

6. Zmienne losowe typu ciągłego (7.04.2008)

Pole trapezu krzywoliniowego

Przypomnienie: figurę ograniczoną przez:

- wykres funkcji $y = f(x)$, gdzie f jest funkcją ciągłą;
- proste $x = a$, $x = b$, $a < b$,
- oś OX (tj. prostą $y = 0$)

będziemy nazywać *trapezem krzywoliniowym* (odpowiadającym funkcji f oraz odcinkowi $[a, b]$).

Pole tej figury można przedstawić w postaci całki:

$$\int_a^b f(x) dx.$$

Pole „nieograniczonego” trapezu krzywoliniowego-całka niewłaściwa

Problem: jesteśmy zainteresowani polem figury ograniczonej: wykresem funkcji $f(x) = e^{-x}$ oraz prostymi $y = 0$, $x = 0$.

Pole tego obszaru można określić jako całkę:

$$\lim_{T \rightarrow \infty} \int_0^T f(x) dx.$$

Korzystając z faktu:

$$\int_0^T e^{-x} dx = -e^{-T} + e^0 = 1 - e^{-T}$$

znajdujemy, że granica ta jest równa 1.

Całka niewłaściwa z funkcji nieujemnej

Całkę niewłaściwą z funkcji nieujemnej f na półprostej $[a, \infty)$ można określić jako granicę:

$$\lim_{T \rightarrow \infty} \int_a^T f(t) dt$$

jeśli ona istnieje.

Analogicznie można całkę niewłaściwą z funkcji nieujemnej f na półprostej $(-\infty, b]$.

Całkę niewłaściwą z funkcji nieujemnej f na prostej $(-\infty, \infty)$ można określić jako granicę $\lim_{T \rightarrow \infty} \int_{-T}^T f(t) dt$, jeśli ona istnieje.

Zmienne losowe typu ciągłego

Definicja 1 *Mówimy, że zmienna losowa X jest typu ciągłego, jeśli istnieje nieujemna funkcja g (spełniająca pewne łagodne warunki- np. jest przedziałami ciągła) taka, że dla każdych $a < b$*

$$P(a < X < b) = \int_a^b g(x)dx.$$

Rozkład jednostajny na odcinku $[0, 1]$

Przykładem zmiennej losowej typu ciągłego jest rozkład jednostajny na odcinku $[0, 1]$ (oznaczenie: $U(0, 1)$). Jego funkcja gęstości u dana jest wzorem

$$u(x) = \begin{cases} 1, & \text{jeśli } 0 \leq x \leq 1, \\ 0 & \text{jeśli } x < 0 \text{ lub } x > 1. \end{cases}$$

Rozkład ten może opisywać np. czas oczekiwania na autobus A , odjeżdżający do miejscowości B co godzinę, przez pasażera C ; zakładamy, że C nie zna rozkładu jazdy dla tej linii i że przychodzi na przystanek w losowym momencie.

Rozkład jednostajny na odcinku $[0, 1]$ -przykład obliczeń

Czas oczekiwania na autobus- zmienna losowa $Y \sim U(0, 1)$.

Prawdopodobieństwo $P(\frac{1}{3} < Y < \frac{1}{2})$ jest równe:

$$P\left(\frac{1}{3} < Y < \frac{1}{2}\right) = \int_{1/3}^{1/2} 1dx = [x]_{1/3}^{1/2} = \frac{1}{2} - \frac{1}{3} = \frac{1}{6}$$

Prawdopodobieństwa odpowiadające nierównościom ostrym i słabym

Dla zmiennej losowej X o rozkładzie typu ciągłego mamy:

$$P(a < X < b) = P(a \leq X < b) = P(a < X \leq b) = P(a \leq X \leq b).$$

Równość ta wynika z własności całki oznaczonej.


Rozkład normalny

Szczególnie ważnym w zastosowaniach jest rozkład normalny.

Definicja 2 *Mówimy, że zmienna losowa X ma rozkład normalny z parametrami μ i σ , gdzie $\mu \in \mathbb{R}$ i $\sigma > 0$, jeżeli gęstość jej rozkładu jest określona wzorem:*

$$\phi_{\mu,\sigma}(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

Skrótowy zapis: $X \sim N(\mu, \sigma)$. Dla $\mu = 0$ i $\sigma = 1$ będziemy pisać zamiast $\phi_{\mu,\sigma}(x)$ krótko $\phi(x)$.



Rysunek 1: Wykresy gęstości rozkładów normalnych: $N(0, 1)$ (linia ciągła), $N(0, 2)$ (linia „kropkowana”), $N(2, 1)$ (linia „kreskowana”).

Rozkład normalny— zastosowania

Wiele cech (zmiennych losowych) w życiu gospodarczym, w świecie przyrody ma rozkład zbliżony do normalnego.

Wynika to z tzw. centralnego twierdzenia granicznego, z którego wynika, że średnia $\frac{1}{n}(X_1 + X_2 + \dots + X_n)$, gdzie X_1, X_2, \dots, X_n są niezależnymi zmiennymi losowymi o tym samym rozkładzie, ma rozkład zbliżony do normalnego $N(\mu, \sigma)$ dla pewnych μ i σ . Dokładniejsze sformułowanie tego twierdzenia wymaga określenia wartości oczekiwanej i wariancji zmiennej losowej typu ciągłego.

Wartość oczekiwana i wariancja dla zmiennych losowych typu ciągłego

Wartość oczekiwana i wariancja zmiennej losowej X typu ciągłego zdefiniowana jest wzorami:

$$\mu = E(X) = \int_{-\infty}^{\infty} xg(x)dx, \quad (1)$$

$$Var(X) = \int_{-\infty}^{\infty} (x - \mu)^2 g(x)dx, \quad (2)$$

gdzie g jest funkcją gęstości zmiennej X .

Wartość oczekiwana i wariancja zmiennej losowej o rozkładzie $U(0, 1)$

Niech $X \sim U(0, 1)$. Funkcja gęstości g jest równa 1 na $[0, 1]$; poza tym przedziałem jest równa 0.

Mamy:

$$E(X) = \int_{-\infty}^{\infty} xg(x)dx = \int_0^1 xdx = \left[\frac{x^2}{2} \right]_0^1 = \frac{1}{2}$$

oraz

$$\begin{aligned} \text{Var}(X) &= \int_{-\infty}^{\infty} \left(x - \frac{1}{2}\right)^2 g(x) dx = \\ &= \int_0^1 \left(x - \frac{1}{2}\right)^2 dx = \left[\frac{x^3}{3} - \frac{x^2}{2} + \frac{x}{4} \right]_0^1 = \frac{1}{3} - \frac{1}{2} + \frac{1}{4} = \frac{1}{12}. \end{aligned}$$

Wartość oczekiwana i wariancja zmiennej losowej o rozkładzie normalnym

Można pokazać, że jeśli $X \sim N(\mu, \sigma)$, to

$$E(X) = \mu, \quad Var(X) = \sigma^2, \quad D(X) = \sigma.$$

Wymaga to obliczenia całek trochę bardziej skomplikowanych niż dla przypadku odpowiadającego $U(0, 1)$.

Obliczanie prawdopodobieństw w rozkładzie normalnym- $N(0, 1)$

Dla $a < b$ prawdopodobieństwo $P(a < X < b)$, gdzie $X \sim N(0, 1)$ jest równe:


$$P(a < X < b) = \int_a^b \phi(x) dx = \Phi(b) - \Phi(a),$$

gdzie Φ jest określona przez:

$$\Phi(t) = \int_{-\infty}^t \phi(x) dx.$$

Funkcja Φ jest dystrybuantą rozkładu normalnego $N(0, 1)$. Funkcji Φ nie da się wyrazić za pomocą skończonej liczby działań na podstawowych funkcjach elementarnych — stąd potrzeba sporządzania tablic statystycznych zawierających wartości funkcji Φ (można je znaleźć w prawie każdym podręczniku statystyki).

Własności funkcji Φ



Rysunek 2: Wykresy gęstości ϕ rozkładu normalnego (z lewej strony) $N(0, 1)$ i dystrybuanty rozkładu normalnego Φ (z prawej strony)

Można pokazać, że $\Phi(0) = 0,5$ oraz $\Phi(t) = 1 - \Phi(-t)$ dla dowolnego t ; stąd można się ograniczyć do tablicowania funkcji Φ dla $t \geq 0$.

Obliczanie prawdopodobieństw w rozkładzie normalnym- $N(\mu, \sigma)$

Można pokazać, że jeśli $X \sim N(\mu, \sigma)$, to

$$\frac{X - \mu}{\sigma} \sim N(0, 1).$$

Wynika to z własności wartości oczekiwanej i dyspersji (omówionych podczas poprzedniego wykładu).

Stąd dla $a < b$ prawdopodobieństwo $P(a < X < b)$, $X \sim N(\mu, \sigma)$ jest równe:

$$P(a < X < b) = P\left(\frac{a - \mu}{\sigma} < \frac{X - \mu}{\sigma} < \frac{b - \mu}{\sigma}\right) = \Phi\left(\frac{b - \mu}{\sigma}\right) - \Phi\left(\frac{a - \mu}{\sigma}\right).$$

Obliczanie prawdopodobieństw w rozkładzie normalnym— przykład

Niech X oznacza wzrost dorosłych mężczyzn w państwie A ; zakładamy, że $X \sim N(177, 10)$.

Chcemy obliczyć: (a) $P(174 < X < 182)$, (b) $P(X > 182)$.

Obliczenia dla (a):

$$\begin{aligned} P(174 < X < 182) &= \Phi\left(\frac{182 - 177}{10}\right) - \Phi\left(\frac{174 - 177}{10}\right) \\ &= \Phi(0,5) - \Phi(-0,3) = \Phi(0,5) - (1 - \Phi(0,3)) = \\ &= \Phi(0,5) + \Phi(0,3) - 1 \approx 0,6915 + 0,6179 - 1 = 0,3094. \end{aligned}$$

Obliczenia dla (b) można przeprowadzić w analogiczny sposób, korzystając z równości:

$$P(X > 182) = 1 - P(X < 182) = 1 - \Phi\left(\frac{182 - 177}{10}\right) = 1 - \Phi(0,5).$$

Centralne Twierdzenie Graniczne

Twierdzenie 1 *Jeżeli X_1, X_2, \dots, X_n są niezależnymi zmiennymi losowymi o tym samym rozkładzie, $E(X_1) = \mu$, $D(X_1) = \sigma$, to zmienna losowa*

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}},$$

gdzie $\bar{X} = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$, ma w przybliżeniu standardowy rozkład normalny $N(0, 1)$, tj.

$$P\left(a \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq b\right) \rightarrow \Phi(b) - \Phi(a)$$

dla dowolnych a i b , $a < b$

Innymi słowy, rozkład \bar{X} jest w przybliżeniu równy rozkładowi normalnemu $N(\mu, \sigma/\sqrt{n})$.

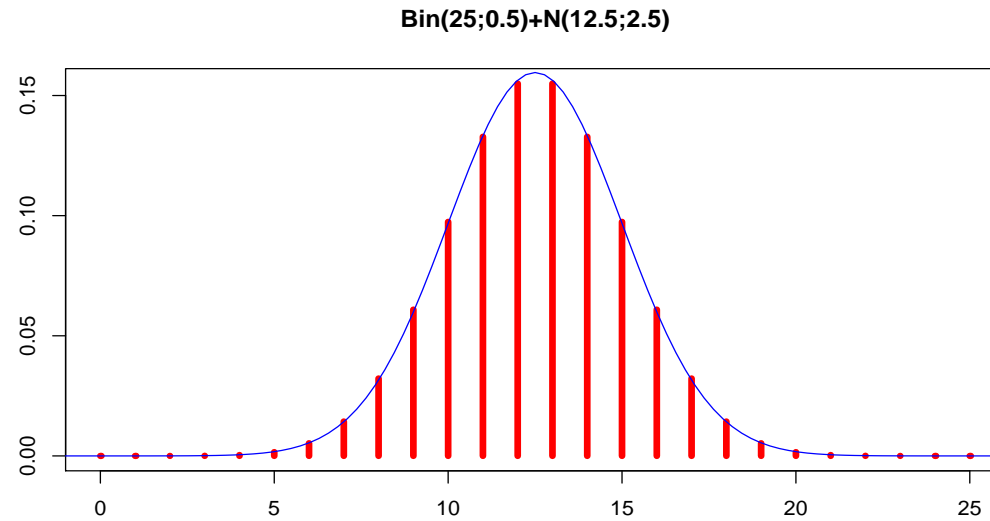
Przykład

Rzucamy monetą 25 razy. Niech Y oznacza liczbę orłów. X ma rozkład $Bin(25; 0,5)$. Zmienna Y może być przedstawiona jako suma 25 niezależnych zmiennych losowych X_1, \dots, X_{25} o rozkładzie $Bin(1; 0,5)$. Korzystając z Centralnego Twierdzenia Granicznego: $\bar{X} \sim N(p, \sigma/\sqrt{n})$, gdzie $n = 25, p = 0,5, \sigma = \sqrt{p(1-p)} = 0,5$, czyli

\bar{X} ma w przybliżeniu rozkład $N(0,5; 0,5/5)$

więc

Y ma w przybliżeniu rozkład $N(12,5; 2,5)$



Rysunek 3: Rozkład dwumianowy $Bin(25; 0,5)$ i odpowiadający mu rozkład normalny $N(12,5; 2,5)$

Cechy o rozkładzie normalnym w życiu gospodarczym i w przyrodzie

Centralne twierdzenie graniczne: sumy wyników niezależnych eksperymentów losowych mają rozkład normalny (w przybliżeniu).

Można oczekiwać, że wielkości takie jak: suma wydatków dziesięciu kolejnych klientów w sklepie; wynik ankiety określającej preferencje osób ankietowanych itd. będą miały rozkład zbliżony do normalnego.

Inne rozkłady ciągłe

Dowolna funkcja g spełniająca warunki:

(i) dziedziną funkcji g jest zbiór liczb rzeczywistych \mathbb{R} ;

(ii) $g(x) \geq 0$ dla $x \in \mathbb{R}$;

(iii) $\int_{-\infty}^{\infty} g(x) = 1$.

jest funkcją gęstością pewnej zmiennej losowej;

Poza rozkładem normalnym i rozkładem jednostajnym $U(0, 1)$ do opisu cech w życiu gospodarczym i naukach przyrodniczych stosuje się wiele innych rozkładów prawdopodobieństwa (wykładniczy, t-Studenta itd.).

Również histogram probabilistyczny spełnia warunki (i)–(iii)- rozkład odpowiadający histogramowi probabilistycznemu jest niekiedy określany mianem histogramu empirycznego.

Lektura uzupełniająca

T. Bednarski, Elementy matematyki w naukach ekonomicznych. Oficyna ekonomiczna. Kraków 2004, str. 234–244.

Koronacki, J., Mielniczuk, J. Statystyka dla studentów kierunków technicznych i przyrodniczych. WNT. Warszawa 2001, s. 111–118.

A. Walanus, Krzywa dzwonowa.

<http://www.statsoft.pl/czytelnia/statdlaka/dzwon.html>

Tablica z wartościami funkcji Φ , dystrybuanty rozkładu normalnego $N(0, 1)$,

<http://www.math.unb.ca/knight/utility/NormTble.htm>; Probability Content from $-\infty$ to Z odpowiada wartościom $\Phi(Z)$, $Z = 0; 0,01; \dots$