

定義：

$g(X)$ の期待値 $E(g(X))$ ：

$$E(g(X)) = \begin{cases} \sum_i g(x_i) p_i = \sum_i g(x_i) f(x_i), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} g(x) f(x) dx, & \text{連続型確率変数} \end{cases}$$

1. 確率変数 X の平均 $E(X)$

$\implies X$ の期待値, $g(X) = X$

$$E(X) = \begin{cases} \sum x_i f(x_i), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} x f(x) dx, & \text{連続型確率変数} \end{cases}$$

$$= \mu, \quad (\text{または, } \mu_x)$$

2. 確率変数 X の分散 $V(X)$

$$\implies (X - \mu)^2 \text{ の期待値, } g(X) = (X - \mu)^2$$

$$V(X) = E((X - \mu)^2)$$

$$= \begin{cases} \sum_i (x_i - \mu)^2 f(x_i), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx, & \text{連続型確率変数} \end{cases}$$

$$= \sigma^2, \quad (\text{または}, \sigma_x^2)$$

確率変数 X の分散 $V(X)$

$\implies X$ の確率分布の確率関数 (離散型の場合), または, 確率密度関数 (連続型の場合) の範囲が広がれば, $V(X)$ は大きい。

いくつかの公式：

1. a, b を定数とする。

定理： $E(aX + b) = aE(X) + b$

証明：

X が離散型確率変数の場合，

$$\begin{aligned} E(aX + b) &= \sum_i (ax_i + b)f(x_i) \\ &= a \sum_i x_i f(x_i) + b \sum_i f(x_i) \\ &= aE(X) + b \end{aligned}$$

途中で， $\sum_i f(x_i) = 1$ に注意

X が連続型確率変数の場合，

$$E(aX + b) = \int_{-\infty}^{\infty} (ax + b)f(x)dx$$

$$\begin{aligned}
&= a \int_{-\infty}^{\infty} x f(x) dx + b \int_{-\infty}^{\infty} f(x) dx \\
&= aE(X) + b
\end{aligned}$$

途中で, $\int_{-\infty}^{\infty} f(x) dx = 1$ に注意

2. 定理: $V(X) = E(X^2) - \mu^2$

証明:

$$\begin{aligned}
V(X) &= E((X - \mu)^2) \\
&= E(X^2 - 2\mu X + \mu^2) \\
&= E(X^2) - 2\mu E(X) + \mu^2 \\
&= E(X^2) - \mu^2
\end{aligned}$$

途中で, $\mu = E(X)$ に注意

3. a, b を定数とする。

定理： $V(aX + b) = a^2V(X)$

証明：

$E(aX + b) = a\mu + b$ に注意して，

$$\begin{aligned} V(aX + b) &= E(((aX + b) - E(aX + b))^2) \\ &= E((aX - a\mu)^2) \\ &= E(a^2(X - \mu)^2) \\ &= a^2E((X - \mu)^2) \\ &= a^2V(X) \end{aligned}$$

を得る。

4. 定理： 確率変数 X について， $E(X) = \mu$ ， $V(X) = \sigma^2$ とする。

$Z = \frac{X - \mu}{\sigma}$ を定義する。

このとき、 $E(Z) = 0$, $V(Z) = 1$ となる。

証明：

$$E(Z) = E\left(\frac{X - \mu}{\sigma}\right) = \frac{E(X) - \mu}{\sigma} = 0$$

$$V(Z) = V\left(\frac{1}{\sigma}X - \frac{\mu}{\sigma}\right) = \frac{1}{\sigma^2}V(X) = 1$$

2 変数： 確率変数 X, Y のある関数： $g(X, Y)$

定義：

$g(X, Y)$ の期待値 $E(g(X, Y))$:

$$E(g(X, Y)) = \begin{cases} \sum_i \sum_j g(x_i, y_j) f(x_i, y_j), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f(x, y) dx dy, & \text{連続型確率変数} \end{cases}$$

1. 確率変数 X の平均 $E(X)$

$\implies X$ の期待値, $g(X, Y) = X$

$$E(X) = \begin{cases} \sum_i \sum_j x_i f(x_i, y_j), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f(x, y) dx dy, & \text{連続型確率変数} \end{cases}$$

$$= \mu_x$$

2. 確率変数 X の分散 $V(X)$

$\Rightarrow (X - \mu_x)^2$ の期待値, $g(X, Y) = (X - \mu_x)^2$

$$V(X) = E((X - \mu_x)^2)$$

$$= \begin{cases} \sum_i \sum_j (x_i - \mu_x)^2 f(x_i, y_j), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \mu_x)^2 f(x, y) dx dy, & \text{連続型確率変数} \end{cases}$$

$$= \sigma_x^2$$

3. 確率変数 X, Y の共分散 $\text{Cov}(X, Y)$

$\Rightarrow (X - \mu_x)(Y - \mu_y)$ の期待値, $g(X, Y) = (X - \mu_x)(Y - \mu_y)$

$$\begin{aligned} & \text{Cov}(X, Y) \\ &= \text{E}((X - \mu_x)(Y - \mu_y)) \end{aligned}$$

$$= \begin{cases} \sum_i \sum_j (x_i - \mu_x)(y_j - \mu_y) f(x_i, y_j), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \mu_x)(y - \mu_y) f(x, y) dx dy, & \text{連続型確率変数} \end{cases}$$

いくつかの公式：

1. 確率変数 X, Y について,

定理： $E(X + Y) = E(X) + E(Y)$

証明：

$$E(X + Y) = \sum_i \sum_j (x_i + y_j) f(x_i, y_j)$$

$$\begin{aligned}
&= \sum_i \sum_j x_i f(x_i, y_j) \\
&+ \sum_i \sum_j y_j f(x_i, y_j) \\
&= E(X) + E(Y)
\end{aligned}$$

2. 確率変数 X と Y が独立のとき,

定理： $E(XY) = E(X)E(Y)$

証明：

$$\begin{aligned}
E(XY) &= \sum_i \sum_j x_i y_j f(x_i, y_j) \\
&= \sum_i \sum_j x_i y_j f(x_i) h(y_j)
\end{aligned}$$

$$\begin{aligned}
&= \sum_i x_i f(x_i) \sum_j y_j h(y_j) \\
&= E(X)E(Y)
\end{aligned}$$

3. 確率変数 X, Y について,

定理： $\text{Cov}(X, Y) = E(XY) - E(X)E(Y)$

証明：

$$\begin{aligned}
&\text{Cov}(X, Y) \\
&= \sum_i \sum_j (x_i - \mu_x)(y_j - \mu_y)p_{ij} \\
&= \sum_i \sum_j (x_i y_j - \mu_x y_j - \mu_y x_i + \mu_x \mu_y)p_{ij} \\
&= \sum_i \sum_j x_i y_j f(x_i, y_j)
\end{aligned}$$

$$\begin{aligned}
& - \mu_x \sum_i \sum_j y_j f(x_i, y_j) \\
& - \mu_y \sum_i \sum_j x_i f(x_i, y_j) \\
& + \mu_x \mu_y \sum_i \sum_j f(x_i, y_j) \\
& = \sum_i \sum_j x_i y_j f(x_i, y_j) - \mu_x \mu_y - \mu_y \mu_x + \mu_x \mu_y \\
& = \sum_i \sum_j x_i y_j f(x_i, y_j) - \mu_x \mu_y \\
& = E(XY) - E(X)E(Y)
\end{aligned}$$

より，一般的な証明：

$$\text{Cov}(X, Y)$$

$$\begin{aligned}
&= \mathbf{E}((X - \mu_x)(Y - \mu_y)) \\
&= \mathbf{E}(XY - \mu_x Y - \mu_y X + \mu_x \mu_y) \\
&= \mathbf{E}(XY) - \mathbf{E}(\mu_x Y) - \mathbf{E}(\mu_y X) + \mu_x \mu_y \\
&= \mathbf{E}(XY) - \mu_x \mathbf{E}(Y) - \mu_y \mathbf{E}(X) + \mu_x \mu_y \\
&= \mathbf{E}(XY) - \mu_x \mu_y - \mu_y \mu_x + \mu_x \mu_y \\
&= \mathbf{E}(XY) - \mu_x \mu_y \\
&= \mathbf{E}(XY) - \mathbf{E}(X)\mathbf{E}(Y)
\end{aligned}$$

4. 確率変数 X と Y が独立のとき,

$$\mathbf{E}(XY) = \mathbf{E}(X)\mathbf{E}(Y)$$

となるので,

$$\text{Cov}(X, Y) = 0$$

を得る。

5. 相関係数 ρ_{xy} :

$$\begin{aligned}\rho_{xy} &= \frac{\text{Cov}(X, Y)}{\sqrt{V(X)}\sqrt{V(Y)}} \\ &= \frac{\text{Cov}(X, Y)}{\sigma_x \sigma_y}\end{aligned}$$

6. 確率変数 X と Y が独立のとき,

$$\text{Cov}(X, Y) = 0$$

となるので,

$$\rho_{xy} = 0$$

を得る。

7. 確率変数 X, Y について,

$$V(X \pm Y) = V(X) \pm 2\text{Cov}(X, Y) + V(Y)$$

証明：

$$\begin{aligned} & V(X \pm Y) \\ &= E(((X \pm Y) - E(X \pm Y))^2) \\ &= E(((X - \mu_x) \pm (Y - \mu_y))^2) \\ &= E((X - \mu_x)^2 \pm 2(X - \mu_x)(Y - \mu_y) \\ &\quad + (Y - \mu_y)^2) \\ &= E((X - \mu_x)^2) \\ &\quad \pm 2E((X - \mu_x)(Y - \mu_y)) \\ &\quad + E((Y - \mu_y)^2) \\ &= V(X) \pm 2\text{Cov}(X, Y) + V(Y) \end{aligned}$$

$$8. -1 \leq \rho_{xy} \leq 1$$

証明：

次のような t に関する式を考える。 $f(t) = V(Xt - Y)$

分散なので、必ずゼロ以上となる。よって、すべての t について、 $f(t) \geq 0$ となるための条件を求めればよい。 t に関する 2 次方程式の判別式がゼロ以下となる条件を求める。 $V(Xt - Y) = V(Xt) - 2\text{Cov}(Xt, Y) + V(Y) = t^2V(X) - 2t\text{Cov}(X, Y) + V(Y)$

$$\frac{D}{2} = (\text{Cov}(X, Y))^2 - V(X)V(Y) \leq 0$$

$$\frac{(\text{Cov}(X, Y))^2}{V(X)V(Y)} \leq 1$$

$$-1 \leq \frac{\text{Cov}(X, Y)}{\sqrt{V(X)}\sqrt{V(Y)}} \leq 1$$

$$-1 \leq \rho_{xy} \leq 1$$

ρ_{xy} が 1 に近いほど、正の相関が強くなる。

ρ_{xy} が -1 に近いほど、負の相関が強くなる。

9. 確率変数 X と Y が独立のとき、

定理： $V(X + Y) = V(X) + V(Y)$

証明：

$$V(X + Y) = V(X) + 2\text{Cov}(X, Y) + V(Y)$$

確率変数 X と Y が独立のとき、

$$\text{Cov}(X, Y) = 0$$

なので、

$$V(X + Y) = V(X) + V(Y)$$

を得る。

10. n 個の確率変数 $X_1, X_2, \dots, X_n$ について：

$E(X_i) = \mu_i$ とするとき、

$$\begin{aligned}
\mathbf{E}(\sum_i X_i) &= \sum_i \mathbf{E}(X_i) = \sum_i \mu_i \\
\mathbf{V}(\sum_i X_i) &\equiv \mathbf{E}(\sum_i (X_i - \mu_i))^2 \\
&= \mathbf{E}(\sum_i (X_i - \mu_i))(\sum_j (X_j - \mu_j)) \\
&= \mathbf{E}(\sum_i \sum_j (X_i - \mu_i)(X_j - \mu_j)) \\
&= \sum_i \sum_j \mathbf{E}((X_i - \mu_i)(X_j - \mu_j)) \\
&= \sum_i \sum_j \text{Cov}(X_i, X_j)
\end{aligned}$$

11. n 個の確率変数 $X_1, X_2, \dots, X_n$ は互いに独立で同じ平均 μ , 分散 σ^2 を持つとする。すなわち, すべての $i = 1, 2, \dots, n$ について,

$$\mathbf{E}(X_i) = \mu, \quad \mathbf{V}(X_i) = \sigma^2$$

を仮定する。

さらに, 算術平均 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ を考える。

このとき,

定理: $E(\bar{X}) = \mu, V(\bar{X}) = \frac{\sigma^2}{n}$

が成り立つ。

証明:

$$\begin{aligned} E(\bar{X}) &= E\left(\sum_i \frac{X_i}{n}\right) = \sum_i E\left(\frac{X_i}{n}\right) \\ &= \sum_i \frac{1}{n} E(X_i) = \sum_i \frac{1}{n} \mu \\ &= \mu \end{aligned}$$

$$\begin{aligned} V(\bar{X}) &= V\left(\sum_i \frac{X_i}{n}\right) = \sum_i V\left(\frac{X_i}{n}\right) \\ &= \sum_i \frac{1}{n^2} V(X_i) = \sum_i \frac{1}{n^2} \sigma^2 \end{aligned}$$

$$= \frac{\sigma^2}{n}$$

3.2 いくつかの分布の平均・分散

ベルヌイ分布の平均と分散： ベルヌイ分布：

$$f(x) = p^x(1 - p)^{1-x} \quad x = 0, 1$$

$$E(X) = p, \quad V(X) = p(1 - p)$$

証明：

平均：

$$\begin{aligned} E(X) &= \sum_x x f(x) \\ &= \sum_{x=0}^1 x p^x (1 - p)^{1-x} \end{aligned}$$