

データ分布と予測

確率変数・確率分布についてのノート

堀田敬介

2003 年 10 月

1 確率分布の期待値・分散

1.1 期待値・分散

$$\begin{aligned} E(X) &= \sum_x f(x), \\ V(X) &= E((x - \mu)^2) \\ &= \sum_x (x - \mu)^2 f(x) \quad (\mu := E(X)) \\ &= \sum_x x^2 f(x) - 2\mu \sum_x x f(x) + \mu^2 \sum_x f(x) \\ &= E(X^2) - E(X)^2 \end{aligned}$$

また,

$$\begin{aligned} E(aX) &= \sum_x ax f(x) \\ &= a \sum_x x f(x) = aE(X), \\ V(aX) &= E(a^2 X^2) - E(aX)^2 \\ &= a^2 E(X^2) - a^2 E(X)^2 = a^2 V(X) \end{aligned}$$

1.2 2つの確率変数について期待値・分散の和・積

2つの確率変数 X, Y について, 同時確率分布 $f(x, y)$ と周辺確率分布 $g(x), h(y)$ を考える.

$$f(x, y) = P(X = x, Y = y), \quad f(x, y) \geq 0, \quad \sum_x \sum_y f(x, y) = 1,$$

$$g(x) = P(X = x) = \sum_y f(x, y),$$

$$h(y) = P(Y = y) = \sum_x f(x, y).$$

$Y \setminus X$	x_1	x_2	$\cdots$	x_n	$h(y)$
y_1	$P(X = x_1, Y = y_1)$	$P(X = x_2, Y = y_1)$	$\cdots$	$P(X = x_n, Y = y_1)$	$P(Y = y_1)$
y_2	$P(X = x_1, Y = y_2)$	$P(X = x_2, Y = y_2)$	$\cdots$	$P(X = x_n, Y = y_2)$	$P(Y = y_2)$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
y_m	$P(X = x_1, Y = y_m)$	$P(X = x_2, Y = y_m)$	$\cdots$	$P(X = x_n, Y = y_m)$	$P(Y = y_m)$
$g(x)$	$P(X = x_1)$	$P(X = x_2)$	$\cdots$	$P(X = x_n)$	1

このとき，

$$\begin{aligned} E(X + Y) &= \sum_x \sum_y (x + y) f(x, y) \\ &= \sum_x \{x \sum_y y f(x, y)\} + \sum_y \{y \sum_x x f(x, y)\} \\ &= \sum_x \{x g(x)\} + \sum_y \{y h(y)\} = E(X) + E(Y), \end{aligned}$$

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

$$\begin{aligned} Cov(X, Y) &= E\{(X - E(X))(Y - E(Y))\} \\ &= E(XY) - E(XE(Y)) - E(YE(X)) + E(E(X)E(Y)) \\ &= E(XY) - E(X)E(Y) - E(Y)E(X) + E(X)E(Y) \\ &= E(XY) - E(X)E(Y). \end{aligned}$$

また，確率変数 X, Y が互いに独立 *independent*¹ の時，即ち，同時確率分布において，

$$\forall x, y \quad f(x, y) = g(x)h(y)$$

が成り立つとき，

$$\begin{aligned} E(XY) &= \sum_x \sum_y xy \cdot f(x, y) \\ &= \sum_x \sum_y xy \cdot g(x)h(y) = \sum_x xg(x) \sum_y yh(y) = E(X)E(Y), \\ Cov(X, Y) &= 0, \\ V(X + Y) &= V(X) + V(Y). \end{aligned}$$

¹相関係数 $\rho = 0$ ($Cov(X, Y) = 0$) のとき，無相関 *uncorrelated* という．独立ならば無相関であるが，逆は必ずしも成り立たない．

1.3 Coffee Break!

$$\begin{aligned}\sum_{k=1}^n k &= 1 + 2 + \cdots + n \\ &= \frac{1}{2} \{ (1 + 2 + \cdots + n) + (n + (n-1) + \cdots + 1) \} \\ &= \frac{1}{2} (n+1) \cdot n = \frac{1}{2} n(n+1)\end{aligned}$$

$$\begin{aligned}\sum_{k=1}^n \{ (k+1)^3 - k^3 \} &= \{ 2^3 - 1^3 \} + \{ 3^3 - 2^3 \} + \cdots + \{ (n+1)^3 - n^3 \} \\ &= (n+1)^3 - 1\end{aligned}$$

である．また，

$$\begin{aligned}(\text{左辺}) &= \sum_{k=1}^n (3k^2 + 3k + 1) \\ &= 3 \sum_{k=1}^n k^2 + 3 \sum_{k=1}^n k + n \\ &= 3 \sum_{k=1}^n k^2 + \frac{3}{2} n(n+1) + n\end{aligned}$$

である．よって，

$$\begin{aligned}\sum_{k=1}^n k^2 &= \frac{1}{3} (n+1)^3 - \frac{1}{3} - \frac{1}{2} n(n+1) - \frac{1}{3} n \\ &= \frac{1}{6} (n+1) \{ 2(n+1)^2 - 3n - 2 \} = \frac{1}{6} n(n+1)(2n+1)\end{aligned}$$

2 モーメント・モーメント母関数

2.1 モーメント

$$\mu_r := E(X^r)$$

を X の (原点まわりの) r 次の積率 (モーメント, moment) という．

$$\mu'_r := E(X - \mu)^r$$

を X の期待値のまわりの r 次のモーメントという。²

$$\alpha_r := E\{(X - \mu)/\sigma\}^r$$

は X の r 次の標準化モーメントという。

$$\mu_1 = E(X), \mu'_2 = V(X)$$

$$\mu_0 \equiv 1, \mu'_1 \equiv 0$$

2.2 モーメント母関数 moment generating function

$$M_X(t) := E(e^{tX})$$

をモーメント母関数という。モーメント母関数は任意の次数のモーメントを生成する (計算する) ために使う。

$$\text{離散型分布} \quad M_X(t) = \sum_x e^{tx} f(x),$$

$$\text{連続型分布} \quad M_X(t) = \int_{-\infty}^{\infty} e^{tx} f(x) dx$$

3

$$M'_X(0) = \mu_1 \quad (= E(X)),$$

$$M''_X(0) = \mu_2 \quad (= E(X^2)),$$

$$M'''_X(0) = \mu_3 \quad (= E(X^3)),$$

$$\vdots$$

$$M_X^{(r)}(0) = \mu_r \quad (= E(X^r))$$

何故こうなるか?

$$\begin{aligned} e^x &= 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \cdots \\ \rightarrow e^{tX} &= 1 + tX + \frac{(tX)^2}{2!} + \frac{(tX)^3}{3!} + \cdots \end{aligned}$$

²モーメント：力学のモーメント (積率, 能率) と数学的に似ているかららしい

³この定義で無限和・積分が存在しないこともある。

より，両辺の期待値をとると，

$$\begin{aligned}
 E(e^{tX}) &= E(1) + E(tX) + E\left(\frac{(tX)^2}{2!}\right) + E\left(\frac{(tX)^3}{3!}\right) + \dots \\
 \Rightarrow M_X(t) &= 1 + tE(X) + \frac{1}{2!}E(X^2)t^2 + \frac{1}{3!}E(X^3)t^3 + \dots \\
 &= 1 + \mu_1 t + \frac{\mu_2}{2!}t^2 + \frac{\mu_3}{3!}t^3 + \dots
 \end{aligned}$$

である．即ち，モーメント母関数 $M_X(t)$ は各項の係数にモーメントを含んでいる！従って，微分すれば低次の項は消え，さらに $t = 0$ とおくことで高次の項も消えるのである！すばらしい！

2.3 (離散型) 確率分布

2.4 (離散) 一様分布

$$f(x) = \frac{1}{n} \quad (x = 1, 2, \dots, n)$$

$$\begin{aligned}
 E(X) &= \sum_x x \frac{1}{n} \\
 &= \frac{1}{n} \sum_x x = \frac{1}{n} \frac{1}{2} n(n+1) = \frac{n+1}{2} \\
 V(X) &= E(X^2) - E(X)^2 \\
 &= \sum_x x^2 \frac{1}{n} - \left(\frac{n+1}{2}\right)^2 \\
 &= \frac{1}{n} \cdot \frac{1}{6} n(n+1)(2n+1) - \frac{(n+1)^2}{4} \\
 &= \frac{1}{12} (n+1) \{2(2n+1) - 3(n+1)\} = \frac{1}{12} (n-1)^2
 \end{aligned}$$

2.5 ベルヌーイ分布

$$f(x) = \begin{cases} p & (x = 0) \\ 1 - p & (x = 1) \end{cases}$$

$$\begin{aligned}
 E(X) &= 0p + 1(1-p) = 1-p, \\
 V(X) &= \{0^2 p + 1^2(1-p)\} - (1-p)^2 = p(1-p)
 \end{aligned}$$

2.6 二項分布 $Bi(n, p)$

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

$$\begin{aligned}
E(X) &= \sum_x x \cdot {}_n C_x p^x q^{n-x} \quad (q := 1-p) \\
&= \sum_x x \cdot \frac{n}{x} \cdot \frac{(n-1)!}{(n-x)!(x-1)!} p \cdot p^{x-1} q^{n-x} \\
&= \sum_x n \cdot {}_{n-1} C_{x-1} p \cdot p^{x-1} q^{n-x} \\
&= np \sum_x {}_{n-1} C_{x-1} p^{x-1} q^{(n-1)-(x-1)} \\
&= np \sum_y {}_m C_y p^y q^{m-y} \quad (m := n-1, y := x-1) \\
&= np \sum_y f(y) = np, \\
E(X^2) &= \sum_x x^2 \cdot {}_n C_x p^x q^{n-x} \quad (q := 1-p) \\
&= np \sum_x x {}_{n-1} C_{x-1} p^{x-1} q^{n-x} \\
&= np \sum_x (x-1+1) {}_{n-1} C_{x-1} p^{x-1} q^{n-x} \\
&= np \left\{ \sum_x (x-1) {}_{n-1} C_{x-1} p^{x-1} q^{n-x} + \sum_x {}_{n-1} C_{x-1} p^{x-1} q^{n-x} \right\} \\
&\quad \left(\begin{aligned} &= np \left\{ \sum_y y {}_m C_y p^y q^{m-y} + \sum_y {}_m C_y p^y q^{m-y} \right\} \quad (m := n-1, y := x-1) \\ &= np(mp+1) \end{aligned} \right) \\
&= np\{(n-1)p+1\} = n(n-1)p^2 + np, \\
V(X) &= E(X^2) - E(X)^2 = n(n-1)p^2 + np - (np)^2 = np(1-p)
\end{aligned}$$

2.6.1 二項分布を正規分布で近似

二項分布 $Bi(n, p)$ (平均 np , 分散 npq) は $n \rightarrow \infty$ の時正規分布に近づく。二項分布 $f(x) = {}_n C_x p^x q^{n-x}$ について $n \rightarrow \infty$ の極限を考える。 $f(x)$ が最大となる点 $x = \bar{x}$ でテーラー展開する。

自然対数をとって、スターリング近似⁴を利用すると、

$$\begin{aligned}
\ln f(x) &= \ln n! - \ln x! - \ln(n-x)! + x \ln p + (n-x) \ln q \\
&= (n \ln n - n) - (x \ln x - x) - ((n-x) \ln(n-x) - (n-x)) + x \ln p + (n-x) \ln q \\
&= (\ln p - \ln q)x - x \ln x - (n-x) \ln(n-x) + n \ln n + n \ln q
\end{aligned}$$

⁴ $\ln y! \approx y \ln y - y$

$x = \bar{x} + \Delta x$ としてテーラー展開すると ,

$$\ln f(\bar{x} + \Delta x) = \ln f(\bar{x}) + B_1 \Delta x + \frac{1}{2} B_2 (\Delta x)^2 + \dots$$

ここで

$$B_1 = \frac{d \ln f(x)}{dx} = \frac{f'(\bar{x})}{f(\bar{x})} = 0 \quad (\bar{x} \text{ で極大})$$

また ,

$$\begin{aligned} \frac{d \ln f(x)}{dx} &= (\ln p - \ln q) - \ln x - x \frac{1}{x} + \ln(n - x) + (n - x) \frac{1}{n - x} \\ &= (\ln p - \ln q) - \ln x + \ln(n - x) \end{aligned}$$

より ,

$$\begin{aligned} B_1 &= \frac{d \ln f(\bar{x})}{dx} = (\ln p - \ln q) - \ln \bar{x} + \ln(n - \bar{x}) = 0 \\ \Leftrightarrow \ln \left\{ \frac{p(n - \bar{x})}{q\bar{x}} \right\} &= 0 \\ \Leftrightarrow \frac{p(n - \bar{x})}{q\bar{x}} &= 1 \Leftrightarrow np = (p + q)\bar{x} = \bar{x} \end{aligned}$$

即ち , 二項分布の平均 ($np = \bar{x}$) が $f(x)$ の極大値を与える (平均が極大を与える → 正規分布と同じ性質)

また ,

$$\begin{aligned} B_2 &= \frac{d^2 \ln f(x)}{dx^2} = -\frac{1}{\bar{x}} - \frac{1}{n - \bar{x}} \\ &= -\frac{1}{np} - \frac{1}{n - np} = -\frac{1}{n} \left(\frac{1}{p} + \frac{1}{q} \right) = -\frac{1}{npq} \end{aligned}$$

n が十分大きい場合を考えるので 3 次以降の項は無視すると ,

$$\ln f(\bar{x} + \Delta x) = \ln f(\bar{x}) + \frac{1}{2} B_2 (\Delta x)^2 = \ln f(\bar{x}) - \frac{1}{2npq} (\Delta x)^2$$

npq は二項分布の分散なので $\sigma^2 := npq$ とおき , 一般の変数 $x = \bar{x} + \Delta x$ について考えると ,

$$f(x) = f(\bar{x}) \exp \left\{ -\frac{1}{2\sigma^2} (x - \bar{x})^2 \right\}$$

これが $n \rightarrow \infty$ としたときの二項分布の確率密度関数 !

$$\int_{-\infty}^{\infty} f(x) dx = 1 \quad \text{より ,} \quad f(\bar{x}) = \frac{1}{\sigma\sqrt{2\pi}}$$

であるので ,

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp \left\{ -\frac{(x - \bar{x})^2}{2\sigma^2} \right\}$$

となる . これはまさに平均 $\bar{x}$, 分散 σ^2 の正規分布 !

即ち , n が十分大きい場合は , 二項分布は , 平均 $\bar{x} := np$, 分散 $\sigma^2 := npq$ の正規分布で近似できる !

2.7 ポアソン分布

$$f(x) = \exp(-\lambda) \frac{\lambda^x}{x!} \quad (x = 0, 1, 2, \dots)$$

$$\begin{aligned} E(X) &= \sum_x x f(x) = \sum_{x=0}^{\infty} e^{-\lambda} \frac{\lambda^x}{(x-1)!} \\ &= \sum_{x=1}^{\infty} e^{-\lambda} \frac{\lambda^x}{(x-1)!} \\ &= e^{-\lambda} \lambda \sum_{x=1}^{\infty} \frac{\lambda^{x-1}}{(x-1)!} \\ &= e^{-\lambda} \lambda \sum_{t=0}^{\infty} \frac{\lambda^t}{t!} = e^{-\lambda} \lambda e^{\lambda} = \lambda, \end{aligned}$$

$$\begin{aligned} E(X(X-1)) &= \sum_{x=0}^{\infty} x(x-1) e^{-\lambda} \frac{\lambda^x}{x!} \\ &= e^{-\lambda} \sum_{x=2}^{\infty} x(x-1) \frac{\lambda^x}{x!} \\ &= e^{-\lambda} \sum_{x=2}^{\infty} \frac{\lambda^x}{(x-2)!} \\ &= e^{-\lambda} \lambda^2 \sum_{x=2}^{\infty} \frac{\lambda^{x-2}}{(x-2)!} = e^{-\lambda} \lambda^2 e^{\lambda} = \lambda^2 \end{aligned}$$

$$\begin{aligned} V(X) &= E(X^2) - E(X)^2 = E(X^2) - E(X) - E(X)^2 + E(X) \\ &= E(X^2 - X) - E(X)^2 + E(X) \\ &= E(X(X-1)) - E(X)^2 + E(X) = \lambda^2 - \lambda^2 + \lambda = \lambda \end{aligned}$$

2.7.1 二項分布からポアソン分布へ

二項分布について $n \rightarrow \infty, p \rightarrow 0$ とする . ただし , 二項分布の期待値が一定 $np = \lambda$ のもとで .

$$\begin{aligned} f(x) &= {}_n C_x p^x (1-p)^{n-x} \\ &= \frac{n!}{(n-x)! x!} p^x (1-p)^{n-x} \\ &= \frac{n(n-1)(n-2) \cdots (n-x+1)}{x!} p^x (1-p)^{n-x} \\ &= \frac{n^x}{x!} \left\{ 1 \left(1 - \frac{1}{n} \right) \left(1 - \frac{2}{n} \right) \cdots \left(1 - \frac{x-1}{n} \right) \right\} p^x (1-p)^{n-x} \end{aligned}$$

$$\begin{aligned}
&= \frac{n^x}{x!} \left\{ \left(1 - \frac{1}{n}\right) \left(1 - \frac{2}{n}\right) \cdots \left(1 - \frac{x-1}{n}\right) \right\} \left(\frac{\lambda}{n}\right)^x \left(1 - \frac{\lambda}{n}\right)^{n-x} \\
&= \frac{\lambda^x}{x!} \left\{ \left(1 - \frac{1}{n}\right) \left(1 - \frac{2}{n}\right) \cdots \left(1 - \frac{x-1}{n}\right) \right\} \left(1 - \frac{\lambda}{n}\right)^{n-x} \\
&= \frac{\lambda^x}{x!} \left\{ \left(1 - \frac{1}{n}\right) \left(1 - \frac{2}{n}\right) \cdots \left(1 - \frac{x-1}{n}\right) \right\} \left(1 - \frac{\lambda}{n}\right)^n \left(1 - \frac{\lambda}{n}\right)^{-x} \\
&= \frac{\lambda^x}{x!} \left\{ \left(1 - \frac{1}{n}\right) \left(1 - \frac{2}{n}\right) \cdots \left(1 - \frac{x-1}{n}\right) \right\} \left\{ \left(1 + \frac{1}{m}\right)^m \right\}^{-\lambda} \left(1 - \frac{\lambda}{n}\right)^{-x}
\end{aligned}$$

最後の等式では, $-\frac{\lambda}{n} = \frac{1}{m}$ とした. ここで $n \rightarrow \infty$ (このとき $p \rightarrow 0$, $m \rightarrow -\infty$) とすると,

$$\lim_{m \rightarrow \pm\infty} \left(1 + \frac{1}{m}\right)^m = e$$

より,

$$f(x) = \frac{1}{x!} \lambda^x \exp(-\lambda)$$

2.8 幾何分布

$$f(x) = p(1-p)^{x-1} \quad (x = 1, 2, \dots)$$

$$\begin{aligned}
E(X) &= \sum_{x=1}^{\infty} xp(1-p)^{x-1} = \sum_{x=1}^{\infty} (x-1+1)p(1-p)^{x-2} \\
&= (1-p) \sum_{x=1}^{\infty} (x-1)p(1-p)^{x-2} + \sum_{x=1}^{\infty} p(1-p)^{x-1} \\
&= (1-p) \sum_{x=2}^{\infty} (x-1)p(1-p)^{x-2} + 1 \\
&= (1-p) \sum_{x=1}^{\infty} xp(1-p)^{x-1} + 1 = (1-p)E(X) + 1 \\
&\Rightarrow E(X) = \frac{1}{p},
\end{aligned}$$

$$\begin{aligned}
E(X^2) &= \sum_{x=1}^{\infty} x^2 p(1-p)^{x-1} = \sum_{x=1}^{\infty} (x-1+1)^2 p(1-p)^{x-1} \\
&= \sum_{x=1}^{\infty} (x-1)^2 p(1-p)^{x-1} + 2 \sum_{x=1}^{\infty} xp(1-p)^{x-1} - \sum_{x=1}^{\infty} p(1-p)^{x-1} \\
&= (1-p) \sum_{x=2}^{\infty} (x-1)^2 p(1-p)^{x-2} + \frac{2}{p} - 1
\end{aligned}$$

$$\begin{aligned}
&= (1-p) \sum_{x=1}^{\infty} xp(1-p)^{x-1} + \frac{2-p}{p} \\
&= (1-p)E(X^2) + \frac{2-p}{p} \\
&\Rightarrow E(X^2) = \frac{2-p}{p^2}, \\
V(X) &= E(X^2) - E(X)^2 = \frac{2-p}{p^2} - \left(\frac{1}{p}\right)^2 = \frac{1-p}{p^2}
\end{aligned}$$

2.9 負の二項分布

$$f(x) = {}_{k+x-1}C_x p^k (1-p)^x, \quad (x = 0, 1, 2, \dots)^5$$

$$\begin{aligned}
E(X) &= \sum_{x=0}^{\infty} x \cdot {}_{k+x-1}C_x p^k (1-p)^x \\
&= \sum_{x=1}^{\infty} x \cdot \frac{k+x-1}{x} \cdot \frac{(k+x-2)!}{(x-1)!(k-1)!} p^k (1-p)^x \\
&= \sum_{x=1}^{\infty} \{k + (x-1)\} \cdot {}_{k+x-2}C_{x-1} p^k (1-p)^x \\
&= k(1-p) \sum_{x=1}^{\infty} {}_{k+x-2}C_{x-1} p^k (1-p)^{x-1} + (1-p) \sum_{x=1}^{\infty} (x-1) \cdot {}_{k+x-2}C_{x-1} p^k (1-p)^{x-1} \\
&= k(1-p) \sum_{y=0}^{\infty} {}_{k+y-1}C_y p^k (1-p)^y + (1-p) \sum_{y=0}^{\infty} y \cdot {}_{k+y-1}C_y p^k (1-p)^y \\
&= k(1-p) + (1-p)E(X) \\
&\Rightarrow E(X) = \frac{k(1-p)}{p}, \\
E(X^2) &= \sum_{x=0}^{\infty} x^2 \cdot {}_{k+x-1}C_x p^k (1-p)^x \\
&= \sum_{x=1}^{\infty} (x-1+1)^2 \cdot {}_{k+x-1}C_x p^k (1-p)^x \\
&= \sum_{x=1}^{\infty} (x-1)^2 \cdot {}_{k+x-1}C_x p^k (1-p)^x + 2 \sum_{x=1}^{\infty} x \cdot {}_{k+x-1}C_x p^k (1-p)^x - \sum_{x=1}^{\infty} {}_{k+x-1}C_x p^k (1-p)^x \\
&= \sum_{x=1}^{\infty} \dots + \frac{2k(1-p)}{p} - 1
\end{aligned}$$

⁵ $k=1$ の時は幾何分布