

# パターン認識と機械学習

## 1.2.2 期待値と分散

吉田拓夢

# 期待値 (expectation)

- 確率分布 $p(x)$ による関数 $f(x)$ への重み付け
  - 離散分布の場合

$$\mathbb{E}[f] = \sum_x p(x) f(x)$$

- 連続変数の場合

$$\mathbb{E}[f] = \int p(x) f(x) dx$$

# 期待値の近似

- 確率分布や確率密度から有限個の $N$ 点を使ってそれらの有限和で近似できる

$$\mathbb{E}[f] \simeq \frac{1}{N} \sum_{n=1}^N f(x_n)$$

- $N \rightarrow \infty$ の極限で近似の厳密化

# 多変数関数の期待値

- 関数 $f(x,y)$ の $x$ の分布に関する平均
- $y$ の関数

$$\mathbb{E}_x [f(x, y)]$$

# 条件付き期待値 (conditional expectation)

- 条件付き分布における条件付き期待値

$$\mathbb{E}_x [f | y] = \sum_x p(x | y) f(x)$$

# 分散 (variance)

- 定義

$$\text{var}[f] = \mathbb{E} [(f(x) - \mathbb{E}[f(x)])^2]$$

→  $f(x)$  の平均値周辺におけるばらつきの尺度

- 2乗の展開

$$\text{var}[f] = \mathbb{E}[f(x)^2] - \mathbb{E}[f(x)]^2$$

- $x$  自身の分散

$$\text{var}[x] = \mathbb{E}[x^2] - \mathbb{E}[x]^2$$

# 補足

- 分散の定義から2乗の展開(連続変数の場合)

$\mathbb{E}[f(x)]$  は定数となるので、 $\mathbb{E}[f(x)] = c$  とおく.

$$\begin{aligned} \text{var}[f] &= \mathbb{E}[(f(x) - \mathbb{E}[f(x)])^2] \\ &= \mathbb{E}[(f(x) - c)^2] \\ &= \int p(x) \{f(x)^2 - 2cf(x) + c^2\} dx \\ &= \int p(x) f(x)^2 dx - 2c \int p(x) f(x) dx + c^2 \int p(x) dx \\ &= \mathbb{E}[f(x)^2] - 2c\mathbb{E}[f(x)] + c^2 \cdot 1 \\ &= \mathbb{E}[f(x)^2] - 2c^2 + c^2 \\ &= \mathbb{E}[f(x)^2] - c^2 \\ &= \mathbb{E}[f(x)^2] - \mathbb{E}[f(x)]^2 \end{aligned}$$

# 共分散 (covariance)

- 定義

$$\begin{aligned} \text{cov}[x, y] &= \mathbb{E}_{x,y} [\{x - \mathbb{E}[x]\} \{y - \mathbb{E}[y]\}] \\ &= \mathbb{E}_{x,y} [xy] - \mathbb{E}[x]\mathbb{E}[y] \end{aligned}$$

2つの確率変数 $x, y$ が同時に変動する度合い  
 $x$ と $y$ が独立 $\rightarrow$ 共分散は0

# ベクトルの共分散

- 定義

$$\begin{aligned} \mathit{cov}[\mathbf{x}, \mathbf{y}] &= \mathbb{E}_{\mathbf{x}, \mathbf{y}} [\{\mathbf{x} - \mathbb{E}[\mathbf{x}]\} \{\mathbf{y}^T - \mathbb{E}[\mathbf{y}^T]\}] \\ &= \mathbb{E}_{\mathbf{x}, \mathbf{y}} [\mathbf{x} \mathbf{y}^T] - \mathbb{E}[\mathbf{x}] \mathbb{E}[\mathbf{y}^T] \end{aligned}$$

- ベクトル $\mathbf{x}$ の成分間の共分散

$$\mathit{cov}[\mathbf{x}] \equiv \mathit{cov}[\mathbf{x}, \mathbf{x}]$$