



通信路符号化(8章)

情報伝達モデル(簡易版)



情報伝達モデル(複雑版)



情報源符号化と通信路符号化の比較


符号化	目標	実現状況	符号長	定理
情報源符号化	効率化	保存領域・通信時間の節約	最短符号の実現 (平均符号長で評価)	情報源符号化定理 (シャノンの第1基本定理)
通信路符号化	信頼性向上	誤りの検出・訂正	冗長性を付加 (情報速度で評価)	通信路符号化定理 (シャノンの第2基本定理)

通信路符号化の基礎概念

通信路符号化は信頼性の向上を達成するのが目的であり、そのために情報部分の他に冗長部分を加える。すなわち、以下のように表せる。

通信路符号 = 情報部分 + 冗長部分


符号化の際には、いかにして冗長部分を作り出すかが重要となる。



通信路符号の概念図



伝送による系列
の変移



送信情報源アルファベットが $A = \{a_1, a_2, \dots, a_r\}$ で符号語長が n のときの受信空間。

例

通信路符号

$$W = \{w_1, w_2\} \\ = \{000, 111\}$$

$$\Omega_1 = \\ \{000, 001, \\ 010, 100\}$$

$$w_1 = 000$$

通信路符号
語 $w_1 = 000$
(情報部分)

$$B^3 = \{0, 1\}^3$$

3ビットの受信空間

$$\Omega_2 = \\ \{111, 110, \\ 101, 011\}$$

$$w_2 = 111$$

通信路符号語以外
の複号領域が冗長
性を生み出す。

$$110, 101, 011 \in \Omega_2$$

(通信路符号における)記号系列の個数

(送信)情報源アルファベットを $A = \{a_1, a_2, \dots, a_r\}$ とする。

A の元からなる長さ n の系列すべての集合を A^n と書く。

このとき、 A^n には $|A|^n = r^n$ 個の要素が含まれる。

例

$$B = \{0, 1\}$$

$$B^3 = \{000, 001, 010, 011, 100, 101, 110, 111\}$$

$$|B| = 2$$

$$|B^3| = |B|^3 = 2^3 = 8$$

通信路符号化では、送信記号の系列すべてを符号として用いるのではなくて、その中の特定の系列だけを符号として扱う。このことが冗長性を生み出す。

例

$$B^3 = \{000, 001, 010, 011, 100, 101, 110, 111\}$$


の部分集合である $W = \{000, 111\}$ の要素だけを通信路符号として用いる。

定義：(通信路符号)

このように、送信記号系列の部分集合 $W \subset A^n$ を(通信路)符号という。また、通信路符号に含まれる各系列 $w \in W$ を(通信路)符号語といふ。なお、通信路符号としては等長符号が持られることが多い。

情報の付加と通信路符号

情報源符号語に冗長性を表す記号列を付加することで、複号領域を形成できる。



代表的系列

定義:(代表的系列)

情報源 $A = \left\{ \begin{matrix} a_1 & , & a_2 & , & \cdots & , & a_r \\ p_1 & , & p_2 & , & \cdots & , & p_r \end{matrix} \right\}$ の長さ n

の系列の中で、各記号 a_i の出現個数 n_i と n の比が生成確率 p_i に等しいような系列を**代表的系列**という。

例

情報源 $A = \left\{ \begin{matrix} a & , & b & , & c \\ 1/6 & , & 2/6 & , & 3/6 \end{matrix} \right\}$ の長さ12の代表的系列。

$$p_a \simeq \frac{n_a}{n}, \therefore n_a = np_a = 12 \times \frac{1}{6} = 2$$

$$p_b \simeq \frac{n_b}{n}, \therefore n_b = np_b = 12 \times \frac{2}{6} = 4$$

$$p_c \simeq \frac{n_c}{n}, \therefore n_c = np_c = 12 \times \frac{3}{6} = 6$$

*bbaccccbabc
cbccbacbcabc*

⋮

記号出現頻度が、同一。(順序は異なる。)
十分な長さの通報は、ほぼ代表的系列。

練習

次の各情報源と系列の長さに対して、代表的系列をそれぞれ3個示せ。

(1) $B = \left\{ \begin{matrix} 0 & , & 1 \\ 1/3 & , & 2/3 \end{matrix} \right\}$ $n = 24$

(2) $S = \left\{ \begin{matrix} a & , & b & , & c & , & d \\ 1/2 & , & 1/4 & , & 1/6 & , & 1/12 \end{matrix} \right\}$ $n = 24$

代表的系列の個数

性質：(代表的系列の個数とエントロピー)

情報源 $A = \left\{ \begin{matrix} a_1 & , & a_2 & , & \cdots & , & a_r \\ p_1 & , & p_2 & , & \cdots & , & p_r \end{matrix} \right\}$ の十分な長さ n

の代表的系列の個数 N は、次式で表される。

$$N = 2^{nH(A)}$$

ここで、 $H(A)$ は情報源 A のエントロピー。

証明

長さ n の代表的系列を $\mathbf{w} = w_1 \cdots w_n$ とし、
その発生確率を $P(\mathbf{w})$ とする。

記号 a_i の発生確率が p_i であり、それが \mathbf{w} に $n_i = np_i$ 個
含まれているので次式が成り立つ。

$$P(\mathbf{w}) = \prod_{a_i \in A} p_i^{n_i} = \prod_{i=1}^r p_i^{np_i}$$

底の変換と指数法則より、次のように計算できる。

$$P(\mathbf{w}) = \prod_{i=1}^r 2^{np_i \log p_i} = 2^{n \sum_{i=1}^r p_i \log p_i}$$

$$= 2^{-nH(A)}$$

n が十分大きければ、代表的系列以外の発生確率は0に漸近する。したがって、代表的系列 \mathcal{W} の個数 N は発生確率の逆数である。すなわち、次式が成り立つ。

$$N = \frac{1}{P(w)} = 2^{nH(A)}$$

QED

情報(伝送)速度

定義:(通信路符号の情報(伝送)速度)

通信路符号 $W = \{w_1, \dots, w_M\} \subseteq A^n$ に対して、
通信路記号1記号あたりに伝送される情報量を、
情報速度あるいは**情報伝送速度**という。

情報速度は主に

R [bit/(通信路) 記号]
の記号が用いられ、

$$R = \frac{\log |W|}{n} = \frac{\log M}{n}$$

と表される。

速度を意味する
Rate
の頭文字。

情報伝送速度の物理的意味

1秒(単位時間)あたりに伝送可能な記号 k [記号/秒] とする。
このとき、1秒あたりで伝送される情報量 R^* [bit/秒] は、
次式で与えられる。

$$R^*[bit/\text{秒}] = k[\text{記号}/\text{秒}] \times R[bit/\text{記号}]$$

[bbs](Bit Per Second)

物理的な通信速度としてよく現れる。
1秒あたりに通信されるビット数(通信路符号を
伝送する際の記号数)

情報(伝送)速度の直観的意味



情報部分のビット長
2
は送信系列の総数

情報部分のビット長
情報速度 = $\frac{\text{情報部分のビット長}}{\text{通信路符号のビット長}}$

通信路符号のビット長
2
は受信の可能性がある系列の総数

$$= \frac{\text{情報部分のビット長}}{\text{情報部分のビット長} + \text{冗長部分のビット長}}$$

例 次のような通信路符号 $W = \{000, 111\} \subseteq \{0, 1\}^3$ の情報速度 R_W を求めよ。

解)

$$R_W = \frac{\log |W|}{n} = \frac{\log 2}{3} = \frac{1}{3} \quad [bit/(通信路) 記号]$$

情報源記号が2種類である。よって、送信情報源として、

$$S = \begin{Bmatrix} a & , & b \\ 0.5 & , & 0.5 \end{Bmatrix}$$

を接続すれば1ビット伝送できる。(相互情報量を1ビットにできる。)よって、

$$R_W = \text{伝送される情報量}/\text{通信路符号長}$$

また、例えば、 $\phi = \{a \mapsto 0, b \mapsto 1\}$ のように情報源符号化も可能である。よって、

$$R_W = \text{情報源符号長}/\text{通信路符号長}$$

練習

次の通信路符号の情報速度を求めよ。

$$(1) \quad W_1 = \{000, 011, 101, 110\} \subseteq \{0,1\}^3$$

$$(2) \quad W_2 = \{000000, 011011, 101101, 11110110\} \subseteq \{0,1\}^6$$

$$(3) \quad W_3 = \left\{ \begin{array}{l} 0000, 0011, 0101, 0110, \\ 1001, 1010, 1100, 1111 \end{array} \right\}$$

$$(4) \quad W_4 = \left\{ \begin{array}{l} 00000000, 00010101, 001001101, 001100110, \\ 010010011, 010111000, 011011110, 011110100, \\ 100010101, 100111110, 101011000, 101110011, \\ 110000110, 110101101, 111001011, 111100000 \end{array} \right\}$$

情報速度と符号語数

情報源 A の長さ n の代表的系列の中から M 個の系列を選んだとする。これらの系列(符号語)を代表的系列の中から等しい確率で用いるとする。

$$M \left\{ \begin{array}{l} \bullet \quad w_1 = w_1^1 \cdots w_n^1 \\ \bullet \quad w_2 = w_1^2 \cdots w_n^2 \\ \cdot \qquad \qquad \vdots \qquad \vdots \\ \bullet \qquad \qquad \vdots \qquad \vdots \\ \bullet \quad w_N = w_1^N \cdots w_n^N \end{array} \right\} N = 2^{nH(A)}$$

このとき、各符号を伝送したときの情報量 R_n は、次式である。

$$R_n = -\log_2 \frac{1}{M} = \log_2 M [bit]$$

自己情報量の式

この情報の伝送に n 記号用いているので、情報速度は次式で与えられる。

$$R = \frac{\log_2 M}{n} [bit / 記号]$$

この式を逆に用いることにより、符号語数 M は情報速度 R と符号語長 n で表すことができる。すなわち、次式が成り立つ。

$$M = 2^{nR} \text{ [個]}$$

この式は通信路符号化定理を導くときに用いられる。

通信路符号化定理(重要)

性質:(通信路符号化定理)

通信路容量 C の通信路 T において、通信路符号 W を用いて情報を伝達する。

この通信路符号 W の複号誤り率を $P_e(W)$ 、情報速度を $R(W)$ と表す。

任意の $\varepsilon > 0$ に対して、

$$R(W) < C$$

ならば

$$P_e(W) < \varepsilon$$

情報速度が通信路容量未満なら、複号誤り率を限りなく0にできるという意味。(通信路容量が情報速度の上限)

を満たす(通信路)符号 W が存在する。


逆に、 $R(W) > C$ なら、 $P_e(W) < \varepsilon$ となる符号 W は存在しない。

証明

証明の方針

A_0 を通信路に接続すれば、伝送される情報量が C となる情報源

- (1) 通信路容量 C を達成する情報源を A_0 とする。
- (2) A_0 から発生する長さ n の代表的系列の中から、
 $M = 2^{nR}$ 個の符号語をランダムに選び、その集合を符号
 $W = \{w_1, w_2, \dots, w_M\}$
とする。
- (3) これらより、誤り確率を求める。



受信される情報源を B_0 とする。

このとき、 A_0 は通信路容量を達成する情報源なので、通信路容量の定義より次式が成り立つ。

$$C = H(A_0) - H(A_0 | B_0)$$

一方、前に示したように、長さ n の代表的系列の数は

$$N = 2^{nH(A_0)}$$

ランダム符号化という。

である。これらの中から代表的系列を、 $M = 2^{nR}$ 個ランダムに選ぶ。(もちろん $R < H(A_0)$ である。)

したがって、ある代表的系列が符号語として選ばれる確率は、

$$p_s = \frac{M}{N} = \frac{2^{nR}}{2^{nH(A_0)}}$$

選択(Select)確率

である。

出力系列1つあたりの入力系列数

$$n_y = 2^{nH(A_0|B_0)}$$

$$M = 2^{nR}$$

符号語数


代表的系列数

$$N = 2^{nH(A_0)}$$

入力系列

出力系列

$$2^{nH(B_0)}$$



出力系列に1
つの符号語し
かなければ誤
らない。

符号語 W_i を通信路 T を通して送り、受信系列 y が得られたとする。通信路には一般に誤りがあり、送信符号(送信系列)は確率的にしかわからない。

しかし、条件付エントロピー $H(A_0 | B_0)$ が平均情報量を意味することから、受信系列が y として受信される長さ n の代表的系列の個数 n_y は平均すれば次式表される。

$$n_y = 2^{nH(A_0 | B_0)}$$

条件付エントロピーが1記号あたりの情報量であり、[bit/記号]の単位を持つことに注意する。

もし、 $n_y = 2^{nH(A_0|B_0)}$ 個の代表的系列の中に W_i 以外に $W = \{w_1, \dots, w_M\}$ の符号語がなければ、送られた符号語が W_i 受信語 y から一意に確定し、誤りなく復号できる。

n_y 個の代表的系列を選んだとき、 W_i 以外の W の符号語を一つも選ばれない確率 p_c は、先ほど求めた p_s を用いて以下のように表せる。

$$p_c = (1 - p_s)^{n_y}$$

正しく(Correctly)複号できる確率。

連續して n_y 回符号語を選ばない確率。

これらまでの式を元にこの確率を計算する。

$$p_c = (1 - p_s)^{n_y}$$

$$= \left(1 - \frac{2^{nR}}{2^{nH(A_0)}} \right)^{2^{nH(A_0|B_0)}}$$

$$\approx 1 - 2^{nH(A_0|B_0)} \cdot \left(\frac{2^{nR}}{2^{nH(A_0)}} \right)$$

$$= 1 - 2^{-n(H(A_0) - H(A_0|B_0))} \cdot 2^{nR}$$

$$= 1 - 2^{-n(C-R)}$$

R < C なので
C - R > 0

テイラー展開
の1次の項

これは誤りなく復号できる確率なので、誤り確率 p_e は次式で表される。

$$p_e = 1 - p_c = 2^{-n(C-R)}$$

以上より、誤り確率は n を大きくすればいくらでも小さくできる。

(前半の証明終)

(後半の証明)

$R > C$ でしかも $p_e \rightarrow 0$ とできたとする。

このときには、誤りなく復号されるのだから、通信路を通じて実際に R [bit/記号] の情報量が伝送されたことになる。しかし、これは通信路容量の定義に矛盾する。

QED

情報源符号化と通信路符号化のまとめ2

符号化	定理	意味
情報源 符号化	シャノンの第 一定理 (情報源符 号化定理)	平均符号長はエントロピー以上 $\frac{H(S)}{\log r} < \bar{L}$
通信路 符号化	シャノンの第 二定理 (通信路符 号化定理)	情報速度は通信路容量以下 $R < C = \max\{H(A) - H(A B)\}$

情報源符号化定理と通信路符号化定理の関係 (シャノンの第1定理と第2定理の関係)

性質: 雑音の無い通信路における通信路符号化定理

理想的な通信路(雑音の無い通信路)で情報伝送する場合、
情報源符号化の定理と通信路符号化の定理は等価となる。

証明

送信者は $S = \left\{ \begin{matrix} s_1 & , & s_2 & , & \cdots & , & s_n \\ p_1 & , & p_2 & , & \cdots & , & p_n \end{matrix} \right\}$ を、 r 元送信アルファベット
 $A = \{a_1, \dots, a_r\}$ で符号化して送信し、受信アルファベット
 $B = \{b_1, \dots, b_{r^r}\}$ の記号列が受信されるものとする。

また、符号を

$\phi = \{s_1 \mapsto w_1, \dots, s_i \mapsto w_i, \dots, s_n \mapsto w_n\}$
とする。ここで、各符号語は、送信記号系列である。

$$\phi(s_i) = w_i = a_1^i a_2^i \cdots a_j^i \cdots a_{l_i}^i, \quad a_j^i \in A$$

この符号の平均の情報速度 $R(\phi)$ [bit/送信記号] は、

情報源のエントロピー $H(S)$ [bit/情報源記号] = $H(S)$ [bit/符号語] と、

平均符号長 $\overline{L(\phi)}$ [送信記号/符号語] を用いて次式で表わされる。

$$R(\phi) = \frac{H(S)}{\overline{L(\phi)}} \quad [bit / 送信記号]$$

一方、雑音の無い通信路では、通信路容量は次式で表せる。

$$\begin{aligned} C &= \max \{H(A) - H(A | B)\} \\ &= \max H(A) \\ &= \log r \quad [\text{bit / 送信記号}] \end{aligned}$$

雑音がないので、
 $H(A | B) = 0$

符号化されたものを送信アルファベット $A = \{a_1, \dots, a_r\}$ の(新たな)情報源とみなす。全ての記号が均等に生成するときが、通信路容量を満足する。よって、以下のような通信路に対する送信情報源となる。

$$A = \left\{ \begin{array}{c} a_1, \dots, a_r \\ 1/r, \dots, 1/r \end{array} \right\}$$

これらを、通信路符号化定理に代入する。

$$R(\phi) < C$$

$$\therefore \frac{H(S)}{L(\phi)} < \log r$$

$$\therefore \frac{H(S)}{\log r} < \overline{L(\phi)}$$

これは、 r 元記号を用いた情報源符号化定理である。

逆に、情報源符号化定理と、雑音の無い通信路における通信路容量より、通信路定理を導ける。

QED