{1}{2^{k_i-1}} > p_i \geq \frac{1}{2^{k_i}}$  をみたす  $k_i$  をとる。この  $k_i$  は

$k_1 \leq k_2 \leq \dots \leq k_n$  をみたす また、

$\sum_{i=1}^n \frac{1}{2^{k_i}} \leq p_i \leq 1$  をみたすことに注意。

ここで  $\sigma$  を次のように作る。

まず、 $|\sigma(x_i)| = k_i$  とし、樹形図を上から埋める形で作る。



例えば、 $\sigma(x_1) = \overbrace{0 \dots 0}^{k_1, \square}$  であるが、 $k_1$  個の 2 進数は  $2^{k_1}$  個ある  
ので、残り  $2^{k_1} - 1$  個ある。さらに  $|\sigma(x_2)| = k_2 \geq k_1$  だ。

$k_2$  個の 2 進数を考え、符号語を1つ作り出すと、残りは

$2^{k_2} - 2^{k_2 - k_1} - 1$  である。次に  $\sigma(x_3)$  をやると残りは

$$(2^{k_2} - 2^{k_2 - k_1} - 1)(2^{k_3 - k_2}) - 1$$

$= 2^{k_3} - 2^{k_3 - k_1} - 2^{k_3 - k_2} - 1$  となる。これを  $\sigma(x_n)$  までやると、

$$2^{k_n} - 2^{k_n - k_1} - 2^{k_n - k_2} - \dots - 1 = 2^{k_n} - 2^{k_n} \left( \sum_{i=1}^n \frac{1}{2^{k_i}} \right)$$

$\geq 2^{k_n} - 2^{k_n} = 0$  となる。∴ 符号が作れる。

ここで  $L = \sum p_i k_i$  だが、 $\frac{1}{2^{k_i - 1}} > p_i \geq \frac{1}{2^{k_i}}$  だ。

$-k_i + 1 \geq \log_2 p_i \geq -k_i$  なのだ。

$$-\log_2 p_i \leq k_i \leq -\log_2 p_i + 1 \quad \text{なので}$$

$$\begin{aligned} \sum -p_i \log_2 p_i &\leq \sum p_i k_i \leq \sum p_i (-\log_2 p_i + 1) \\ &= -\sum p_i \log_2 p_i + 1. \end{aligned}$$

$$\therefore S_2(p) \leq L \leq S_2(p) + 1 \quad \text{となる.} \quad //$$

→ 効率のよい符号 → テキスト圧縮に応用.

定義 3.9 等長符号  $\sigma$  を考える.  $x, y \in X$  に対し.

$$\sigma(x) = x_1 x_2 \dots x_n \quad (x_i \in \{0, 1\}, y \text{ も同様}) \text{ とするとき}$$

$x$  と  $y$  の距離を

$$d(x, y) = \{i \mid 1 \leq i \leq n, x_i \neq y_i\} \text{ で定義する.}$$

→  $d(\sigma(x), \sigma(y))$  とかくときもある.

これをハミング距離という.


定義 3.10  $\sigma$  は上と同様とする.

$\sigma(x)$  に  $k$  個の誤りがあるとする.

この誤りを誤りがあると判断できるとき.  $k$ -誤り検出符号という.

この誤りを訂正できるとき、 $k$ -誤り訂正符号という。

例(1)  $X = \{a, b, c, d\}$  とし、 $\sigma$  を



$00$  が 1 つ誤り  $01$  になると、 $01$  も符号語なの?

誤りを検出できない。

(2)  $a: 000$        $\sigma$  を定義すると 1-誤り検出になる  
 $b: 011$   
 $c: 101$   
 $d: 110$

命題 3.11.  $M = \min\{d(x, y) \mid x, y \in X, x \neq y\}$  とする。

(1)  $k < M$  に対し、 $\sigma$  は  $k$ -誤り検出

(2)  $k \leq \frac{M-1}{2}$  に対し、 $\sigma$  は  $k$ -誤り訂正。

⊙<sup>(1)</sup>  $\sigma(x)$  に  $l$  ( $\leq k$ ) 個の誤りがあるとき、 $l < M$  より

これは他の符号語にならない。∴ 誤りが検出できる



(2)

また、 $\sigma(x)$  に  $l$  ( $\leq k$ ) 個の誤りがあり、それを  $x'$  とすると、

$d(\sigma(x), x') = l$  であるので  $\forall y \in X$  に対し、

$d(\sigma(y), x') \geq M - l \geq l + 1$  である。∴ 最も近い  $\sigma(x)$  に  $x'$  は訂正できる。

例.  $X = \{a, b, c, d, e, f, g, h\}$  とし、

a: 0000000

$C_1, C_2, C_3, (C_1+C_2), (C_2+C_3), (C_1+C_3), (C_1+C_2+C_3)$

b: 0010111

c: 0101101

で  $\sigma$  を定義すると、 $M=4$  である。

d: 0111010

e: 1001011

3 誤り検出, 1 誤り訂正

f: 1011100

g: 1100110

h: 1110001