

# STATYSTYKA MATEMATYCZNA

Stanisław Jaworski

SGGW, KEiS

*Ostatnia modyfikacja: 17 stycznia 2023, Warszawa*

TEMATYKA WYKŁADÓW

5.2	Porównanie z normą . . . . .	27
5.3	Porównanie dwóch populacji . . . . .	28
5.4	Określenia . . . . .	29

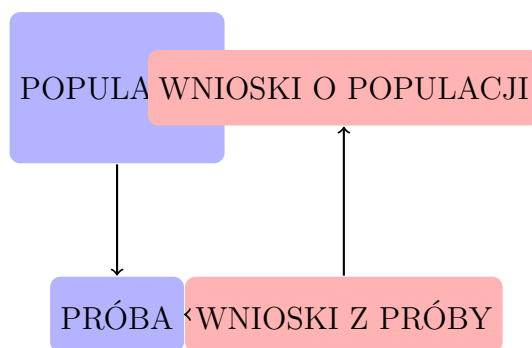
## Spis treści

<b>1</b>	<b>Podstawy</b>	<b>2</b>	<b>6</b>	<b>Hipotezy proste</b>	<b>31</b>
1.1	Główna idea . . . . .	2	6.1	Lemat Neymana–Pearsona . . . . .	31
<b>2</b>	<b>Model statystyczny</b>	<b>3</b>	6.2	Model dwupunktowy . . . . .	32
2.1	Model dwumianowy . . . . .	3	6.3	Jednostajny vs Beta . . . . .	34
2.2	Model gaussowski . . . . .	5	<b>7</b>	<b>Hipotezy złożone</b>	<b>35</b>
2.3	Model wykładniczy . . . . .	6	7.1	Iloraz wiarygodności . . . . .	35
<b>3</b>	<b>Estymatory punktowe</b>	<b>7</b>	7.2	Model dwupunktowy . . . . .	36
3.1	Estymatory Nieobciążone . . . . .	7	7.3	Model gaussowski . . . . .	37
3.2	Estymatory Największej Wiarygodności . . . . .	12	7.4	Moc testu . . . . .	40
3.2.1	Model Poissona . . . . .	16	7.5	Liczność próby . . . . .	41
3.2.2	Model gaussowski . . . . .	18	<b>8</b>	<b>Testy JNM w modelach z monotonicznym ilorazem wiarygodności</b>	<b>41</b>
<b>4</b>	<b>Estymacja przedziałowa</b>	<b>20</b>	<b>9</b>	<b>Elementy teorii podejmowania decyzji</b>	<b>44</b>
<b>5</b>	<b>Weryfikacja hipotez</b>	<b>26</b>	<b>10</b>	<b>Statystyka bayesowska</b>	<b>48</b>
5.1	Rodzaje błędów . . . . .	26			

# 1 Podstawy

## 1.1 Główna idea

Wnioskowanie statystyczne polega na wnioskowaniu o populacji na podstawie próby



### **Populacja**

Zbiór obiektów z wyróżnioną cechą (cechami). *Obiektami mogą być przedmioty lub wartości cechy*

### **Próba**

Wybrana część populacji podlegająca badaniu. *Próba powinna stanowić reprezentację populacji w tym sensie, że częstości występowania w próbie każdej z badanych cech nie powinny się znacznie różnić od częstości występowania tych cech w populacji.*

### **Cecha**

Wielkość losowa charakteryzująca obiekty danej populacji

## 2 Model statystyczny

### 2.1 Model dwumianowy

#### Doświadczenie Bernoulliego

#### Doświadczenie Bernoulliego

Wykonujemy dwuwynikowe doświadczenie. Wyniki nazywane są umownie *SUKCES* oraz *PORAŻKA*. Prawdopodobieństwo sukcesu wynosi  $\theta$  (porażki:  $1 - \theta$ )

#### Zmienna losowa

Zmienną losową  $X$  jest wynik doświadczenia, a dokładniej

$$X = \begin{cases} 1 & \text{gdy wynik jest SUKCESEM} \\ 0 & \text{gdy wynik jest PORAŻKĄ} \end{cases}$$

#### Schemat Bernoulliego

#### Schemat Bernoulliego

Doświadczenie Bernoulliego wykonujemy  $n$  krotnie w sposób niezależny. Zmienną losową  $X$  jest liczba sukcesów.

#### Rozkład dwumianowy

Zmienna losowa  $X$  ma rozkład  $B(n, \theta)$ :

$$P_{n,\theta}(X = k) = \binom{n}{k} \theta^k (1 - \theta)^{n-k}, \quad 0 < \theta < 1, \quad k = 0, 1, \dots, n.$$

#### *Przykład*

Wadliwość procesu produkcyjnego wynosi 10%. Obliczyć prawdopodobieństwo, że na dziesięć wylosowanych produktów będą co najwyżej dwa złe.

#### *Rozwiązanie*

Doświadczenie Bernoulliego: wylosowanie jednego produktu.

Sukces: produkt wadliwy

Porażka: produkt dobry

Prawdopodobieństwo sukcesu: 0.1  
Prawdopodobieństwo porażki: 0.9

*Rozwiązanie*

Schemat Bernoulliego: wylosowanie dziesięciu produktów

$X$  – liczba wadliwych produktów wśród dziesięciu wylosowanych produktów.

Prawdopodobieństwo wylosowania co najwyżej dwóch złych:

$$P_{10,0.1}(X \leq 2) = P_{10,0.1}(X = 0) + P_{10,0.1}(X = 1) + P_{10,0.1}(X = 2)$$

*Przykład*

Nie znamy wadliwości procesu produkcyjnego. Losujemy dziesięć produktów i zliczamy liczbę złych produktów.

*Model statystyczny*

$X$  – liczba wadliwych produktów wśród dziesięciu produktów wylosowanych.

$\mathcal{X} = \{0, 1, \dots, 10\}$  - wszystkie możliwe realizacje zmiennej losowej  $X$

$\Theta = (0, 1)$  - wszystkie możliwe wartości parametru  $\theta$  (prawdopodobieństwa sukcesu)

**Model statystyczny**  $(\mathcal{X}, \{P_{10,\theta} : \theta \in \Theta\})$

- $\mathcal{X}$  – przestrzeń próby
- $\Theta$  – przestrzeń parametrów
- $\{P_{10,\theta} : \theta \in \Theta\}$  – rodzina rozkładów (w tym przypadku jest to rodzina rozkładów dwumianowych)

*Przykład*

Wiemy, że wadliwość procesu produkcyjnego może wynosić albo 0.1 albo 0.2. Losujemy dziesięć produktów i zliczamy liczbę złych produktów.

*Model statystyczny*

$X$  – liczba wadliwych produktów wśród dziesięciu produktów wylosowanych.

$\mathcal{X} = \{0, 1, \dots, 10\}$  - wszystkie możliwe realizacje zmiennej losowej  $X$

$\Theta = \{0.1, 0.2\}$  - wszystkie możliwe wartości parametru  $\theta$  (prawdopodobieństwa sukcesu)

### Model statystyczny

$$(\mathcal{X}, \{P_{10,\theta} : \theta \in \Theta\})$$

## 2.2 Model gaussowski


### Rozkład normalny

#### Zmienna losowa o rozkładzie normalnym

Zmienna losowa  $X$  ma rozkład normalny  $N(\mu, \sigma^2)$ :

$$f_{\mu,\sigma^2}(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2} \cdot \frac{(x - \mu)^2}{\sigma^2}\right\}, \quad -\infty < x < \infty$$

$$E_{\mu,\sigma^2}X = \mu, \quad D_{\mu,\sigma^2}^2X = \sigma^2$$




### Prawo trzech sigm

$$P\{|X - \mu| < \sigma\} = 0.68268 \approx 0.68 \quad (1)$$

$$P\{|X - \mu| < 2\sigma\} = 0.95550 \approx 0.96 \quad (2)$$

$$P\{|X - \mu| < 3\sigma\} = 0.99730 \approx 0.997 \quad (3)$$

*Przykład*



Założmy, że waga (w kilogramach) wylosowanego noworodka jest zmienną losową o rozkładzie normalnym. Jak określić model statystyczny dla doświadczenia polegającego na wylosowaniu i zważeniu noworodka?

*Rozwiązanie*

- $X$  – waga wylosowanego noworodka
- Założenie:  $X \sim N(\mu, \sigma^2)$
- $\mathcal{X} = (-\infty, \infty)$
- $\theta = (\mu, \sigma^2)$  – parametr dwuwymiarowy
- $\Theta = \mathbb{R} \times \mathbb{R}^+$  – przestrzeń parametrów

**Model statystyczny**

$$(\mathcal{X}, \{f_{\mu, \sigma^2} : (\mu, \sigma^2) \in \Theta\})$$

Zwróćmy uwagę na to, że model jest „za szeroki”. Chcielibyśmy, aby:  $\mathcal{X} = (0, \infty)$  oraz  $\Theta = \mathbb{R}^+ \times \mathbb{R}^+$ ?

## 2.3 Model wykładniczy

**Rozkład wykładniczy**

**Zmienna losowa o rozkładzie wykładniczym**

Zmienna losowa  $X$  ma rozkład wykładniczy  $E(\lambda)$ :

$$f_\lambda(x) = \frac{1}{\lambda} \exp\left\{-\frac{x}{\lambda}\right\} \mathbf{1}_{(0,\infty)}(x), \quad x \in \mathbb{R}$$

*Przykład*

Założmy, że czas losowej rozmowy telefonicznej jest zmienną losową o rozkładzie wykładniczym. Jak określić model statystyczny dla doświadczenia polegającego na wylosowaniu rozmowy i określeniu czasu jej trwania?

*Rozwiązanie*

- $X$  – czas trwania wylosowanej rozmowy
- Założenie:  $X \sim E(\lambda)$
- $\mathcal{X} = (0, \infty)$

**Model statystyczny**

$$(\mathcal{X}, \{f_\lambda : \lambda \in \mathbb{R}^+\})$$

## 3 Estymatory punktowe

### 3.1 Estymatory Nieobciążone

Model statystyczny  $(\mathcal{X}, \{P_\theta : \theta \in \Theta\})$

Niech  $g : \Theta \rightarrow \mathbb{R}$

**Zadanie:** oszacować nieznaną wartość  $g(\theta)$

**Estymator wielkości  $g(\theta)$**

Wybrać takie  $\delta(X_1, \dots, X_n)$ , aby dla każdego  $\theta \in \Theta$

$$E_\theta \delta(X_1, \dots, X_n) = \theta$$

$$E_\theta (\delta(X_1, \dots, X_n) - g(\theta))^2 = \min!$$

**Model dwupunktowy: estymacja parametru  $\theta$**

Model statystyczny dla próby  $X_1, X_2, \dots, X_n$  z rozkładu dwupunktowego  $D(\theta)$ :

$$(\{0, 1\}^n, \{P_\theta : \theta \in \langle 0, 1 \rangle\}),$$

gdzie  $P_\theta(x_1, x_2, \dots, x_n) = \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i}$ , dla  $\theta \in (0, 1)$ .

Zmienna losowa  $X_i$  przyjmuje wartość 1, gdy wynik  $i$ -tego doświadczenia Bernoulliego kończy się SUKCESEM oraz wartość 0 w przeciwnym przypadku. Stąd rozkład prawdopodobieństwa zmiennej losowej  $X_i$  ma postać

$$P_\theta(x_i) = \begin{cases} \theta & \text{dla } x_i = 1 \\ 1 - \theta & \text{dla } x_i = 0 \end{cases} = \theta^{x_i} (1 - \theta)^{1 - x_i}.$$

Z niezależności zmiennych losowych wynika, że rozkład prawdopodobieństwa wektora  $(X_1, X_2, \dots, X_n)$  ma postać:

$$P_\theta(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P_\theta(x_i) = \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i}$$

### Model dwumianowy: estymacja parametru $\theta$

Niech  $X_1, X_2, \dots, X_n$  będzie próbą z rozkładu dwupunktowego  $D(\theta)$ . Model statystyczny dla  $T = \sum_{i=1}^n X_i$  ma postać:

$$(\{0, 1, \dots, n\}, \{P_\theta : \theta \in \langle 0, 1 \rangle\}),$$

gdzie  $P_\theta(t) = \binom{n}{t} \theta^t (1 - \theta)^{n-t}$ , dla  $t \in \{0, 1, \dots, n\}$  oraz  $\theta \in (0, 1)$ .

- $E_\theta T = n\theta$ , dla każdego  $\theta \in \langle 0, 1 \rangle$
- $D^2 T = n\theta(1 - \theta)$ , dla każdego  $\theta \in \langle 0, 1 \rangle$

Wniosek: Zmienna losowa  $T/n = \frac{1}{n} \sum_{i=1}^n X_i$  jest estymatorem nieobciążonym parametru  $\theta$ . Wariancja tego estymatora wynosi  $\frac{\theta(1-\theta)}{n}$ .

### Model dwumianowy: estymacja parametru $g(\theta) = \theta(1 - \theta)$

Niech  $X_1, X_2, \dots, X_n$  będzie próbą z rozkładu dwupunktowego  $D(\theta)$ . Niech

$$T = \frac{1}{n} \sum_{i=1}^n X_i.$$



Estymatorem nieobciążonym parametru  $g(\theta)$  jest

$$\hat{g}(T) = \frac{T(n-T)}{n(n-1)}.$$

Szukamy takiej funkcji  $\hat{g} : \{0, 1, \dots, n\} \rightarrow \langle 0, 0.25 \rangle$ , dla której zachodzi:

$$E_\theta \hat{g}(T) = \theta(1-\theta), \text{ dla każdego } \theta \in \langle 0, 1 \rangle.$$

$$\begin{aligned} E_\theta \hat{g}(T) &= \sum_{t=0}^n \hat{g}(t) \binom{n}{t} \theta^t (1-\theta)^{n-t} = \theta(1-\theta) \\ (1-\theta)^n \sum_{t=0}^n \hat{g}(t) \binom{n}{t} \left(\frac{\theta}{1-\theta}\right)^t &= \theta(1-\theta) \\ \sum_{t=0}^n \hat{g}(t) \binom{n}{t} \left(\frac{\theta}{1-\theta}\right)^t &= \left(\frac{\theta}{1-\theta}\right) \left(1 + \left(\frac{\theta}{1-\theta}\right)\right)^{n-2} \end{aligned}$$

Podstawienie:  $v = \theta/(1-\theta)$

$$\begin{aligned} \sum_{t=0}^n \hat{g}(t) \binom{n}{t} v^t &= v(1+v)^{n-2} \\ \sum_{t=0}^n \hat{g}(t) \binom{n}{t} v^t &= \sum_{t=0}^{n-2} \binom{n-2}{t} v^{t+1} \end{aligned}$$

Postać funkcji  $\hat{g}$  wynika z warunków:

$$\hat{g}(0) \binom{n}{0} = 0 = g(n) \binom{n}{n} \text{ oraz } \hat{g}(t) \binom{n}{t} = \binom{n-2}{t-1}, \quad t = 1, 2, \dots, n-1$$

**Model Poissona: Estymacja**  $P_\theta(X=0) = e^{-\theta}$

Niech  $X_1, X_2, \dots, X_n$  będzie próbą z rozkładu Poissona z parametrem  $\theta$ .

Oznaczmy

$$\bullet Y_j = \begin{cases} 1, & \text{jeżeli } X_j = 0, \\ 0, & \text{jeżeli } X_j > 0. \end{cases}, \text{ dla } j = 1, 2, \dots, n$$

- $T = \sum_{j=1}^n Y_j$

Estymatorami nieobciążonymi parametru  $g(\theta) = e^{-\theta}$  są:

- $Y_1$ ,
- $T/n$ ,
- $(1 - \frac{1}{n})^T$ .

$$E_\theta(Y_1) = 1 \cdot P_\theta(Y_1 = 1) + 0 \cdot P_\theta(Y_1 = 0) = P_\theta(X_1 = 0) = e^{-\theta}$$

Analogicznie  $E_\theta(Y_j) = e^{-\theta}$  dla  $j = 2, \dots, n$

$$\text{Zatem } E_\theta(T/n) = \frac{1}{n} E_\theta(T) = \frac{1}{n} \sum_{i=1}^n E_\theta(Y_j) = \frac{1}{n} \sum_{i=1}^n e^{-\theta} = e^{-\theta}$$

Ze wzoru na prawdopodobieństwo całkowite:

$$E_\theta(E_\theta(Y_1|T)) = E_\theta(Y_1) = e^{-\theta}$$

Zatem  $E_\theta(Y_1|T)$  jest estymatorem nieobciążonym parametru  $e^{-\theta}$ . Można pokazać, że  $E_\theta(Y_1|T) = (1 - \frac{1}{n})^T$ .

$$\begin{aligned} E_\theta(Y_1|T=t) &= P_\theta\{X_1=0|T=t\} = \frac{P_\theta\{X_1=0, T=t\}}{P_\theta(T=t)} \\ &= \frac{\sum_{x_2+\dots+x_n=t} P_\theta\{X_1=0, X_2=x_2, \dots, X_n=x_n\}}{P_\theta(T=t)} \\ &= \frac{\sum_{x_2+\dots+x_n=t} P_\theta\{X_1=0\} P_\theta\{X_2=x_2\} \dots P_\theta\{X_n=x_n\}}{P_\theta(T=t)} \\ &= \frac{\sum_{x_2+\dots+x_n=t} e^{-\theta} \cdot \frac{\theta^{x_2}}{x_2!} e^{-\theta} \cdot \dots \cdot \frac{\theta^{x_n}}{x_n!} e^{-\theta}}{P_\theta(T=t)} \\ &= \frac{\sum_{x_2+\dots+x_n=t} e^{-\theta n} \cdot \frac{\theta^t}{x_2! \dots x_n!}}{P_\theta(T=t)} = \frac{e^{-\theta n} \cdot \theta^t \cdot \sum_{x_2+\dots+x_n=t} \frac{1}{x_2! \dots x_n!}}{P_\theta(T=t)} \\ &= \frac{\frac{e^{-\theta n} \cdot \theta^t}{t!} \cdot (n-1)^t}{P_\theta(T=t)} \end{aligned}$$

Skorzystałem ze wzoru  $\sum_{k_1+\dots+k_m=t} \frac{t!}{k_1! \dots k_m!} a_1^{k_1} \dots a_m^{k_m} = (a_1 + \dots + a_m)^t$  Wystarczy teraz zauważyć, że  $T = \sum_{i=1}^n X_i$  ma rozkład Poissona z parametrem  $n\theta$ . Zatem podstawiamy

$$P_\theta(T = t) = \frac{(n\theta)^t}{t!} e^{-n\theta}$$

i po uproszczeniach algebraicznych otrzymujemy

$$E_\theta(Y_1|T = t) = \left(1 - \frac{1}{n}\right)^t.$$

### Podsumowanie

Model	Parametr	ENMW(Parametr)
Dwumianowy	$\theta$	$T/n$
	$\theta(1 - \theta)$	$\frac{T(n-T)}{n(n-1)}$
Poisona	$e^{-\theta}$	$\left(1 - \frac{1}{n}\right)^T$

Uwaga:  $T = \sum_i X_i$

### Estymatory nieobciążone o minimalnej wariancji - przykład

#### Model gaussowski: estymacja parametrów

Niech

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

$$S^2 = \begin{cases} \sum_{i=1}^n (X_i - \mu)^2, & \mu \text{ jest znane,} \\ \sum_{i=1}^n (X_i - \bar{X})^2, & \mu \text{ nie jest znane.} \end{cases}$$

### Estymatory nieobciążone o minimalnej wariancji - przykład

#### Model gaussowski: estymacja parametrów

Zmienna losowa  $\bar{X}$  ma rozkład  $N\left(\mu, \frac{\sigma^2}{n}\right)$

Zmienna losowa  $S^2/\sigma^2$  ma rozkład chi-kwadrat z  $\nu$  stopniami swobody:

$$\nu = \begin{cases} n, & \mu \text{ jest znane,} \\ n - 1, & \mu \text{ nie jest znane.} \end{cases}$$

**Estymatory nieobciążone o minimalnej wariancji - przykład**

**Model gaussowski: estymacja parametrów**

$$E_{\mu,\sigma} S^\alpha = \begin{cases} \frac{\sigma^\alpha}{K_{\nu,\alpha}}, & \nu + \alpha > 0, \\ \infty, & \nu + \alpha \leq 0, \end{cases}$$

gdzie  $K_{\nu,\alpha} = \Gamma\left(\frac{\nu}{2}\right) / \left(2^{\frac{\alpha}{2}} \Gamma\left(\frac{\nu+\alpha}{2}\right)\right)$

**Estymatory nieobciążone o minimalnej wariancji - przykład**

**Model gaussowski: estymacja parametrów**

Jeżeli  $\mu$  oraz  $\sigma$  nie są znane, to

- $ENMW[\mu] = \bar{X}$
- $ENMW[\sigma^2] = \frac{1}{n-1} S^2$
- $ENMW[\sigma] = \frac{\Gamma\left(\frac{n-1}{2}\right)}{\sqrt{2}\Gamma\left(\frac{n}{2}\right)} S$
- $ENMW\left[\frac{\mu}{\sigma}\right] = \frac{\sqrt{2}\Gamma\left(\frac{n-1}{2}\right)}{\Gamma\left(\frac{n}{2}-1\right)} \frac{\bar{X}}{S}$

### 3.2 Estymatory Największej Wiarogodności

**ENW: przykład wstępny**

Wykonano 50 rzutów nieznaną monetą i otrzymano 32 orły.

Jakie jest prawdopodobieństwo wyrzucenia orła w pojedynczym rzucie?

**ENW: przykład wstępny**

Model statystyczny rzutów monetą


$$(\{0, 1, \dots, 50\}, \{Bin(50, \theta), \theta \in [0, 1]\})$$

Prawdopodobieństwo uzyskania 32 orłów w 50 rzutach

$$p_{\theta}(32) = \binom{50}{32} \theta^{32} (1 - \theta)^{50-32}$$

Dla jakiego  $\theta$  uzyskanie 32 orłów jest najbardziej prawdopodobne?

**ENW: przykład wstępny**



**ENW: przykład wstępny**

**Zasada wiarygodności**

Wybrać tę wartość parametru  $\theta$ , dla której uzyskanie 32 orłów w 50 rzutach jest najbardziej prawdopodobne

tzn. wartość  $\theta$  maksymalizującą  $p_{\theta}(32)$

## Estymatory największej wiarygodności

### Wiarygodność

Model statystyczny  $(\mathcal{X}, \mathcal{B}, \{P_\theta, \theta \in \Theta\})$

Dla ustalonego  $x \in \mathcal{X}$  wielkość

$$L(\theta; x) = p_\theta(x)$$

nazywamy wiarygodnością parametru  $\theta$ .

## Estymatory największej wiarygodności

### Estymator Największej Wiarygodności

Jeżeli przy każdym ustalonym  $x \in \mathcal{X}$  istnieje  $\hat{\theta} = \hat{\theta}(x) \in \Theta$  takie, że

$$L(\hat{\theta}; x) \geq L(\theta; x) \quad (\forall \theta \in \Theta),$$

to odwzorowanie  $\hat{\theta} : \mathcal{X} \rightarrow \Theta$  nazywamy estymatorem największej wiarygodności.

## Estymatory największej wiarygodności

### Twierdzenie

Jeżeli  $h : \Theta \rightarrow \Theta$  jest funkcją różnowartościową oraz  $\hat{\theta}$  jest  $ENW[\theta]$ , to  $h(\hat{\theta})$  jest  $ENW[h(\theta)]$ .

### ENW funkcji parametrycznej

Jeżeli  $h : \Theta \rightarrow \Theta$ , to  $ENW[h(\theta)]$  określamy jako  $h(\hat{\theta})$ , gdzie  $\hat{\theta}$  jest  $ENW[\theta]$ .

## Estymator Największej Wiarygodności - przykład

**Model dwupunktowy:**  $ENW[\theta]$

Zaobserwowano  $X_1 = x_1, \dots, X_n = x_n$ .

Wiarygodność parametru  $\theta$ :

$$L(\theta; x_1, \dots, x_n) = \theta^t (1 - \theta)^{n-t}, \quad \text{gdzie } t = \sum_{i=1}^n x_i$$

Znaleźć  $\hat{\theta}$  maksymalizujące wiarygodność ( $t$  jest ustalone)

### Estymator Największej Wiarygodności - przykład

Model dwupunktowy:  $ENW[\theta]$

$\hat{\theta}$  jest rozwiązaniem równania

$$\frac{dL(\theta; x_1, \dots, x_n)}{d\theta} = 0$$

### Estymator Największej Wiarygodności - przykład

Model dwupunktowy:  $ENW[\theta]$

Zamiast  $L(\theta; x_1, \dots, x_n) = \theta^t(1 - \theta)^{n-t}$  łatwiej

$$\begin{aligned}\mathcal{L}(\theta; x_1, \dots, x_n) &= \log L(\theta; x_1, \dots, x_n) \\ &= t \log \theta + (n - t) \log(1 - \theta)\end{aligned}$$

### Estymator Największej Wiarygodności - przykład

Model dwupunktowy:  $ENW[\theta]$

Mamy

$$\begin{aligned}\frac{d\mathcal{L}}{d\theta} &= \frac{t}{\theta} - \frac{n-t}{1-\theta} = 0 \\ ENW[\theta] &= \frac{T}{n}\end{aligned}$$

### Estymator Największej Wiarygodności - przykład

Model dwupunktowy:  $ENW[\theta(1 - \theta)]$

$$ENW[\theta(1 - \theta)] = \hat{\theta}(1 - \hat{\theta})$$

gdzie

$$\hat{\theta} = ENW[\theta]$$

### 3.2.1 Model Poissona

#### Estymator Największej Wiarygodności - przykład

**Model Poissona:**  $ENW[\theta]$

Zaobserwowano  $X_1 = x_1, \dots, X_n = x_n$ .

Wiarygodność parametru  $\theta$ :

$$L(\theta; x_1, \dots, x_n) = \frac{(n\theta)^t}{x_1! \cdots x_n!} e^{-(n\theta)}, \quad \text{gdzie } t = \sum_{i=1}^n x_i$$

Znaleźć  $\hat{\theta}$  maksymalizującą wiarygodność ( $t$  jest ustalone)

#### Estymator Największej Wiarygodności - przykład

**Model Poissona:**  $ENW[\theta]$

$\hat{\theta}$  jest rozwiązaniem równania

$$\frac{dL(\theta; x_1, \dots, x_n)}{d\theta} = 0$$

#### Estymator Największej Wiarygodności - przykład

**Model Poissona:**  $ENW[\theta]$

Zamiast  $L(\theta; x_1, \dots, x_n) = \frac{(n\theta)^t}{x_1! \cdots x_n!} e^{-(n\theta)}$  łatwiej

$$\begin{aligned} \mathcal{L}(\theta; x_1, \dots, x_n) &= \log L(\theta; x_1, \dots, x_n) \\ &= t \log n + t \log \theta - \sum_{i=1}^n \log(x_i!) - n\theta \end{aligned}$$

#### Estymator Największej Wiarygodności - przykład

**Model Poissona:**  $ENW[\theta]$

Mamy

$$\begin{aligned} \frac{d\mathcal{L}}{d\theta} &= \frac{t}{\theta} - n = 0 \\ ENW[\theta] &= \frac{T}{n} \end{aligned}$$



### Estymator Największej Wiarygodności - przykład

Model Poissona:  $ENW[\lambda = e^{-\theta}]$

$$ENW[\lambda] = e^{-\tilde{\theta}} \left( \stackrel{\text{ozn}}{=} \tilde{\lambda} \right)$$

gdzie

$$\tilde{\theta} = ENW[\theta]$$

### Estymator Największej Wiarygodności - przykład

Model Poissona:  $ENW[\lambda]$  vs  $ENMW[\lambda]$

Ryzyko  $\tilde{\lambda} = ENW[\lambda]$

$$R_{\tilde{\lambda}}(\lambda) = E_{\theta}(\tilde{\lambda} - \lambda)^2 = E_{\theta}\tilde{\lambda}^2 - 2\lambda E_{\theta}\tilde{\lambda} + \lambda^2$$

Ryzyko  $\hat{\lambda} = ENMW[\lambda]$

$$R_{\hat{\lambda}}(\lambda) = E_{\theta}(\hat{\lambda} - \lambda)^2 = D_{\theta}^2\hat{\lambda}^2$$

### Estymator Największej Wiarygodności - przykład

Model Poissona:  $R_{\tilde{\lambda}}(\lambda)$

$$\begin{aligned} E_{\theta}\tilde{\lambda}^2 &= \sum_{t=0}^{\infty} \left( e^{-\frac{t}{n}} \right)^2 \frac{(n\theta)^t}{t!} e^{-n\theta} = e^{-n\theta} \sum_{t=0}^{\infty} \frac{(n\theta e^{-\frac{2}{n}})^t}{t!} \\ &= \exp \left\{ -n\theta \left( 1 - e^{-\frac{2}{n}} \right) \right\} = \lambda^{n(1-e^{-\frac{2}{n}})} \end{aligned}$$

$$\begin{aligned} E_{\theta}\tilde{\lambda} &= \sum_{t=0}^{\infty} e^{-\frac{t}{n}} \frac{(n\theta)^t}{t!} e^{-n\theta} = e^{-n\theta} \sum_{t=0}^{\infty} \frac{(n\theta e^{-\frac{1}{n}})^t}{t!} \\ &= \exp \left\{ -n\theta \left( 1 - e^{-\frac{1}{n}} \right) \right\} = \lambda^{n(1-e^{-\frac{1}{n}})} \end{aligned}$$

### Estymator Największej Wiarygodności - przykład

Model Poissona:  $R_{\tilde{\lambda}}(\lambda)$


$$R_{\tilde{\lambda}}(\lambda) = \lambda^{n(1-e^{-\frac{2}{n}})} - 2\lambda^{1+n(1-e^{-\frac{1}{n}})} + \lambda^2$$

Model Poissona:  $R_{\hat{\lambda}}(\lambda)$

$$R_{\hat{\lambda}}(\lambda) = D_{\lambda}^2\hat{\lambda} = \lambda^{(2-\frac{1}{n})} - \lambda^2$$

### Estymator Największej Wiarygodności - przykład

Model Poissona:  $R_{\hat{\lambda}}(\lambda)$  vs  $R_{\tilde{\lambda}}(\lambda)$



### 3.2.2 Model gaussowski

#### Estymator Największej Wiarygodności - przykład

Model gaussowski:  $ENW[\mu]$  i  $ENW[\sigma^2]$

Zaobserwowano  $X_1 = x_1, \dots, X_n = x_n$ .

Wiarygodność parametru  $(\mu, \sigma^2)$ :

$$L(\mu, \sigma^2; x_1, \dots, x_n) = \left( \frac{1}{\sigma\sqrt{2\pi}} \right)^n \exp \left\{ -\frac{1}{2} \sum_{i=1}^n \left( \frac{x_i - \mu}{\sigma} \right)^2 \right\}$$

Znaleźć  $\hat{\mu}$  i  $\hat{\sigma}^2$  maksymalizujące wiarygodność

#### Estymator Największej Wiarygodności - przykład

Model gaussowski:  $ENW[\mu]$  i  $ENW[\sigma^2]$

$(\hat{\mu}, \hat{\sigma}^2)$  jest rozwiązaniem równania

$$\begin{cases} \frac{\partial L(\mu, \sigma^2; x_1, \dots, x_n)}{\partial \mu} = 0 \\ \frac{\partial L(\mu, \sigma^2; x_1, \dots, x_n)}{\partial \sigma^2} = 0 \end{cases}$$

### Estymator Największej Wiarygodności - przykład

Model gaussowski:  $ENW[\mu]$  i  $ENW[\sigma^2]$

Zamiast  $L(\theta; x_1, \dots, x_n)$  łatwiej

$$\begin{aligned}\mathcal{L}(\mu, \sigma^2; x_1, \dots, x_n) &= \log L(\mu, \sigma^2; x_1, \dots, x_n) \\ &= -n \log \sqrt{2\pi} - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\end{aligned}$$

### Estymator Największej Wiarygodności - przykład

Model gaussowski:  $ENW[\mu]$  i  $ENW[\sigma^2]$

Mamy

$$\begin{cases} \frac{\partial \mathcal{L}}{\partial \mu} = -\frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0 \\ \frac{\partial \mathcal{L}}{\partial \sigma^2} = -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 = 0 \end{cases}$$

### Estymator Największej Wiarygodności - przykład

Model gaussowski:  $ENW[\mu]$  i  $ENW[\sigma^2]$

Otrzymujemy

$$\begin{aligned}ENW[\mu] &= \bar{X} \\ ENW[\sigma^2] &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2\end{aligned}$$

### Estymator Największej Wiarygodności - przykład

Model gaussowski: estymacja wariancji

Niech  $c > 0$  oraz

$$S^2(c) = c \sum_{i=1}^n (X_i - \bar{X})^2$$

Ryzyko estymatora  $S^2(c)$ :

$$R_{\mu, \sigma^2} \left( c \sum_{i=1}^n (X_i - \bar{X})^2 \right)$$

Dla jakiego  $c$  ryzyko jest jednostajnie najmniejsze?

## Estymator Największej Wiarygodności - przykład

Model gaussowski: estymacja wariancji

$$\begin{aligned} R_{\mu, \sigma^2} & \left( c \sum_{i=1}^n (X_i - \bar{X})^2 \right) \\ & = E_{\mu, \sigma^2} \left[ c \sum_{i=1}^n (X_i - \bar{X})^2 - \sigma^2 \right]^2 \\ & = \sigma^4 [c^2(n^2 - 1) - 2c(n - 1) + 1] \end{aligned}$$

## Estymator Największej Wiarygodności - przykład

Model gaussowski: estymacja wariancji

$$\begin{aligned} R_{\mu, \sigma^2}(ENMW[\sigma^2]) & = \frac{2}{n-1} \sigma^4 \\ R_{\mu, \sigma^2}(ENW[\sigma^2]) & = \frac{2n-1}{n^2} \sigma^4 \end{aligned}$$

Estymator o jednostajnie najmniejszym ryzyku

$$\frac{1}{n+1} \sum_{i=1}^n (X_i - \bar{X})^2$$

## 4 Estymacja przedziałowa

### Estymacja przedziałowa

**Przedział ufności (estymator przedziałowy)**


**Przedział ufności (estymator przedziałowy)** jest przedziałem o końcach zależnych od próby, który z pewnym z góry zadany prawdopodobieństwem  $1 - \alpha$  pokrywa nieznaną wartość parametru  $\theta$ :

$$P\{\theta \in (\underline{\theta}(X_1, \dots, X_n), \bar{\theta}(X_1, \dots, X_n))\} \geq 1 - \alpha \quad (\forall \theta).$$

**Poziom ufności** jest to ustalone prawdopodobieństwo  $1 - \alpha$ .

Ilustracja estymacji przedziałowej parametru  $\theta$  (oznaczonego pionową [niebieską](#) linią) na poziomie ufności  $1 - \alpha$

Populacja z wyróżnioną cechą  $X$



**Przedział ufności dla średniej  $\mu$  w rozkładzie normalnym  $N(\mu, \sigma^2)$**

Wariancja  $\sigma^2$  jest nieznana

Poziom ufności:  $1 - \alpha$

Przedział ufności

$$\left( \bar{X} - t(\alpha; n - 1) \frac{S}{\sqrt{n}}, \bar{X} + t(\alpha; n - 1) \frac{S}{\sqrt{n}} \right)$$

gdzie  $t(\alpha; n - 1)$  jest wartością krytyczną rozkładu  $t$ -Studenta o  $n - 1$  stopniach swobody.

$\nu$	$t(\gamma; \nu)$			
	$\gamma$			
	0.1	0.05	0.025	0.01
8	1.8595	2.3060	2.7515	3.3554
9	1.8331	2.2622	2.6850	3.2498
10	1.8125	2.2281	2.6338	3.1690

*Przykład*

Na podstawie próby 1.1, 1.2, 0.8, 0.9, 1.2, 1.3, 1.0, 0.7, 0.8, 1.0 oszacować wartość średnią  $\mu$  rozkładu obserwowanej cechy  $X \sim N(\mu, \sigma^2)$ , na poziomie ufności  $1 - \alpha = 0.95$ .

**Wniosek.** Średnia wartość cechy jest jakąś liczbą z przedziału (0.86, 1.14). Zaufanie do tego wniosku wynosi 95%.

$$\bar{x} = \frac{1.1 + 1.2 + \dots + 1.0}{10} = 1.0$$

$$\sum (x_i - \bar{x})^2 = (1.1 - 1.0)^2 + \dots + (1.0 - 1.0)^2 = 0.36$$

$$s^2 = \frac{0.36}{10 - 1} = 0.04, \quad s = \sqrt{s^2} = 0.2, \quad t(0.05; 9) = 2.2622$$

$$t(0.05; 9) \frac{s}{\sqrt{n}} = 2.2622 \frac{0.2}{\sqrt{10}} = 0.14$$

$$(1 - 0.14, 1 + 0.14) = (0.86, 1.14)$$

**Przedział ufności dla wariancji w rozkładzie normalnym**

Średnia  $\mu$  jest nieznaną

Poziom ufności:  $1 - \alpha$

$$\left( \frac{\sum_i (X_i - \bar{X})^2}{\chi^2(\frac{\alpha}{2}; n - 1)}, \frac{\sum_i (X_i - \bar{X})^2}{\chi^2(1 - \frac{\alpha}{2}; n - 1)} \right)$$

$\chi^2(\alpha; \nu)$  jest stabilizowaną wartością krytyczną rozkładu chi-kwadrat z  $\nu$  stopniami swobody.

$\nu$	Wartości krytyczne $\chi^2(\alpha; r)$			
	$\alpha$			
	0.975	0.950	0.050	0.025
8	2.1797	2.7326	15.5073	17.5345
9	2.7004	3.3251	16.9190	19.0228
10	3.2470	3.9403	18.3070	20.4832

### Przykład

Na podstawie próby 1.1, 1.2, 0.8, 0.9, 1.2, 1.3, 1.0, 0.7, 0.8, 1.0 oszacować zróżnicowanie rozkładu obserwowanej cechy (na poziomie ufności  $1 - \alpha = 0.95$ ).

$$\bar{x} = \frac{1.1 + 1.2 + \dots + 1.0}{10} = 1.0$$

$$\sum_i (x_i - \bar{x})^2 = (1.1 - 1.0)^2 + \dots + (1.0 - 1.0)^2 = 0.36$$

$$\chi^2\left(\frac{\alpha}{2}; n - 1\right) = \chi^2(0.025; 9) = 19.0228$$

$$\chi^2\left(1 - \frac{\alpha}{2}; n - 1\right) = \chi^2(0.975; 9) = 2.7004$$

$$\left(\frac{0.36}{19.0228}, \frac{0.36}{2.7004}\right) = (0.019, 0.133)$$

**Wniosek.** Wariancja cechy jest liczbą z przedziału (0.019, 0.133). Zaufanie do tego wniosku wynosi 95%.

### Estymacja prawdopodobieństwa sukcesu

Założenie:  $X \sim D(\theta)$

Próba:  $X_1, X_2, \dots, X_n$

$k = \sum_{i=1}^n X_i$  ( $X = 0$  lub  $X = 1$ )

Przedział ufności dla  $\theta$  (dokładny)

$$(B^{-1}(\alpha/2; k, n - k + 1), B^{-1}(1 - \alpha/2; k + 1, n - k))$$

$B(t; \alpha, \beta)$  jest wartością dystrybuanty zmiennej losowej beta  $B(\alpha, \beta)$  o parametrach  $(\alpha, \beta)$ , w punkcie  $t \in \langle 0, 1 \rangle$

$$B(t; \alpha, \beta) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \int_0^t x^{\alpha-1}(1-x)^{\beta-1} dx$$

### Ryszard Zieliński

Przedział ufności dla frakcji, *Matematyka Stosowana* 10, 2009

[https://wojtek.zielinski.statystyka.info/Moj\\_ojciec/public\\_html/MS090618\\_Zielinski.pdf](https://wojtek.zielinski.statystyka.info/Moj_ojciec/public_html/MS090618_Zielinski.pdf)

### Estymacja prawdopodobieństwa sukcesu

$\hat{\theta} = k/n$  – oszacowanie punktowe

Przedział przybliżony

$$\left( \hat{\theta} - u_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{\theta}(1-\hat{\theta})}{n}}, \hat{\theta} + u_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{\theta}(1-\hat{\theta})}{n}} \right)$$

	Kwantyle $u_\alpha$ rozkładu normalnego $N(0, 1)$				
$\alpha$	0.002	0.003	0.004	0.005	0.006
0.96	1.7744	1.7866	1.7991	1.8119	1.8250
0.97	1.9110	1.9268	1.9431	1.9600	1.9774
0.98	2.0969	2.1201	2.1444	2.1701	2.1973
0.99	2.4089	2.4573	2.5121	2.5758	2.6521

Na przykład  $u_{0.975} = 1.96$  Populacja 1, cecha  $X_1$

Populacja 2, cecha  $X_2$

### Oznaczenia

Próby:  $X_{11}, \dots, X_{1n_1}; X_{21}, \dots, X_{2n_2}$

$$\bar{X}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} X_{ij}, \quad s_i^2 = \frac{\sum_{j=1}^{n_i} (X_{ij} - \bar{X}_i)^2}{n_i - 1}$$

$$s_e^2 = \frac{\sum_{j=1}^{n_1} (X_{1j} - \bar{X}_1)^2 + \sum_{j=1}^{n_2} (X_{2j} - \bar{X}_2)^2}{n_1 + n_2 - 2}, \quad s_r^2 = s_e^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)$$

### Ocena różnicy między średnimi $\mu_1 - \mu_2$

Ocena punktowa:  $\bar{X}_1 - \bar{X}_2$

Założenia:

1.  $X_1 \sim N(\mu_1, \sigma_1^2), X_2 \sim N(\mu_2, \sigma_2^2)$

2.  $X_1, X_2$  są niezależne

3.  $\sigma_1^2 = \sigma_2^2$

Przedział ufności (poziom ufności  $1 - \alpha$ )

$$(\bar{X}_1 - \bar{X}_2 - t(\alpha; n_1 + n_2 - 2)s_r, \bar{X}_1 - \bar{X}_2 + t(\alpha; n_1 + n_2 - 2)s_r)$$



**Przykład.** Z dwóch populacji pobrano próby: 60, 62, 65, 63, 60 oraz 58, 53, 57, 56, 61. Oceń różnicę średnich.

$$\bar{x}_1 = 62, \sum_{i=1}^5 (x_{1i} - \bar{x}_1)^2 = 18, \bar{x}_2 = 57, \sum_{i=1}^5 (x_{2i} - \bar{x}_2)^2 = 34$$

$$s_r^2 = \frac{18 + 34}{5 + 5 - 2} \left( \frac{1}{5} + \frac{1}{5} \right) = 2.6$$

$$t(0.05; 8) = 2.3060; t(0.05; 8)s_r = 3.72$$

$$(62 - 57 - 3.72, 62 - 57 + 3.72) = (1.28, 8.72)$$

**Wniosek.** Różnica średnich jest liczbą z przedziału (1.28, 8.72) **Ocena różnicy frakcji**  $p_1 - p_2$

Założenia:  $X_1 \sim D(p_1), X_2 \sim D(p_2)$

Cechy  $X_1, X_2$  są niezależne

Próba 1:  $X_{11}, X_{12}, \dots, X_{1n_1}$  ( $X_{1i} = 0$  lub 1)

Próba 2:  $X_{21}, X_{22}, \dots, X_{2n_2}$  ( $X_{2i} = 0$  lub 1)

$$k_1 = \sum_{i=1}^{n_1} X_{1i}$$

$$k_2 = \sum_{i=1}^{n_2} X_{2i}$$

Ocena punktowa:  $\hat{p}_1 - \hat{p}_2 = \frac{k_1}{n_1} - \frac{k_2}{n_2}$

Przybliżony przedział ufności (poziom ufności  $1 - \alpha$ )

$$\hat{p}_1 - \hat{p}_2 \pm u_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}$$

## 5 Weryfikacja hipotez

### 5.1 Rodzaje błędów

#### Weryfikacja hipotez statystycznych

##### Błąd I rodzaju

Błąd wnioskowania polegający na odrzuceniu hipotezy, gdy w rzeczywistości jest ona prawdziwa.

##### Błąd II rodzaju

Błąd wnioskowania polegający na nieodrzućeniu hipotezy, gdy w rzeczywistości jest ona fałszywa.

Hipoteza	Decyzja o hipotezie	
	nie odrzucić	odrzućić
prawdziwa	prawidłowa	błędna
fałszywa	błędna	prawidłowa

Błąd I rodzaju kontroluje się przez zadanie małej wartości dla poziomu istotności. **Poziom istotności** jest to górne ograniczenie prawdopodobieństwa popełnienia błędu I rodzaju.

Błąd II rodzaju nie można kontrolować w taki sposób, jak błąd I rodzaju. W praktyce nie wiadomo, ile dokładnie wynosi prawdopodobieństwo popełnienia tego błędu.

## 5.2 Porównanie z normą

### Porównanie średniej z normą

Cecha  $X$  ma rozkład normalny  $N(\mu, \sigma^2)$

Średnia  $\mu$  oraz wariancja  $\sigma^2$  są nieznane

$$H_0 : \mu = \mu_0$$

Test Studenta (poziom istotności  $\alpha$ )

Próba:  $X_1, \dots, X_n$

Statystyka testowa

$$t_{\text{emp}} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} .$$

Jeżeli  $|t_{\text{emp}}| > t(\alpha; n - 1)$ , to hipotezę odrzucamy.

### Porównanie zróżnicowania z normą

Cecha  $X$  ma rozkład normalny  $N(\mu, \sigma^2)$

Średnia  $\mu$  oraz wariancja  $\sigma^2$  są nieznane

$$H_0 : \sigma^2 = \sigma_0^2$$

Statystyka chi-kwadrat (poziom istotności  $\alpha$ )

Próba:  $X_1, \dots, X_n$

$$\text{Statystyka testowa } \chi_{\text{emp}}^2 = \frac{\sum_i (X_i - \bar{X})^2}{\sigma_0^2}$$

Wartości krytyczne  $\chi^2(1 - \frac{\alpha}{2}; n - 1)$ ,  $\chi^2(\frac{\alpha}{2}; n - 1)$

Jeżeli  $\chi_{\text{emp}}^2 < \chi^2(1 - \frac{\alpha}{2}; n - 1)$  lub  $\chi_{\text{emp}}^2 > \chi^2(\frac{\alpha}{2}; n - 1)$  to hipotezę  $H_0 : \sigma^2 = \sigma_0^2$  odrzucamy.

### Porównanie frakcji z normą

Cecha  $X \sim D(p)$

$p$  nie jest znane

$$H_0 : p = p_0$$

Statystyka testowa

$$u_{\text{emp}} = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}}$$

Wartość krytyczna:  $u_{1-\frac{\alpha}{2}}$

Jeżeli  $|u_{\text{emp}}| > u_{1-\frac{\alpha}{2}}$ , to hipotezę odrzucamy.

## 5.3 Porównanie dwóch populacji

### Porównanie średnich

Cecha  $X_1$  ma rozkład normalny  $N(\mu_1, \sigma_1^2)$

Cecha  $X_2$  ma rozkład normalny  $N(\mu_2, \sigma_2^2)$

Średnia  $\mu_1$  oraz wariancja  $\sigma_1^2$  są nieznane

Średnia  $\mu_2$  oraz wariancja  $\sigma_2^2$  są nieznane

$\sigma_1^2 = \sigma_2^2$

$$H_0 : \mu_1 = \mu_2$$

test t-Studenta

$$t_{\text{emp}} = \frac{\bar{X}_1 - \bar{X}_2}{S_r}$$

Wartość krytyczna  $t(\alpha; n_1 + n_2 - 2)$

Jeżeli  $|t_{\text{emp}}| > t(\alpha; n_1 + n_2 - 2)$ , to hipotezę  $H_0 : \mu_1 = \mu_2$  odrzucamy

### Porównanie frakcji

Cecha  $X_1$  ma rozkład dwupunktowy  $D(p_1)$

Cecha  $X_2$  ma rozkład dwupunktowy  $D(p_2)$

$$H_0 : p_1 = p_2$$

Statystyka testowa

$$u_{\text{emp}} = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{\hat{p}(1 - \hat{p})(\frac{1}{n_1} + \frac{1}{n_2})}}$$

gdzie

$$\hat{p}_1 = \frac{k_1}{n_1}, \hat{p}_2 = \frac{k_2}{n_2}, \hat{p} = \frac{(k_1 + k_2)}{(n_1 + n_2)}$$

Jeżeli  $|u_{\text{emp}}| \geq u_{1-\alpha/2}$ , to hipotezę  $H_0 : p_1 = p_2$  odrzucamy

## 5.4 Określenia

### Pojęcia

Model statystyczny

$$(\mathcal{X}, \{P_\theta, \theta \in \Theta\})$$

### Hipoteza statystyczna

Podzbiór  $\Theta_0$  zbioru  $\Theta$ .

$\Theta_0$  nazywamy **hipotezą zerową**

$\Theta_1 = \Theta \setminus \Theta_0$  nazywamy **hipotezą alternatywną**

### Pojęcia

#### Hipoteza prosta

Zbiór  $\Theta_0$  jest jednoelementowy

#### Hipoteza złożona

Zbiór  $\Theta_0$  ma więcej niż jeden element

### Zapis klasyczny

$$H_0 : \theta \in \Theta_0 \quad H_1 : \theta \in \Theta_1$$

### Pojęcia

#### Test statystyczny

Procedura statystyczna, w wyniku której podejmujemy jedną z dwóch decyzji:

- odrzucić hipotezę zerową  $H_0$
- nie ma podstaw do odrzucenia hipotezy zerowej  $H_0$

## Pojęcia

### Test statystyczny

Test hipotezy  $H_0$  utożsamiamy z funkcją  $\phi : \mathcal{X} \rightarrow \{0, 1\}$

$$\phi(x) = \begin{cases} 1 & \text{odrzuć } H_0 \\ 0 & \text{nie odrzucać } H_0 \end{cases}$$

### Obszar krytyczny

$$\{x \in \mathcal{X} : \phi(x) = 1\}$$

## Pojęcia

### Zrandomizowany test statystyczny

Funkcja  $\phi : \mathcal{X} \rightarrow [0, 1]$

$$\phi(x) \begin{cases} = 1 & \text{odrzuć } H_0 \\ \in (0, 1) & \text{na podstawie niezależnego od } X \text{ mecha-} \\ & \text{nizmu losowego odrzuć } H_0 \text{ z prawdopodo-} \\ & \text{bieństwem } \phi(x) \\ = 0 & \text{nie odrzucać } H_0 \end{cases}$$

## Pojęcia

### Błąd I rodzaju

Błąd polegający na odrzuceniu hipotezy zerowej  $H_0$ , gdy w rzeczywistości jest ona prawdziwa.

### Poziom istotności

Niech  $\alpha \in (0, 1)$ . Test  $\phi$  jest na poziomie istotności  $\alpha$ , jeżeli

$$E_\theta \phi(X) = P_\theta\{\phi(X) = 1\} \leq \alpha, \quad \forall \theta \in \Theta_0$$

### Rozmiar testu

$$\sup_{\theta \in \Theta_0} E_\theta \phi(X) = \sup_{\theta \in \Theta_0} P_\theta\{\phi(X) = 1\}$$

## Pojęcia

### Błąd II rodzaju

Błąd polegający na nieodrzuconiu hipotezy zerowej  $H_0$ , gdy w rzeczywistości jest ona fałszywa

### Moc testu

$$\Theta_1 \in \theta \rightarrow E_\theta \phi(X) = P_\theta\{\phi(X) = 1\}$$

## 6 Hipotezy proste

### 6.1 Lemat Neymana–Pearsona

#### Lemat Neymana–Pearsona

##### Założenia

Niech  $P_{\theta_0}$  oraz  $P_{\theta_1}$  będą rozkładami prawdopodobieństwa o gęstościach  $f_0$  i  $f_1$ . Niech  $\alpha \in (0, 1)$  będzie ustaloną liczbą

#### Lemat Neymana–Pearsona

##### Istnienie testu

Istnieją takie stałe  $t$  i  $\gamma$ , że

$$\phi(x) = \begin{cases} 1, & \text{gdy } f_1(x) > t f_0(x) \\ \gamma, & \text{gdy } f_1(x) = t f_0(x) \\ 0, & \text{gdy } f_1(x) < t f_0(x) \end{cases}$$

jest testem hipotezy  $H_0 : \theta = \theta_0$  przeciwko  $H_1 : \theta = \theta_1$  na poziomie istotności  $\alpha$ , tzn.

$$(*) \quad E_{\theta_0} \phi(X) = \alpha$$

#### Lemat Neymana–Pearsona

##### Dostateczność

Jeżeli test  $\phi$  spełnia warunek (\*) i dla pewnego  $t$  warunek

$$(**) \quad \phi(x) = \begin{cases} 1, & \text{gdy } f_1(x) > t f_0(x) \\ 0, & \text{gdy } f_1(x) < t f_0(x) \end{cases}$$

to  $\phi$  jest testem najmocniejszym na poziomie istotności  $\alpha$

### Konieczność

Jeżeli  $\phi$  jest testem najmocniejszym na poziomie istotności  $\alpha$ , to spełnia on warunek (\*\*)

## 6.2 Model dwupunktowy

### Hipotezy proste - przykład

**Model dwupunktowy:**  $H_0 : \theta = \theta_0$  vs  $H_1 : \theta = \theta_1$

Niech  $\theta_0 < \theta_1 \in (0, 1)$ . Model statystyczny

$$\{\{0, 1, \dots, n\}, \{B(n, \theta), \theta \in \Theta = \{\theta_0, \theta_1\}\}\}$$

$$H_0 : \theta = \theta_0 \quad H_1 : \theta = \theta_1$$

$$f_0(x) = \binom{n}{x} \theta_0^x (1 - \theta_0)^{n-x}$$

$$f_1(x) = \binom{n}{x} \theta_1^x (1 - \theta_1)^{n-x}$$

### Hipotezy proste - przykład

**Model dwupunktowy:**  $H_0 : \theta = \theta_0$  vs  $H_1 : \theta = \theta_1$

Konstrukcja testu  $\phi(x)$

$$\phi(x) = 1 \Leftrightarrow \frac{f_1(x)}{f_0(x)} > t \Leftrightarrow \left[ \frac{\theta_1(1 - \theta_0)}{\theta_0(1 - \theta_1)} \right]^x > t \left[ \frac{1 - \theta_0}{1 - \theta_1} \right]^n$$

Obszar krytyczny:  $\{x > k\}$

### Hipotezy proste - przykład

**Model dwupunktowy:**  $H_0 : \theta = \theta_0$  vs  $H_1 : \theta = \theta_1$

Obszar krytyczny:  $\{x > k\}$

Stała  $k$  dobrana jest tak, że

$$E_{\theta_0} \phi(X) = P_{\theta_0} \{X > k\} \leq \alpha$$



### Hipotezy proste - przykład

**Model dwupunktowy:**  $H_0 : \theta = \theta_0$  vs  $H_1 : \theta = \theta_1$

Niech  $n = 100$ ,  $\theta_0 = 0.05$ ,  $\theta_1 = 0.15$ ,  $\alpha = 0.05$

$k$	8	9	10	11
$P_{0.05}\{x > k\}$	0.06309	0.02819	0.01147	0.00427

Test niezrandomizowany

$$\phi(x) = \begin{cases} 1, & \text{jeżeli } x > 9, \\ 0, & \text{jeżeli } x \leq 9. \end{cases}$$

Rozmiar testu:  $P_{0.05}\{x > 9\} = 0.02819$

Błąd II rodzaju:  $P_{0.15}\{x \leq 9\} = 0.05509$

### Hipotezy proste - przykład

**Model dwupunktowy:**  $H_0 : \theta = \theta_0$  vs  $H_1 : \theta = \theta_1$

Niech  $n = 100$ ,  $\theta_0 = 0.05$ ,  $\theta_1 = 0.15$ ,  $\alpha = 0.05$

$k$	8	9	10	11
$P_{0.05}\{x > k\}$	0.06309	0.02819	0.01147	0.00427
$P_{0.05}\{x = k\}$	0.06487	0.03490	0.01672	0.00720

Test zrandomizowany

$$\phi(x) = \begin{cases} 1, & \text{jeżeli } x > 9 \\ 0.62495, & \text{jeżeli } x = 9 \\ 0, & \text{jeżeli } x < 9 \end{cases}$$

### Hipotezy proste - przykład

**Model dwupunktowy:**  $H_0 : \theta = \theta_0$  vs  $H_1 : \theta = \theta_1$

Rozmiar testu zrandomizowanego

$$\begin{aligned} &P_{0.05}\{x > 9\} + 0.62495 \cdot P_{0.05}\{x = 9\} \\ &= 0.02819 + 0.62495 \cdot 0.03490 = 0.05 \end{aligned}$$

### 6.3 Jednostajny vs Beta

#### Hipotezy proste - przykład

$H_0 : U(0, 1)$  vs  $H_1 : B(a, b)$

Niech  $a, b > 1$ . Model statystyczny

$$\{(0, 1), \{U(0, 1), B(a, b)\}\}$$

$$H_0 : U(0, 1) \text{ vs } H_1 : B(a, b)$$

$$f_0(x) = 1 \cdot \mathbf{1}_{(0,1)}(x)$$

$$f_1(x) \propto x^{a-1}(1-x)^{b-1} \mathbf{1}_{(0,1)}(x)$$

#### Hipotezy proste - przykład

$H_0 : U(0, 1)$  vs  $H_1 : B(a, b)$

$$\phi(x) = 1 \Leftrightarrow \frac{f_1(x)}{f_0(x)} > t \Leftrightarrow x^{a-1}(1-x)^{b-1} > t$$

Obszar krytyczny:  $\{x_0 < x < x_1\}$

Liczby  $x_0, x_1$  dobrane są tak, że

$$E_{\theta_0} \phi(X) = P_{U(0,1)}\{x_0 < X < x_1\} \leq \alpha$$

#### Hipotezy proste - przykład

$H_0 : U(0, 1)$  vs  $H_1 : B(a, b)$

$$x_0^{a-1}(1-x_0)^{b-1} = x_1^{a-1}(1-x_1)^{b-1}$$

Ponieważ  $x_1 = x_0 + \alpha$ , więc

$$\left[ \frac{x_0 + \alpha}{x_0} \right]^{a-1} \left[ \frac{1 - x_0 - \alpha}{1 - x_0} \right]^{b-1} = 1$$

## Hipotezy proste - przykład

$H_0 : U(0, 1)$  vs  $H_1 : B(a, b)$

$a$	$b$	$x_0$	$x_1$
2	2	0.47500	0.52500
2	3	0.30865	0.35865
2	4	0.22556	0.27556
3	2	0.64135	0.69135
3	3	0.47500	0.52500
3	4	0.37517	0.42517
4	2	0.72444	0.77444
4	3	0.57483	0.62483
4	4	0.47500	0.52500

## 7 Hipotezy złożone

### 7.1 Iloraz wiarygodności

Hipotezy złożone

Problem

$$(\mathcal{X}, \{P_\theta, \theta \in \Theta\})$$

$$H_0 : \theta \in \Theta_0 \text{ vs } H_1 : \theta \in \Theta_1$$

$H_0$  i/lub  $H_1$  złożone

Hipotezy złożone

Iloraz wiarygodności (1)

$$\lambda(x) = \frac{\sup_{\theta \in \Theta_1} f_\theta(x)}{\sup_{\theta \in \Theta_0} f_\theta(x)}$$

Iloraz wiarygodności (2)

$$\lambda(x) = \frac{\sup_{\theta \in \Theta} f_\theta(x)}{\sup_{\theta \in \Theta_0} f_\theta(x)}$$

## Hipotezy złożone

Test

$$\phi(x) = \begin{cases} 1, & \text{gdym } \lambda(x) > t \\ \gamma, & \text{gdym } \lambda(x) = t \\ 0, & \text{gdym } \lambda(x) < t \end{cases}$$

Dobór stałej  $t$

$$\sup_{\theta \in \Theta_0} E_{\theta} \phi(X) \leq \alpha$$

## 7.2 Model dwupunktowy

Hipotezy złożone - przykład

Model dwupunktowy:  $H_0 : \theta \leq \theta_0$  vs  $H_1 : \theta > \theta_0$

Niech  $\theta_0 \in (0, 1)$ . Model statystyczny

$$\{ \{0, 1, \dots, n\}, \{B(n, \theta), \theta \in \Theta = (0, 1)\} \}$$

$$H_0 : \theta \leq \theta_0 \text{ vs } H_1 : \theta > \theta_0$$

$$f_{\theta}(x) = \binom{n}{x} \theta^x (1 - \theta)^{n-x}$$

Dla danego  $x$

$$\sup_{\theta \in (0, 1)} f_{\theta}(x) = f_{\frac{x}{n}}(x) = \binom{n}{x} \left(\frac{x}{n}\right)^x \left(1 - \frac{x}{n}\right)^{n-x}$$

Hipotezy złożone - przykład

Model dwupunktowy:  $H_0 : \theta \leq \theta_0$  vs  $H_1 : \theta > \theta_0$

$$\sup_{\theta \in \Theta_0} f_{\theta}(x) = \begin{cases} \binom{n}{x} \left(\frac{x}{n}\right)^x \left(1 - \frac{x}{n}\right)^{n-x}, & \text{jeżeli } \frac{x}{n} \leq \theta_0, \\ \binom{n}{x} \theta_0^x (1 - \theta_0)^{n-x}, & \text{jeżeli } \frac{x}{n} > \theta_0, \end{cases}$$

$$\sup_{\theta \in \Theta_1} f_{\theta}(x) = \begin{cases} \binom{n}{x} \theta_0^x (1 - \theta_0)^{n-x}, & \text{jeżeli } \frac{x}{n} \leq \theta_0, \\ \binom{n}{x} \left(\frac{x}{n}\right)^x \left(1 - \frac{x}{n}\right)^{n-x}, & \text{jeżeli } \frac{x}{n} > \theta_0. \end{cases}$$

### Hipotezy złożone - przykład

Model dwupunktowy:  $H_0 : \theta \leq \theta_0$  vs  $H_1 : \theta > \theta_0$

$$\lambda(x) = \frac{\sup_{\theta \in \Theta_1} f_\theta(x)}{\sup_{\theta \in \Theta_0} f_\theta(x)} = \begin{cases} \frac{\binom{n}{x} \theta_0^x (1 - \theta_0)^{n-x}}{\binom{n}{x} \left(\frac{x}{n}\right)^x \left(1 - \frac{x}{n}\right)^{n-x}}, & \text{jeżeli } \frac{x}{n} \leq \theta_0, \\ \frac{\binom{n}{x} \left(\frac{x}{n}\right)^x \left(1 - \frac{x}{n}\right)^{n-x}}{\binom{n}{x} \theta_0^x (1 - \theta_0)^{n-x}}, & \text{jeżeli } \frac{x}{n} > \theta_0. \end{cases}$$

### Hipotezy złożone - przykład

Model dwupunktowy:  $H_0 : \theta \leq \theta_0$  vs  $H_1 : \theta > \theta_0$

$\lambda(x)$  jest rosnąca ze względu na  $x$

$$\lambda(x) > t \Leftrightarrow x > k$$

Dobór stałej  $k$

$$\sup_{\theta \leq \theta_0} P_\theta\{X > k\} = P_{\theta_0}\{X > k\} \leq \alpha$$

## 7.3 Model gaussowski

### Hipotezy złożone - przykład

Model gaussowski:  $H_0 : \mu = \mu_0$  vs  $H_1 : \mu \neq \mu_0$

Niech  $\mu_0 \in \mathcal{R}$ . Model dla próby  $\mathbb{X} = (X_1, X_2, \dots, X_n)$ :

$$(\mathcal{R}^n, \{N(\mu \mathbf{1}_n, \sigma^2 \mathbf{I}_n), \theta = (\mu, \sigma^2) \in \mathcal{R} \times \mathcal{R}_+\})$$

$$\Theta = \mathcal{R} \times \mathcal{R}_+ \quad \Theta_0 = \{\mu_0\} \times \mathcal{R}_+ \quad \Theta_1 = (\mathcal{R} \setminus \{\mu_0\}) \times \mathcal{R}_+$$

$$H_0 : \mu = \mu_0 \text{ vs } H_1 : \mu \neq \mu_0$$

$$f_{\mu, \sigma}(\mathbf{x}) = \left(\frac{1}{\sigma \sqrt{2\pi}}\right)^n \exp \left\{ -\frac{1}{2} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma}\right)^2 \right\}$$

### Hipotezy złożone - przykład

**Model gaussowski:**  $H_0 : \mu = \mu_0$  vs  $H_1 : \mu \neq \mu_0$

$$\sup_{\theta \in \Theta_0} f_{\mu, \sigma}(x) = f_{\mu_0, \tilde{\sigma}}(x) = \left( \frac{1}{\tilde{\sigma} \sqrt{2\pi}} \right)^n \exp \left\{ -\frac{n}{2} \right\}$$

$$\tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu_0)^2$$

$$\sup_{\theta \in \Theta} f_{\mu, \sigma}(x) = f_{\bar{x}, \hat{\sigma}}(x) = \left( \frac{1}{\hat{\sigma} \sqrt{2\pi}} \right)^n \exp \left\{ -\frac{n}{2} \right\}$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

### Hipotezy złożone - przykład

**Model gaussowski:**  $H_0 : \mu = \mu_0$  vs  $H_1 : \mu \neq \mu_0$

Iloraz wiarygodności

$$\lambda(x) = \frac{\sup_{\theta \in \Theta} f_{\mu, \sigma}(x)}{\sup_{\theta \in \Theta_0} f_{\mu, \sigma}(x)} = \left( \frac{\tilde{\sigma}}{\hat{\sigma}} \right)^n$$

$$\sum_{i=1}^n (X_i - \mu_0)^2 = \sum_{i=1}^n (X_i - \bar{X} + \bar{X} - \mu_0)^2 = \sum_{i=1}^n (X_i - \bar{X})^2 + n(\bar{X} - \mu_0)^2$$

$$\lambda(x) = \left( 1 + \frac{n(\bar{X} - \mu_0)^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \right)^{\frac{n}{2}}$$

### Hipotezy złożone - przykład

**Model gaussowski:**  $H_0 : \mu = \mu_0$  vs  $H_1 : \mu \neq \mu_0$

$$\phi(x) = 1 \Leftrightarrow \lambda(x) > t \Leftrightarrow \frac{n(\bar{X} - \mu_0)^2}{\sum_{i=1}^n (X_i - \bar{X})^2} > t'$$

Dobór stałej  $t'$

$$E_{H_0} \phi(X) = \alpha$$

### Hipotezy złożone - przykład

Model gaussowski:  $H_0 : \mu = \mu_0$  vs  $H_1 : \mu \neq \mu_0$

- jeżeli  $H_0$  jest prawdziwa, to

$$\sqrt{n}(\bar{X} - \mu_0) \sim N(0, \sigma^2) \quad \text{czyli} \quad \frac{n(\bar{X} - \mu_0)^2}{\sigma^2} \sim \chi_1^2$$

- dla wszystkich  $\theta \in \Theta$

$$\frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2 \sim \chi_{n-1}^2$$

- $\bar{X}$  oraz  $\sum_{i=1}^n (X_i - \bar{X})^2$  są niezależne

### Hipotezy złożone - przykład

Model gaussowski:  $H_0 : \mu = \mu_0$  vs  $H_1 : \mu \neq \mu_0$

Jeżeli hipoteza  $H_0$  jest prawdziwa, to

$$\frac{n(\bar{X} - \mu_0)^2}{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2} \sim F_{1, n-1}$$

### Hipotezy złożone - przykład

Model gaussowski:  $H_0 : \mu = \mu_0$  vs  $H_1 : \mu \neq \mu_0$

$H_0$  jest odrzucana na poziomie istotności  $\alpha$ , jeżeli

$$(*) \quad \frac{n(\bar{X} - \mu_0)^2}{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2} > F_{1, n-1}^\alpha$$

Ponieważ  $t_v = \sqrt{F_{1, v}}$ , więc (\*) jest równoważne

$$(\clubsuit) \quad \frac{|\bar{X} - \mu_0|}{S} \sqrt{n} > t_{n-1}^\alpha$$

Test ( $\clubsuit$ ) nazywa się **testem Studenta**

## 7.4 Moc testu

Moc testu

Określenie

$$\Theta_1 \ni \theta \rightarrow E_\theta \phi(X) = P_\theta \{\phi(X) = 1\}$$

Moc testu - przykład

Model gaussowski ( $\sigma^2$  znana):  $H_0 : \mu \leq \mu_0$  vs  $H_1 : \mu > \mu_0$

Niech  $\mu_0 \in \mathcal{R}$ .

$$(\mathcal{R}^n, \{N(\mu \mathbf{1}_n, \sigma^2 \mathbf{I}_n), \theta = \mu \in \mathcal{R}\})$$

$$\Theta = \mathcal{R} \quad \Theta_0 = (-\infty, \mu_0] \quad \Theta_1 = (\mu_0, \infty)$$

$$H_0 : \mu \leq \mu_0 \text{ vs } H_1 : \mu > \mu_0$$

Obszar krytyczny testu

$$\frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} > u_{1-\alpha}$$

Moc testu - przykład

Model gaussowski ( $\sigma^2$  znana):  $H_0 : \mu \leq \mu_0$  vs  $H_1 : \mu > \mu_0$

Niech  $\mu > \mu_0$ . Prawdopodobieństwo odrzucenia  $H_0$

$$\begin{aligned} P_\mu \left\{ \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} > u_{1-\alpha} \right\} &= \\ P_\mu \left\{ \frac{\bar{X} - \mu}{\sigma} \sqrt{n} > u_{1-\alpha} - \frac{\mu - \mu_0}{\sigma} \sqrt{n} \right\} &= \\ 1 - \Phi \left( u_{1-\alpha} - \frac{\mu - \mu_0}{\sigma} \sqrt{n} \right) & \end{aligned}$$

Moc testu jest zależna od  $(\mu - \mu_0)/\sigma$



## 7.5 Liczność próby

### Liczność próby

**Model gaussowski ( $\sigma^2$  znana):**  $H_0 : \mu \leq \mu_0$  vs  $H_1 : \mu > \mu_0$

Niech  $(\mu - \mu_0)/\sigma = x_0$  będzie daną liczbą. Powiedzmy, że interesuje nas osiągnięcie dla tej wartości mocy co najmniej  $\gamma$ . Szukamy takiego  $n$ , że

$$1 - \Phi(u_{1-\alpha} - x_0\sqrt{n}) \geq \gamma$$

Rozwiązanie:

$$u_{1-\alpha} - x_0\sqrt{n} \leq u_{1-\gamma}$$

Stąd

$$n \geq \left[ \frac{u_{1-\alpha} - u_{1-\gamma}}{x_0} \right]^2$$

**minimalne  $n$**

$x_0$	0.6	0.7	0.8	0.85	0.9	0.95
0.01	48987	61720	78488	89783	105073	129946
0.1	489	617	784	897	1050	1299
0.2	122	154	196	224	262	324
0.3	54	68	87	99	116	144
0.4	30	38	49	56	65	81
0.5	19	24	31	35	42	51
0.6	13	17	21	24	29	36
0.7	9	12	16	18	21	26
0.8	7	9	12	14	16	20
0.9	6	7	9	11	12	16
1	4	6	7	8	10	12

## 8 Testy JNM w modelach z monotonicznym ilorazem wiarygodności

### Pojęcia

#### Model statystyczny

Rozpatrujemy model statystyczny

$$(\mathcal{X}, \{P_\theta, \theta \in \Theta\})$$

w którym  $\Theta$  jest pewnym przedziałem na prostej.

### Rodzina rozkładów z monotonicznym ilorazem wiarygodności

$\{P_\theta, \theta \in \Theta\}$  jest rodziną z monotonicznym ilorazem wiarygodności, jeżeli istnieje taka funkcja  $T(x)$ , że jeżeli  $\theta' > \theta$ , to iloraz  $p_{\theta'}(x)/p_\theta(x)$  jest niemalejącą funkcją  $T(x)$ .

#### Przykłady

- Rodzina rozkładów dwumianowych

$$\{Bin(n, \theta), \theta \in \langle 0, 1 \rangle\}$$

- Rodzina rozkładów jednostajnych

$$\{U(0, \theta) : \theta > 0\}$$

- Jednoparametrowe rodziny wykładnicze z gęstościami

$$p_\theta(x) = \exp\{c(\theta)T(x) - b(\theta)\} \cdot h(x)$$

### Twierdzenie Karlina i Rubina

Niech  $(\mathcal{X}, \{P_\theta, \theta \in \Theta\})$  będzie rodziną rozkładów z monotonicznym ilorazem wiarygodności względem funkcji  $T$ .

1. Dla testowania hipotezy  $H_0 : \theta \leq \theta_0$ , przy alternatywie  $H_1 : \theta > \theta_0$ , istnieje test JNM, określony w następujący sposób:

$$(*) \quad \phi(x) = \begin{cases} 1, & \text{gdy } T(x) > C, \\ \gamma, & \text{gdy } T(x) = C, \\ 0, & \text{gdy } T(x) < C, \end{cases}$$

gdzie stałe  $C$  i  $\gamma$  są wyznaczone z warunku

$$(**) \quad E_{\theta_0} \phi(X) = \alpha.$$

2. Funkcja

$$\beta(\theta) = E_\theta \phi(X)$$

jest rosnąca w każdym punkcie  $\theta$ , w którym  $\beta(\theta) < 1$ .

4. Dla każdego  $\theta'$  test określony warunkami (\*) oraz (\*\*) jest testem JNM dla testowania  $H_0 : \theta \leq \theta'$ , przy alternatywie  $H_1 : \theta > \theta'$ , na poziomie istotności  $\alpha' = \beta(\theta')$ .
5. Dla dowolnego  $\theta < \theta_0$  test ten minimalizuje  $\beta(\theta)$  (prawdopodobieństwo błędu pierwszego rodzaju) wśród wszystkich testów spełniających (\*\*)

### Wniosek

Jeżeli  $(\mathcal{X}, \{P_\theta, \theta \in \Theta\})$  jest rodziną wykładniczą o rozkładzie

$$p_\theta(x) = \exp\{c(\theta)T(x) - b(\theta)\} \cdot h(x)$$

i jeżeli  $c(\theta)$  jest funkcją rosnącą, to test JNM hipotezy  $H_0 : \theta \leq \theta_0$  wobec  $H_1 : \theta > \theta_0$  ma postać

$$(*) \quad \phi(x) = \begin{cases} 1, & \text{gdy } T(x) > C, \\ \gamma, & \text{gdy } T(x) = C, \\ 0, & \text{gdy } T(x) < C, \end{cases}$$

gdzie stałe  $C$  i  $\gamma$  są wyznaczone z warunku

$$E_{\theta_0}\phi(X) = \alpha.$$

Jeżeli  $c(\theta)$  jest funkcją malejącą, to w definicji testu  $\phi$  znaki nierówności zmieniają się na przeciwne.

*Przykłady, w których można zastosować wniosek*

- Niech  $X_1, X_2, \dots, X_n$  będzie próbą z rozkładu  $N(\mu, 1)$ . Weryfikujemy hipotezę  $H_0 : \mu \leq 0$  wobec hipotezy alternatywnej  $H_1 : \mu > 0$ , na poziomie istotności  $\alpha \in (0, 1)$ .
- Niech  $X_1, X_2, \dots, X_n$  będzie próbą z rozkładu  $E(\lambda)$ . Weryfikujemy hipotezę  $H_0 : \lambda \leq \lambda_0$  wobec hipotezy alternatywnej  $H_1 : \lambda > \lambda_0$ , na poziomie istotności  $\alpha \in (0, 1)$ . W tym przykładzie  $\lambda_0$  jest ustaloną wartością dodatnią.

## 9 Elementy teorii podejmowania decyzji

### Wprowadzenie

#### Przykład

Kupujemy 10 używanych samolotów. Pewna nieznaną ich ilość  $\theta$  może latać 1000 godzin bez naprawy i każdy z nich daje zysk  $1000z$ . Każdy z pozostałych będzie wymagał naprawy co da stratę w wysokości  $1000q$ . Przed podjęciem decyzji za cenę  $1000r$  można na 1000 godzin wypożyczyć jeden z samolotów i decyzję uzależnić od jego zachowania. Przeanalizować problem i wybrać najlepsze postępowanie.

Decyzje:

$d_1 =$  kupić samoloty

$d_2 =$  nie kupować samolotów

Bierzemy samolot na próbę:

$x_1$ (wynik próby OK)	$x_2$ (wynik próby nie OK)
$P_\theta(x_1) = \theta/10$	$P_\theta(x_2) = 1 - \theta/10$

Model statystyczny

$$\{\{0, 1\}, \{D(\theta/10), \theta \in \Theta = \{0, 1, \dots, 10\}\}\}$$

Funkcja straty

$$L(d_1, \theta) = r - \theta z + (10 - \theta)q$$

$$L(d_2, \theta) = r \text{ dla wszystkich } \theta$$

Postępowania (reguły decyzyjne) Wybrać najlepszą regułę decyzyjną! ■

	$x_1$	$x_2$
$\delta_1$	nie kupować	nie kupować
$\delta_2$	kupić	kupić
$\delta_3$	kupić	nie kupować
$\delta_4$	nie kupować	kupić

## Definicje

Model statystyczny

$$\{\mathcal{X}, \{P_\theta : \theta \in \Theta\}\}$$

1. Zbiór obserwacji  $\mathcal{X}$
2. Zbiór stanów natury  $\Theta$
3. Zbiór decyzji  $\mathcal{D}$
4. Funkcja straty  $L(d, \theta) : \mathcal{D} \times \Theta \rightarrow \mathcal{R}$
5. Reguła decyzyjna  $\delta : \mathcal{X} \rightarrow \mathcal{D}$
6. Ryzyko reguły  $\delta$ :  $R_\delta(\theta) = E_\theta\{L(\delta(X), \theta)\}$

**Zadanie:** znaleźć regułę  $\delta$  „optymalizującą” ryzyko

Optymalizacja:

1. jednostajna minimalizacja ryzyka
2. zasada minimaksu
3. reguła Bayesa

## Estymacja

1. Zbiór decyzji  $\mathcal{D} = \Theta = \mathcal{R}$
2. Funkcja straty  $L(d, \theta) = (d - \theta)^2$
3. Reguła decyzyjna  $\delta$ : estymator parametru  $\theta$
4. Ryzyko reguły  $\delta$ : błąd średniokwadratowy

Jeżeli ograniczymy się do takich reguł  $\delta$ , że

$$E_\theta \delta(X) = \theta, \quad \forall \theta \in \Theta$$

to reguła **jednostajnie minimalizująca ryzyko** jest ENMW.

	$\theta \in \Theta_0$	$\theta \notin \Theta_0$
$d_1$	0	1
$d_2$	1	0

## Weryfikacja hipotez

1. Zbiór decyzji

$$\mathcal{D} = \{d_1 = \{\theta \in \Theta_0\}, d_2 = \{\theta \notin \Theta_0\}\}$$

2. Funkcja straty  $L(d, \theta)$
3. Reguła decyzyjna  $\delta$ : test  $\phi$
4. Ryzyko reguły  $\delta$ : prawdopodobieństwo błędnego wnioskowania

Jeżeli ograniczymy się do takich reguł  $\delta$ , że

$$E_{\theta} \delta(X) \leq \alpha, \quad \forall \theta \in \Theta_0$$

to reguła **jednostajnie minimalizująca ryzyko** jest testem jednostajnie najmocniejszym.

## Optymalizacja

1. **Jednostajna minimalizacja ryzyka**

Znaleźć taką regułę  $\delta$ , że jeżeli  $\delta'$  jest jakąkolwiek inną regułą, to

$$R_{\delta}(\theta) \leq R_{\delta'}(\theta) \quad \forall \theta \in \Theta$$

2. **Zasada minimaksu**

Znaleźć taką regułę  $\delta$ , że jeżeli  $\delta'$  jest jakąkolwiek inną regułą, to

$$\max_{\theta} R_{\delta}(\theta) \leq \max_{\theta} R_{\delta'}(\theta)$$

### 3. Zasada Bayesa

Znaleźć taką regułę  $\delta$ , że jeżeli  $\delta'$  jest jakąkolwiek inną regułą, to

$$\int_{\Theta} R_{\delta}(\theta)\Pi(d\theta) \leq \int_{\Theta} R_{\delta'}(\theta)\Pi(d\theta)$$

gdzie  $\Pi$  jest taką miarą na zbiorze  $\Theta$ , że  $\int_{\Theta} \Pi(d\theta) = 1$

*Przykład, cd. – Ryzyko reguły decyzyjnej*

$x_1 =$  próba pozytywna     $x_2 =$  próba negatywna

Reguła  $\delta_1$ :     $\delta_1(x_1) = d_2$      $\delta_1(x_2) = d_2$

$$R_{\delta_1}(\theta) = r$$

Reguła  $\delta_2$ :     $\delta_2(x_1) = d_1$      $\delta_2(x_2) = d_1$


$$R_{\delta_2}(\theta) = r - \theta z + (10 - \theta)q$$

Reguła  $\delta_3$ :     $\delta_3(x_1) = d_1$      $\delta_3(x_2) = d_2$

$$R_{\delta_3}(\theta) = \frac{\theta}{10}\{r - \theta z + (10 - \theta)q\} + \left[1 - \frac{\theta}{10}\right]r$$

Reguła  $\delta_4$ :     $\delta_4(x_1) = d_2$      $\delta_4(x_2) = d_1$

$$R_{\delta_4}(\theta) = \frac{\theta}{10}r + \left[1 - \frac{\theta}{10}\right]\{r - \theta z + (10 - \theta)q\}$$



$$z = 0.2 \quad q = 0.3 \quad r = 0.1$$

$$\delta_1 : \max_{\theta} R_{\delta_1}(\theta) = 0.1$$

$$\delta_2 : \max_{\theta} R_{\delta_2}(\theta) = R_{\delta_2}(0) = 3.1$$

$$\delta_3 : \max_{\theta} R_{\delta_3}(\theta) = R_{\delta_3}(3) = 0.55$$

$$\delta_4 : \max_{\theta} R_{\delta_4}(\theta) = R_{\delta_4}(0) = 3.1$$

### Zasada bayesowska

$$P\{\theta = i\} = p_i, \quad i = 0, 1, 2, \dots, 10$$

$$\text{Średnie ryzyko reguły } \delta = \sum_{i=0}^{10} R_{\delta}(\theta = i)p_i$$

$$P\{\theta = i\} = \frac{1}{11}, \quad i = 0, 1, 2, \dots, 10$$

	średnie ryzyko		
	$z = 0.20$	$z = 0.20$	$z = 0.20$
	$q = 0.30$	$q = 0.05$	$q = 0.50$
	$r = 0.10$	$r = 0.10$	$r = 0.01$
$\delta_1$	0.10	0.100	0.10
$\delta_2$	0.60	-0.650	1.60
$\delta_3$	-0.15	-0.525	0.15
$\delta_4$	0.85	-0.025	1.55



## 10 Statystyka bayesowska

### Elementy statystyki bayesowskiej

Model statystyczny

$$\{\mathcal{X}, \{P_\theta : \theta \in \Theta\}\}$$

### Rozkład *a priori*

Rozkład prawdopodobieństwa  $\Pi$  na zbiorze  $\Theta$

### Oznaczenia

Rozkład  $P_\theta$  oznaczać będziemy  $P(\cdot|\theta)$ , a jego gęstość przez  $p(\cdot|\theta)$ . Gęstość rozkładu *a priori* oznaczać będziemy przez  $\pi(\cdot)$ .

### Rozkład *a posteriori*

$$\pi(\theta|x) = \pi(\theta) \frac{p(x|\theta)}{p(x)}, \quad p(x) = \int_{\Theta} \pi(\theta) p(x|\theta) d\theta$$

### Estymacja bayesowska

1. Funkcja starty:  $L(\hat{\theta}, \theta)$
2. Ryzyko bayesowskie:

$$\begin{aligned} \int_{\Theta} \left[ \int_{\mathcal{X}} L(\hat{\theta}(x), \theta) p(x|\theta) dx \right] \pi(\theta) d\theta &= \\ &= \int_{\mathcal{X}} \left[ \int_{\Theta} L(\hat{\theta}(x), \theta) \pi(\theta|x) d\theta \right] p(x) dx \end{aligned}$$

Estymator bayesowski minimalizuje

$$\int_{\Theta} L(\hat{\theta}(x), \theta) \pi(\theta|x) d\theta$$

3. Jeżeli  $L(\hat{\theta}, \theta) = (\hat{\theta} - \theta)^2$ , to estymatorem bayesowskim jest wartość oczekiwana rozkładu *a posteriori*

## Bayesowskie testowanie hipotez

1. Zbiór decyzji

$$\mathcal{D} = \{d_1 = \{\theta = \theta_1\}, d_2 = \{\theta = \theta_2\}\}$$

2. Funkcja straty  $L(d, \theta)$

	$\theta = \theta_1$	$\theta = \theta_2$
$d_1$	$L_{11}$	$L_{12}$
$d_2$	$L_{21}$	$L_{22}$

3. Rozkład *a priori*

$$P\{\theta = \theta_1\} = \pi_1 \quad P\{\theta = \theta_2\} = \pi_2 \quad \pi_1 + \pi_2 = 1$$

4. Oczekiwana strata *a posteriori* reguły  $\delta$  (tzn.  $\int_{\Theta} L(\delta(x), \theta)\pi(\theta|x)d\theta$ )

$$\delta(x) = d_1 \sim \pi_1 p(x|\theta_1)L_{11} + \pi_2 p(x|\theta_2)L_{12}$$

$$\delta(x) = d_2 \sim \pi_1 p(x|\theta_1)L_{21} + \pi_2 p(x|\theta_2)L_{22}$$

5. Reguła bayesowska: obszar przyjęć decyzji  $d_2$

$$\left\{ x \in \mathcal{X} : \frac{p(x|\theta_2)}{p(x|\theta_1)} > \frac{\pi_1[L_{21} - L_{11}]}{\pi_2[L_{12} - L_{22}]} \right\}$$

*Przykład: model dwumianowy*

Model pojedynczej obserwacji  $X$ :

$$(\{0, 1\}, \{D(\theta), \theta \in [0, 1]\})$$

Rozkład *a priori*  $U(0, 1)$ :  $\pi(\theta) = 1$  ( $\theta \in [0, 1]$ )

Rozkład *a posteriori* ( $n = 1$ )

$$P(1) = \int_0^1 P(1|\theta)\pi(\theta)d\theta = \int_0^1 \theta d\theta = \frac{1}{2}$$

$$P(0) = \int_0^1 P(0|\theta)\pi(\theta)d\theta = \int_0^1 (1 - \theta)d\theta = \frac{1}{2}$$

$$\pi(\theta|1) = \frac{P(1|\theta)\pi(\theta)}{P(1)} = 2\theta$$

$$\pi(\theta|0) = \frac{P(0|\theta)\pi(\theta)}{P(0)} = 2(1 - \theta)$$

*Przykład: model dwumianowy*  
Rozkład a posteriori ( $n = 2$ )

$$P(2) = \int_0^1 P(1|\theta)^2 \pi(\theta) d\theta = \int_0^1 \theta^2 d\theta = \frac{1}{3}$$

$$P(1) = 2 \int_0^1 P(1|\theta)P(0|\theta)\pi(\theta) d\theta = 2 \int_0^1 \theta(1 - \theta) d\theta = \frac{1}{3}$$

$$P(0) = \int_0^1 P(0|\theta)^2 \pi(\theta) d\theta = \int_0^1 (1 - \theta)^2 d\theta = \frac{1}{3}$$

$$\pi(\theta|2) = \frac{P(1|\theta)^2 \pi(\theta)}{P(2)} = 3\theta^2$$

$$\pi(\theta|1) = \frac{P(1|\theta)P(0|\theta)\pi(\theta)}{P(1)} = 3\theta(1 - \theta)$$

$$\pi(\theta|0) = \frac{P(0|\theta)^2 \pi(\theta)}{P(0)} = 3(1 - \theta)^2$$

*Przykład: model dwumianowy*  
Rozkład a posteriori ( $n$ )

$$P(k) = \binom{n}{k} \int_0^1 P(1|\theta)^k P(0|\theta)^{n-k} \pi(\theta) d\theta$$

$$= \binom{n}{k} \int_0^1 \theta^k (1 - \theta)^{n-k} d\theta = \frac{1}{n+1}$$

$$\pi(\theta|k) = \frac{\binom{n}{k} P(1|\theta)^k P(0|\theta)^{n-k} \pi(\theta)}{P(k)}$$

$$= (n+1) \binom{n}{k} \theta^k (1 - \theta)^{n-k}$$

\*\*\*

$$\int_0^1 x^{a-1} (1-x)^{b-1} dx = \frac{\Gamma(a)\Gamma(b)}{\Gamma(a+b)}, \quad \int_0^1 x^m (1-x)^l dx = \frac{m!l!}{(m+l+1)!}$$

Przykład: model dwumianowy

Estymator bayesowski

$$\begin{aligned}\hat{\theta}(k) &= \int_0^1 \theta \pi(\theta|k) d\theta \\ &= (n+1) \binom{n}{k} \int_0^1 \theta^{k+1} (1-\theta)^{n-k} d\theta \\ &= (n+1) \binom{n}{k} \frac{(k+1)!(n-k)!}{(n+2)!} \\ &= \frac{k+1}{n+2}\end{aligned}$$

Niech  $\theta_1 < \theta_2 \in (0, 1)$ . Model statystyczny

$$\{\{0, 1, \dots, n\}, \{B(n, \theta), \theta \in \Theta = \{\theta_1, \theta_2\}\}\}$$

Zbiór decyzji

$$\mathcal{D} = \{d_1 = \{\theta = \theta_1\}, d_2 = \{\theta = \theta_2\}\}$$

Bayesowski obszar przyjęć decyzji  $d_2$

$$\begin{aligned}\left\{ x \in \mathcal{X} : \frac{p(x|\theta_2)}{p(x|\theta_1)} > \frac{\pi_1[L_{21} - L_{11}]}{\pi_2[L_{12} - L_{22}]} \right\} \\ \frac{\theta_2^k (1-\theta_2)^{n-k}}{\theta_1^k (1-\theta_1)^{n-k}} > \gamma \\ \left[ \frac{\theta_2(1-\theta_1)}{\theta_1(1-\theta_2)} \right]^k > \gamma \left[ \frac{1-\theta_1}{1-\theta_2} \right]^n\end{aligned}$$

Reguła bayesowska

$$k > n \frac{\log \left[ \frac{1-\theta_1}{1-\theta_2} \right]}{\log \left[ \frac{\theta_2}{\theta_1} \right] + \log \left[ \frac{1-\theta_1}{1-\theta_2} \right]} + \log \gamma$$

Niech  $\pi_1 = \pi_2 = 0.5$ . Funkcja straty  $L(d, \theta)$

	$\theta = \theta_1$	$\theta = \theta_2$
$d_1$	0	1
$d_2$	1	0

Reguła bayesowska

$$k > n \frac{\log \left[ \frac{1-\theta_1}{1-\theta_2} \right]}{\log \left[ \frac{\theta_2}{\theta_1} \right] + \log \left[ \frac{1-\theta_1}{1-\theta_2} \right]}$$

Ryzyko reguły: prawdopodobieństwo błędnej decyzji

\*\*\*

Niech  $n = 100$ ,  $\theta_1 = 0.05$ ,  $\theta_2 = 0.15$   
 Decyzja  $d_2$ , jeżeli  $k > 9.19$