

## 確率論 IV

石綿 元

第 5 回講義

## 目次

1	分布関数・母関数及び中心極限定理	2
1.1	累積分布関数 . . . . .	2
1.2	積率母関数 . . . . .	2
1.3	確率母関数 . . . . .	4
1.4	中心極限定理 . . . . .	6
2	確率過程 < 参考 >	8
2.1	確率過程 . . . . .	8
2.2	マルコフ連鎖 . . . . .	8
2.3	ポアソン過程と $\Gamma$ -分布 . . . . .	9

## 1 分布関数・母関数及び中心極限定理

### 1.1 累積分布関数

「第1回講義 データの視覚化」において、度数と相対累積度数のヒストグラムを作成した。このとき、相対累積度数の持つ意味は、ある度数における割合を求めたり、ある割合以下の度数を知るためのグラフとして機能していた。確率分布は経験分布である度数分布の理論分布であった。度数分布と確率分布を対比して考えると、累積相対度数について対応するものが累積分布関数である。

すなわち、確率変数  $X$  について

$$\mathcal{F}(t) = P(X \leq t)$$

である関数  $\mathcal{F}(t)$  を  $X$  の累積分布関数もしくは分布関数と定義する。

#### ■離散型

$$\mathcal{F}(t) = P(X \leq t) = \sum_{x_i \leq t} f(x_i)$$

#### ■連続型

$$\mathcal{F}(t) = P(X \leq t) = \int_{-\infty}^t f(x) dx$$

■確率密度関数と分布関数の関係 微分積分学の基本定理より、 $\mathcal{F}'(x) = f(x)$ 。つまり、分布関数の接線の傾きが確率密度関数のその点での値(高さ)であり、分布関数の値(高さ)は、確率密度関数のその点までの面積である。

### 1.2 積率母関数

#### 1.2.1 積率母関数(離散型)

確率変数  $X$  の確率分布  $f(x_i)$  に対して、

$$M_X(t) = \sum_{i=1}^{\infty} e^{tx_i} f(x_i) = E[e^{tX}]$$

を離散型確率変数  $X$  の積率母関数と定義する。

■ゼロ回微分(微分しないまま) まず、定義  $M_X(t)$  に、そのまま  $t=0$  を代入すると、

$$M_X(0) = \sum_{i=1}^{\infty} e^0 f(x_i) = \sum_{i=1}^{\infty} f(x_i) = 1$$

である。全確率を表す。

## ■一回微分

$$M'_X(t) = \frac{d}{dt}M_X(t) = \sum_{i=1}^{\infty} x_i e^{tx_i} f(x_i)$$

ここで、 $t=0$  を代入すると、

$$M'_X(0) = \sum_{i=1}^{\infty} x_i f(x_i)$$

これは、原点周りの1次積率であり、つまりは期待値である。

## ■二回微分

$$M''_X(t) = \frac{d}{dt}M'_X(t) = \sum_{i=1}^{\infty} x_i^2 e^{tx_i} f(x_i)$$

ここで、 $t=0$  を代入すると、

$$M''_X(0) = \sum_{i=1}^{\infty} x_i^2 f(x_i)$$

これは、原点周りの2次積率  $E[X^2]$  になっている。したがって、分散と期待値の関係を用いて

$$V[X] = E[X^2] - (E[X])^2 = M''_X(0) - (M'_X(0))^2$$

が導出できる。

## 1.2.2 積率母関数（連続型）

確率変数  $X$  の確率分布  $f(x)$  に対して、

$$M_X(t) = \int_{-\infty}^{\infty} e^{tx} f(x) dx = E[e^{tX}]$$

を連続型確率変数  $X$  の積率母関数と定義する。

■ゼロ回微分（微分しないまま） まず、定義  $M_X(t)$  に、そのまま  $t=0$  を代入すると、

$$M_X(0) = \int_{-\infty}^{\infty} e^0 f(x) dx = \int_{-\infty}^{\infty} f(x) dx = 1$$

である。全確率を表す。

## ■一回微分

$$M'_X(t) = \frac{d}{dt}M_X(t) = \int_{-\infty}^{\infty} x e^{tx} f(x) dx$$

ここで、 $t=0$  を代入すると、

$$M'_X(0) = \int_{-\infty}^{\infty} x f(x) dx$$

これは、原点周りの1次積率であり、つまりは期待値である。

■二回微分

$$M_X''(t) = \frac{d}{dt} M_X'(t) = \int_{-\infty}^{\infty} x^2 e^{tx} f(x) dx$$

ここで、 $t = 0$  を代入すると、

$$M_X''(0) = \int_{-\infty}^{\infty} x^2 f(x) dx$$

これは、原点周りの2次積率  $E[X^2]$  になっている。したがって、分散と期待値の関係を用いて

$$V[X] = E[X^2] - (E[X])^2 = M_X''(0) - (M_X'(0))^2$$

が導出できる。

### 1.3 確率母関数

#### 1.3.1 確率母関数（離散型）

離散型確率変数  $X$  の確率分布  $f(x_i)$  に対して、

$$G(z) = \sum_{i=1}^{\infty} z^{x_i} f(x_i) = E[z^X]$$

を確率変数  $X$  の確率母関数と定義する。ここで、 $z = e^t$  のとき、 $M_X(t)$  である。

■全体確率  $z = 1$  を代入すると全確率が示される。

$$G(1) = \sum_{i=1}^{\infty} 1^{x_i} f(x_i) = \sum_{i=1}^{\infty} f(x_i) = 1$$

■期待値  $G(z)$  を  $z$  で一回微分する。

$$G'(z) = \frac{d}{dz} G(z) = \sum_{i=1}^{\infty} x_i z^{x_i-1} f(x_i)$$

これに  $z = 1$  を代入すると

$$G'(1) = \sum_{x=1}^{\infty} x_i 1^{x_i-1} f(x_i) = \sum_{x=1}^{\infty} x_i f(x_i)$$

これは期待値である。

■分散  $G(z)$  を  $z$  で二回微分する。

$$G''(z) = \frac{d^2}{dz^2} G(z) = \sum_{i=1}^{\infty} x_i(x_i - 1) z^{x_i-2} f(x_i)$$

これに  $z = 1$  を代入すると

$$\begin{aligned} G''(1) &= \sum_{i=1}^{\infty} x_i(x_i - 1) 1^{x_i-2} f(x_i) \\ &= \sum_{i=1}^{\infty} x_i^2 f(x_i) - \sum_{i=1}^{\infty} x_i f(x_i) \end{aligned}$$

ここで、右辺第1項目は  $E[X^2]$  である。よって、

$$E[X^2] = G''(1) + G'(1)$$

分散と期待値の関係から

$$V[X] = E[X^2] - (E[X])^2 = G''(1) + G'(1) - \{G'(1)\}^2$$

とすることで、分散が求まる。

### 1.3.2 確率母関数 (連続型)

連続型確率変数  $X$  の確率分布  $f(x)$  に対して、

$$G(z) = \int_{-\infty}^{\infty} z^x f(x) dx = E[z^X]$$

を確率変数  $X$  の確率母関数と定義する。ここで、 $z = e^t$  のとき、 $M_X(t)$  である。

■全体確率  $z = 1$  を代入すると全確率が示される。

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

■期待値  $G(z)$  を  $z$  で一回微分する。

$$G'(z) = \frac{d}{dz} G(z) = \int_{-\infty}^{\infty} x z^{x-1} f(x) dx$$

これに  $z = 1$  を代入すると

$$G'(1) = \int_{-\infty}^{\infty} x 1^{x-1} f(x) dx = \int_{-\infty}^{\infty} x f(x) dx$$

これは期待値である。

■分散  $G(z)$  を  $z$  で二回微分する。

$$G''(z) = \frac{d^2}{dz^2} G(z) = \int_{-\infty}^{\infty} x(x-1) z^{x-2} f(x) dx$$

これに  $z = 1$  を代入すると

$$\begin{aligned} G''(1) &= \int_{-\infty}^{\infty} x(x-1) 1^{x-2} f(x) dx \\ &= \int_{-\infty}^{\infty} x^2 f(x) dx - \int_{-\infty}^{\infty} x f(x) dx \end{aligned}$$

ここで、右辺第1項目は  $E[X^2]$  である。よって、

$$E[X^2] = G''(1) + G'(1)$$

分散と期待値の関係から

$$V[X] = E[X^2] - (E[X])^2 = G''(1) + G'(1) - \{G'(1)\}^2$$

とすることで、分散が求まる。

## 1.4 中心極限定理

### 1.4.1 チェビシエフの不等式

確率変数  $X$  について、平均  $\mu = E[X]$ 、分散  $\sigma^2 = V[X]$  とするとき、任意の  $\varepsilon > 0$  に対して

$$P(|X - \mu| \geq \varepsilon) \leq \frac{\sigma^2}{\varepsilon^2}$$

が成立する。

■Proof 分散の定義から確認してみる。

$$\begin{aligned} V[X] = \sigma^2 &= \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx = \int_{-\infty}^{\mu - \varepsilon} (x - \mu)^2 f(x) dx + \int_{\mu - \varepsilon}^{\mu + \varepsilon} (x - \mu)^2 f(x) dx + \int_{\mu + \varepsilon}^{\infty} (x - \mu)^2 f(x) dx \\ &\geq \int_{-\infty}^{\mu - \varepsilon} (x - \mu)^2 f(x) dx + \int_{\mu + \varepsilon}^{\infty} (x - \mu)^2 f(x) dx \\ &\text{ここで、} x \text{ は、任意 } \varepsilon \text{ よりも外側を動くので、} x - \mu \text{ よりも } \varepsilon \text{ のほうが小さいから、} \\ &\geq \int_{-\infty}^{\mu - \varepsilon} \varepsilon^2 f(x) dx + \int_{\mu + \varepsilon}^{\infty} \varepsilon^2 f(x) dx = \varepsilon^2 \int_{-\infty}^{\mu - \varepsilon} f(x) dx + \varepsilon^2 \int_{\mu + \varepsilon}^{\infty} f(x) dx = \varepsilon^2 P(|X - \mu| \geq \varepsilon) \\ &\text{よって、} \\ &\sigma^2 \geq \varepsilon^2 P(|X - \mu| \geq \varepsilon) \end{aligned}$$

### 1.4.2 大数の法則

確率変数  $X$  が、平均  $\mu = E[X]$ 、分散  $\sigma^2 = V[X]$  のとある確率分布に従うとする。

いま、 $n$  個のまったく独立な確率変数  $X_1, X_2, X_3, \dots, X_n$  が、すべて独立に確率変数  $X$  と同一の確率分布に従うとする。

この同一の確率分布に従う  $n$  個のまったく独立な確率変数  $X_1, X_2, X_3, \dots, X_n$  の総平均を

$$\bar{X} = \frac{X_1 + X_2 + X_3 + \dots + X_n}{n}$$

とおく。

このとき、 $n$  が十分大きいならば、 $\bar{X}$  が  $\mu = E[X]$  に近づく。すなわち、

$$\lim_{n \rightarrow \infty} P(|\bar{X} - \mu| < \varepsilon) = 1$$

■理論的確認 総平均の期待値を  $E[\bar{X}] = \mu$  また、総平均の分散は、 $V[\bar{X}] = \frac{\sigma^2}{n}$  であるとして代入すると、チェビシエフの不等式から、

$$P(|\bar{X} - \mu| \geq \varepsilon) = P(|\bar{X} - E[\bar{X}]| \geq \varepsilon) \leq \frac{V[\bar{X}]}{\varepsilon^2} = \frac{\sigma^2}{n\varepsilon^2}$$

このとき、

$$\lim_{n \rightarrow \infty} \frac{\sigma^2}{n\varepsilon^2} = 0$$

つまり、両端がゼロに近づく確率分布の総面積となるので、

$$\lim_{n \rightarrow \infty} P(|\bar{X} - \mu| < \varepsilon) = 1$$

## 1.4.3 中心極限定理

■中心極限定理-[[本節は非常に重要である]] 確率変数  $X$  が、平均  $\mu = E[X]$ 、分散  $\sigma^2 = V[X]$  のとある確率分布に従うとする。

いま、 $n$  個のまったく独立な確率変数  $X_1, X_2, X_3, \dots, X_n$  が、すべて独立に確率変数  $X$  と同一の確率分布に従うとする。

この同一の確率分布に従う  $n$  個のまったく独立な確率変数  $X_1, X_2, X_3, \dots, X_n$  の総平均を

$$\bar{X} = \frac{X_1 + X_2 + X_3 + \dots + X_n}{n}$$

とおく。

このとき、 $n$  が十分大きいならば、確率変数  $X$  が従う分布によらず、総和の平均  $\bar{X}$  は平均  $\mu$ 、分散  $\frac{\sigma^2}{n}$  の正規分布  $N\left(\mu, \frac{\sigma^2}{n}\right)$  に近づく。

さらに、確率変数  $X$  が「平均  $\mu$ 、分散  $\sigma^2$  のある分布」に従うとき、 $\bar{X}$  ではなく、 $X$  と同一の確率分布に従う  $n$  個のまったく独立な確率変数  $X_i$  の和を確率変数  $S$  とすると、

$$S = X_1 + X_2 + X_3 + \dots + X_n = \sum_{i=1}^n X_i$$

も中心極限定理によって正規分布に近づくが、その場合の正規分布は  $N(n\mu, n\sigma^2)$  に近づく。

■正規近似 中心極限定理より、同一の分布に従う  $n$  個の確率変数の総和の平均は  $n$  が大きいとき正規分布に従うと考えてよい。これには、離散型、連続型についても関係ない。精密さを要求しない場合、おおむね **30 個以上** 程度でも正規近似できると考えてもよい。

特に、2 項分布の試行回数  $n$  が大きく、かつ、 $p$  が小さくないとき、正規分布に近似される。

例さいころを 30 回転がす試行について 1 の目が出るかどうかに着目すると、ベルヌーイ試行となり、確率変数  $X$  は、2 項分布に従う。したがって、 $B(30, \frac{1}{6})$  である。このとき、この 2 項分布の平均は、 $np = 30 \times \frac{1}{6} = 5$  であり、分散は  $np(1-p) = 30 \times \frac{1}{6} \times (1 - \frac{1}{6}) = 5 \times \frac{5}{6} = \frac{25}{6}$  である。

$$f(x) = {}_{30}C_x \left(\frac{1}{6}\right)^x \left(1 - \frac{1}{6}\right)^{30-x}$$

この平均と分散を持つ正規分布は、 $N(5, \frac{25}{6})$

$$f(x) = \frac{1}{\sqrt{2\pi \frac{25}{6}}} e^{-\frac{1}{2} \frac{(x-5)^2}{\frac{25}{6}}}$$

さいころを 120 回転がす試行について、再び、1 の目が出るかどうかに着目するベルヌーイ試行の確率変数  $X$  は、2 項分布  $B(120, \frac{1}{6})$  である。このとき、この 2 項分布の平均は、 $np = 120 \times \frac{1}{6} = 20$  であり、分散は  $np(1-p) = 120 \times \frac{1}{6} \times (1 - \frac{1}{6}) = 20 \times \frac{5}{6} = \frac{100}{6}$  である。

$$f(x) = {}_{120}C_x \left(\frac{1}{6}\right)^x \left(1 - \frac{1}{6}\right)^{120-x}$$

この平均と分散を持つ正規分布は、 $N(20, \frac{100}{6})$

$$f(x) = \frac{1}{\sqrt{2\pi \frac{100}{6}}} e^{-\frac{1}{2} \frac{(x-20)^2}{\frac{100}{6}}}$$

## 2 確率過程 < 参考 >

### 2.1 確率過程

時間  $t$  をパラメータに持つ確率変数の族  $X_t$  を確率過程と定義する。 $t$  が決まれば、 $X_t$  は1つの確率変数となる。

### 2.2 マルコフ連鎖

#### 2.2.1 マルコフ連鎖の定義

状態空間  $S = \{1, 2, 3, \dots, N\}$  上の離散時間確率過程である確率変数列  $\{X_n; n = 0, 1, 2, \dots\}$  が任意の時刻列  $n = 1, 2, \dots$  任意の状態列  $s_0, s_1, \dots, s_n \in S$  に対して、次の条件付き確率

$$P(\{X_n(\omega) = s_n\} | \{X_0(\omega) = s_0, \dots, X_{n-1}(\omega) = s_{n-1}\}) = P(\{X_n(\omega) = s_n\} | \{X_{n-1}(\omega) = s_{n-1}\})$$

が成立するとき、 $\{X_n\}$  は、 $S$  上のマルコフ連鎖と定義する。

$X_0 \sim X_{n-1}$  が起こった条件の下で  $X_n$  が起こる条件付き確率が  $X_n$  の直前である現在の状態  $X_{n-1}$  のみによって決まり、 $X_0 \sim X_{n-2}$  とは独立である。この性質をマルコフ性と呼ぶ。

■推移確率  $S$  上のマルコフ連鎖  $\{X_n; n = 0, 1, 2, \dots\}$  に対して、

$$P(\{X_n(\omega) = j\} | \{X_{n-1}(\omega) = i\}) = P_{ij}^{(n)}$$

とおくとき、 $P_{ij}^{(n)}$  を推移確率と定義する。

さらに、 $P_{ij}^{(n)}$  を  $(i, j)$  成分とする  $N$  次正方行列

$$P^{(n)} = [P_{ij}^{(n)}] = \begin{bmatrix} p(1 \rightarrow 1) & p(1 \rightarrow 2) & \cdots & p(1 \rightarrow N) \\ p(2 \rightarrow 1) & p(2 \rightarrow 2) & \cdots & p(2 \rightarrow N) \\ \cdots & \cdots & \cdots & \cdots \\ p(N \rightarrow 1) & p(N \rightarrow 2) & \cdots & p(N \rightarrow N) \end{bmatrix}_{i \rightarrow j}$$

この行列を時刻  $n - 1$  におけるマルコフ連鎖  $\{X_n\}$  の推移行列と定義する。

#### 2.2.2 チャップマン・コロモゴロフの方程式

$\forall m, \forall n \in \mathbf{N}$  のとき、

$$P^{(m+n)} = P^{(m)} P^{(n)}$$

が成立する。このとき、推移確率は  $P^{(m+n)}$  の各成分である。

#### 2.2.3 マルコフ連鎖の例と状態推移図

例 1) 状態  $S = \{0, 1\}$ 、時刻  $n - 1$  で

$$\begin{array}{ll} 0 \rightarrow 0 & \text{に変わる確率 } 1 - \varepsilon_n \\ 0 \rightarrow 1 & \text{に変わる確率 } \varepsilon_n \\ 1 \rightarrow 0 & \text{に変わる確率 } p_n \\ 1 \rightarrow 1 & \text{に変わる確率 } 1 - p_n \end{array}$$



とするとき、

$$\begin{aligned} P_{00}^{(n)} &= 1 - \varepsilon_n \\ P_{01}^{(n)} &= \varepsilon_n \\ P_{10}^{(n)} &= p_n \\ P_{11}^{(n)} &= 1 - p_n \end{aligned}$$

推移行列は、

$$P^{(n)} = \begin{bmatrix} 1 - \varepsilon_n & \varepsilon_n \\ p_n & 1 - p_n \end{bmatrix}$$




図1 状態推移図

## 2.3 ポアソン過程と $\Gamma$ -分布

### 2.3.1 ポアソン過程の定義

■定義 事象が時刻  $t = 0$  から  $t$  までに発生した数を  $N(t)$  とする。この  $N(t)$  が実現する確率について、

1.  $P(N(0) = 0) = 1$
2. 十分小さい時間幅  $h$  について  $P(N(t+h) - N(t) = 1) = \lambda h + o(h)$  ( $h \rightarrow 0$ )
3. 十分小さい時間幅  $h$  について  $P(N(t+h) - N(t) \geq 2) = o(h)$  ( $h \rightarrow 0$ )
4. 時刻  $t_0 < t_1 < t_2 < \dots < t_n$  に対して、確率変数  $N(t)$  は、各幅  $t_i - t_{i-1}$  の幅のみに依存（これを定常増分という）して、互いに排反な区間の増分  $N(t_2) - N(t_1), N(t_3) - N(t_2), \dots, N(t_n) - N(t_{n-1})$  は、互いに独立（これを独立増分という）。（このとき  $N(t)$  は定常独立増分であるという）

この4つを満たす  $N(t)$  をポアソン過程と定義する。ここで、パラメータ  $\lambda$  は正数。 $o(h)$  はランダウ記号\*1。

■定理 ポアソン過程  $N(t)$  は、平均  $\mu = \lambda t$  のポアソン分布である。

**Proof)**  $N(t)$  の具体的な形を考えていく。いま、 $N(t) = k$  について、とりうる確率をすべて表現すると、 $k = 0, 1, 2, 3, \dots$  として、すべての確率の和は、当然、

$$P_0(t) + P_1(t) + P_2(t) + P_3(t) + \dots = 1$$

これら各  $P_k(t)$  に共通な一般化した形が確率変数  $N(t)$  をもつ関数である。まず、 $P_0(t)$  から順に考えていくと、定義の条件 2. と 3. よりすぐに

$$P_1(h) \approx \lambda h, \quad P_2(h) + P_3(h) + \dots \approx 0$$

\*1 ランダウ記号の定義：

$$\lim_{x \rightarrow a} \frac{f(x)}{h(x)} = 0 \Rightarrow f(x) = o(h(x)) \quad (x \rightarrow a)$$

よって、

$$P_0(h) = 1 - (P_1(h) + P_2(h) + P_3(h) + \dots) = 1 - \lambda h$$

いま、 $h$  の幅とは  $(t, t+h]$  であって、 $(0, t]$  とは排反であるから定義の条件 4. より、独立事象の確率であるから、

$$P_0(t+h) = P_0(t) \cdot P_0(h) \approx P_0(t)(1 - \lambda h) = P_0(t) - \lambda h P_0(t)$$

が成り立つ。よって、

$$\begin{aligned} \frac{P_0(t+h) - P_0(t)}{h} &= -\lambda P_0(t) \\ \lim_{h \rightarrow 0} \frac{P_0(t+h) - P_0(t)}{h} &= \lim_{h \rightarrow 0} \{-\lambda P_0(t)\} \\ P_0'(t) &= -\lambda P_0(t) \end{aligned}$$

ここで、変数分離形として、

$$\begin{aligned} \frac{dP_0(t)}{dt} &= -\lambda P_0(t) \\ \int \frac{1}{P_0(t)} dt &= \int -\lambda dt + \gamma \\ \log P_0(t) &= -\lambda t + \gamma \\ P_0(t) &= e^{-\lambda t + \gamma} = e^\gamma e^{-\lambda t} \end{aligned}$$

ここで、 $e^\gamma = C$  とおくと、 $P_0(t) = C e^{-\lambda t}$ 。また、定義の条件 1. より、 $P_0(0) = 1$  だから、 $P_0(0) = C e^{-\lambda \cdot 0} = 1$  より  $C = 1$ 。つまり、

$$P_0(t) = e^{-\lambda t}$$

次に、 $k = 1$  のときを考えると、 $(0, t]$  で 1 回発生もしくは  $(t, t+h]$  で 1 回発生であるから、

$$P_1(t+h) = P_1(t) \cdot P_0(h) + P_0(t) \cdot P_1(h) = P_1(t) \cdot (1 - \lambda h) + P_0(t) \cdot (\lambda h)$$

よって、

$$\begin{aligned} \frac{P_1(t+h) - P_1(t)}{h} &= -\lambda P_1(t) + \lambda P_0(t) \\ \lim_{h \rightarrow 0} \frac{P_1(t+h) - P_1(t)}{h} &= \lim_{h \rightarrow 0} \{-\lambda P_1(t) + \lambda P_0(t)\} \\ P_1'(t) &= -\lambda P_1(t) + \lambda P_0(t) \\ P_1'(t) + \lambda P_1(t) &= \lambda P_0(t) \end{aligned}$$

線形微分方程式なので、変数  $t$  の取り得る範囲は 0 から  $t$  までだから、

$$\begin{aligned} P_1(t) &= e^{-\int_0^t \lambda ds} \left\{ \int_0^t \lambda P_0(s) e^{\int_0^s \lambda ds} ds + \gamma \right\} \\ &= e^{-\lambda t} \left\{ \int_0^t \lambda P_0(s) e^{\lambda s} ds + \gamma \right\} \\ &= e^{-\lambda t} \int_0^t \lambda e^{\lambda s} P_0(s) ds + e^{-\lambda t} \gamma \end{aligned}$$

ここで、 $e^{-\lambda t}\gamma = C$  とおくと、

$$P_1(t) = e^{-\lambda t} \int_0^t \lambda e^{\lambda s} P_0(s) ds + C$$

いま、 $t = 0$  を代入してみると、積分区間は 0 から 0 までの積分で、1 点での積分はゼロだから、 $P_1(0) = C$  とわかる。よって、

$$P_1(t) = e^{-\lambda t} \int_0^t \lambda e^{\lambda s} P_0(s) ds + P_1(0) \quad (1)$$

時刻 0 での発生回数はないので、発生回数がない確率は  $P_0(0) = 1$  であるが、発生回数が 1 の場合の発生確率  $P_1(0) = 0$  である。

全く同様に  $k$  回の場合を考えると、 $(0, t]$  での発生回数と  $(t, t+h]$  での発生回数をあわせて  $k$  であるから、

$$P_k(t+h) = P_k(t) \cdot P_0(h) + P_{k-1}(t) \cdot P_1(h) + P_{k-2}(t) \cdot P_2(h) + \dots$$

いま、定義の条件 3. より、 $P_2(h), P_3(h), \dots, \approx 0$  だから、

$$P_k(t+h) \approx P_k(t) \cdot (1 - \lambda h) + P_{k-1}(t) \cdot (\lambda h)$$

よって、 $k = 1$  の場合の式 (1) を導出したときと全く同様に

$$\begin{aligned} \frac{P_k(t+h) - P_k(t)}{h} &= -\lambda P_k(t) + \lambda P_{k-1}(t) \\ P_k'(t) &= -\lambda P_k(t) + \lambda P_{k-1}(t) \\ P_k(t) &= e^{-\lambda t} \int_0^t \lambda e^{\lambda s} P_{k-1}(s) ds + P_k(0) \end{aligned}$$

時刻 0 での発生回数はないので、発生回数が 1 以上の場合の発生確率  $P_k(0) = 0$  ( $k \neq 0$ ) である。よって、

$$P_k(t) = e^{-\lambda t} \int_0^t \lambda e^{\lambda s} P_{k-1}(s) ds \quad (2)$$

式 (2) を具体的に解いていく。

$$\begin{aligned} P_1(t) &= e^{-\lambda t} \int_0^t \lambda e^{\lambda s} P_0(s) ds = e^{-\lambda t} \int_0^t \lambda e^{\lambda s} e^{-\lambda s} ds = e^{-\lambda t} \lambda [s]_0^t = \lambda t e^{-\lambda t} \\ P_2(t) &= e^{-\lambda t} \int_0^t \lambda e^{\lambda s} P_1(s) ds = e^{-\lambda t} \int_0^t \lambda e^{\lambda s} \lambda s e^{-\lambda s} ds = e^{-\lambda t} \int_0^t \lambda^2 s ds = e^{-\lambda t} \lambda^2 \left[ \frac{1}{2} s^2 \right]_0^t = e^{-\lambda t} \frac{(\lambda t)^2}{2!} \\ P_3(t) &= e^{-\lambda t} \int_0^t \lambda e^{\lambda s} e^{-\lambda s} \frac{(\lambda s)^2}{2!} ds = e^{-\lambda t} \lambda^3 \frac{1}{2!} \left[ \frac{1}{3} s^3 \right]_0^t = e^{-\lambda t} \frac{(\lambda t)^3}{3!} \\ &\vdots \\ P_k(t) &= e^{-\lambda t} \frac{(\lambda t)^k}{k!} \end{aligned}$$

つまり、ポアソン過程  $N(t)$  は、平均  $\mu = \lambda t$  のポアソン分布である。

2.3.2  $\Gamma$ -分布の導出

連続型確率密度関数とその性質に関しては、前回までの講義で解説したが、理解のしやすい連続型一様分布を除くと、指数分布と  $\chi^2$ -分布については、 $\Gamma$ -分布の特別な場合であり、 $F$ -分布は、 $\chi^2$ -分布どうしの組み合わせで、 $t$ -分布は、標準正規分布と  $\chi^2$ -分布の組み合わせで導出できた。では、正規分布と  $\Gamma$ -分布どのように導出されるのだろうか。正規分布については、次の講義回で導出と統計上の意味・意義を詳しく解説する。ここでは、 $\Gamma$ -分布について調べてみよう。

前節のポアソン過程において、 $\alpha$  以上の値をとる確率は、分布関数を考慮して、

$$P(X_t \geq \alpha) = 1 - \sum_{k=0}^{\alpha-1} e^{-\lambda t} \frac{(\lambda t)^k}{k!} = 1 - e^{-\lambda t} \sum_{k=0}^{\alpha-1} \frac{(\lambda t)^k}{k!} \equiv \mathcal{D}(t)$$

この  $\mathcal{D}(t)$  について、時刻  $t$  での微少変化を考える。 $(\alpha$  以上が起こる時間変化を求める)

$$\begin{aligned} \frac{d\mathcal{D}(t)}{dt} &= \lambda e^{-\lambda t} \sum_{k=0}^{\alpha-1} \frac{(\lambda t)^k}{k!} - e^{-\lambda t} \sum_{k=0}^{\alpha-1} \frac{k(\lambda t)^{k-1} \lambda}{k!} \\ &= \lambda e^{-\lambda t} \sum_{k=0}^{\alpha-1} \frac{(\lambda t)^k}{k!} - \lambda e^{-\lambda t} \sum_{k=0}^{\alpha-1} \frac{k(\lambda t)^{k-1}}{k!} \end{aligned}$$

ここで、 $\sum$  の  $k=0$  を具体的に代入すると、

$$\begin{aligned} &= \lambda e^{-\lambda t} + \lambda e^{-\lambda t} \sum_{k=1}^{\alpha-1} \frac{(\lambda t)^k}{k!} - \lambda e^{-\lambda t} \sum_{k=1}^{\alpha-1} \frac{k(\lambda t)^{k-1}}{k!} \\ &= \lambda e^{-\lambda t} \left\{ 1 + \sum_{k=1}^{\alpha-1} \frac{(\lambda t)^k}{k!} - \sum_{k=1}^{\alpha-1} \frac{k(\lambda t)^{k-1}}{k!} \right\} \\ &= \lambda e^{-\lambda t} \left[ 1 + \sum_{k=1}^{\alpha-1} \left\{ \frac{(\lambda t)^k}{k!} - \frac{(\lambda t)^{k-1}}{(k-1)!} \right\} \right] \end{aligned}$$

ここで、 $\sum$  の中を計算すると、 $k=1$  と  $k=\alpha-1$  のみ残り、残りの項はすべてカスケード状に消える。

$$\begin{aligned} &= \lambda e^{-\lambda t} \left[ 1 + \frac{(\lambda t)^1}{1!} - \frac{(\lambda t)^0}{0!} + \frac{(\lambda t)^2}{2!} - \frac{(\lambda t)^1}{1!} + \cdots + \frac{(\lambda t)^{\alpha-2}}{(\alpha-2)!} - \frac{(\lambda t)^{\alpha-3}}{(\alpha-3)!} + \frac{(\lambda t)^{\alpha-1}}{(\alpha-1)!} - \frac{(\lambda t)^{\alpha-2}}{(\alpha-2)!} \right] \\ &= \lambda e^{-\lambda t} \frac{(\lambda t)^{\alpha-1}}{(\alpha-1)!} \\ &= \frac{\lambda^\alpha}{(\alpha-1)!} e^{-\lambda t} t^{\alpha-1} \end{aligned}$$

ここで、 $\lambda = \frac{1}{\beta}$  と置き、 $(\alpha-1)! = \Gamma(\alpha)$  であるから、

$$= \frac{1}{\beta^\alpha \Gamma(\alpha)} t^{\alpha-1} e^{-\frac{t}{\beta}}$$

この確率変数  $t$  は、時刻  $t$  での微少変化量だから、 $x$  で表すとすると、

$$f(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-\frac{x}{\beta}}$$

$\Gamma$ -分布は、単位時間あたり  $\frac{1}{\beta}$  で起こる事象が  $\alpha$  回起こるまでの時間を表し、機械や電子部品の寿命モデルなどに現れてくる。

## 索引

$F$ -分布, 12

$\chi^2$ -分布, 12

確率過程, 8

確率分布, 2, 3, 5-7

確率変数, 2-9

確率変数の族, 8

確率変数列, 8

確率母関数, 4, 5

確率密度関数, 2

$\Gamma$ -分布, 12

期待値, 3-6

期待値と分散の関係, 3-5

経験分布, 2

指数分布, 12

条件付き確率, 8

状態空間, 8

状態推移図, 8

推移確率, 8

推移行列, 8

正規近似, 7

正規分布, 7, 12

積率, 3

積率母関数, 2, 3

接線の傾き, 2

線形微分方程式, 10

相対累積度数, 2

大数の法則, 6

チェビシェフの不等式, 6

中心極限定理, 7

$t$ -分布, 12

定常独立増分, 9

度数, 2

度数分布, 2

2項分布, 7

微少変化量, 12

ヒストグラム, 2

微分積分学の基本定理, 2

標準正規分布, 12

分散, 5, 6

分布関数, 2

ベルヌーイ試行, 7

変数分離形, 10

ポアソン過程, 9, 11, 12

ポアソン分布, 9, 11

マルコフ性, 8

マルコフ連鎖, 8

面積, 2

ランダウ記号, 9

離散型確率変数, 2, 4

離散時間確率過程, 8

理論分布, 2

累積相対度数, 2

累積分布関数, 2

連続型一様分布, 12

連続型確率変数, 3, 5

連続型確率密度関数, 12