

## Spis treści

1	Oznaczenia i definicje	4
2	Wnioskowanie statystyczne	4
2.1	Statystyki dostateczne	4
2.1.1	Rodzina rozkładów wykładniczych	5
2.2	Rozkłady niektórych statystyk	5
2.3	Estymatory	6
2.3.1	Definicje	6
2.3.2	Metody wyznaczania estymatorów	8
3	Testowanie hipotez statystycznych	8
3.1	Testy najmocniejsze	8
3.2	Testy ilorazowe	9
4	Statystyka bayesowska	10
4.1	Bayesowskie przedziały ufności	10
4.2	Rodziny sprzeczne	10
4.3	Decyzje statystyczne	11
4.4	Reguły bayesowskie	11
5	Rachunek prawdopodobieństwa	11
5.1	Funkcje zmiennych losowych	12
5.2	Funkcje charakterystyczne	12
5.3	Zbiory nośne probabilistyczne	13
5.4	Prawa wielkich liczb	14
5.4.1	Słabe prawa wielkich liczb	14
5.4.2	Mocne prawa wielkich liczb	15
5.5	Centralne Twierdzenia Graniczne	16
5.6	Nierówności	17
6	Tabela rozkładów dyskretnych	18
7	Tabela rozkładów ciągłych	19

## Statystyka Matematyczna Skrypt

SKN  
Matematyki Stosowanej

s k n  
· · ·  
· m s

11 czerwca 2006

## 7 Tabela rozkładów ci ęłych

Nazwa	Funkcja g sto ci	Parametry	$E X$	$D^2 X$	Dystrybucanta	F. tworz ca
Jednostajny	$\chi < a, b > \frac{1}{b-a}$	$a < b$	$\frac{1}{2}(a+b)$	$\frac{1}{12}(b-a)^2$	$\frac{x-a}{b-a}$	$\frac{e^{bt} - e^{at}}{t(b-a)}$
Normalny	$\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$	$\sigma > 0$	$\mu$	$\sigma^2$	$\sigma$	$\frac{e^{it\mu} - e^{-it\mu}}{2it}$
Trojki ęny	$\frac{1}{a} \left(1 - \frac{ x }{a}\right)$	$ x  < a$	0	$\frac{2}{3}a^2$		
Log-normalny	$\frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}}$	$\sigma > 0$	$e^{\mu + \frac{\sigma^2}{2}}$	$(e^{\sigma^2} - 1)e^{2\mu + \sigma^2}$		
Pareto	$\chi < b, \infty > a b^a x^{-(a+1)}$	$a, b > 0$	$\frac{ba}{a-1} ; a > 1$	$\frac{b^2 a}{(a-1)^2(a-2)} ; a > 2$	$1 - \left(\frac{b}{x}\right)^a$	$(1 - \frac{t}{b})^{-a-1}$
Wykładniczy	$\chi R_{++} \lambda e^{-\lambda x}$	$\lambda > 0$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$	$1 - e^{-\lambda x}$	$(1 - \frac{t}{\lambda})^{-1}$
Gamma ( $\lambda, s$ )	$\chi R_{++} + \Gamma(s) \lambda^s x^{s-1} e^{-\lambda x}$	$s > 0$	$\frac{s}{\lambda}$	$\frac{s}{\lambda^2}$		$(1 - \theta t)^{-k}$
Beta	$\frac{\Gamma(p+q)}{\Gamma(p)\Gamma(q)} x^{p-1} (1-x)^{q-1}$	$x, p, q > 0, x < 1$	$\frac{p}{p+q}$	$\frac{pq}{(p+q)^2(p+q+1)}$		
Laplace'a	$\frac{1}{2a} e^{-\frac{ x-\mu }{a}}$	$\sigma > 0$	$\mu$	$2\sigma^2$		
Cauchy'ego	$\frac{1}{\pi} \frac{1}{1+x^2}$		-	-		$\frac{1}{\pi} \arctan(\frac{x}{a}) + \frac{1}{2}$
Uog. Cauchy'ego	$\frac{1}{\pi} \frac{b}{b^2 + (x-a)^2}$	$b > 0$	-	-		
Weibulla	$s \lambda x^{s-1} e^{-\lambda x^s}$	$\lambda, s > 0$	$\frac{1}{\lambda} \left(1 + \frac{1}{s}\right)$	$\frac{1}{\lambda} \left(1 + \frac{2}{s}\right) - \frac{2}{s^2} \left(1 + \frac{1}{s}\right)$		
Chi-kw (1 df)	$\frac{1}{\sqrt{2\pi x}} e^{-\frac{x}{2}}$		1	2		$(1 - 2it)^{-\frac{1}{2}}$
Chi-kw (n df)	$\frac{x^{\frac{n}{2}-1} e^{-\frac{x}{2}}}{\Gamma(\frac{n}{2}) 2^{\frac{n}{2}}}$		$n$	$2n$		$(1 - 2it)^{-\frac{n}{2}}$
T-studenta (n df)	$\frac{\Gamma(\frac{n+1}{2})}{\Gamma(\frac{n}{2})} \sqrt{\frac{n}{\pi}} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}$	$n > 2$	0	$\frac{n}{n-2}$		
Snedecora	$\frac{\Gamma(\frac{n}{2})}{\Gamma(\frac{n}{2})} \frac{1}{2} \sqrt{\frac{n}{\pi}} \left(1 + \frac{x^2}{n}\right)^{-\frac{n}{2}}$	$m > 0 \wedge n \in \mathbb{N}$	$\frac{n}{n-2} \wedge n > 2$	$\frac{2n^2(n+m-2)}{m(n-2)^2(n-4)} \wedge n > 4$		
Logistyczny	$\frac{1}{4} \frac{e^{-x}}{(1+e^{-x})^2}$	$\lambda > 0$				
Maxwella	$\chi R_{++} + \frac{\lambda^3}{2} x^2 e^{-\lambda x}$	$\lambda > 0$	$\frac{2}{\lambda}$	$\frac{3\pi - 8}{2\pi} \lambda$		
Rayleigha	$\chi R_{++} + \lambda x e^{-\frac{x^2}{2}}$	$\lambda > 0$	$\frac{1}{\lambda} \sqrt{\lambda \pi}$	$\frac{4-\pi}{4} \lambda$	$1 - \exp\left(-\frac{x^2}{2\sigma^2}\right)$	

## 6 Tabela rozkładów dyskretnych

Nazwa	$P(X=t)$	$EX$	$D^2X$	Dystrybuanta	F. tworząca
Zerowy	$P(1) = p$	$p$	$1-p$		
Dwupunktowy	$\frac{1}{p^k(1-p)^{1-k}}$	$\frac{n+1}{n}$	$\frac{n^2-1}{n}$		
Równomierny	$\frac{1}{n}$	$\frac{n+1}{2}$	$\frac{n^2-1}{12}$		
Dwumianowy	$\binom{n}{k} p^k (1-p)^{n-k}$	$np$	$np(1-p)$		
Poissona	$\frac{\lambda^k}{k!} e^{-\lambda}$	$\lambda$	$\lambda$	$\frac{\Gamma(k+1, \lambda)}{k!}$	$\exp(\lambda(e^t - 1))$
Geometryczny	$p(1-p)^{k-1}$	$\frac{1}{p}$	$\frac{1-p}{p^2}$		
Hipergeometryczny	$\frac{\binom{m}{k} \binom{N-m}{n-k}}{\binom{N}{n}}$	$\frac{nM}{N}$	$\frac{n \frac{M}{N} (1 - \frac{M}{N})(N-n)}{(N-1)}$		
Uj. dwumianowy (Pascala)	$\binom{k-1}{m-1} p^m (1-p)^{k-m}$	$\frac{m}{p}$	$\frac{m(1-p)}{p^2}$		
Logarytmiczny	$\frac{\theta^k}{k \log(1-\theta)}$				

$$\begin{aligned} (s) &= \int_0^{\infty} t^{s-1} e^{-t} dt \\ (s+1) &= s(s) \\ (n) &= (n-1)! \wedge n \in \mathbb{N} \\ B(p, q) &= \int_0^1 t^{p-1} (1-t)^{q-1} dt \\ B(p, q) &= \frac{\Gamma(p) \Gamma(q)}{\Gamma(p+q)} \end{aligned}$$

Autorzy  
Katarzyna Łuckowska  
Marcin Szymański  
Paweł Wietraszek

Niniejszy skrypt napisany został jako pomoc dla studiujących statystykę matematyczną. Wszelkie teksty w nim zawarte stanowią własność intelektualną autorów.

Pracę zło ono w języku  $\text{\LaTeX} 2_{\epsilon}$

## 1 Oznaczenia i definicje

Ozn. 1 (Przestrze parametrów).

Ozn. 2 (Przestrze prób).  $\mathfrak{X} \in \mathbb{R}^n$

Ozn. 3 (Obserwacja losowa). wektor losowy  $X \in \mathfrak{X}$

Ozn. 4 (Rodzina rozkładów prawdopodobieństwa).  $\{P_\theta : \theta \in \mathfrak{X}\}$

Def. 5 (Model statystyczny; Przestrze statystyczna).

$$(\mathfrak{X}, S, \{P_\theta : \theta \in \mathfrak{X}\}) \wedge S = B(\mathfrak{X})$$

Def. 6 (Identyfikowalność). Własność modelu:  $\theta_1 \neq \theta_2 \Rightarrow P_{\theta_1} \neq P_{\theta_2}$

Def. 7 (Statystyka). Funkcja  $t : \mathfrak{X} \rightarrow \mathbb{R}^k$  taka, że  $\forall X \in \mathfrak{X}$   $t(X)$  jest zmienną losową na  $(\mathfrak{X}, S, \{P_\theta : \theta \in \mathfrak{X}\}) \wedge S = B(\mathfrak{X})$

Def. 8 (Statystyka k-wymiarowa).  $T : \mathbb{R}^n \rightarrow \mathbb{R}^k$   $T(X_1, \dots, X_n) \wedge X_1, \dots, X_n \sim iid F$

Def. 9 (k-ta statystyka porządkowa).  $X_{k:n}$  k-ta liczba w rosnąco uporządkowanym ciągu

Def. 10 (Mediana).

$$M_e = \begin{cases} X_{\frac{n+1}{2}:n} & \iff n \equiv (1 \bmod 2) \\ \frac{1}{2}(X_{\frac{n}{2}:n} + X_{\frac{n}{2}+1:n}) & \iff 2 \mid n \end{cases}$$

Def. 11 (Dystrybucja empiryczna).  $\hat{F}_n(t) = \frac{\text{card}\{x_i : x_i \leq t\}}{n}$

Tw. 1 (Gliwko-Cantelli).

$$\sup_t |F(t) - \hat{F}_n(t)| \xrightarrow{n \rightarrow \infty} 0$$

Tw. 2 (Własności dystrybucji empirycznej).

- $\forall t \in \mathbb{R} \quad F_n(t, \underline{X}) \xrightarrow{1} F(t)$
- $\forall n \forall t \in \mathbb{R} \quad E_F F_n(t, \underline{X}) = F(t)$
- $\sqrt{n} \frac{F_n(t, \underline{X}) - F(t)}{\sqrt{F(t)[1-F(t)]}} \xrightarrow{d} Z \sim \mathcal{N}(0, 1)$

## 2 Wnioskowanie statystyczne

### 2.1 Statystyki dostateczne

Def. 12 (Statystyka dostateczna).  $T$ , że rozk. warunkowy  $P_\theta\{ \cdot | T = t \}$  nie zależy od  $\theta$

Def. 13 (Statystyka dostateczna). Statystyka dostateczna dla  $\theta$  to taka, która generuje podział dostateczny przestrzeni prób.

Tw. 3 (O faktoryzacji).  $T$  jest dostateczna  $\iff$

$$f_\theta(\mathbf{x}_n) = g_\theta(T(\mathbf{x}_n))h(\mathbf{x}_n)$$

$g_\theta$  - zależy od  $\theta$ , zależy od  $\mathbf{x}_n$  tylko przez  $T$

$h$  - nie zależy od  $\theta$ , zależy od  $\mathbf{x}_n$

Def. 14 (Podział dostateczny). Podział  $\mathfrak{A}$  przestrzeni prób  $\mathfrak{X}$  jest dostateczny dla  $\theta$ , jeśli przy każdym ustalonym zbiorze  $A \in \mathfrak{A}$  rozkład warunkowy próby pod warunkiem  $A$  nie zależy od  $\theta$ .

Def. 15 (Konstrukcja minimalnego podziału dostatecznego). (do napisania)

Def. 16 (Minimalna statystyka dostateczna). Statystyka  $S$  jest minimalną statystyką dostateczną  $\iff$  gdy dla każdej innej statystyki dostatecznej  $T$  istnieje funkcja  $h$  taka, że  $S = h(T)$ .

Def. 17 (Minimalna statystyka dostateczna). Minimalna statystyka dostateczna dla  $\theta$  to taka, która generuje minimalny podział dostateczny przestrzeni prób.

Def. 18 (Statystyka zupełna). Statystyka  $T = T(X)$  jest zupełna, jeżeli dla wszystkich  $\theta \in \Theta$  z równości  $E_\theta h(T) = 0$  wynika że  $h \equiv 0$  z prawdopodobieństwem 1 na zbiorze wartości  $T$ .

Def. 19 (Statystyka swobodna wzgl.  $\theta$ ). Statystyka, której rozkład nie zależy od  $\theta$ .

Def. 20 (Statystyka swobodna I rzędu). Statystyka, której wartość oczekiwana nie zależy od  $\theta$ .

Tw. 4 (Basu). Jeżeli  $T$  jest statystyką dostateczną zupełną dla  $\theta$ , a  $V$  statystyką swobodną, to  $T$  i  $V$  są niezależnymi zmiennymi losowymi.

Tw. 5. Minimalna statystyka dostateczna nie musi być zupełna

Tw. 6. Jeżeli  $T$  jest statystyką dostateczną zupełną to jest minimalną statystyką dostateczną

### 5.6 Nierówność

Tw. 87 (Schwarz). Jeśli  $EX^2 < \infty$  i  $EY^2 < \infty$ , to

$$E(|XY|) \leq \sqrt{EX^2} \cdot \sqrt{EY^2},$$

ponadto równość zachodzi wtedy i tylko wtedy, gdy  $X$  i  $Y$  są liniowo zależne.

Tw. 88 (Jensen). Niech  $E|X| < \infty$  oraz  $g : \mathbb{R} \rightarrow \mathbb{R}$  wypukła, taka że  $E|g(X)| < \infty$ , wtedy

$$g(EX) \leq Eg(X).$$

Tw. 89 (Czebyszew). Niech  $X$  będzie nieujemną zmienną losową. Wtedy dla każdego  $\varepsilon > 0$

$$P(X \geq \varepsilon) \leq \frac{EX}{\varepsilon}.$$

Tw. 90 (Czebyszew). Niech  $g : \mathbb{R}_+ \rightarrow \mathbb{R}$  borelowska, niemalejąca i dodatnia, wtedy

$$P(|X| > a) \leq \frac{Eg(|X|)}{g(a)}$$

[Przykład] Dla  $g(x) = x^2$  i  $X := X - EX$  otrzymujemy

$$\forall \varepsilon > 0 \quad P(|X - EX| \geq \varepsilon) \leq \frac{\text{Var } X}{\varepsilon^2}.$$

Tw. 91 (Hölder). Niech  $p, q > 1$  oraz  $\frac{1}{p} + \frac{1}{q} = 1$  i  $E|X|^p < \infty$ ,  $E|Y|^q < \infty$ , wtedy  $E|XY| < \infty$  oraz

$$E|XY| \leq (E|X|^p)^{\frac{1}{p}} (E|Y|^q)^{\frac{1}{q}}.$$

Tw. 92 (Minkowski). Niech  $p \geq 1$  wtedy

$$(E|X + Y|^p)^{\frac{1}{p}} \leq (E|X|^p)^{\frac{1}{p}} + (E|Y|^p)^{\frac{1}{p}}$$

Tw. 93 (Kołomogorow). Niech  $X_1, \dots, X_n$  będą niezależnymi zmiennymi losowymi, takimi że  $EX_i = 0$  i  $EX_i^2 < \infty$   $i = 1, \dots, n$ . Jeśli  $\exists c > 0$ , że  $P(|X_i| \leq c) = 1$ ,  $i = 1, \dots, n$  to

$$\forall \varepsilon > 0 \quad P(\max_{1 \leq k \leq n} |S_k| \geq \varepsilon) \geq 1 - \frac{(c + \varepsilon)^2}{ES_n^2},$$

gdzie  $S_n = X_1 + \dots + X_n$ .

## 5.5 Centralne Twierdzenia Graniczne

Tw. 79 (CTG). Niech  $X_1, X_2, \dots$  będą niezależnymi zmiennymi losowymi o tym samym rozkładzie oraz niech  $EX = 0$  i  $VarX = 1$ . Wtedy

$$\frac{X_1 + \dots + X_n}{\sqrt{n}} \xrightarrow{d} \mathcal{N}(0, 1).$$

Tw. 80. Niech  $X_1, X_2, \dots$  będą niezależnymi zmiennymi losowymi o tym samym rozkładzie, niech  $EX_1 = \mu$  i  $VarX_1 = \sigma^2$ . Wtedy dla każdego  $\varepsilon$

$$P \frac{X_1 + \dots + X_n - n\mu}{\sigma\sqrt{n}} \leq \varepsilon \rightarrow_{n \rightarrow \infty} (\varepsilon).$$

Tw. 81 (Lindeberga-Levy'ego). Jeżeli zmienne losowe  $X_1, X_2, \dots$  są niezależne o jednakowych rozkładach z parametrami  $EX_k = \mu$ ,  $VarX_k = \sigma^2$  dla  $k=1, 2, \dots$ , to

$$\lim_{n \rightarrow \infty} P a < \frac{S_n - n\mu}{\sigma\sqrt{n}} \leq b = (b) - (a),$$

gdzie jest dystrybuantą rozkładu normalnego  $\mathcal{N}(0, 1)$ . Oznacza to, że suma  $S_n$  ma rozkład asymptotycznie normalny  $\mathcal{N}(n\mu, \sigma\sqrt{n})$ .

Tw. 82 (de Moivre'a-Laplace'a). Jeżeli zmienne losowe  $X_1, X_2, \dots$  są niezależne o jednakowych rozkładach dwupunktowych Bern(p), to

$$\lim_{n \rightarrow \infty} P a < \frac{S_n - np}{\sqrt{npq}} \leq b = (b) - (a),$$

gdzie jest dystrybuantą rozkładu normalnego  $\mathcal{N}(0, 1)$ . Oznacza to, że suma  $S_n$  ma rozkład asymptotycznie normalny  $\mathcal{N}(np, \sqrt{npq})$ .

Tw. 83 (Berry-Esséen). Jeżeli  $(X_n)$  jest ciągiem niezależnych zmiennych losowych o tym samym rozkładzie i  $E|X_1|^3 < \infty$  to,

$$\sup_{t \in \mathbb{R}} P \frac{S_n - ES_n}{\sqrt{VarS_n}} \leq t - (t) \leq C \frac{E|X_1 - EX_1|^3}{\sigma^3\sqrt{n}},$$

gdzie  $\sigma = \sqrt{VarX_1}$  oraz  $\frac{1}{\sqrt{2\pi}} \leq C < 0, 8$ .

Tw. 84 (Poissona). Jeżeli zmienne losowe  $X_1, X_2, \dots$  są niezależne o rozkładach dwumianowych  $Bin(n, p_n)$  i jeśli  $np_n = \lambda$  dla  $n=1, 2, \dots$ , to

$$\lim_{n \rightarrow \infty} P(X_n = k) = \lim_{n \rightarrow \infty} \frac{n!}{(n-k)!k!} p_n^k (1-p_n)^{n-k} = \frac{\lambda^k}{k!} e^{-\lambda}.$$

Def. 86 (Warunek Lindeberga). Ciąg zmiennych losowych  $(X_n)$  spełnia warunek Lindeberga, jeśli dla każdego  $\varepsilon > 0$

$$\frac{1}{s_n^2} \sum_{k=1}^n E[(X_k - EX_k)^2 \mathbf{1}_{\{|X_k - EX_k| > \varepsilon s_n\}}] \rightarrow_{n \rightarrow \infty} 0,$$

gdzie  $s_n^2 = \sum_{k=1}^n VarX_k$ .

Def. 87 (Warunek Lapunowa). Ciąg zmiennych losowych  $(X_n)$  spełnia warunek Lapunowa, jeśli dla wszystkich  $k$  naturalnych i dla pewnego  $\delta > 0$  jest  $E|X_k|^{2+\delta} < \infty$  oraz

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^{2+\delta}} \sum_{k=1}^n E|X_k - EX_k|^{2+\delta} = 0.$$

Lem. 85. Warunek Lapunowa pociąga za sobą warunek Lindeberga.

Tw. 86. Jeśli ciąg niezależnych zmiennych losowych  $(X_n)$  spełnia warunek Lindeberga, to

$$P \frac{S_n - ES_n}{s_n} \leq a \rightarrow_{n \rightarrow \infty} (a)$$

jednostajnie względem  $a$ .

## 2.1.1 Rodzina rozkładów wykładniczych

Def. 21 (Rodzina rozkładów wykładniczych). Rodzina rozkładów  $\{P_\theta : \theta \in \Theta\}$  taka, że każdy rozkład jest postaci

$$p_\theta(x) = e^{-\sum_{j=1}^k c_j(\theta)T_j(x) - b(\theta)} h(x)$$

i  $T_1, \dots, T_k$  są liniowo niezależne, a  $c_1, \dots, c_k$  tworzą  $k$ -wymiarowy zbiór

Tw. 7. Dla rodziny wykładniczej

$$(T_1(X), \dots, T_k(X))$$

jest minimalną statystyką dostateczną oraz statystyką zupełną.

Tw. 8. Dla próby z rodziny wykładniczej

$$\left( T_1(X_i), \dots, T_k(X_i) \right)_i$$

jest statystyką dostateczną zupełną.

## 2.2 Rozkłady niektórych statystyk

Def. 22 (rednia).  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$

- Jest nieobciążonym estymatorem wartości oczekiwanej
- Jest zgodnym estymatorem wartości oczekiwanej

Tw. 9.  $Var(\bar{X}) = \frac{1}{n} Var(X)$

Def. 23 (Wariancja z próby).  $S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$

- Jest obciążonym estymatorem wariancji  $S^2(X) = \frac{n-1}{n} \sigma^2$

Tw. 10 (Fisher). Jeżeli  $X_1, \dots, X_n \sim iid N(m, \sigma^2)$  to

1.  $\bar{X}, S^2$  są niezależne

2.  $\bar{X} \sim (m, \frac{\sigma^2}{n})$

3.  $\frac{nS^2}{\sigma^2} \sim \chi_{n-1}^2$

Tw. 11. Jeżeli  $X_1, \dots, X_k \sim iid N(0, 1)$  to

1.  $X_i^2 \sim \chi_k^2$

2.  $E(\sum_{i=1}^k X_i^2) = \sum_{i=1}^k EX_i^2 = k$

Tw. 12. Jeżeli  $Y_1, \dots, Y_m$  są niezależne  $\wedge Y_i \sim \chi_{v_i}^2$  to

$$Y_i \sim \chi_{v_i}^2$$

Tw. 13. Jeżeli  $X_1, \dots, X_{n_1} \sim iid N(m_1, \sigma_1^2) \wedge Y_1, \dots, Y_{n_2} \sim iid N(m_2, \sigma_2^2)$  to

$$\frac{n_1 S_1^2}{\sigma_1^2} + \frac{n_2 S_2^2}{\sigma_2^2} \sim \chi_{n_1 + n_2 - 2}^2$$

Tw. 14 (Gosset). Jeżeli  $X, Y$  są niezależne  $\wedge X \sim N(0, 1) \wedge Y \sim \chi_v^2$  to

1.  $\frac{X}{\sqrt{Y/v}} \sim t_v$

2.  $\frac{\sqrt{v} \frac{\bar{X} - m}{S}}{\frac{S^2}{\sigma^2}} = \frac{\bar{X} - m}{S} \sqrt{v-1} \sim t_{v-1}$

Tw. 15. Jeżeli  $X, Y$  są niezależne  $\wedge X \sim \chi_{v_1}^2 \wedge Y \sim \chi_{v_2}^2$  to

$$F = \frac{X/v_1}{Y/v_2} \sim F_{v_1, v_2}$$

Lem. 16. (Na mocy CTG) Jeżeli  $X$  ma rozkład dwumianowy to

$$\frac{\bar{X} - np}{np(1-p)} \sim N\left(np, \overline{np(1-p)}\right)$$

Uwaga: Jeżeli nie znamy  $p$  to przy konstruowaniu przedziału ufności zakładamy najgorszy przypadek  $p = \frac{1}{2}$

Tw. 17.  $X_1, \dots, X_{n_1} \text{ iid} \sim N(m_1, \sigma_1^2) \wedge S_1^2 = \frac{1}{n_1} \sum_{i=1}^{n_1} (X_i - \bar{X})^2 \wedge Y_1, \dots, Y_{n_2} \text{ iid} \sim N(m_2, \sigma_2^2) \wedge S_2^2 = \frac{1}{n_2} \sum_{i=1}^{n_2} (Y_i - \bar{Y})^2$

$$F = \frac{\frac{\frac{n_1 S_1^2}{\sigma_1^2}}{\frac{n_1 - 1}{\sigma_1^2}}}{\frac{\frac{n_2 S_2^2}{\sigma_2^2}}{\frac{n_2 - 1}{\sigma_2^2}}} \sim F(n_1 - 1, n_2 - 1)$$

Tw. 18 (Rozkład k-tej statystyki pozycyjnej).

$$\begin{aligned} F_{X_{k:n}} = P(X_{k:n} < x) &= \sum_{i=k}^n \frac{n!}{m!(n-m)!} (F(x))^i (1-F(x))^{n-i} = \\ &= \frac{n!}{(k-1)!(n-k)!} \int_0^{F(x)} t^{k-1} (1-t)^{n-k} dt \\ f_{X_{k:n}} = P(X_{k:n} = x) &= \frac{n!}{(k-1)!(n-k)!} (F(x))^{k-1} (1-F(x))^{n-k} f(x) \end{aligned}$$

## 2.3 Estymatory

### 2.3.1 Definicje

Def. 24 (Estymator). Statystyka  $T(X_1, X_2, \dots, X_n)$ , której rozkład zależy od pewnego parametru  $\theta$  rozkładu populacji, dla  $(X_1 = x_1, \dots, X_n = x_n)$ , liczbę  $T(x_1, x_2, \dots, x_n)$  nazywamy wartością estymatora.

Def. 25 (Kwadratowa funkcja straty estymatora  $T$ ).  $L(T, \theta) = T(x) - g(\theta)^2$

Def. 26 (Ryzyko estymatora  $T$ ; Bł d redniokwadratowy).  $R_T(\theta) = E_\theta L(T, \theta)$

Tw. 19. Jeżeli  $T$  jest estymatorem  $\theta$  to dla jego ryzyka zachodzi

$$R_T(\theta) = \text{Var}T(x) + (ET(x) - \theta)^2$$

Def. 27 (Najlepszy estymator).

$$T_0 : \forall \theta \in \Theta \forall T \in D R_{T_0}(\theta) \leq R_T(\theta)$$

gdzie  $D$  - zbiór estymatorów

Def. 28 (Estymator zgodny). Estymator  $U_n(\omega, \theta) = f(X_1(\omega), X_2(\omega), \dots, X_n; \theta)$  parametru  $\theta$  jest zgodny, gdy jest on zbieżny według prawdopodobieństwa do parametru  $\theta$ , tzn. gdy

$$\forall \varepsilon > 0 \lim_{n \rightarrow \infty} P(\{\omega : |U_n(\omega; \theta) - \theta| > \varepsilon\}) = 0$$

Def. 29 (Estymator nieobciążony). Estymator  $U_n$  jest nieobciążonym estymatorem parametru  $\theta \iff$

$$\forall n \in \mathbb{N} \quad E(U_n) = \theta$$

Def. 30 (Estymator asymptotycznie nieobciążony). Estymator  $U_n$  jest asymptotycznie nieobciążonym estymatorem parametru  $\theta \iff$

$$\lim_{n \rightarrow \infty} E(U_n) = \theta$$

Tw. 20. Jeżeli  $\lim_{n \rightarrow \infty} E_\theta U_n = \theta$  (przynajmniej asymptotycznie nieobciążony) oraz  $\lim_{n \rightarrow \infty} D^2 U_n = 0$ , to  $U_n$  jest zgodnym estymatorem parametru  $\theta$ .

Def. 31 (Obciążenie estymatora).  $E(U_n) - \theta$

Def. 32 (Estymator NMW). Estymatorem nieobciążonym o minimalnej wariancji parametru  $\theta$  nazywamy ten spośród nieobciążonych estymatorów tego parametru, który ma najmniejszą wariancję.

Tw. 71 (SPWL Markowa). Niech  $(X_n)$  będzie ciągiem zmiennych losowych takich, że

$$\lim_{n \rightarrow \infty} \frac{\text{Var}RS_n}{n^2} = 0,$$

wtedy  $(X_n)$  spełnia SPWL.

Tw. 72 (PWL Czebyszewa lub Markowa). Niech  $(X_n)$  będzie ciągiem zmiennych losowych niezależnych o skończonych wariancjach  $\sigma_n^2 = \text{Var}RX_n, n=1,2,\dots$ . Jeżeli

$$\lim_{n \rightarrow \infty} \frac{1}{n^2} \sum_{k=1}^n \sigma_k^2 = 0,$$

to ciąg  $(X_n)$  spełnia SPWL.

Tw. 73 (SPWL Czebyszewa). Jeśli  $X_n$  są niezależne lub parami nieskorelowane i mają wspólnie ograniczone wariancję, tj.

$$\exists K \quad \text{Var}X_i < K \quad i = 1, 2, \dots$$

to ciąg  $(X_n)$  spełnia SPWL.

Tw. 74 (PWL Chinczyna). Niech  $(X_n)$  będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie i skończonej wartości oczekiwanej  $\mu$ . Wtedy ciąg  $(X_n)$  spełnia SPWL, tzn.

$$\lim_{n \rightarrow \infty} P\left(\frac{1}{n}S_n - \mu \leq \varepsilon\right) = 1.$$

### 5.4.2 Mocne prawa wielkich liczb

Def. 85 (MPWL). Mówimy, że ciąg  $(X_n)$  spełnia mocne prawo wielkich liczb, jeżeli ciąg zmiennych losowych  $(\frac{1}{n}(S_n - ES_n))$  jest zbieżny do zera z prawdopodobieństwem 1, tzn. dla każdego  $\varepsilon > 0$

$$P \lim_{n \rightarrow \infty} \frac{S_n - ES_n}{n} = 0 = 1.$$

Tw. 75 (MPWL Bernoulliego). Oznaczmy przez  $S_n$  liczbę sukcesów w schemacie Bernoulliego  $n$  prób z prawdopodobieństwem sukcesu w pojedynczej próbie równym  $p$ . Wtedy dla każdego  $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P \sup_{k \geq n} \frac{S_k}{k} - p \leq \varepsilon = 1.$$

Tw. 76 (Twierdzenie Kołomogorowa). Jeśli  $(X_n)_{n=1}^{\infty}$  jest ciągiem niezależnych zmiennych losowych takich, że  $\text{Var}RX_n < \infty, n=1,2,\dots$ , przy czym

$$\sum_{n=1}^{\infty} \frac{\text{Var}RX_n}{n^2} < \infty,$$

to z prawdopodobieństwem 1

$$\lim_{n \rightarrow \infty} \frac{S_n - ES_n}{n} = 0.$$

Tw. 77 (MPWL Kołomogorowa). Jeżeli  $(X_n)_{n=1}^{\infty}$  jest ciągiem niezależnych zmiennych losowych o jednakowym rozkładzie,  $E|X_1| < \infty$ , to  $(X_n)$  spełnia MPWL, czyli

$$\lim_{n \rightarrow \infty} \frac{S_n}{n} = EX_1$$

z prawdopodobieństwem 1.

Lem. 78. Jeśli  $X_1, X_2, \dots$  takie, że  $EX_n = \mu$  dla  $n = 1, 2, \dots$  to jeśli

$$P\left(\lim_{n \rightarrow \infty} \frac{X_n}{\mu} = 0\right) = 0 \implies \text{MPWL nie zachodzi}$$

d) Jeżeli  $X_n \xrightarrow{L} X$ ,  $EX_n \rightarrow EX$  to  $X_n \xrightarrow{L^1} X$ ,

e) Jeżeli  $X_n \xrightarrow{P} X$ , to istnieje podciąg  $(X_{n_k})$  taki, że  $X_{n_k} \xrightarrow{L^1} X$ .

Tw. 64. Jeżeli  $P$  jest rozkładem dyskretnym, to dla zmiennych losowych określonych na przestrzeni probabilistycznej  $(\mathcal{F}, P)$  zachodzi równoważność:

$$X_n \xrightarrow{L^1} X \Leftrightarrow X_n \xrightarrow{P} X.$$

Def. 81. Rodzinę zmiennych losowych  $\{X_t : t \in T\}$  nazywamy jednostajnie całkowalną, jeżeli

$$\lim_{C \rightarrow \infty} \sup_{t \in T} E |X_t| \cdot I_{\{|X_t| > C\}} = 0.$$

Lem. 65. Jeżeli  $|X_t| \leq Y$  dla  $t \in T$ ,  $EY < \infty$ , to rodzina zmiennych losowych  $\{X_t : t \in T\}$  jest jednostajnie całkowalna.

Tw. 66.  $X_n \xrightarrow{L^p} X$  dla  $p \geq 1$  wtedy i tylko wtedy, gdy

i)  $X_n \xrightarrow{P} X$ ,

ii) Rodzina  $\{|X_n|^p\}$  jest jednostajnie całkowalna.

Def. 82. Niech  $(\mu_n)_{n=1}^\infty$  będzie ciągiem rozkładów prawdopodobieństwa na  $(E, \mathcal{B}(E))$ . Mówimy, że jest on słabo zbieżny do rozkładu  $\mu$  jeżeli dla każdej funkcji ciągłej i ograniczonej  $f : E \rightarrow \mathbb{R}$  zachodzi

$$\lim_{n \rightarrow \infty} \int_E f d\mu_n = \int_E f d\mu.$$

Def. 83. Niech  $X, X_1, X_2, \dots$  będą zmiennymi losowymi o rozkładach  $\mu, \mu_1, \mu_2, \dots$  odpowiednio. Mówimy, że ciąg  $(X_n)$  jest zbieżny według rozkładu do  $X$ , jeżeli ciąg  $(\mu_n)$  słabo zbiega do  $\mu$ , co zapisujemy  $X_n \xrightarrow{d} X$ .

Tw. 67. Następujące warunki są równoważne:

a) Ciąg  $(\mu_n)$  słabo zbiega do  $\mu$ ,

b)  $\limsup_{n \rightarrow \infty} \mu_n(F) \leq \mu(F)$  dla każdego domkniętego zbioru  $F$ ,

c)  $\liminf_{n \rightarrow \infty} \mu_n(G) \geq \mu(G)$  dla każdego otwartego zbioru  $G$ ,

d)  $\lim_{n \rightarrow \infty} \mu_n(B) = \mu(B)$  dla każdego zbioru  $B$  takiego, że  $\mu(\partial B) = 0$ .

Tw. 68 (Sche e). Niech  $\mu$  będzie miarą  $\sigma$ -skończoną oraz funkcje  $f_n$  i  $f$  będą nieujemne i takie, że miary

$$\nu_n(A) = \int_A f_n d\mu, \quad \nu(A) = \int_A f d\mu$$

są miarami probabilistycznymi. Niech ponadto  $f_n \rightarrow f$  p.n. względem miary  $\mu$ . Wówczas

$$\sup_A |\nu_n(A) - \nu(A)| \rightarrow 0.$$

Mówimy wtedy, że miary  $\nu_n$  zbiegają do miary  $\nu$  w normie całkowitej wariancji.

Tw. 69. Niech  $\mu_n, \mu$  będą rozkładami ciągłymi o gęstościach  $f_n, f$  odpowiednio. Jeżeli  $f_n \rightarrow f$  p.n. względem miary Lebesgue'a, to ciąg rozkładów  $(\mu_n)$  słabo zbiega do rozkładu  $\mu$ .

## 5.4 Prawa wielkich liczb

### 5.4.1 Słabe prawa wielkich liczb

Def. 84 (SPWL). Mówimy, że ciąg  $(X_n)$  spełnia słabe prawo wielkich liczb, jeżeli ciąg zmiennych losowych  $(\frac{1}{n}(S_n - ES_n))$  jest zbieżny według prawdopodobieństwa do zera, tzn. dla każdego  $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P \frac{S_n - ES_n}{n} > \varepsilon = 0 \quad \lim_{n \rightarrow \infty} P \frac{S_n - ES_n}{n} \leq \varepsilon = 1.$$

Tw. 70 (PWL Bernoulliego). Jeżeli  $S_n = X_1 + X_2 + \dots + X_n$  ma rozkład dwumianowy  $\text{Bin}(n, p)$ , to dla każdego  $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P \frac{S_n}{n} - p \leq \varepsilon = 1.$$

Tw. 21 (Rao-Blackwella). Jeżeli  $\hat{g}$  jest estymatorem nieobciążonym funkcji  $g(\theta)$  i jeżeli  $T$  jest statystyką dostateczną dla rodziny rozkładów  $\mathfrak{F}$ , to  $E_{\theta}(\hat{g}|T)$  jest estymatorem nieobciążonym o wariancji jednostajnie nie większej od wariancji  $\hat{g}$ .

Tw. 22 (Lehman-Sche ego). Dla dowolnego estymatora nieobciążonego  $S(X)$  parametru  $\theta$  estymator postaci

$$E_{\theta} S(X)|T$$

(gdzie  $T$  jest statystyką dostateczną zupełną) jest ENMW.

Lem. 23. Dla dowolnego estymatora  $\hat{\theta}$  jego błąd średniokwadratowy jest sumą jego wariancji i kwadratu obciążenia, tj.

$$E(\hat{\theta} - \theta)^2 = \text{Var}(\hat{\theta}) + (E(\hat{\theta}) - \theta)^2.$$

Lem. 24. Jeżeli estymator jest nieobciążony to jego błąd średniokwadratowy (ryzyko) jest równe wariancji.

Def. 33 (Funkcja informacji Fishera).

$$I(\theta) = E_{\theta} \left( \frac{\partial \ln f(X, \theta)}{\partial \theta} \right)^2 = n \cdot E_{\theta} \left( \frac{\partial \ln f_i(X_i, \theta)}{\partial \theta} \right)^2$$

Lem. 25. Przy spełnionych założeniach nierówności Rao-Cramera zachodzi:

$$I(\theta) = -E_{\theta} \frac{\partial^2}{\partial \theta^2} \ln f_{\theta}(X)$$

Tw. 26 (Nierówno Rao-Cramera).

$$\text{Var} \hat{\theta}_n \geq \frac{1}{I(\hat{\theta})}$$

Tw. 27. Niech będą spełnione założenia nierówności Rao-Cramera. Wtedy estymator nieobciążony o wariancji  $I(\theta)^{-1}$  istnieje  $\Leftrightarrow$

$$\frac{\partial}{\partial \theta} \ln f_{\theta}(x) = a(\theta) \bar{\theta}(X) - \theta$$

Wtedy  $\bar{\theta}(X)$  jest ENMW dla  $\theta$  oraz  $a(\theta) = I(\theta)$ .

Def. 34 (Efektywno estymatora). Efektywnością estymatora  $\hat{\theta}$  nazywamy funkcję

$$ef_{\theta}(\hat{\theta}) = \frac{\text{Var}_{\theta}(\hat{\theta})^{-1}}{\frac{1}{I(\theta)}} = \frac{1}{\text{Var}_{\theta}(\hat{\theta}) \cdot I(\theta)}.$$

Def. 35 (Estymator najefektywniejszy).  $\hat{\theta} : \forall \theta \quad ef_{\theta}(\hat{\theta}) = 1$

Lem. 28. Jeśli estymator jest estymatorem najefektywniejszym to jest on również ENMW. (Implikacja odwrotna jest nieprawdziwa)

Def. 36 (Błąd standardowy estymatora). Błędem standardowym estymatora  $\hat{\theta}$  parametru  $\theta$  nazywamy dowolny estymator jego odchylenia standardowego  $\sigma(\hat{\theta})$  i oznaczamy go  $SE(\hat{\theta})$ .

Def. 37 (Estymator studentyzowany). Niech  $\hat{\theta}$  będzie nieobciążonym estymatorem parametru  $\theta$ . Wówczas studentyzowanym estymatorem  $\theta$  nazywamy wielkość

$$\frac{\hat{\theta} - \theta}{SE(\hat{\theta})}.$$

Def. 38 (Funkcja centralna). Funkcją centralną nazywamy funkcję  $t(X, \theta)$ , której rozkład nie zależy od  $\theta$  i która dla każdego  $X = x$  jest monotoniczną funkcją  $\theta$ .

Def. 39 (Konstrukcja zbiorów ufności). Wyznaczamy stałe  $t_1, t_2$  takie, że  $P_{\theta}(t_1 \leq t(X, \theta) \leq t_2) = 1 - \alpha$ .

$$t_1 \leq t(X, \theta) \leq t_2 \Leftrightarrow \hat{\theta}_1(X) \leq \theta \leq \hat{\theta}_2(X)$$

Przedział  $(\hat{\theta}_1(X); \hat{\theta}_2(X))$  jest przedziałem ufności dla  $\theta$  na poziomie ufności  $1 - \alpha$ .

Def. 40 (Przedział ufności). Para statystyk  $L(X), U(X)$  określa przedział ufności na poziomie ufności  $1 - \alpha$ ,  $\alpha \in (0, 1)$  - ustalone.

1) Jeżeli  $P_{\theta}[L(X) \leq \theta \leq U(X)] \geq 1 - \alpha$  to  $[L(X), U(X)]$  - przedział ufności dla  $\theta$  na poziomie ufności  $1 - \alpha$

2) Jeżeli  $P_{\theta}[L(X) \leq \theta] \geq 1 - \alpha$  to  $[L(X), +\infty)$  - przedział ufności dla  $\theta$  na poziomie ufności  $1 - \alpha$

3) Jeżeli  $P_{\theta}[\theta \leq U(X)] \geq 1 - \alpha$  to  $[-\infty, U(X)]$  - przedział ufności dla  $\theta$  na poziomie ufności  $1 - \alpha$

Def. 41 (Asymptotyczny przedział ufności). Przedział  $(\underline{g}_n; \bar{g}_n)$ , gdzie  $\underline{g}_n = \underline{g}(x_1, \dots, x_n)$  i  $\bar{g}_n = \bar{g}(x_1, \dots, x_n)$ , jest asymptotycznym przedziałem ufności dla  $g(\theta)$  na poziomie  $1 - \alpha$ , jeżeli

$$\forall \theta \in \Theta \lim_{n \rightarrow \infty} P_{\theta} \underline{g}_n \leq g(\theta) \leq \bar{g}_n \geq 1 - \alpha$$

## 2.3.2 Metody wyznaczania estymatorów

Def. 42 (Metoda momentów).

$$\bar{x} = EX = f(\theta) \Rightarrow \theta = f^{-1}(x)$$

Def. 43 (Metoda najwi kszej wiarygodno ci).

$$f(x_1, \dots, x_n, \theta) = \prod_{i=1}^n f(x_i, \theta)$$

$$\hat{\theta} : \frac{\partial \ln f(x_1, \dots, x_n, \theta)}{\partial \theta} = 0$$

## 3 Testowanie hipotez statystycznych

Def. 44 (Test zrandomizowany). Test  $H_0: \theta \in \Theta_0$  przeciw  $H_1: \theta \in \Theta_1$  utożsamiamy z funkcją  $\varphi: (X) \rightarrow \langle 0; 1 \rangle$  taką że jeżeli  $\varphi(x) = 0$  to nie odrzucamy  $H_0$ , jeżeli  $\varphi(x) = 1$  to odrzucamy  $H_0$ , a jeżeli  $\varphi(x) \in (0; 1)$ , to uruchamiamy losowanie niezależne od próby losowej  $X$ , w którym odrzucamy  $H_0$  z prawdopodobieństwem  $\varphi(x)$ .

Def. 45 (Test niezrandomizowany).

$$\varphi: \mathfrak{X} \rightarrow \{0; 1\}$$

Def. 46 (Obszar krytyczny testu).

$$W = \{x \in \mathfrak{X}: \varphi(x) = 1\}$$

Wtedy  $\varphi(x) = \chi_W(x)$ Def. 47. Test hipotezy  $H_0$  na poziomie istotności  $\alpha$  jest to każdy test  $\varphi$  taki, że

$$\forall \theta \in \Theta_0 E_\theta \varphi(X) \leq \alpha$$

Dla testu niezrandomizowanego

$$E_\theta \varphi(X) = P_\theta(X \in W)$$

Def. 48 (Bł d I rodzaju). Odrzucenie prawdziwego  $H_0$ Def. 49 (Bł d II rodzaju). Przyjęcie fałszywego  $H_0$ Def. 50 (Poziom istotno ci; rozmiar testu).  $\alpha = P\{X_n \in W | H_0\} = P(I \text{ rodz.})$ Def. 51.  $\beta = P\{X_n \in (X \setminus W | H_1\} = P(II \text{ rodz.})$ Def. 52 (Moc testu).  $P\{X_n \in W | H_1\} = M(W) = 1 - \beta$ Def. 53. Funkcja mocy testu jest to funkcja  $\pi: \Theta \rightarrow \langle 0; 1 \rangle$ ,

$$\pi(\theta) = E_\theta \varphi(X), \theta \in \Theta$$

Def. 54 (Test nieobci ony). Dla  $\alpha \in (0, 1)$   $P\{X_n \in W | H_0\} = \alpha \wedge P\{X_n \in W | H_1\} > \alpha$ Def. 55 (Test zgodny).  $\lim_{n \rightarrow \infty} P\{X_n \in W | H_1\} = 1$ Tw. 29 (Porównanie mocy testów). Założenia:  $W, W^* \in \mathfrak{X} \wedge P\{X_n \in W^* | H_0\} \leq P\{X_n \in W | H_0\}$ Jeżeli  $M(W^*) = P\{X_n \in W^* | H_1\} \geq P\{X_n \in W | H_1\} = M(W)$  to test oparty na  $W^*$  jest jednostajnie mocniejszy od testu opartego na  $W$ 

## 3.1 Testy najmocniejsze

Def. 56 (Test najmocniejszy). Test, który minimalizuje  $\beta$  przy zadanym  $\alpha$ Lem. 30 (Neymana - Pearsona). Niech  $R$  będzie dowolnym zbiorem w  $\mathfrak{X}$  takim, że  $P_{\theta_0}(R) \leq \alpha$ . Przypuśćmy że istnieje zbiór  $R^* \subset \mathfrak{X}$ , gdzie  $R^* = \{x: \frac{p_1(x)}{p_0(x)} \geq K\}$ , dla którego  $P_{\theta_0}(R^*) = \alpha$ . Wtedy  $P_{\theta_1}(R^*) \geq P_{\theta_1}(R)$ .Lem. 31 (Wniosek z lematu Neymana-Pearsona). Jeśli  $\beta$  jest mocą testu najmocniejszego na poziomie  $\alpha \in (0; 1)$  dla  $H_0: P = P_0$  przeciw  $H_1: P = P_1$ , to  $\beta > \alpha$ , chyba że  $P_0 = P_1$ .Tw. 56 (O odwrotnym przekształceniu Fouriera). Rozkład prawdopodobieństwa  $\mu$ , który ma całkowalną funkcję charakterystyczną  $\varphi$ , ma także ograniczoną i ciągłą gęstość  $f$ , daną wzorem

$$f(x) = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-isx} \varphi(s) ds.$$

Tw. 57. Jeżeli funkcja charakterystyczna  $\varphi$  zmiennej losowej  $X$  jest okresowa o okresie  $2\pi$ , to  $X$  jest zmienną losową typu dyskretnego, przyjmującą tylko wartości całkowite

$$P(X = k) = \frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-itk} \varphi(t) dt.$$

## 5.3 Zbie no ci probabilistyczne

Def. 80. Ciąg zmiennych losowych  $(X_n)_{n=1}^{\infty}$  jest zbieżny do zmiennej losowej  $X$ :

a) prawie na pewno, jeżeli

$$P\{\omega: \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)\} = 1,$$

co oznaczamy  $X_n \xrightarrow{1} X$ ,b) według prawdopodobieństwa, jeżeli dla każdego  $\varepsilon > 0$ 

$$\lim_{n \rightarrow \infty} P(|X_n - X| > \varepsilon) = 0,$$

co oznaczamy  $X_n \xrightarrow{P} X$ ,b) według  $p$ -tego momentu (w  $L^p$ ),  $0 < p < \infty$ , jeżeli  $E|X|^p < \infty$ ,  $E|X_n|^p < \infty$  dla  $n = 1, 2, \dots$  oraz

$$\lim_{n \rightarrow \infty} E|X_n - X|^p = 0,$$

co oznaczamy  $X_n \xrightarrow{L^p} X$ .

Tw. 58 (Warunek równoważny zbie no ci prawie na pewno).

$$X_n \xrightarrow{1} X \Leftrightarrow \forall \varepsilon > 0: \lim_{N \rightarrow \infty} P \sup_{k \geq N} |X_k - X| \geq \varepsilon = 0$$

Tw. 59. Jeżeli dla każdego  $\varepsilon > 0$   $\sum_{n=1}^{\infty} P(|X_n - X| \geq \varepsilon) < \infty$ , to  $X_n \xrightarrow{1} X$ .Tw. 60. Jeżeli  $EX_n^2 < \infty$ ,  $EX^2 < \infty$  oraz  $\sum_{n=1}^{\infty} E(X_n - X)^2 < \infty$ , to  $X_n \xrightarrow{1} X$ .Tw. 61 (Twierdzenie o dwóch szeregach). Jeśli  $(X_n)$  - niezależne zmienne losowe oraz

$$EX_n < \infty \quad \forall n \quad \text{oraz} \quad \sum_{n=1}^{\infty} EX_n < \infty \Rightarrow \sum_{n=1}^{\infty} X_n \text{ zb. p.n.}$$

Tw. 62 (Warunki Cauchy'ego). Zachodzą następujące warunki Cauchy'ego:

a)

$$X_n \xrightarrow{1} X \Leftrightarrow \forall \varepsilon > 0: \lim_{N \rightarrow \infty} P \sup_{n, m \geq N} |X_n - X_m| < \varepsilon = 1,$$

b)

$$X_n \xrightarrow{P} X \Leftrightarrow \forall \varepsilon > 0: \lim_{n, m \rightarrow \infty} P(|X_n - X_m| > \varepsilon) = 0.$$

Tw. 63. Zachodzą następujące implikacje:

a) Jeżeli  $X_n \xrightarrow{1} X$ , to  $X_n \xrightarrow{P} X$ ,b) Jeżeli  $X_n \xrightarrow{L^p} X$ , to  $X_n \xrightarrow{P} X$ ,c) Jeżeli  $X_n \xrightarrow{L^p} X$ ,  $p \geq q$  to  $X_n \xrightarrow{L^q} X$ ,



## 5.1 Funkcje zmiennych losowych

Tw. 48. Jeżeli zmienna losowa  $X: \Omega \rightarrow (a, b)$ ,  $-\infty \leq a < b \leq \infty$  ma rozkład o gęstości  $f_X$  oraz  $\varphi: (a, b) \rightarrow \mathbb{R}$  jest klasy  $C^1$  oraz  $\varphi' \neq 0$ , to zmienna losowa  $Y = \varphi(X)$  ma rozkład o gęstości

$$f_Y(y) = f_X(h(y)) |h'(y)| I_{\varphi(a,b)}(y),$$

gdzie  $h = \varphi^{-1}$ .

Tw. 49. Załóżmy, że znamy gęstość  $f_{X,Y}$  wektora dwuwymiarowego  $(X, Y)$  oraz, że dany jest wektor  $(U, W) = (\varphi_1(X, Y), \varphi_2(X, Y))$ . Zatem mamy

$$\begin{aligned} u &= \varphi_1(x, y) & x &= \phi_1(u, w) \\ w &= \varphi_2(x, y) & y &= \phi_2(u, w) \end{aligned}$$

wtedy Jakobian  $J$  wyraża się wzorem

$$J = \begin{vmatrix} \frac{\partial \phi_1}{\partial u} & \frac{\partial \phi_1}{\partial w} \\ \frac{\partial \phi_2}{\partial u} & \frac{\partial \phi_2}{\partial w} \end{vmatrix}$$

natomiast funkcja gęstości wektora losowego  $(U, W)$  wygląda następująco

$$f_{U,W}(u, w) = |J| \cdot f_{X,Y}(\phi_1(u, w), \phi_2(u, w)).$$

Tw. 50 (Addytywność rozkładu Gamma). Jeżeli  $X_i \sim (\lambda, s_i) = \chi_{R+} \frac{\lambda^s}{\Gamma(s)} x^{s-1} e^{-\lambda x}$  to

$$\theta X_i \sim (\lambda, \theta s_i)$$

oraz dla sumy

$$\sum_i X_i \sim (\lambda, \sum_i s_i)$$

## 5.2 Funkcje charakterystyczne

Def. 78 (Funkcja charakterystyczna). Funkcją charakterystyczną zmiennej losowej  $X: \Omega \rightarrow \mathbb{R}$  nazywamy funkcję  $\varphi_X: \mathbb{R} \rightarrow \mathbb{C}$ , daną wzorem

$$\varphi_X(t) = E e^{itX} \quad t \in \mathbb{R}.$$

Tw. 51 (Własności funkcji charakterystycznych). Niech  $\varphi_X$  będzie funkcją charakterystyczną zmiennej losowej  $X$ . Wtedy

- $\varphi_X(0) = 1$
- $|\varphi_X(t)| \leq 1$
- $\varphi_X(t) = \overline{\varphi_X(-t)}$
- $\varphi_X(t)$  jest jednostajnie ciągła

Def. 79. Funkcję  $\varphi: \mathbb{R} \rightarrow \mathbb{C}$  nazywamy dodatnio określoną wtedy i tylko wtedy, gdy dla każdego naturalnego  $n$ , dla każdego ciągu  $t_1, \dots, t_n$  liczb rzeczywistych i zespolonych  $z_1, \dots, z_n$  mamy

$$\sum_{k,l \leq n} \varphi(t_k - t_l) z_k \bar{z}_l \geq 0.$$

Tw. 52 (Bochnera). Funkcja  $\varphi$  jest funkcją charakterystyczną pewnego rozkładu prawdopodobieństwa wtedy i tylko wtedy, gdy jest ciągła, dodatnio określona i  $\varphi(0) = 1$ .

Tw. 53. Jeśli  $E|X|^n < \infty$ ,  $n \in \mathbb{N}$ , to  $n$ -ta pochodna funkcji charakterystycznej  $\varphi_X^{(n)}$  istnieje i jest jednostajnie ciągła, a ponadto

$$\varphi_X^{(n)}(0) = i^n E X^n.$$

Tw. 54. Jeśli  $X, Y$  są niezależnymi zmiennymi losowymi, to

$$\varphi_{X+Y}(t) = \varphi_X(t) \varphi_Y(t).$$

Tw. 55. Jeśli rozkłady prawdopodobieństwa  $\mu$  i  $\nu$  na  $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$  mają równe funkcje charakterystyczne, czyli  $\varphi_\mu(t) = \varphi_\nu(t)$  dla wszystkich  $t \in \mathbb{R}$ , to  $\mu = \nu$ .

Def. 57 (Monotoniczny iloraz wiarygodności). Mówimy, że rodzina rozkładów  $\{P_\theta: \theta \in \Theta\}$  jest rodziną rozkładów z monotonicznym ilorazem wiarygodności, jeżeli istnieje taka funkcja  $T(x)$ , że dla  $\theta' > \theta$  iloraz

$$\frac{p_{\theta'}(x)}{p_\theta(x)}$$

jest niemalejącą funkcją argumentu  $T(x)$ .

Tw. 32. Rodzina rozkładów o funkcji prawdopodobieństwa  $p_\theta(x) = \binom{n}{x} \theta^x (1-\theta)^{n-x}$ ,  $\theta \in (0, 1)$  jest rodziną o monotonicznym ilorazie wiarygodności.

Tw. 33. Jednoparametrowa rodzina wykładnicza  $p_\theta(x) = e^{c(\theta)t(x)-b(\theta)} h(x)$  jest rodziną o monotonicznym ilorazie wiarygodności.

Tw. 34. Rodzina rozkładów jednostajnych  $U(0; \theta)$ ,  $\theta > 0$  jest rodziną o monotonicznym ilorazie wiarygodności.

Tw. 35 (Test JNM dla monotonicznego ilorazu wiarygodności). Niech  $H_0: \theta \leq \theta_0$ ,  $H_1: \theta > \theta_0$ , a  $\{p_\theta: \theta \in \Theta\}$  jest rodziną rozkładów z monotonicznym ilorazem wiarygodności. Wówczas:

a) Dla weryfikacji  $H_0$  przeciw  $H_1$  istnieje test jednostajnie najmocniejszy określony jako:

$$\varphi(x) = \begin{cases} 1 & \text{dla } T(x) > k \\ c & \text{dla } T(x) = k \\ 0 & \text{dla } T(x) < k \end{cases}$$

gdzie stałe  $c, k$  są wyznaczone z warunku  $E_{\theta_0} \varphi(X) = \alpha$ .

b) Funkcja  $\beta(\theta) = E_\theta \varphi(X) = P_\theta(T(x) > k)$  jest ściśle rosnąca w zbiorze w którym  $\beta(\theta) < 1$ .

c) Dla każdego  $\theta'$  test zdefiniowany w a) jest jednostajnie najmocniejszy dla  $H'_0: \theta \leq \theta'$  przeciw  $H'_1: \theta > \theta'$  na poziomie istotności  $\alpha' = \beta(\theta)$ .

d) Dla dowolnego  $\theta < \theta_0$  test z a) minimalizuje prawdopodobieństwo błędu I rodzaju  $\beta(\theta)$  wśród wszystkich testów spełniających  $E_{\theta_0} \varphi(X) = \alpha$ .

Lem. 36 (Wniosek). Jeżeli  $\{P_\theta: \theta \in \Theta\}$  jest rodziną wykładniczą o gęstościach

$$p_\theta(x) = e^{c(\theta)T(x)-b(\theta)} h(x)$$

i jeżeli  $c(\theta)$  jest funkcją ściśle rosnącą, to test JNM  $\varphi(x)$  ma postać jak w punkcie a powyższego twierdzenia. Jeśli  $c(\theta)$  jest funkcją ściśle malejącą to w definicji testu  $\varphi$  znaki nierówności zmieniają się na przeciwnie.

## 3.2 Testy ilorazowe

Def. 58. Wiarygodnością hipotezy  $H_i$  ( $i = 0, 1$ ) gdy zaobserwowano  $x$  nazywamy liczbę

$$L_{H_i}(x) = \sup_{\theta \in \Theta_i} L(x; \theta)$$

Def. 59 (Iloraz wiarygodności).  $\lambda(x) = \frac{L_{H_1}(x)}{L_{H_0}(x)}$

Def. 60 (Obszar krytyczny).  $W = \{x: \lambda(x) > k\}$  gdzie  $k$  jest takie, aby  $\sup_{\theta \in \Theta_0} P_\theta(\lambda(x) > k) = \alpha$ . Jeśli z powodu dyskretności rozkładu nie zachodzi powyższa równość, wtedy ustala się  $k'$  tak, aby  $P_\theta(\lambda(x) > k') \leq \alpha < P_\theta(\lambda(x) > k' - 1)$

Tw. 37 (Rozkład ilorazu wiarygodności ci w du ych próbach). Przy następujących założeniach:

- $X = X_1, \dots, X_n$  - próba losowa
- $X_i \in \mathbb{R}^s$
- Hipoteza  $H_0$  oraz zbiór  $\Theta_0$  określone przez układ liniowo niezależnych warunków postaci  $h_j(\theta) = 0$ ,  $j = 1, \dots, r$
- $\theta' \neq \theta'' \Rightarrow P_{\theta'} \neq P_{\theta''}$
- $L(X, \theta) = p_\theta(X)$  dwukrotnie różniczkowalna w sposób ciągły względem  $\theta$
- $\sup_{\theta \in \Theta_0} L(X, \theta) = L(X, \hat{\theta})$

oraz spełnionych warunkach regularności z nierówności Rao-Cramera, dla zmiennej losowej  $2 \ln \lambda(X)$  zachodzi:

$$2 \ln \lambda(X) \xrightarrow{d} \chi_r^2$$

gdzie  $\lambda(X) = \frac{L(X, \hat{\theta}_{N|W})}{L(X, \hat{\theta})}$ , a  $r$  jest liczbą równań określających hipotezę  $H_0$ .

Obszar krytyczny testu ma wówczas postać  $\{x: 2 \ln \lambda(X) > k\}$ , gdzie  $k$  jest kwantylem rzędu  $1 - \alpha$  rozkładu  $\chi_r^2$ .

## 4 Statystyka bayesowska

Ozn. 61 (Rozkład a priori). ( )

Ozn. 62 (Rozkład a posteriori). ( jx)

Def. 63 (Schemat podstawowy statystyki bayesowskiej)

$$P(\text{hipoteza } j \text{ dane}) = \frac{P(\text{dane} | \text{hipoteza } j) P(\text{hipoteza } j)}{P(\text{dane})}$$

Tw. 38 (Rozkład a posteriori).

$$p(x) = \frac{p(x; \theta)}{p(x)} = \frac{R(p(x; \theta))}{p(x; \theta)}$$

$p(x; \theta)$  - gęstość prawdopodobieństwa rozkładu a priori

### 4.1 Bayesowskie przedziały ufności

Def. 64 (Bayesowski przedział ufności) Bayesowskim przedziałem ufności na poziomie  $\alpha$  nazywamy przedział  $[\hat{\theta}_1; \hat{\theta}_2]$  taki, że

$$P(\hat{\theta}_1 < \theta < \hat{\theta}_2 | jx) = 1 - \alpha$$

Def. 65 (Bayesowski przedział ufności) Najmniejszy zbiór

$$I : P(\theta \in I | jx) > 1 - \alpha$$

Lem. 39. Dla bayesowskiego przedziału ufności zachodzi

$$\int_I p(\theta) d\theta = 1 - \alpha$$

Def. 66 (Niewaściwy rozkład a priori). Jeżeli  $\theta$  jest zbiorem nieograniczony,  $\theta \in R$  jest nieskończona to wówczas  $\theta$  jest niewaściwym rozkładem a priori.

### 4.2 Rodziny sprężone

Def. 67 (Sprężona rodzina rozkładów) Rodzinę S rozkładów a priori parametru  $\theta$  nazywamy sprężoną do rodziny P =  $f(\theta; x)$  jeżeli

$$f(\theta; x) = \int_{\theta \in S} p(\theta; x) d\theta$$

Lem. 40 (Przykłady rodzin sprężonych).

$\theta$  próba:  $X \sim \text{Bin}(n; \theta)$   
 a priori:  $\text{Beta}(\alpha; \beta)$   
 a posteriori:  $f(\theta; x) \sim \text{Beta}(\alpha + x; \beta + n - x)$

$\theta$  próba:  $X \sim \text{Poiss}(\theta)$   
 a priori:  $\text{Gamma}(\alpha; \lambda)$   
 a posteriori:  $f(\theta; x) \sim \text{Gamma}(\alpha + x; \lambda + \frac{1}{x})$   
 $E(\theta; x) = \frac{\alpha}{\lambda + \frac{1}{x}}$

$\theta$  próba:  $X \sim N(\theta; \sigma^2)$   
 a priori:  $N(\mu; \tau^2)$   
 a posteriori:  $f(\theta; x) \sim N(\frac{\tau^2 \mu + \frac{\sigma^2}{n} \bar{x}}{\tau^2 + \frac{\sigma^2}{n}}; \frac{1}{\tau^2 + \frac{\sigma^2}{n}})$

$\theta$  próba:  $X \sim N(\theta; \frac{1}{\theta})$   
 a priori:  $\text{Gamma}(\alpha; \lambda)$   
 a posteriori:  $f(\theta; x) \sim \text{Gamma}(\alpha + \sum_{i=1}^n x_i; \lambda + \frac{n}{2})$

Def. 68 (Naturalna rodzina wykładnicza). Naturalną rodziną wykładniczą nazywamy rodzinę

$$f(x; \theta) = K(\theta) e^{-\theta T(x)}$$

gdzie  $K(\theta)$  jest stałą normującą.

Tw. 41. Rozkład a posteriori dla naturalnej rodziny wykładniczej ma postać

$$f(\theta; x) = \frac{e^{-\theta T(x)}}{\int e^{-\theta T(x)} d\theta}$$

## 4.3 Decyzje statystyczne

Ozn. 69. A - zbiór decyzji (akcji)

Ozn. 70 (Strata).  $L: A \rightarrow R$

$L(a; \theta)$  - strata gdy obserwacja pochodzi z  $\theta$  i zostaje podjęta decyzja a

Ozn. 71 (Reguła decyzyjna).  $\delta: X \rightarrow A$  - reguła decyzyjna =  $\delta(x)$  dla pewnego x

Def. 72 (Funkcja ryzyka reguły decyzyjnej).

$$R(\delta; \theta) = E L(\delta; \theta)$$

Def. 73 (Reguły optymalne). Mówimy, że reguła  $\delta_1$  jest nie gorsza niż  $\delta_2$  jeżeli

$$R(\delta_1; \theta) \leq R(\delta_2; \theta)$$

Jeżeli dodatkowo  $R(\delta_1; \theta) < R(\delta_2; \theta)$  to  $\delta_1$  jest lepsza od  $\delta_2$ .

Def. 74 (Reguła dopuszczalna) Reguła  $\delta \in D$  jest dopuszczalna, jeżeli  $\delta$  nie ma reguły lepszych od.

Tw. 42 (O redukcji przez dostateczność) Niech  $A \in R^k$  - zbiór wypukły, a  $L(\theta; \delta)$  - wypukła funkcja decyzji. Jeżeli  $\delta$  jest regułą decyzyjną i T jest statystyką dostateczną dla  $\theta$ , to reguła decyzyjna

$$\tilde{\delta} = E(\delta | T) = t$$

jest nie gorsza od  $\delta$ .

### 4.4 Reguły bayesowskie

Def. 75 (Ryzyko bayesowskie)

$$r(\delta; \theta) = E R(\delta; \theta) = \int R(\delta; \theta) p(\theta) d\theta = E E L(\delta; \theta)$$

Def. 76 (Reguła bayesowska) Jeżeli dla ustalonego rozkładu a priori istnieje reguła decyzyjna taka, że  $\delta \in D$   $r(\delta; \theta) \leq r(\delta'; \theta)$ , to nazywamy regułą bayesowską przy rozkładzie a priori.

Def. 77 (Ryzyko a posteriori).

$$R_x(\delta; \theta) = \int L(\delta; \theta) p(\theta | jx) d\theta = E L(\delta; \theta) | jx$$

Tw. 43. Wystarczy minimalizować  $R_x(\delta; \theta)$  aby znaleźć regułę bayesowską.

Lem. 44. Jeżeli  $L(\theta; a) = (a - \theta)^2$ , to reguła bayesowską (estymatorem bayesowskim) jest wartość oczekiwana rozkładu a posteriori.

Lem. 45. Jeżeli  $L(\theta; a) = |a - \theta|$ , to reguła bayesowską jest mediana rozkładu a posteriori.

## 5 Rachunek prawdopodobieństwa

Tw. 46. Wartości wariancji:

$$1. \text{Var}(X + c) = \text{Var}(X)$$

$$2. \text{Var}(aX) = a^2 \text{Var}(X)$$

Ponadto, jeżeli  $X, Y$  są niezależnymi zmiennymi losowymi to zachodzi

$$1. \text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y)$$

$$2. \text{Var}(X - Y) = \text{Var}(X) + \text{Var}(Y)$$

Tw. 47.

$$\text{Var}(X) = E(X^2) - (E(X))^2$$