

# 「パターン認識と機械学習」

## 1.6 情報理論

小野寺喜行

# 情報量を得る尺度【 $h(x)$ 】

- 確率分布  $p(x)$  に依存
- 事象  $x, y$  が無関係のとき

$$h(x, y) = h(x) + h(y)$$

$$p(x, y) = p(x)p(y)$$



$$h(x) = -\log_2 p(x) \quad \text{単位: ビット}$$

# 情報の平均量【 $H[x]$ 】

$$H[x] = -\sum_x p(x) \log_2 p(x)$$



エントロピー(entropy)と呼ばれる

# エントロピー

- 8個の可能な状態を等確率で取るとき

$$H[x] = -8 \times \frac{1}{8} \log_2 \frac{1}{8} = 3 \text{ ビット}$$

# エントロピー

- 8個の可能な状態  $\{a, b, c, d, e, f, g, h\}$

各確率は  $\left(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}\right)$

とする時

$$H[x] = -\frac{1}{2} \log_2 \frac{1}{2} - \frac{1}{4} \log_2 \frac{1}{4} - \frac{1}{8} \log_2 \frac{1}{8}$$

$$- \frac{1}{16} \log_2 \frac{1}{16} - \frac{4}{64} \log_2 \frac{1}{64} = 2 \text{ ビット}$$

# エントロピー

- 非一様な分布のエントロピーは一様な場合より小さい
- 確率変数の状態を送信するときの平均符号長と同じになる

# 多重度

- $N$  個の同じ物体をたくさんの箱に入れる場合、 $i$  番目の箱に入る個数を  $n_i$  としたときの箱への入れ方の総数  $W$

$$W = \frac{N!}{\prod_i n_i!}$$



多重度(multiplicity)

# 多重度のエントロピー

- 多重度の対数を適当に定数倍したものの

$$H = \frac{1}{N} \ln W = \frac{1}{N} \ln N! - \frac{1}{N} \sum_i \ln n_i!$$

# 多重度のエントロピー

- $n_i / N$ を一定で  $N \rightarrow \infty$  とし、スターリングの近似式

$$\ln N! \cong N \ln N - N$$

を使い、 $\sum_i n_i = N$  より

$$H = - \lim_{N \rightarrow \infty} \sum_i \left( \frac{n_i}{N} \right) \ln \left( \frac{n_i}{N} \right) = - \sum_i p_i \ln p_i$$

$$\left( p_i = \lim_{N \rightarrow \infty} (n_i / N) \right)$$

# 確率変数 $X$

- 箱を離散確率変数  $X$  の状態  $x_i$  と解釈すると


$$p(X = x_i) = p_i$$

- 確率変数  $X$  のエントロピー

$$H[p] = - \sum_i p(x_i) \ln p(x_i)$$

# 確率分布とエントロピー

- 少ない値で鋭いピークを持つような分布のエントロピーは低い(左)
- たくさんの値に広がっている分布のエントロピーは高い(右)



# 確率分布とエントロピー

- $p_i = 1, p_{j \neq i} = 0$  となる分布でエントロピーは最小値0となる
- エントロピーの最大値は

$$\tilde{H} = - \sum_i p(x_i) \ln p(x_i) + \lambda \left( \sum_i p(x_i) - 1 \right)$$

を最大化する時、つまり  $p(x_i)$  すべて等しい分布で  $H = \ln M$

(  $M$  は  $x_i$  の状態の総数 )

# 確率分布とエントロピー

- 実際に最大値であることを確かめるため、エントロピーを2階微分

$$\frac{\partial \tilde{H}}{\partial p(x_i) \partial p(x_j)} = -I_{ij} \frac{1}{p_i}$$

(  $I_{ij}$  は単位行列の成分)

# 連続変数 $x$ の分布のエントロピー

- $x$  を等間隔の区間  $\Delta$  に分けると

$$\int_{i\Delta}^{(i+1)\Delta} p(x) dx = p(x_i) \Delta$$

となる  $x_i$  が必ず存在

- $x_i$  の値を観測する確率  $p(x_i) \Delta$

# 連続変数 $x$ の分布のエントロピー

- 離散分布のエントロピー

$$H_{\Delta} = - \sum_i p(x_i) \Delta \ln(p(x_i) \Delta)$$

$$= - \sum_i p(x_i) \Delta \ln p(x_i) - \ln \Delta$$

# 連続変数 $x$ の分布のエントロピー

- $-\ln \Delta$  を無視し、 $\Delta \rightarrow 0$  の極限をとると

$$\lim_{\Delta \rightarrow 0} \left\{ - \sum_p p(x_i) \Delta \ln p(x_i) \right\} = - \int p(x) \ln p(x) dx$$



微分エントロピー

- 離散と連続のエントロピーは  $\ln \Delta$  だけ異なる

# 連続変数 $x$ の分布のエントロピー

- 複数の連続変数  $\mathbf{x}$  の、その密度に対する微分エントロピー

$$H[\mathbf{x}] = -\int p(\mathbf{x}) \ln p(\mathbf{x}) d\mathbf{x}$$

# 連続変数の場合のエントロピー最大化

- 次の3つの制約のもとで最大化する

$$\int_{-\infty}^{\infty} p(x) dx = 1$$

$$\int_{-\infty}^{\infty} xp(x) dx = \mu$$

$$\int_{-\infty}^{\infty} (x - \mu)^2 p(x) dx = \sigma^2$$

# 連続変数の場合のエントロピー最大化

- ラグランジュ乗数法を使い、以下の汎関数を  $p(x)$  について最大化して求める

$$\begin{aligned} & -\int_{-\infty}^{\infty} p(x) \ln p(x) dx + \lambda_1 \left( \int_{-\infty}^{\infty} p(x) dx - 1 \right) \\ & + \lambda_2 \left( \int_{-\infty}^{\infty} xp(x) dx - \mu \right) \\ & + \lambda_3 \left( \int_{-\infty}^{\infty} (x - \mu)^2 p(x) dx - \sigma^2 \right) \end{aligned}$$

# 連続変数の場合のエントロピー最大化

- 変分法により汎関数の微分を0とおくと

$$p(x) = \exp \left\{ -1 + \lambda_1 + \lambda_2 x + \lambda_3 (x - \mu)^2 \right\}$$



制約式に代入し、最終的に

$$p(x) = \frac{1}{(2\pi\sigma^2)^{1/2}} \exp \left\{ -\frac{(x - \mu)^2}{2\sigma^2} \right\}$$

(ガウス分布)

# ガウス分布の微分エントロピー

$$H[x] = \frac{1}{2} \left\{ 1 + \ln(2\pi\sigma^2) \right\}$$

- $\sigma^2$  が増えて分布が幅広くなるにつれて大きくなる
- $\sigma^2 < 1/(2\pi e)$  のとき  $H[x] < 0$  となる

# 同時分布 $p(\mathbf{x}, \mathbf{y})$

- $\mathbf{x}$  が既知のとき、対応する  $\mathbf{y}$  の値の特定に必要な付加情報

$$H[\mathbf{y} | \mathbf{x}] = - \iint p(\mathbf{y}, \mathbf{x}) \ln p(\mathbf{y} | \mathbf{x}) d\mathbf{y} d\mathbf{x}$$



条件付きエントロピー (conditional entropy)

# 同時分布 $p(\mathbf{x}, \mathbf{y})$

- 確率の乗法定理より、条件付きエントロピーは以下の関係を満たす

$$H[\mathbf{x}, \mathbf{y}] = H[\mathbf{y} | \mathbf{x}] + H[\mathbf{x}]$$