

Metody probabilistyczne

12. Twierdzenia graniczne II

Wojciech Kotłowski





Instytut Informatyki PP

<http://www.cs.put.poznan.pl/wkotlowski/>

20.01.2021

Centralne Twierdzenie Graniczne

Schemat Bernoulliego ($p = \frac{1}{2}$): rozkład zmiennej $\bar{X}_n = \frac{S_n}{n}$



Standaryzacja zmiennej losowej

Zmienną X , dla której $EX = 0$ i $D^2(X) = 1$ nazywa się **zmienną losową standaryzowaną**

Standaryzacja zmiennej losowej

Zmienną X , dla której $EX = 0$ i $D^2(X) = 1$ nazywa się **zmienną losową standaryzowaną**

Standaryzacja zmiennej losowej:

Dla dowolnej zmiennej X , zmienna:

$$U = \frac{X - EX}{D(X)} \quad \text{jest zmienną standaryzowaną}$$

Zadanie 1

Udowodnij to stwierdzenie korzystając ze znanych własności $E(aX + b) = aEX + b$ oraz $D^2(aX + b) = a^2 D^2(X)$

Schemat Bernoulliego $B(n, p)$

$$S_n = \sum_{i=1}^n X_i, \quad ES_n = np, \quad D^2(S_n) = np(1-p)$$
$$\bar{X}_n = \frac{S_n}{n}, \quad E\bar{X}_n = p, \quad D^2(\bar{X}_n) = \frac{p(1-p)}{n}$$

Schemat Bernoulliego $B(n, p)$

$$S_n = \sum_{i=1}^n X_i, \quad ES_n = np, \quad D^2(S_n) = np(1-p)$$
$$\bar{X}_n = \frac{S_n}{n}, \quad E\bar{X}_n = p, \quad D^2(\bar{X}_n) = \frac{p(1-p)}{n}$$

Jak zachowuje się ciąg S_n (lub \bar{X}_n) po **standaryzacji**?

$$U_n = \frac{S_n - ES_n}{D(S_n)} = \frac{S_n - np}{\sqrt{np(1-p)}} = \frac{\bar{X}_n - E\bar{X}_n}{D(\bar{X}_n)} = \frac{\bar{X}_n - p}{\sqrt{p(1-p)}}\sqrt{n}$$

Schemat Bernoulliego $B(n, p)$

$$S_n = \sum_{i=1}^n X_i, \quad ES_n = np, \quad D^2(S_n) = np(1-p)$$
$$\bar{X}_n = \frac{S_n}{n}, \quad E\bar{X}_n = p, \quad D^2(\bar{X}_n) = \frac{p(1-p)}{n}$$

Jak zachowuje się ciąg S_n (lub \bar{X}_n) po **standaryzacji**?

$$U_n = \frac{S_n - ES_n}{D(S_n)} = \frac{S_n - np}{\sqrt{np(1-p)}} = \frac{\bar{X}_n - E\bar{X}_n}{D(\bar{X}_n)} = \frac{\bar{X}_n - p}{\sqrt{p(1-p)}} \sqrt{n}$$

Interpretacja: patrzymy na S_n (lub \bar{X}_n) dobierając zawsze skalę i przesunięcie początku układu współrzędnych tak, aby wartość oczekiwana znajdowała się w punkcie 0, a odchylenie standardowe było jednostkowe.

Schemat Bernoulliego $B(n, p)$

$$S_n = \sum_{i=1}^n X_i, \quad ES_n = np, \quad D^2(S_n) = np(1-p)$$
$$\bar{X}_n = \frac{S_n}{n}, \quad E\bar{X}_n = p, \quad D^2(\bar{X}_n) = \frac{p(1-p)}{n}$$


Jak zachowuje się ciąg S_n (lub \bar{X}_n) po **standaryzacji**?

$$U_n = \frac{S_n - ES_n}{D(S_n)} = \frac{S_n - np}{\sqrt{np(1-p)}} = \frac{\bar{X}_n - E\bar{X}_n}{D(\bar{X}_n)} = \frac{\bar{X}_n - p}{\sqrt{p(1-p)}}\sqrt{n}$$


Interpretacja: patrzymy na S_n (lub \bar{X}_n) dobierając zawsze skalę i przesunięcie początku układu współrzędnych tak, aby wartość oczekiwana znajdowała się w punkcie 0, a odchylenie standardowe było jednostkowe.

Ciąg U_n nie zbiega teraz do liczby, ponieważ ma stale jednostkowe odchylenie standardowe!


Rozkład zmiennej U_n ($p = \frac{1}{2}$)




Rozkład zmiennej U_n ($p = \frac{1}{2}$)




Rozkład zmiennej U_n ($p = \frac{1}{2}$)




Rozkład zmiennej U_n ($p = \frac{1}{2}$)



Rozkład zmiennej U_n ($p = \frac{1}{2}$)



Rozkład zmiennej U_n ($p = \frac{1}{2}$)



Twierdzenie Moivre'a-Laplace'a

Rozważmy ciąg niezależnych zmiennych losowych X_1, X_2, X_3, \dots , gdzie $X_n \sim B(p)$ dla wszystkich n

$$S_n = \sum_{i=1}^n X_i \sim B(n, p), \quad U_n = \frac{S_n - np}{\sqrt{np(1-p)}}$$

Dystrybuanta zmiennej U_n zbiega do dystrybuanty standardowego rozkładu normalnego:

$$\forall x \quad \lim_{n \rightarrow \infty} F_{U_n}(x) = \Phi(x)$$

Wnioski z twierdzenia Moivre'a-Laplace'a

- Dla dużych n , rozkład zmiennej U_n można przybliżyć rozkładem normalnym $N(0, 1)$:

$$U_n = \frac{S_n - np}{\sqrt{np(1-p)}} \simeq X, \quad \text{gdzie } X \sim N(0, 1)$$

Wnioski z twierdzenia Moivre'a-Laplace'a

- Dla dużych n , rozkład zmiennej U_n można przybliżyć rozkładem normalnym $N(0, 1)$:

$$U_n = \frac{S_n - np}{\sqrt{np(1-p)}} \simeq X, \quad \text{gdzie } X \sim N(0, 1)$$

- Równoważnie, można przybliżyć rozkład zmiennej $S_n \sim B(n, p)$:

$$S_n \simeq \sqrt{np(1-p)}X + np \sim N(np, np(1-p))$$

Wnioski z twierdzenia Moivre'a-Laplace'a

- Dla dużych n , rozkład zmiennej U_n można przybliżyć rozkładem normalnym $N(0, 1)$:

$$U_n = \frac{S_n - np}{\sqrt{np(1-p)}} \simeq X, \quad \text{gdzie } X \sim N(0, 1)$$

- Równoważnie, można przybliżyć rozkład zmiennej $S_n \sim B(n, p)$:

$$S_n \simeq \sqrt{np(1-p)}X + np \sim N(np, np(1-p))$$

- **Wniosek:** dla dużych n , rozkład dwumianowy $B(n, p)$ można przybliżyć rozkładem normalnym $N(np, np(1-p))$

Wnioski z twierdzenia Moivre'a-Laplace'a

- Dla dużych n , rozkład zmiennej U_n można przybliżyć rozkładem normalnym $N(0, 1)$:

$$U_n = \frac{S_n - np}{\sqrt{np(1-p)}} \simeq X, \quad \text{gdzie } X \sim N(0, 1)$$

- Równoważnie, można przybliżyć rozkład zmiennej $S_n \sim B(n, p)$:

$$S_n \simeq \sqrt{np(1-p)}X + np \sim N(np, np(1-p))$$

- **Wniosek:** dla dużych n , rozkład dwumianowy $B(n, p)$ można przybliżyć rozkładem normalnym $N(np, np(1-p))$
- Przybliżenie to można stosować już dla niewielkiego n : warunek stosowalności określa się zwykle na: $np \geq 5$ i $n(1-p) \geq 5$.

Przykład

Oszacuj prawdopodobieństwo, że liczba sukcesów S_n w rozkładzie dwumianowym $B(n = 30, p = \frac{1}{3})$ znajdzie się w zakresie $\{9, 10, 11, 12\}$.

Przykład

Oszacuj prawdopodobieństwo, że liczba sukcesów S_n w rozkładzie dwumianowym $B(n = 30, p = \frac{1}{3})$ znajdzie się w zakresie $\{9, 10, 11, 12\}$.

Odpowiedź dokładna:

$$P(9 \leq S_n \leq 12) = \sum_{k=9}^{12} \binom{30}{k} \left(\frac{1}{3}\right)^k \left(\frac{2}{3}\right)^{30-k} \simeq 0.548$$

Przykład

Oszacuj prawdopodobieństwo, że liczba sukcesów S_n w rozkładzie dwumianowym $B(n = 30, p = \frac{1}{3})$ znajdzie się w zakresie $\{9, 10, 11, 12\}$.

Odpowiedź przybliżona:

Warunki przybliżenia spełnione: $np = 10 \geq 5$, $n(1 - p) = 20 \geq 5$

$$P(a \leq S_n \leq b) = P\left(\frac{a - np}{\sqrt{np(1 - p)}} \leq \frac{S_n - np}{\sqrt{np(1 - p)}} \leq \frac{b - np}{\sqrt{np(1 - p)}}\right)$$

Przykład

Oszacuj prawdopodobieństwo, że liczba sukcesów S_n w rozkładzie dwumianowym $B(n = 30, p = \frac{1}{3})$ znajdzie się w zakresie $\{9, 10, 11, 12\}$.

Odpowiedź przybliżona:

Warunki przybliżenia spełnione: $np = 10 \geq 5$, $n(1 - p) = 20 \geq 5$

$$P(a \leq S_n \leq b) = P\left(\frac{a - np}{\sqrt{np(1 - p)}} \leq \underbrace{\frac{S_n - np}{\sqrt{np(1 - p)}}}_{U_n \simeq X \sim N(0,1)} \leq \frac{b - np}{\sqrt{np(1 - p)}}\right)$$

Przykład

Oszacuj prawdopodobieństwo, że liczba sukcesów S_n w rozkładzie dwumianowym $B(n = 30, p = \frac{1}{3})$ znajdzie się w zakresie $\{9, 10, 11, 12\}$.

Odpowiedź przybliżona:

Warunki przybliżenia spełnione: $np = 10 \geq 5$, $n(1 - p) = 20 \geq 5$

$$\begin{aligned} P(a \leq S_n \leq b) &= P\left(\frac{a - np}{\sqrt{np(1 - p)}} \leq \underbrace{\frac{S_n - np}{\sqrt{np(1 - p)}}}_{U_n \simeq X \sim N(0,1)} \leq \frac{b - np}{\sqrt{np(1 - p)}}\right) \\ &\simeq P\left(\frac{a - np}{\sqrt{np(1 - p)}} \leq X \leq \frac{b - np}{\sqrt{np(1 - p)}}\right) \quad (X \sim N(0,1)) \end{aligned}$$

Przykład

Oszacuj prawdopodobieństwo, że liczba sukcesów S_n w rozkładzie dwumianowym $B(n = 30, p = \frac{1}{3})$ znajdzie się w zakresie $\{9, 10, 11, 12\}$.

Odpowiedź przybliżona:

Warunki przybliżenia spełnione: $np = 10 \geq 5$, $n(1 - p) = 20 \geq 5$

$$\begin{aligned} P(a \leq S_n \leq b) &= P\left(\frac{a - np}{\sqrt{np(1 - p)}} \leq \underbrace{\frac{S_n - np}{\sqrt{np(1 - p)}}}_{U_n \simeq X \sim N(0,1)} \leq \frac{b - np}{\sqrt{np(1 - p)}}\right) \\ &\simeq P\left(\frac{a - np}{\sqrt{np(1 - p)}} \leq X \leq \frac{b - np}{\sqrt{np(1 - p)}}\right) \quad (X \sim N(0,1)) \\ &= \Phi\left(\frac{b - np}{\sqrt{np(1 - p)}}\right) - \Phi\left(\frac{a - np}{\sqrt{np(1 - p)}}\right) \end{aligned}$$

Przykład

Oszacuj prawdopodobieństwo, że liczba sukcesów S_n w rozkładzie dwumianowym $B(n = 30, p = \frac{1}{3})$ znajdzie się w zakresie $\{9, 10, 11, 12\}$.

Odpowiedź przybliżona:

Warunki przybliżenia spełnione: $np = 10 \geq 5$, $n(1 - p) = 20 \geq 5$

$$\begin{aligned} P(a \leq S_n \leq b) &= P\left(\frac{a - np}{\sqrt{np(1 - p)}} \leq \underbrace{\frac{S_n - np}{\sqrt{np(1 - p)}}}_{U_n \simeq X \sim N(0,1)} \leq \frac{b - np}{\sqrt{np(1 - p)}}\right) \\ &\simeq P\left(\frac{a - np}{\sqrt{np(1 - p)}} \leq X \leq \frac{b - np}{\sqrt{np(1 - p)}}\right) \quad (X \sim N(0,1)) \\ &= \Phi\left(\frac{b - np}{\sqrt{np(1 - p)}}\right) - \Phi\left(\frac{a - np}{\sqrt{np(1 - p)}}\right) \end{aligned}$$

Aby zwiększyć dokładność, bierzemy $b = 12.5$, $a = 8.5$:

$$P(8.5 \leq S_n \leq 12.5) \simeq \Phi(0.968) - \Phi(-0.581) \simeq 0.553$$

(odpowiedź dokładna: 0.548)

Zadanie 2

Używając przybliżenia rozkładem normalnym oszacuj prawdopodobieństwo, że liczba sukcesów S_n w rozkładzie $B(n = 72, p = \frac{2}{3})$ przekroczy 55. Następnie wyznacz górne ograniczenie tego prawdopodobieństwa poprzez odpowiednie zastosowanie nierówności Czebyszewa i porównaj. Możesz również numerycznie wyznaczyć dokładną odpowiedź, aby sprawdzić jak dobre jest przybliżenie.

Dowód twierdzenia Moivre'a-Laplace'a

Pokazuje się, że dla dużych n , rozkład zmiennej $S_n \sim B(n, p)$ można przybliżyć rozkładem zmiennej $X \sim N(np, np(1-p))$.

Innymi słowy:

$$P(S_n = k) = \underbrace{\binom{n}{k} p^k (1-p)^{n-k}}_{B(n,p)} \simeq \underbrace{\frac{1}{\sqrt{2\pi np(1-p)}} e^{-\frac{(k-np)^2}{2np(1-p)}}}_{N(np, np(1-p))} = f_X(k)$$

Dowód twierdzenia Moivre'a-Laplace'a

Pokazuje się, że dla dużych n , rozkład zmiennej $S_n \sim B(n, p)$ można przybliżyć rozkładem zmiennej $X \sim N(np, np(1-p))$.

Innymi słowy:

$$P(S_n = k) = \underbrace{\binom{n}{k} p^k (1-p)^{n-k}}_{B(n,p)} \simeq \underbrace{\frac{1}{\sqrt{2\pi np(1-p)}} e^{-\frac{(k-np)^2}{2np(1-p)}}}_{N(np, np(1-p))} = f_X(k)$$

Główne narzędzia: wzór Stirlinga oraz rozwinięcie w szereg Taylora

Dowód pomijamy, ponieważ udowodnimy później ogólniejsze twierdzenie, którego to będzie szczególnym przypadkiem.

Centralne Twierdzenie Graniczne

$X_1, X_2, X_3 \dots$ – ciąg niezależnych zmiennych losowych o tym samym rozkładzie, $EX_i = \mu$, $D^2(X_i) = \sigma^2$.

Centralne Twierdzenie Graniczne

$X_1, X_2, X_3 \dots$ – ciąg niezależnych zmiennych losowych o tym samym rozkładzie, $EX_i = \mu$, $D^2(X_i) = \sigma^2$.

Zgodnie z prawem wielkich liczb:

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{\text{z pr. 1}} \mu$$

Możemy jednak ustandaryzować ciąg średnich:

$$U_n = \frac{\bar{X}_n - E\bar{X}_n}{D(\bar{X}_n)} = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n}$$

Do czego dąży U_n ?

Centralne Twierdzenie Graniczne

Twierdzenie Lindeberga-Levy'ego

Niech $X_1, X_2, X_3 \dots$ będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie z $EX_i = \mu$ i $D^2(X_i) = \sigma^2$. Niech:

$$U_n = \frac{\bar{X}_n - E\bar{X}_n}{D(\bar{X}_n)} = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n}, \quad \text{gdzie } \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

Wtedy:

$$\forall x \quad \lim_{n \rightarrow \infty} F_{U_n}(x) = \Phi(x),$$

gdzie Φ jest dystrybuantą standardowego rozkładu normalnego $N(0, 1)$.

Zjawisko zbiegania rozkładu standaryzowanej średniej do rozkładu normalnego jest **uniwersalne!**

Centralne Twierdzenie Graniczne

Twierdzenie Lindeberga-Levy'ego

Niech $X_1, X_2, X_3 \dots$ będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie z $EX_i = \mu$ i $D^2(X_i) = \sigma^2$. Niech:

$$U_n = \frac{\bar{X}_n - E\bar{X}_n}{D(\bar{X}_n)} = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n}, \quad \text{gdzie } \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

Wtedy:

$$\forall x \quad \lim_{n \rightarrow \infty} F_{U_n}(x) = \Phi(x),$$

gdzie Φ jest dystrybuantą standardowego rozkładu normalnego $N(0, 1)$.


Zjawisko zbiegania rozkładu standaryzowanej średniej do rozkładu normalnego jest **uniwersalne!**

Rozkład normalny jest **powszechny**: powstaje ilekroć obserwowane zjawiska są wynikiem uśredniania wielu niezależnych losowych przyczynków.

Przykład: rozkład jednostajny Unif[0, 1]

X_1, X_2, X_3, \dots – niezależne zmienne $\sim \text{Unif}[0, 1]$


$$EX_i = \frac{1}{2}, \quad D^2(X_i) = \frac{1}{12}$$



Przykład: rozkład jednostajny Unif[0, 1]

X_1, X_2, X_3, \dots – niezależne zmienne $\sim \text{Unif}[0, 1]$

$$EX_i = \frac{1}{2}, \quad D^2(X_i) = \frac{1}{12}$$




$$S_n = X_1 + \dots + X_n, \quad U_n = \frac{S_n - ES_n}{D(S_n)} =$$

Przykład: rozkład jednostajny Unif[0, 1]


X_1, X_2, X_3, \dots – niezależne zmienne $\sim \text{Unif}[0, 1]$

$$EX_i = \frac{1}{2}, \quad D^2(X_i) = \frac{1}{12}$$




$$S_n = X_1 + \dots + X_n, \quad U_n = \frac{S_n - ES_n}{D(S_n)} = \frac{S_n - \frac{n}{2}}{\sqrt{\frac{n}{12}}}$$


Przykład: rozkład jednostajny Unif[0, 1]




Przykład: rozkład jednostajny Unif[0, 1]




Przykład: rozkład jednostajny Unif[0, 1]




Przykład: rozkład jednostajny Unif[0, 1]




Przykład: rozkład jednostajny Unif[0, 1]



Przykład: rozkład jednostajny Unif[0, 1]




Przykład: rozkład jednostajny Unif[0, 1]



Przykład: rozkład wykładniczy ($\lambda = 1$)

X_1, X_2, X_3, \dots – niezależne zmienne $\sim \text{Exp}(\lambda = 1)$


$$EX_i = \frac{1}{\lambda} = 1, \quad D^2(X_i) = \frac{1}{\lambda^2} = 1$$



Przykład: rozkład wykładniczy ($\lambda = 1$)

X_1, X_2, X_3, \dots – niezależne zmienne $\sim \text{Exp}(\lambda = 1)$

$$EX_i = \frac{1}{\lambda} = 1, \quad D^2(X_i) = \frac{1}{\lambda^2} = 1$$




$$S_n = X_1 + \dots + X_n, \quad U_n = \frac{S_n - ES_n}{D(S_n)} =$$

Przykład: rozkład wykładniczy ($\lambda = 1$)


X_1, X_2, X_3, \dots – niezależne zmienne $\sim \text{Exp}(\lambda = 1)$

$$EX_i = \frac{1}{\lambda} = 1, \quad D^2(X_i) = \frac{1}{\lambda^2} = 1$$




$$S_n = X_1 + \dots + X_n, \quad U_n = \frac{S_n - ES_n}{D(S_n)} = \frac{S_n - n}{\sqrt{n}}$$


Przykład: rozkład wykładniczy ($\lambda = 1$)




Przykład: rozkład wykładniczy ($\lambda = 1$)




Przykład: rozkład wykładniczy ($\lambda = 1$)




Przykład: rozkład wykładniczy ($\lambda = 1$)




Przykład: rozkład wykładniczy ($\lambda = 1$)




Przykład: rozkład wykładniczy ($\lambda = 1$)




Przykład: rozkład wykładniczy ($\lambda = 1$)




Przykład: rozkład wykładniczy ($\lambda = 1$)




Przykład: rozkład wykładniczy ($\lambda = 1$)



Przykład: rozkład wykładniczy ($\lambda = 1$)



Przykład: rozkład wykładniczy ($\lambda = 1$)



Zbieżność według dystrybuant

Mówimy, że ciąg zmiennych X_1, X_2, \dots jest zbieżny do zmiennej X :

- Z prawdopodobieństwem jeden (ozn. $X_n \xrightarrow{\text{z pr. 1}} X$), gdy:

$$P\left(\lim_{n \rightarrow \infty} X_n = X\right) = 1$$

- Według prawdopodobieństwa (ozn. $X_n \xrightarrow{P} X$), gdy:

$$\forall \epsilon > 0 \quad \lim_{n \rightarrow \infty} P(|X_n - X| > \epsilon) = 0$$

Zbieżność według dystrybuant

Mówimy, że ciąg zmiennych X_1, X_2, \dots jest zbieżny do zmiennej X :

- Z prawdopodobieństwem jeden (ozn. $X_n \xrightarrow{\text{z pr. 1}} X$), gdy:

$$P\left(\lim_{n \rightarrow \infty} X_n = X\right) = 1$$

- Według prawdopodobieństwa (ozn. $X_n \xrightarrow{P} X$), gdy:

$$\forall \epsilon > 0 \quad \lim_{n \rightarrow \infty} P(|X_n - X| > \epsilon) = 0$$

- Według dystrybuant (ozn. $X_n \xrightarrow{D} X$), gdy:

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_X(x) \quad \text{w każdym punkcie ciągłości } F_X$$

Zbieżność według dystrybuant

Mówimy, że ciąg zmiennych X_1, X_2, \dots jest zbieżny do zmiennej X :

- Z prawdopodobieństwem jeden (ozn. $X_n \xrightarrow{\text{z pr. 1}} X$), gdy:

$$P\left(\lim_{n \rightarrow \infty} X_n = X\right) = 1$$

- Według prawdopodobieństwa (ozn. $X_n \xrightarrow{P} X$), gdy:

$$\forall \epsilon > 0 \quad \lim_{n \rightarrow \infty} P(|X_n - X| > \epsilon) = 0$$

- Według dystrybuant (ozn. $X_n \xrightarrow{D} X$), gdy:

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_X(x) \quad \text{w każdym punkcie ciągłości } F_X$$

$$\text{Zachodzi: } X_n \xrightarrow{\text{z pr. 1}} X \Rightarrow X_n \xrightarrow{P} X \Rightarrow X_n \xrightarrow{D} X,$$

czyli zbieżność według dystrybuant jest **najłagodniejszą** z typów zbieżności

Podsumowanie

X_1, X_2, X_3, \dots – ciąg **niezależnych** zmiennych losowych o **tym samym rozkładzie** z wartością oczekiwaną $EX_i = \mu$ i wariancją $D^2(X_i) = \sigma^2$

$$\text{Definiujemy } \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

- Prawo Wielkich Liczb

$$\bar{X}_n \xrightarrow{\text{z pr. 1}} \mu$$

- Centralne Twierdzenie Graniczne

$$\frac{\bar{X}_n - E\bar{X}_n}{D(\bar{X}_n)} = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n} \xrightarrow{D} U \sim N(0, 1)$$

Funkcja tworząca momenty

Funkcję tworzącą momenty zmiennej losowej X definiujemy jako:

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

Dziedziną M_X jest zbiór $t \in \mathbb{R}$ dla których wyrażenie po prawej stronie istnieje (tzn. jest skończone)

Funkcja tworząca momenty

Funkcję tworzącą momenty zmiennej losowej X definiujemy jako:

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

Dziedziną M_X jest zbiór $t \in \mathbb{R}$ dla których wyrażenie po prawej stronie istnieje (tzn. jest skończone)

- Dla **dyskretnych** zmiennych losowych:

$$M_X(t) = \sum_{x_i} e^{tx_i} P(X = x_i)$$

- Dla **ciągłych** zmiennych losowych:

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

Przykłady

- Rozkład **dwupunktowy**: dla $X \sim B(p)$

$$M_X(t) = E(e^{tX}) = pe^{t \cdot 1} + (1-p)e^{t \cdot 0} = pe^t + 1 - p$$

Dziedzina funkcji: \mathbb{R}

Przykłady

- Rozkład **dwupunktowy**: dla $X \sim B(p)$

$$M_X(t) = E(e^{tX}) = pe^{t \cdot 1} + (1-p)e^{t \cdot 0} = pe^t + 1 - p$$

Dziedzina funkcji: \mathbb{R}

- Rozkład **dwumianowy**: dla $X \sim B(n, p)$

$$M_X(t) = \sum_{k=0}^n e^{tk} P(X = k) = \sum_{k=0}^n \binom{n}{k} e^{tk} p^k (1-p)^{n-k}$$

Przykłady

- Rozkład **dwupunktowy**: dla $X \sim B(p)$

$$M_X(t) = E(e^{tX}) = pe^{t \cdot 1} + (1-p)e^{t \cdot 0} = pe^t + 1 - p$$

Dziedzina funkcji: \mathbb{R}

- Rozkład **dwumianowy**: dla $X \sim B(n, p)$

$$\begin{aligned} M_X(t) &= \sum_{k=0}^n e^{tk} P(X = k) = \sum_{k=0}^n \binom{n}{k} e^{tk} p^k (1-p)^{n-k} \\ &= \sum_{k=0}^n \binom{n}{k} (pe^t)^k (1-p)^{n-k} \end{aligned}$$

Przykłady

- Rozkład **dwupunktowy**: dla $X \sim B(p)$

$$M_X(t) = E(e^{tX}) = pe^{t \cdot 1} + (1-p)e^{t \cdot 0} = pe^t + 1 - p$$

Dziedzina funkcji: \mathbb{R}

- Rozkład **dwumianowy**: dla $X \sim B(n, p)$

Wynika ze wzoru:

$$(x + y)^n = \sum_{k=0}^n \binom{n}{k} x^k y^{n-k}$$

$$\begin{aligned} M_X(t) &= \sum_{k=0}^n e^{tk} P(X = k) = \sum_{k=0}^n \binom{n}{k} e^{tk} p^k (1-p)^{n-k} \\ &= \sum_{k=0}^n \binom{n}{k} (pe^t)^k (1-p)^{n-k} = (pe^t + 1 - p)^n \end{aligned}$$

Przykłady

- Rozkład **dwupunktowy**: dla $X \sim B(p)$

$$M_X(t) = E(e^{tX}) = pe^{t \cdot 1} + (1-p)e^{t \cdot 0} = pe^t + 1 - p$$

Dziedzina funkcji: \mathbb{R}

- Rozkład **dwumianowy**: dla $X \sim B(n, p)$

$$\begin{aligned} M_X(t) &= \sum_{k=0}^n e^{tk} P(X = k) = \sum_{k=0}^n \binom{n}{k} e^{tk} p^k (1-p)^{n-k} \\ &= \sum_{k=0}^n \binom{n}{k} (pe^t)^k (1-p)^{n-k} = (pe^t + 1 - p)^n \end{aligned}$$

Dziedzina funkcji: \mathbb{R}

Przykłady

- Rozkład **jednostajny**: dla $X \sim \text{Unif}[0, 1]$:

$$M_X(t) = \int_{-\infty}^{\infty} f(x)e^{tx} dx = \int_0^1 e^{tx} dx$$

Przykłady

- Rozkład **jednostajny**: dla $X \sim \text{Unif}[0, 1]$:

$$\begin{aligned} M_X(t) &= \int_{-\infty}^{\infty} f(x)e^{tx} dx = \int_0^1 e^{tx} dx \\ &= \begin{cases} \int_0^1 e^0 dx = 1 & \text{dla } t = 0 \end{cases} \end{aligned}$$

Przykłady

- Rozkład **jednostajny**: dla $X \sim \text{Unif}[0, 1]$:

$$\begin{aligned} M_X(t) &= \int_{-\infty}^{\infty} f(x)e^{tx} dx = \int_0^1 e^{tx} dx \\ &= \begin{cases} \int_0^1 e^0 dx = 1 & \text{dla } t = 0 \\ \left. \frac{1}{t} e^{tx} \right|_0^1 = \frac{e^t - 1}{t} & \text{dla } t \neq 0 \end{cases} \end{aligned}$$

Dziedzina: \mathbb{R}

Przykłady

- Rozkład **jednostajny**: dla $X \sim \text{Unif}[0, 1]$:

$$\begin{aligned} M_X(t) &= \int_{-\infty}^{\infty} f(x)e^{tx} dx = \int_0^1 e^{tx} dx \\ &= \begin{cases} \int_0^1 e^0 dx = 1 & \text{dla } t = 0 \\ \left. \frac{1}{t} e^{tx} \right|_0^1 = \frac{e^t - 1}{t} & \text{dla } t \neq 0 \end{cases} \end{aligned}$$

Dziedzina: \mathbb{R}

- Rozkład **wykładniczy**: dla $X \sim \text{Exp}(\lambda)$

$$M_X(t) = \int_{-\infty}^{\infty} f(x)e^{tx} dx = \lambda \int_0^{\infty} e^{-\lambda x} e^{tx} dx$$

Przykłady

- Rozkład **jednostajny**: dla $X \sim \text{Unif}[0, 1]$:

$$\begin{aligned} M_X(t) &= \int_{-\infty}^{\infty} f(x)e^{tx} dx = \int_0^1 e^{tx} dx \\ &= \begin{cases} \int_0^1 e^0 dx = 1 & \text{dla } t = 0 \\ \left. \frac{1}{t} e^{tx} \right|_0^1 = \frac{e^t - 1}{t} & \text{dla } t \neq 0 \end{cases} \end{aligned}$$

Dziedzina: \mathbb{R}

- Rozkład **wykładniczy**: dla $X \sim \text{Exp}(\lambda)$

$$\begin{aligned} M_X(t) &= \int_{-\infty}^{\infty} f(x)e^{tx} dx = \lambda \int_0^{\infty} e^{-\lambda x} e^{tx} \\ &= \lambda \int_0^{\infty} e^{(t-\lambda)x} dx = \lambda \left. \frac{1}{t-\lambda} e^{(t-\lambda)x} \right|_0^{\infty} \end{aligned}$$

Przykłady

- Rozkład **jednostajny**: dla $X \sim \text{Unif}[0, 1]$:

$$\begin{aligned} M_X(t) &= \int_{-\infty}^{\infty} f(x)e^{tx} dx = \int_0^1 e^{tx} dx \\ &= \begin{cases} \int_0^1 e^0 dx = 1 & \text{dla } t = 0 \\ \left. \frac{1}{t} e^{tx} \right|_0^1 = \frac{e^t - 1}{t} & \text{dla } t \neq 0 \end{cases} \end{aligned}$$

Dziedzina: \mathbb{R}

- Rozkład **wykładniczy**: dla $X \sim \text{Exp}(\lambda)$

$$\begin{aligned} M_X(t) &= \int_{-\infty}^{\infty} f(x)e^{tx} dx = \lambda \int_0^{\infty} e^{-\lambda x} e^{tx} dx \\ &= \lambda \int_0^{\infty} e^{(t-\lambda)x} dx = \lambda \left. \frac{1}{t-\lambda} e^{(t-\lambda)x} \right|_0^{\infty} \end{aligned}$$

Powyższe wyrażenie istnieje tylko dla $t < \lambda$, wtedy $M_X(t) = \frac{\lambda}{\lambda - t}$

Dziedzina: $(-\infty, \lambda)$

Zadania

Zadanie 3

Niech $X \sim \text{Pois}(\lambda)$ ma rozkład Poissona z parametrem λ . Pokaż, że:

$$M_X(t) = \exp\{\lambda(e^t - 1)\}$$

Zadanie 4

Niech $X \sim N(0, 1)$ ma standardowy rozkład normalny. Pokaż, że:

$$M_X(t) = e^{t^2/2}$$

Funkcja tworząca momenty tworzy momenty

- $M_X(0) = E(e^{0X}) = E(1) = 1$

Funkcja tworząca momenty tworzy momenty

- $M_X(0) = E(e^{0X}) = E(1) = 1$
- Wyznaczmy pierwszą pochodną:

$$M'_X(t) = \left(E(e^{Xt}) \right)' = E \left((e^{Xt})' \right)$$

Funkcja tworząca momenty tworzy momenty

- $M_X(0) = E(e^{0X}) = E(1) = 1$
- Wyznamy pierwszą pochodną:

$$M'_X(t) = \left(E(e^{Xt}) \right)' = E \left((e^{Xt})' \right)$$

Wchodzimy z pochodną do środka wartości oczekiwanej, co wynika z liniowości wartości oczekiwanej:

$$\left(E(e^{Xt}) \right)' = \left(\sum_{x_i} e^{x_i t} P(X = x_i) \right)' = \sum_{x_i} (e^{x_i t})' P(X = x_i)$$

Dla zmiennych ciągłych również zachodzi (przy założeniach)

Funkcja tworząca momenty tworzy momenty

- $M_X(0) = E(e^{0X}) = E(1) = 1$
- Wyznaczmy pierwszą pochodną:

$$M'_X(t) = \left(E(e^{Xt}) \right)' = E \left((e^{Xt})' \right) = E \left(X e^{Xt} \right)$$

Stąd $M'_X(0) = E(Xe^0) = E(X)$

Funkcja tworząca momenty tworzy momenty

- $M_X(0) = E(e^{0X}) = E(1) = 1$
- Wyznaczmy pierwszą pochodną:

$$M'_X(t) = \left(E(e^{Xt}) \right)' = E \left((e^{Xt})' \right) = E \left(X e^{Xt} \right)$$

Stąd $M'_X(0) = E(Xe^0) = E(X)$

- Wyznaczamy drugą pochodną:

$$M''_X(t) = \left(E(Xe^{Xt}) \right)' = E \left(X(e^{Xt})' \right) = E \left(X^2 e^{Xt} \right)$$

Funkcja tworząca momenty tworzy momenty

- $M_X(0) = E(e^{0X}) = E(1) = 1$
- Wyznaczymy pierwszą pochodną:

$$M'_X(t) = \left(E(e^{Xt}) \right)' = E \left((e^{Xt})' \right) = E \left(X e^{Xt} \right)$$

Stąd $M'_X(0) = E(Xe^0) = E(X)$

- Wyznaczamy drugą pochodną:

$$M''_X(t) = \left(E(Xe^{Xt}) \right)' = E \left(X(e^{Xt})' \right) = E \left(X^2 e^{Xt} \right)$$

Stąd $M''_X(0) = E(X^2 e^0) = E(X^2)$

Funkcja tworząca momenty tworzy momenty

- $M_X(0) = E(e^{0X}) = E(1) = 1$
- Wyznaczymy pierwszą pochodną:

$$M'_X(t) = \left(E(e^{Xt})\right)' = E\left(\left(e^{Xt}\right)'\right) = E\left(Xe^{Xt}\right)$$

Stąd $M'_X(0) = E(Xe^0) = E(X)$

- Wyznaczamy drugą pochodną:

$$M''_X(t) = \left(E(Xe^{Xt})\right)' = E\left(X\left(e^{Xt}\right)'\right) = E\left(X^2e^{Xt}\right)$$

Stąd $M''_X(0) = E(X^2e^0) = E(X^2)$

- Ogólniej: k -ta pochodna w zerze $M_X^{(k)}(0)$ daje k -ty moment $E(X^k)$

Funkcja tworząca momenty tworzy momenty

- $M_X(0) = E(e^{0X}) = E(1) = 1$
- Wyznaczmy pierwszą pochodną:

$$M'_X(t) = \left(E(e^{Xt})\right)' = E\left((e^{Xt})'\right) = E\left(Xe^{Xt}\right)$$

Stąd $M'_X(0) = E(Xe^0) = E(X)$

- Wyznaczamy drugą pochodną:

$$M''_X(t) = \left(E(Xe^{Xt})\right)' = E\left(X(e^{Xt})'\right) = E\left(X^2e^{Xt}\right)$$

Stąd $M''_X(0) = E(X^2e^0) = E(X^2)$

- Ogólniej: k -ta pochodna w zerze $M_X^{(k)}(0)$ daje k -ty moment $E(X^k)$
- Jeśli $M_X(t)$ istnieje w okolicy zera (tzn na przedziale $(-\epsilon, \epsilon)$ dla pewnego $\epsilon > 0$), to wszystkie momenty zmiennej X są skończone ($E(|X|^k) < \infty$ dla $k = 1, 2, \dots$)

Przykład

- Rozkład dwupunktowy $X \sim B(p)$: $M_X(t) = pe^t + 1 - p$

$$M'_X(t) = pe^t, \quad M'_X(0) = p, \quad M''_X(t) = pe^t, \quad M''_X(0) = p$$

Przykład

- Rozkład dwupunktowy $X \sim B(p)$: $M_X(t) = pe^t + 1 - p$

$$M'_X(t) = pe^t, \quad M'_X(0) = p, \quad M''_X(t) = pe^t, \quad M''_X(0) = p$$

Stąd $EX = p$ oraz $D^2(X) = E(X^2) - (EX)^2 = p - p^2 = p(1 - p)$

Przykład

- Rozkład **dwupunktowy** $X \sim B(p)$: $M_X(t) = pe^t + 1 - p$

$$M'_X(t) = pe^t, \quad M'_X(0) = p, \quad M''_X(t) = pe^t, \quad M''_X(0) = p$$

Stąd $EX = p$ oraz $D^2(X) = E(X^2) - (EX)^2 = p - p^2 = p(1 - p)$

- Rozkład **wykładniczy** $X \sim \text{Exp}(\lambda)$: $M_X(t) = \frac{\lambda}{\lambda - t}$

$$M'_X(t) = \frac{\lambda}{(\lambda - t)^2}, \quad M'_X(0) = \frac{1}{\lambda}, \quad M''_X(t) = \frac{2\lambda}{(\lambda - t)^3} \quad M''_X(0) = \frac{2}{\lambda^2}$$

Przykład

- Rozkład **dwupunktowy** $X \sim B(p)$: $M_X(t) = pe^t + 1 - p$

$$M'_X(t) = pe^t, \quad M'_X(0) = p, \quad M''_X(t) = pe^t, \quad M''_X(0) = p$$

Stąd $EX = p$ oraz $D^2(X) = E(X^2) - (EX)^2 = p - p^2 = p(1 - p)$

- Rozkład **wykładniczy** $X \sim \text{Exp}(\lambda)$: $M_X(t) = \frac{\lambda}{\lambda - t}$

$$M'_X(t) = \frac{\lambda}{(\lambda - t)^2}, \quad M'_X(0) = \frac{1}{\lambda}, \quad M''_X(t) = \frac{2\lambda}{(\lambda - t)^3}, \quad M''_X(0) = \frac{2}{\lambda^2}$$

Stąd $EX = \frac{1}{\lambda}$ oraz $D^2(X) = \frac{2}{\lambda^2} - \frac{1}{\lambda^2} = \frac{1}{\lambda^2}$

Przykład

- Rozkład **dwupunktowy** $X \sim B(p)$: $M_X(t) = pe^t + 1 - p$

$$M'_X(t) = pe^t, \quad M'_X(0) = p, \quad M''_X(t) = pe^t, \quad M''_X(0) = p$$

Stąd $EX = p$ oraz $D^2(X) = E(X^2) - (EX)^2 = p - p^2 = p(1 - p)$

- Rozkład **wykładniczy** $X \sim \text{Exp}(\lambda)$: $M_X(t) = \frac{\lambda}{\lambda - t}$

$$M'_X(t) = \frac{\lambda}{(\lambda - t)^2}, \quad M'_X(0) = \frac{1}{\lambda}, \quad M''_X(t) = \frac{2\lambda}{(\lambda - t)^3}, \quad M''_X(0) = \frac{2}{\lambda^2}$$

Stąd $EX = \frac{1}{\lambda}$ oraz $D^2(X) = \frac{2}{\lambda^2} - \frac{1}{\lambda^2} = \frac{1}{\lambda^2}$

Zadanie 5

Wyznacz w ten sposób wartość oczekiwaną i wariancję dla rozkładów: dwumianowego, Poissona i standardowego normalnego

Funkcje tworzące momenty sumy niezależne zmiennych

Niech X i Y – niezależne, oraz $Z = X + Y$. Wtedy:

$$M_Z(t) = M_X(t) \cdot M_Y(t)$$

Funkcje tworzące momenty sumy niezależne zmiennych

Niech X i Y – niezależne, oraz $Z = X + Y$. Wtedy:

$$M_Z(t) = M_X(t) \cdot M_Y(t)$$

Dowód:

$$M_Z(t) = E(e^{tZ}) = E(e^{t(X+Y)}) = E(e^{tX} e^{tY})$$

Funkcje tworzące momenty sumy niezależne zmiennych

Niech X i Y – niezależne, oraz $Z = X + Y$. Wtedy:

$$M_Z(t) = M_X(t) \cdot M_Y(t)$$

Dowód:

$$\begin{aligned} M_Z(t) &= E(e^{tZ}) = E(e^{t(X+Y)}) = E(e^{tX} e^{tY}) \\ &= E(e^{tX}) E(e^{tY}) = M_X(t) \cdot M_Y(t) \end{aligned}$$

Jeśli X_1 i X_2 są niezależne
to $E(X_1 X_2) = E(X_1) E(X_2)$
Podstaw $X_1 = e^{tX}$ i $X_2 = e^{tY}$

Funkcje tworzące momenty sumy niezależne zmiennych

Niech X i Y – niezależne, oraz $Z = X + Y$. Wtedy:

$$M_Z(t) = M_X(t) \cdot M_Y(t)$$

Dowód:

$$\begin{aligned} M_Z(t) &= E(e^{tZ}) = E(e^{t(X+Y)}) = E(e^{tX} e^{tY}) \\ &= E(e^{tX}) E(e^{tY}) = M_X(t) \cdot M_Y(t) \end{aligned}$$

Funkcja tworząca sumy zmiennych niezależnych jest iloczynem funkcji tworzących poszczególnych zmiennych
(spłot rozkładów \iff mnożenie funkcji tworzących)

Funkcje tworzące momenty sumy niezależne zmiennych

Niech X i Y – niezależne, oraz $Z = X + Y$. Wtedy:

$$M_Z(t) = M_X(t) \cdot M_Y(t)$$

Dowód:

$$\begin{aligned} M_Z(t) &= E(e^{tZ}) = E(e^{t(X+Y)}) = E(e^{tX} e^{tY}) \\ &= E(e^{tX}) E(e^{tY}) = M_X(t) \cdot M_Y(t) \end{aligned}$$

Funkcja tworząca sumy zmiennych niezależnych jest iloczynem funkcji tworzących poszczególnych zmiennych
(spłot rozkładów \iff mnożenie funkcji tworzących)

Wniosek: Jeśli X_1, \dots, X_n – niezależne zmienne losowe o tym samym rozkładzie z funkcją tworzącą momenty $M_X(t)$, to dla $Y = X_1 + \dots + X_n$:

$$M_Y(t) = (M_X(t))^n$$

Translacja i skalowanie

Dla zmiennej losowej X zdefiniujmy $Y = aX + b$. Wtedy:

$$M_Y(t) = e^{bt} M_X(at)$$

Translacja i skalowanie

Dla zmiennej losowej X zdefiniujmy $Y = aX + b$. Wtedy:

$$M_Y(t) = e^{bt} M_X(at)$$

Dowód:

$$M_Y(t) = E(e^{tY}) = E(e^{atX+bt}) = e^{bt} E(e^{(at)X}) = e^{bt} M_X(at)$$

Translacja i skalowanie

Dla zmiennej losowej X zdefiniujmy $Y = aX + b$. Wtedy:

$$M_Y(t) = e^{bt} M_X(at)$$

Dowód:

$$M_Y(t) = E\left(e^{tY}\right) = E\left(e^{atX+bt}\right) = e^{bt} E\left(e^{(at)X}\right) = e^{bt} M_X(at)$$

Wniosek: Funkcja tworząca momenty zmiennej $Y \sim N(\mu, \sigma^2)$ ma postać:

$$M_Y(t) = e^{\mu t + \frac{1}{2}\sigma^2 t^2}$$

Translacja i skalowanie

Dla zmiennej losowej X zdefiniujmy $Y = aX + b$. Wtedy:

$$M_Y(t) = e^{bt} M_X(at)$$

Dowód:

$$M_Y(t) = E\left(e^{tY}\right) = E\left(e^{atX+bt}\right) = e^{bt} E\left(e^{(at)X}\right) = e^{bt} M_X(at)$$

Wniosek: Funkcja tworząca momenty zmiennej $Y \sim N(\mu, \sigma^2)$ ma postać:

$$M_Y(t) = e^{\mu t + \frac{1}{2}\sigma^2 t^2}$$

Dowód: $Y = \sigma X + \mu$, gdzie $X \sim N(0, 1)$ i $M_X(t) = e^{\frac{1}{2}t^2}$

Rozkład prawdopodobieństwa a funkcja tworząca

Z definicji funkcja tworząca momenty jest jednoznacznie zdefiniowana przez rozkład prawdopodobieństwa

Zachodzi również własność odwrotna: rozkład jest jednoznacznie zdefiniowany przez funkcję tworzącą momenty

Rozkład prawdopodobieństwa a funkcja tworząca

Z definicji funkcja tworząca momenty jest jednoznacznie zdefiniowana przez rozkład prawdopodobieństwa

Zachodzi również własność odwrotna: rozkład jest jednoznacznie zdefiniowany przez funkcję tworzącą momenty

Twierdzenie: Jeśli funkcję tworzące momenty zmiennych X i Y są równe w okolicy zera (tzn. na przedziale $(-\epsilon, \epsilon)$ dla pewnego $\epsilon > 0$), to X i Y mają **ten sam rozkład**

Dowód pomijamy (zgrubnie: jeśli funkcje tworzące są równe, to wszystkie momenty dowolnego rzędu są równe, co determinuje rozkład)

Rozkład prawdopodobieństwa a funkcja tworząca

Z definicji funkcja tworząca momenty jest jednoznacznie zdefiniowana przez rozkład prawdopodobieństwa

Zachodzi również własność odwrotna: rozkład jest jednoznacznie zdefiniowany przez funkcję tworzącą momenty

Twierdzenie: Jeśli funkcję tworzącą momenty zmiennych X i Y są równe w okolicy zera (tzn. na przedziale $(-\epsilon, \epsilon)$ dla pewnego $\epsilon > 0$), to X i Y mają **ten sam rozkład**

Dowód pomijamy (zgrubnie: jeśli funkcje tworzące są równe, to wszystkie momenty dowolnego rzędu są równe, co determinuje rozkład)

Wniosek: Suma niezależnych zmiennych o rozkładzie normalnym ma rozkład normalny

Dowód: $X \sim N(\mu_X, \sigma_X^2)$, $Y \sim N(\mu_Y, \sigma_Y^2)$ niezależne, $Z = X + Y$

$$M_Z(t) = M_X(t) \cdot M_Y(t) = e^{\mu_X t + \frac{1}{2}\sigma_X^2 t^2} e^{\mu_Y t + \frac{1}{2}\sigma_Y^2 t^2} = e^{(\mu_X + \mu_Y)t + \frac{1}{2}(\sigma_X^2 + \sigma_Y^2)t^2}$$

Jest to funkcja tworząca rozkładu $N(\mu_X + \mu_Y, \sigma_X^2 + \sigma_Y^2)$

Twierdzenie o zbieżności

Niech X, X_1, X_2, \dots będzie ciągiem zmiennych losowych, których funkcje tworzące momenty są określone na przedziale $(-\epsilon, \epsilon)$ dla pewnego $\epsilon > 0$.

Jeśli $\forall t \in (-\epsilon, \epsilon) \lim_{n \rightarrow \infty} M_{X_n}(t) = M_X(t)$, to $X_n \xrightarrow{D} X$

Zbieżność w sensie funkcji tworzących momenty implikuje zbieżność w sensie rozkładów

(pozostawiamy bez dowodu)

Dowód Centralnego Twierdzenia Granicznego

Twierdzenie Lindeberga-Levy'ego

Niech $X_1, X_2, X_3 \dots$ będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie z $EX_i = \mu$ i $D^2(X_i) = \sigma^2$. Wtedy:

$$U_n = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n} \xrightarrow{D} X \sim N(0, 1)$$

Uwaga: Dowód przy założeniu, że zmienne X_i mają funkcję tworzącą momenty zdefiniowaną w pewnym otoczeniu zera $(-\epsilon, \epsilon)$

Dowód Centralnego Twierdzenia Granicznego

Twierdzenie Lindeberga-Levy'ego

Niech $X_1, X_2, X_3 \dots$ będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie z $EX_i = \mu$ i $D^2(X_i) = \sigma^2$. Wtedy:

$$U_n = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n} \xrightarrow{D} X \sim N(0, 1)$$

Uwaga: Dowód przy założeniu, że zmienne X_i mają funkcję tworzącą momenty zdefiniowaną w pewnym otoczeniu zera $(-\epsilon, \epsilon)$

Dowód: Zdefiniujmy $Z_i = \frac{X_i - \mu}{\sigma}$, a stąd $EZ_i = 0$, $D(Z_i) = 1$. Wtedy $\frac{\bar{X}_n - \mu}{\sigma} = \bar{Z}_n$, a więc musimy pokazać, że:

$$U_n = \bar{Z}_n \sqrt{n} = \frac{Z_1 + \dots + Z_n}{\sqrt{n}} \xrightarrow{D} X \sim N(0, 1)$$

Pokażemy, że ciąg funkcji tworzących $M_{U_n}(t)$ zbiega do funkcji tworzącej $M_X(t) = e^{\frac{1}{2}t^2}$.

Dowód Centralnego Twierdzenia Granicznego

Niech $M_Z(t)$ będzie funkcją tworzącą momenty zmiennych Z_1, Z_2, \dots

Dowód Centralnego Twierdzenia Granicznego

Niech $M_Z(t)$ będzie funkcją tworzącą momenty zmiennych Z_1, Z_2, \dots

Z rozwinięcia w szereg Taylora wokół zera:

$$M_Z(t) = M_Z(0) + M'_Z(0)t + \frac{1}{2}M''_Z(0)t^2 + o(t^2)$$

Dowód Centralnego Twierdzenia Granicznego

Niech $M_Z(t)$ będzie funkcją tworzącą momenty zmiennych Z_1, Z_2, \dots

Z rozwinięcia w szereg Taylora wokół zera:

$$M_Z(t) = M_Z(0) + M'_Z(0)t + \frac{1}{2}M''_Z(0)t^2 + o(t^2) = 1 + \frac{1}{2}t^2 + o(t^2)$$

$$= 1$$

$$= EZ = 0$$

$$= E(Z^2) = D^2(Z) - (EZ)^2 = 1$$

Dowód Centralnego Twierdzenia Granicznego

Niech $M_Z(t)$ będzie funkcją tworzącą momenty zmiennych Z_1, Z_2, \dots

Z rozwinięcia w szereg Taylora wokół zera:

$$M_Z(t) = M_Z(0) + M'_Z(0)t + \frac{1}{2}M''_Z(0)t^2 + o(t^2) = 1 + \frac{1}{2}t^2 + o(t^2)$$

Z niezależności i skalowania:

$$M_{Z_1+\dots+Z_n}(t) = (M_Z(t))^n, \quad M_{U_n}(t) = M_{\frac{Z_1+\dots+Z_n}{\sqrt{n}}}(t) = \left(M_Z\left(\frac{t}{\sqrt{n}}\right) \right)^n$$

Dowód Centralnego Twierdzenia Granicznego

Niech $M_Z(t)$ będzie funkcją tworzącą momenty zmiennych Z_1, Z_2, \dots

Z rozwinięcia w szereg Taylora wokół zera:

$$M_Z(t) = M_Z(0) + M'_Z(0)t + \frac{1}{2}M''_Z(0)t^2 + o(t^2) = 1 + \frac{1}{2}t^2 + o(t^2)$$

Z niezależności i skalowania:

$$M_{Z_1+\dots+Z_n}(t) = (M_Z(t))^n, \quad M_{U_n}(t) = M_{\frac{Z_1+\dots+Z_n}{\sqrt{n}}}(t) = \left(M_Z\left(\frac{t}{\sqrt{n}}\right) \right)^n$$

Stąd:

$$M_{U_n}(t) = \left(1 + \frac{t^2}{2n} + o\left(\frac{t^2}{2n}\right) \right)^n$$

Dowód Centralnego Twierdzenia Granicznego

Niech $M_Z(t)$ będzie funkcją tworzącą momenty zmiennych Z_1, Z_2, \dots

Z rozwinięcia w szereg Taylora wokół zera:

$$M_Z(t) = M_Z(0) + M'_Z(0)t + \frac{1}{2}M''_Z(0)t^2 + o(t^2) = 1 + \frac{1}{2}t^2 + o(t^2)$$

Z niezależności i skalowania:

$$M_{Z_1+\dots+Z_n}(t) = (M_Z(t))^n, \quad M_{U_n}(t) = M_{\frac{Z_1+\dots+Z_n}{\sqrt{n}}}(t) = \left(M_Z\left(\frac{t}{\sqrt{n}}\right) \right)^n$$

Stąd:

$$M_{U_n}(t) = \left(1 + \frac{t^2}{2n} + o\left(\frac{t^2}{2n}\right) \right)^n \xrightarrow{n \rightarrow \infty} e^{\frac{1}{2}t^2},$$

ponieważ $\lim_{n \rightarrow \infty} \left(1 + \frac{x}{n} + o\left(\frac{1}{n}\right) \right)^n = e^x$

Funkcje charakterystyczne

Funkcja tworząca momenty może nie istnieć w otoczeniu zera (gdy wyższe momenty zmiennej losowej są nieskończone)

Funkcje charakterystyczne

Funkcja tworząca momenty może nie istnieć w otoczeniu zera (gdy wyższe momenty zmiennej losowej są nieskończone)

Funkcja charakterystyczna: zamień t na liczbę **urojoną** $i \cdot t$ w definicji funkcji tworzącej momenty:

$$\psi_X(t) = E\left(e^{itX}\right)$$

Funkcje charakterystyczne

Funkcja tworząca momenty może nie istnieć w otoczeniu zera (gdy wyższe momenty zmiennej losowej są nieskończone)

Funkcja charakterystyczna: zamień t na liczbę **urojoną** $i \cdot t$ w definicji funkcji tworzącej momenty:

$$\psi_X(t) = E\left(e^{itX}\right)$$

Funkcja charakterystyczna ma zupełnie analogiczne własności do funkcji tworzącej momenty, a równocześnie jest określona dla dowolnego $t \in \mathbb{R}$

Funkcja charakterystyczna jest **transformatą Fouriera** gęstości prawdopodobieństwa

W podręcznikach teorii prawdopodobieństwa udowadnia się Centralne Twierdzenie Graniczne za pomocą funkcji charakterystycznych (brak założenia o istnieniu wszystkich momentów)