

# 講義「情報理論」

## 第3回 情報量とエントロピー (2)

情報理工学専攻 情報知識ネットワーク研究室  
喜田拓也

# 情報量の定義（おさらい）

## 定義2.1

確率  $p$  で生起する事象が起きたことを知ったときに得られる情報量  $I(p)$  を自己情報量と呼び、

$$I(p) = -\log_a p$$

と定義する。ただし、 $a$  ( $a \neq 1$ ) は定数とする。

$a = 2$  の場合、単位はビット (bit) という

自然対数で計るときはナット (nat)  $1 \text{ nat} \doteq 1.443 \text{ bit}$

10を底とする対数で計るときはハートレー (Hartley)

もしくはディット (dit) またはデシット (decit)  $1 \text{ Hartley} \doteq 3.322 \text{ bit}$

確率  $1/2$  で生じる結果を知ったときの情報量 = 1 [bit]

# エントロピー（おさらい）

## 定義2.3

確率変数  $X$  がとりうる値が  $x_1, x_2, \dots, x_M$  とし,  $X$  がそれぞれの値をとる確率が  $p_1, p_2, \dots, p_M$  (ただし,  $p_1 + p_2 + \dots + p_M = 1$ ) であるとき, 確率変数  $X$  のエントロピーを

$$H(X) = -\sum_{i=1}^M p_i \log_2 p_i$$

ビットと定義する.

例題2.1: 偏りのないコインを2回投げて表の出た枚数を確率変数  $X$  とする. このとき,  $X$  のエントロピー  $H(X)$  は何ビットか?

$$\begin{aligned} H(X) &= -\frac{1}{4} \log_2 \frac{1}{4} - \frac{1}{2} \times \log_2 \frac{1}{2} - \frac{1}{4} \log_2 \frac{1}{4} \\ &= 2 \times \frac{2}{4} + \frac{1}{2} = 1.5 \quad (\text{ビット}) \end{aligned}$$

$X$	0	1	2
確率	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$

# 今日の内容

2.3 エントロピーの性質

2.4 結合エントロピー

2.5 条件付きエントロピー

2.6 相互情報量

# エントロピーの性質

## 定理2.1

$M$ 個の値をとる確率変数 $X$ のエントロピー $H(X)$ は次の性質を満たす.

- (1)
- (2)  $H(X)$ が最小値0となるのは、ある値をとる確率が1で、他の $M - 1$ 個の値をとる確率がすべて0のときに限る. すなわち、 $X$ のとり値が初めから確定している場合のみである.
- (3)  $H(X)$ が最大値 $\log_2 M$ となるのは、 $M$ 個の値がすべて $1/M$ で等しい場合に限る.

# 補助定理A.1[シャノンの補助定理]

## 補助定理A.1

$p_1, p_2, \dots, p_M$  および  $q_1, q_2, \dots, q_M$  を

$$p_1 + p_2 + \dots + p_M = 1,$$

$$q_1 + q_2 + \dots + q_M \leq 1$$

を満たす任意の非負の数とする(ただし,  $p_i \neq 0$  のときは  $q_i \neq 0$  とする). このとき,

$$-\sum_{i=1}^M p_i \log_2 q_i \geq -\sum_{i=1}^M p_i \log_2 p_i \quad (\text{A.3})$$

が成立する. 等号は  $q_i = p_i$  ( $i = 1, 2, \dots, M$ ) のとき, またそのときに限って成立する.

証明は教科書を参照

つまり, 確率分布  $P = \{p_i\}_{i=1}^M$  とちよつと違う分布  $q_i$  (ただし総和が1以下) を持ってきて,  $\log_2$  の内側の  $p_i$  と置き換えると, **元よりも少し大きくなる.**

# 定理2.1の証明

$X$ のエントロピー $H(X)$ は

$$H(X) = - \sum_{i=1}^M p_i \log_2 p_i .$$

$-\log_2 p_i \geq 0$  だから

$0 \leq p_i \leq 1$  なので、明らかに  $0 \leq H(S)$  であり、 $H(S) = 0$  が成立するのは、 $p_1, p_2, \dots, p_k$  のうち一つが 1 で他が 0 の場合である。

$\sum_{i=1}^M p_i = 1$  だから

補助定理A.1(シャノンの補助定理)を $q_i = 1/M$ として適用すると、

$$\begin{aligned} H(X) &= - \sum_{i=1}^M p_i \log_2 p_i \\ &\leq - \sum_{i=1}^M p_i \log_2 \frac{1}{M} \\ &= \log_2 M . \end{aligned}$$

補助定理A.1より

等号が成立するのは  $p_i = q_i = 1/M$  のときのみである。□

# エントロピー関数

定義2.4

エントロピー関数とは,  $0 \leq x \leq 1$  で定義される関数


$$\mathcal{H}(x) = -x \log_2 x - (1 - x) \log_2 (1 - x)$$

のことをいう.

二つの値1, 0 をそれぞれ 0.2, 0.8 の確率  
でとる確率変数Xのエントロピー $H(X)$ は,

$$\begin{aligned} H(X) &= -\sum_{i=1}^2 p_i \log p_i \\ &= -0.2 \log 0.2 - 0.8 \log 0.8 \\ &= \mathcal{H}(0.2) \\ &\cong 0.7219 \end{aligned}$$

となる.



エントロピー関数



# 二つの情報を一度に聞いたときの情報量は？

X: 日経平均株価が下がって1万6000円を割ったそうだよ

Y: また円高で, 1ドル105円ほどになったよ

へ, へえ~~~~

はたして,  $H(X, Y) = H(X) + H(Y)$  だろうか？

## 例 2.2

二つの確率変数 $X, Y$ を考える.  $X$ は $x_1, x_2, \dots, x_{M_X}$ の値をとり,  
 $Y$ は $y_1, y_2, \dots, y_{M_Y}$ の値をとるものとする. 確率変数の組 $(X, Y)$   
の値が $(x, y)$ となる結合確率分布を $P(x, y)$ と書く

表2.1 ある日の天気 $X$ とコンビニのアイスクリームの売上高 $Y$ の結合確率分布 $P(x, y)$

$P(x, y)$		$Y$		$P(x)$
		1万円以上	1万円未満	
$X$	晴	0.5	0.1	0.6
	雨	0.2	0.2	0.4
$P(y)$		0.7	0.3	

組 $(X, Y)$ をまとめて考えると, 4つの値をとる確率変数 $Z$ の  
エントロピー $H(Z)$ として考えることができる

# 結合エントロピー

定義2.5

確率変数 $X$ と $Y$ の結合エントロピー $H(X, Y)$ は,

$$H(X, Y) = - \sum_{i=1}^{M_X} \sum_{j=1}^{M_Y} P(x_i, y_j) \log_2 P(x_i, y_j)$$

により定義される. これを結合エントロピーと呼ぶ. ただし,

$\{x_1, x_2, \dots, x_{M_X}\}$ および $\{y_1, y_2, \dots, y_{M_Y}\}$ は, それぞれ $X$ と $Y$ が取りうる値の集合とする.

表2.1から,  $(X, Y)$  の結合エントロピーは,

$$\begin{aligned} H(X, Y) &= -0.5 \times \log 0.5 - 0.1 \times \log 0.1 \\ &\quad - 0.2 \times \log 0.2 - 0.2 \times \log 0.2 \\ &\doteq 1.76 \text{ (ビット)}. \end{aligned}$$

Try 練習問題2.2

# 結合エントロピーの性質

定理2.2

確率変数 $X$ と $Y$ の結合エントロピー $H(X, Y)$ に対し,

$$0 \leq H(X, Y) \leq H(X) + H(Y)$$

が成り立つ. また  $H(X, Y) = H(X) + H(Y)$  となるのは,  
 $X$  と  $Y$  が独立のときのみである.

# 定理2.2の証明

[証明] 結合エントロピーの定義より  $0 \leq H(X, Y)$  は明らかである。  
よって、 $H(X, Y) \leq H(X) + H(Y)$  を証明する。

$$H(X) = - \sum_{i=1}^{M_X} P(x_i) \log_2 P(x_i) = - \sum_{i=1}^{M_X} \sum_{j=1}^{M_Y} P(x_i, y_j) \log_2 P(x_i),$$

$$H(Y) = - \sum_{j=1}^{M_Y} P(y_j) \log_2 P(y_j) = - \sum_{j=1}^{M_Y} \sum_{i=1}^{M_X} P(x_i, y_j) \log_2 P(y_j).$$

したがって、

$$H(X) + H(Y) = - \sum_{j=1}^{M_Y} \sum_{i=1}^{M_X} P(x_i, y_j) \log_2 P(x_i) P(y_j)$$

# 定理2.2の証明(つづき)

A.1節の補助定理A.1(シャノンの補助定理)を適用すると,

$$\begin{aligned} & - \sum_{j=1}^{M_Y} \sum_{i=1}^{M_X} P(x_i, y_j) \log_2 P(x_i)P(y_j) \\ & \geq - \sum_{j=1}^{M_Y} \sum_{i=1}^{M_X} P(x_i, y_j) \log_2 P(x_i, y_j) \end{aligned}$$

が成り立つ. すなわち,  $H(X) + H(Y) \geq H(X, Y)$  となる.

等号が成り立つのは, シャノンの補助定理の統合条件より, すべての  $i, j$  に対して  $P(x_i, y_j) = P(x_i)P(y_j)$  が成立する場合である. これは,  $X$  と  $Y$  が独立であるときに他ならない.  $\square$

# ちよつと休憩

# 関連情報を事前に知っていた時の情報量は？

関連する情報が既知だと、驚きは少なくなる

→ エントロピーは小さくなっているはず！



## 例2.2 (p.17)

アイスクリームの売上高が「1万円以上」だったとき、実際の天気についての曖昧さ(エントロピー)は、晴と雨の確率がそれぞれ5/7と2/7であるから、

$$H(X|1万円以上) = \mathcal{H}(5/7) \doteq 0.8631 \text{ (bit)}.$$

同様に、売上高が「1万円未満」のときは、

$$H(X|1万円未満) = \mathcal{H}(1/3) \doteq 0.9183 \text{ (bit)}.$$

売上高が「1万円以上」「1万円未満」となる確率は、それぞれ0.7と0.3なので、この割合でエントロピーを平均すると、

$$\begin{aligned} H(X|Y) &\doteq 0.7 \times 0.8631 + 0.3 \times 0.9183 \\ &\doteq 0.8797 \text{ (bit)} \end{aligned}$$

となる。これは、 $X$ のエントロピー

$$H(X) = \mathcal{H}(0.6) = 0.9710 \text{ (bit)}$$

と比べて確かに小さい。


表2.2  $Y$  で条件付けた  $X$  の確率分布

$P(X Y)$		$Y$	
		1万円以上	1万円未満
$X$	晴	5/7	1/3
	雨	2/7	2/3

# 条件付きエントロピー

## 定義2.6

確率変数 $Y$ で条件を付けた $X$ の条件付きエントロピー $H(X|Y)$ は,



により定義される. ただし,  $\{x_1, x_2, \dots, x_{M_X}\}$ および  
 $\{y_1, y_2, \dots, y_{M_Y}\}$ は, それぞれ $X$ と $Y$ が取りうる値の集合とする.

Try 練習問題2.3

# 結合エントロピーと条件付きエントロピーの関係

## 定理2.3

$\{x_1, x_2, \dots, x_{M_X}\}$  および  $\{y_1, y_2, \dots, y_{M_Y}\}$  をとりうる値の集合とする確率変数  $X$  および  $Y$  に関し、以下が成り立つ。

$$(1) H(X|Y) = - \sum_{i=1}^{M_X} \sum_{j=1}^{M_Y} P(x_i, y_j) \log_2 P(x_i|y_j)$$

(2)

$$(3) 0 \leq H(X|Y) \leq H(X)$$

( $H(X|Y) = H(X)$  は  $X$  と  $Y$  が独立の時のみ成立)

$$(4) 0 \leq H(Y|X) \leq H(Y)$$

( $H(Y|X) = H(Y)$  は  $X$  と  $Y$  が独立の時のみ成立)

別の情報を得ると、エントロピーは変化しないか減少する

# 定理2.3(2)の証明

[証明] 結合エントロピーと条件付き確率の定義から,

$$\begin{aligned} H(X, Y) &= - \sum_{i=1}^{M_X} \sum_{j=1}^{M_Y} P(x_i, y_j) \log_2 P(x_i, y_j) \\ &= - \sum_{i=1}^{M_X} \sum_{j=1}^{M_Y} P(x_i, y_j) \log_2 \frac{P(x_i, y_j)P(x_i)}{P(x_i)} \\ &= - \sum_{i=1}^{M_X} \sum_{j=1}^{M_Y} P(x_i, y_j) \{ \log_2 P(x_i) + \log_2 P(y_j | x_i) \} \\ &= H(X) + H(Y|X) \end{aligned}$$

ベイズの定理

が成立する.

$H(X, Y) = H(Y) + H(X|Y)$  も同様にして証明できる.  $\square$

# 相互情報量の定義 [定義2.7]

例2.2において、天気 $X$ についての曖昧さは、

$$H(X) = -\sum_{i=1}^n p(x_i) \log p(x_i) \doteq 0.9710 \text{ (bit)}.$$

アイスクリームの売上高 $Y$ を聞いたとき、残っている曖昧さは、

$$H(X|Y) \doteq 0.8797 \text{ (bit)}.$$

したがって、売上高 $Y$ を聞くことで、天気 $X$ について

$$\begin{aligned} I(X; Y) &= H(X) - H(X|Y) \\ &\doteq 0.9710 - 0.8797 = \mathbf{0.0913} \text{ (bit)} \end{aligned}$$

だけ、**曖昧さが減少する**。

言い換えると、売上高 $Y$ を聞くことで天気 $X$ に関する情報量が、  
(平均として) $I(X; Y) \doteq 0.0913$  (bit) 得られることを意味する。

この $I(X; Y)$ を $X$ と $Y$ の**相互情報量** (mutual information) と呼ぶ。

# 相互情報量の性質(1) [定理2.4(1)]

相互情報量の定義

$$I(X; Y) = H(X) - H(X|Y)$$

と、先ほどの結合エントロピーと条件付きエントロピーの関係

$$H(X, Y) = H(X) + H(Y|X) = H(Y) + H(X|Y)$$

から,

$$\begin{aligned} I(X; Y) &= H(X) - H(X|Y) \\ &= H(X) + H(Y) - H(X, Y) \\ &= H(Y) - H(Y|X) \\ &= I(Y; X) \end{aligned}$$


XとYに関して対称

$$= \sum_i \sum_j p(x_i, y_j) \log \frac{p(x_i, y_j)}{p(x_i)p(y_j)}$$

が成り立つ.

$$\ast H(X|Y) = - \sum_{j=1}^m p(y_j) \sum_{i=1}^n p(x_i|y_j) \log p(x_i|y_j) = - \sum_{i=1}^n \sum_{j=1}^m p(x_i, y_j) \log p(x_i|y_j)$$

# 相互情報量の性質(2) [定理2.4(2)]



相互情報量 $I(X; Y)$ は,  $X$ と $Y$ に共通して含まれる情報の量を表すと解釈できる.  $I(X; Y)$ の範囲は, 次式のとおりである.

$$0 \leq I(X; Y) \leq \min\{H(X), H(Y)\}$$

[証明]

$I(X; Y) = H(X) - H(X|Y)$ と,  $H(X|Y) \leq H(X)$ の関係から, 左側は明らか. 右側の不等式についても,  $I(X; Y) = H(X) - H(X|Y) = H(Y) - H(Y|X)$ の関係と,  $H(X|Y) \geq 0$ ,  $H(Y|X) \geq 0$ であることから導ける.

# 今日のまとめ

## 2.3 エントロピーの性質

$$0 \leq H(X) \leq \log_2 M$$


二つの確率変数に対するエントロピー

2.4 結合エントロピー  $H(X, Y)$

2.5 条件付きエントロピー  $H(X|Y), H(Y|X)$

2.6 相互情報量  $I(X; Y)$

次回  
情報源のモデルについて





# 補足： 確率の統計的な定義

標本集合のどの要素(根源事象)も同程度に確からしく起こる場合は古典的定義で問題ない。

この仮定が適用できない場合は困る。

根源事象の  
生起にかたより  
がある場合

試行を $n$ 回繰り返し行ったときに事象 $A$ が起こった回数を $n(A)$ とする。このとき、

$$P(A) = \lim_{n \rightarrow \infty} \frac{n(A)}{n}$$

を事象 $A$ の確率とする。

しかし、現実には無限回の試行は不可能なので困る。

# 補足： 条件付き確率と独立性

ある事象 $A$ が起こったという条件のもとで別の事象 $B$ が起こる確率を考える。

$n$ 回の試行を行って事象 $A$ ,  $A \cap B$ がそれぞれ $n(A)$ 回,  $n(A \cap B)$ 回起こったとする。これらの事象の起こる頻度の比(統計的定義による確率)はそれぞれ

$$\frac{n(A)}{n}, \quad \frac{n(A \cap B)}{n}.$$

である。また、事象 $A$ が起こったという条件のもとで事象 $B$ が起こる頻度の比率を考えると、

$$\frac{n(A \cap B)}{n(A)} = \frac{\frac{n(A \cap B)}{n}}{\frac{n(A)}{n}}.$$

# 補足： 条件付き確率と独立性(つづき)

$P(A) > 0$ のとき,

$$P(B|A) = \frac{P(A \cap B)}{P(A)}$$

を, 事象 $A$ が起こったもとでの事象 $B$ の条件付き確率と定義する.  
このとき, 明らかに次式が成り立つ.

$$P(A \cap B) = P(A)P(B|A).$$

事象 $B$ の起こる確率が事象 $A$ の生起に無関係な場合, すなわち

$$P(B|A) = P(B)$$

が成り立つとき, 事象 $A$ と事象 $B$ は独立であるという. このとき, 明らかに次式が成り立つ.

$$P(A \cap B) = P(A)P(B).$$

# 補足： 条件付き確率の簡単な例

1個のサイコロを振る試行を考える。

サイコロの出目が偶数である事象を $A$ ，  
サイコロの出目が4以上である事象を $B$ とする

事象 $A$ の確率 $P(A)$ は  $P(A) = \frac{3}{6} = \frac{1}{2}$  偶数である確率

事象 $B$ の確率 $P(B)$ は  $P(B) = \frac{3}{6} = \frac{1}{2}$  4,5,6である確率

事象 $A \cap B$ の確率は  $P(A \cap B) = \frac{2}{6} = \frac{1}{3}$  4か6である確率

このとき、事象 $A$ で条件付けた事象 $B$ の確率 $P(B|A)$ は

$$P(B|A) = \frac{P(A \cap B)}{P(A)} = \frac{\frac{1}{3}}{\frac{1}{2}} = \frac{2}{3}.$$

出目が偶数であることは分かっている場合で4以上である確率

# 補足： ベイズの定理

## ベイズの定理


全事象  $\Omega$  を互いに排反な  $n$  個の事象  $B_1, B_2, \dots, B_n$  に分割する。  
すなわち,

$$B_i \cap B_j = \emptyset \quad (i \neq j),$$

$$B_1 \cup B_2 \cup \dots \cup B_n = \Omega.$$

このとき、任意の事象  $A$  に対して次が成り立つ。

$$P(B_k|A) = \frac{P(B_k)P(A|B_k)}{\sum_{i=1}^n P(B_i)P(A|B_i)}$$



次の関係は  $\Omega = B \cup B^c$  の場合の簡略版

$$P(B|A) = \frac{P(B)P(A|B)}{P(B)P(A|B) + P(B^c)P(A|B^c)} = \frac{P(A, B)}{P(A)}.$$

$P(A, B)$  は  
 $P(A \cap B)$   
と同じ意味

# 補足： ベイズの定理を使う例題

## [問題]

ガンを診断するための検査法があり、あなたがそれを受けると仮定しよう。

$C$  を、被検査者がガンであるという事象、


$A$  を、検査の結果が被検査者はガンであると示す事象とする。

(つまり検査結果が陽性となる事象)

検査法の認識力が95% ( $P(A|C) = 0.95$  かつ  $P(A^c|C^c) = 0.95$ ) であるとし、

検査を受ける人の中で実際にガンである割合が  $P(C) = 0.01$  であるとする。

このとき・・・



検査の結果が陽性だったとき、あなたが本当にガンである確率はいくらか？

(つまり、 $P(C|A)$ を求めなさい)

# 補足： ベイズの定理を使う例題の解答

[答え] ベイズの定理より,

$$P(C|A) = \frac{P(C)P(A|C)}{\sum_{i=1}^2 P(C_i)P(A|C_i)} = \frac{P(C)P(A|C)}{P(C)P(A|C) + P(C^c)P(A|C^c)}$$

である. これに,

$$P(C) = 0.01, \quad P(C^c) = 1 - P(C) = 0.99,$$

$$P(A|C) = 0.95, \quad P(A|C^c) = 1 - P(A^c|C^c) = 0.05$$

を代入すると,

$$P(C|A) = \frac{0.01 \times 0.95}{0.01 \times 0.95 + 0.99 \times 0.05} = \frac{19}{118} \approx 0.161.$$



たったの16%!  
よかったお



# 補足：相互情報量の計算例

最初のガンの検査の例について，ガンである確率変数を $X$ ，検査の結果の確率変数を $Y$ として相互情報量を計算してみよう。

$$P_{Y|X}(A|C) = P_{Y|X}(A^c|C^c) = 0.95, P_X(C) = 0.01 \quad \text{なので,}$$

$$\begin{aligned} P_Y(A) &= P_{Y|X}(A|C)P_X(C) + P_{Y|X}(A|C^c)P_X(C^c) \\ &= 0.95 \times 0.01 + 0.05 \times 0.99 \\ &= 0.0095 + 0.0495 = 0.059 . \end{aligned}$$

$$\therefore H(Y) = \mathcal{H}(0.059) \doteq 0.323 .$$

次に， $H(Y|X = C) = \mathcal{H}(0.95) \doteq 0.286$ ，

$$H(Y|X = C^c) = \mathcal{H}(0.05) \doteq 0.286 \quad \text{なので,}$$

$$\begin{aligned} H(Y|X) &\doteq 0.01 \times 0.286 + 0.99 \times 0.286 \\ &= 0.286 . \end{aligned}$$

したがって，相互情報量 $I(X;Y)$ は，

$$\begin{aligned} I(X;Y) &= H(Y) - H(Y|X) \\ &\doteq 0.323 - 0.286 \\ &= 0.037 \quad (\text{bit}). \end{aligned}$$

ちなみに  
 $H(X) \doteq 0.0808$

$P(Y X)$		$X$	
		$C$	$C^c$
$Y$	$A$	0.95	0.05
	$A^c$	0.05	0.95

$P(X,Y)$		$X$	
		$C$	$C^c$
$Y$	$A$	0.0095	0.0495
	$A^c$	0.0005	0.9405