

**WYKŁADY Z TEORII  
TESTOWANIA HIPOTEZ**



Tadeusz Inglot

**WYKŁADY Z TEORII  
TESTOWANIA HIPOTEZ**



Oficyna Wydawnicza GiS

Wrocław 2021

*Tadeusz Inglot*

Wydział Matematyki  
Politechnika Wrocławska  
tadeusz.inglot@pwr.edu.pl

*Projekt okładki:*

IMPRESJA Studio Grafiki Reklamowej

Copyright © 2021 by Tadeusz Inglot

Utwór w całości ani we fragmentach nie może być powielany ani rozpowszechniany za pomocą urządzeń elektronicznych, mechanicznych, kopiujących, nagrywających i innych. Ponadto utwór nie może być umieszczany ani rozpowszechniany w postaci cyfrowej zarówno w internecie, jak i w sieciach lokalnych, bez pisemnej zgody posiadacza praw autorskich.

Skład książki w systemie L<sup>A</sup>T<sub>E</sub>X wykonał autor.

ISBN 978-83-62780-90-7

---

Wydanie I, Wrocław 2021  
Oficyna Wydawnicza GiS, s.c., [www.gis.wroc.pl](http://www.gis.wroc.pl)  
Druk i oprawa: Drukarnia I-BiS Bierońscy, Sp. kom.

---

## Spis treści

Przedmowa .....	7
1. Wstęp .....	9
2. Testowanie hipotez prostych .....	13
3. Testy wynikowe .....	18
3.1. Średniokwadratowa różniczkowalność modelu .....	18
3.2. Testy wynikowe dla hipotezy prostej .....	25
3.3. Testy wynikowe dla hipotezy złożonej .....	29
3.4. Gładki test Neymana .....	33
4. Testowanie jednostajności .....	37
4.1. Proces empiryczny .....	37
4.2. Klasyczne testy jednostajności .....	43
4.3. Klasa testów kwadratowych .....	49
4.4. Własności asymptotyczne testów przy alternatywach .....	55
5. Testy zgodności dla hipotezy złożonej .....	59
5.1. Testy oparte na procesie empirycznym .....	59

5.2. Test chi-kwadrat . . . . .	65
5.3. Testy regresyjne. Test Shapiro-Wilka . . . . .	69
5.4. Gładki test Neymana . . . . .	72
5.5. Przykład. Testowanie normalności . . . . .	74
6. Adaptacyjne testy wynikowe . . . . .	77
7. Porównywanie testów. Efektywność . . . . .	84
7.1. Efektywność Pitmana . . . . .	85
7.2. Efektywność Bahadura . . . . .	91
7.3. Efektywność Kallenberg . . . . .	99
7.4. Ilustracja geometryczna różnych pojęć efektywności . . . . .	109
8. Dodatek . . . . .	112
8.1. Nierówność Craméra-Rao . . . . .	112
8.2. Dowód twierdzenia 12 . . . . .	113
Zadania . . . . .	119
Propozycje ćwiczeń laboratoryjnych . . . . .	130
Literatura . . . . .	138
Nota bibliograficzna . . . . .	139
Skorowidz . . . . .	141

## Przedmowa

Niniejszy podręcznik jest zapisem wykładów z *Teorii testowania hipotez*, które prowadziłem w latach 2005–2015 dla studentów matematyki specjalności *statystyka matematyczna* na 2 lub 3 semestrze studiów magisterskich (8 lub 9 semestr jednolitych pięcioletnich studiów magisterskich). Przedmiot obejmował 30 godzin wykładu oraz 30 godzin laboratorium z ćwiczeniami audytoryjnymi. Książka nie jest więc całościowym przeglądem bardzo obszernego współcześnie działu statystyki, a zawiera raczej pewien subiektywny, ograniczony czasem wykładu, wybór materiału. Staralem się pokazać najważniejsze wyniki klasyczne, a równocześnie nie rezygnować z odniesień do aktualnych, nowych rozwiązań. Na przykładzie wybranych zagadnień i twierdzeń, przedstawiłem ogólne idee, które przewijają się w różnych zagadnieniach testowania oraz te fakty z teorii prawdopodobieństwa, które stoją za rozważaniami statystycznymi. Uzupełnieniem wykładu są propozycje zadań i ćwiczeń laboratoryjnych. Z jednej strony ilustrują wykład, a z drugiej rozszerzają jego zakres poprzez wprowadzenie do innych problemów testowania i zapoznanie czytelnika z nieobjętymi wykładem testami znanymi z literatury ostatnich kilkudziesięciu lat.

Rozdział 7.3 zawiera podstawowe wiadomości o efektywności Kallenberg, które nie były dotąd prezentowane w literaturze w języku polskim poza artykułem Ledwiny (2005). Twierdzenie 12 i jego dowód w rozdziale 8.2, oparty na monografii [Va], są nowe. Rozdział 8 wykracza poza ramy wykładu i został dodany dla kompletności niniejszego opracowania. Rozdział 4 można wyłożyć przed rozdziałami 2 i 3.

Od czytelnika wymaga się znajomości standardowych wykładów z analizy, algebry, teorii miary, analizy funkcjonalnej, rachunku prawdopodobieństwa oraz statystyki matematycznej przewidzianych w programach studiów matematycznych. Do podstawowych pojęć i twierdzeń z tych przedmiotów odwołuję się bez bliższych wyjaśnień lub odsyłania do podręczników.

Wrocław, wrzesień 2021 r.

Tadeusz Inglot





# 1. Wstęp

Niech  $X$  będzie zmienną losową o wartościach w przestrzeni mierzalnej  $(\mathcal{X}, \mathcal{A})$  oraz  $\mathcal{P}$  pewną rodziną rozkładów na  $\mathcal{X}$  i niech  $X_1, \dots, X_n$  będzie próbą prostą z rozkładu  $P \in \mathcal{P}$ . Produkt  $(\mathcal{X}^n, \mathcal{A}^n, \mathcal{P}^n) = (\mathcal{X}, \mathcal{A}, \mathcal{P})^n$  nazywamy modelem statystycznym. W dalszym ciągu wykładu, mówiąc o takim modelu, będziemy używać wygodnego terminu roboczego *model produktowy*.

Pojęcie modelu statystycznego definiuje się ogólniej, dopuszczając obserwacje o różnych rozkładach, a nawet zależne (co tutaj pomijamy). Niech  $X_1, \dots, X_n$  będą niezależnymi zmiennymi losowymi, gdzie  $X_i$  mają wartości w przestrzeniach  $(\mathcal{X}_i, \mathcal{A}_i, \mathcal{P}_i)$ ,  $i = 1, \dots, n$ , a  $\mathcal{P}_i$  są pewnymi rodzinami rozkładów. Wtedy przestrzeń produktową

$$(\mathcal{X}_1 \times \dots \times \mathcal{X}_n, \mathcal{A}_1 \times \dots \times \mathcal{A}_n, \mathcal{P}_1 \times \dots \times \mathcal{P}_n)$$

nazywamy modelem statystycznym. Przypuśćmy, że  $\tilde{\mathcal{P}}_0 \subset \tilde{\mathcal{P}} = \mathcal{P}_1 \times \dots \times \mathcal{P}_n$  jest ustalonym podzbiorem  $\tilde{\mathcal{P}}$  oraz  $\tilde{\mathcal{P}}_1 = \tilde{\mathcal{P}} \setminus \tilde{\mathcal{P}}_0$ . Rozważamy zagadnienie decyzyjne polegające na rozstrzygnięciu czy  $\tilde{P} \in \tilde{\mathcal{P}}_0$  czy  $\tilde{P} \in \tilde{\mathcal{P}}_1$  na podstawie próby  $X_1, \dots, X_n$ , gdzie  $\tilde{P}$  jest rozkładem tej próby (w modelu produktowym  $\tilde{P} = P^n$ ). Oznaczmy dwie konkurencyjne hipotezy  $H_j : \tilde{P} \in \tilde{\mathcal{P}}_j$ ,  $j = 0, 1$ . Rozważamy więc problem testowania  $H_0$  (hipoteza zerowa) przeciwko  $H_1$  (hipoteza alternatywna). Rozstrzygnięcia dokonuje się za pomocą testu statystycznego.

Bez straty ogólności możemy przyjąć, że rodzina  $\mathcal{P}$  (w modelu produktowym) jest sparametryzowana, tzn.  $\mathcal{P} = \{P_\gamma : \gamma \in \Gamma\}$ , gdzie  $\Gamma$  jest pewnym zbiorem parametrów. Wtedy, oznaczając  $\Gamma_0 = \{\gamma : P_\gamma \in \mathcal{P}_0\}$ , równoważnie  $H_0 : \gamma \in \Gamma_0$  przeciwko  $H_1 : \gamma \in \Gamma_1 = \Gamma \setminus \Gamma_0$ . Jeśli  $\Gamma$  jest podzbiorem  $\mathbb{R}^k$ ,  $k \geq 1$ , to mówimy o problemie parametrycznym, w przeciwnym wypadku nieparametrycznym. Często  $\Gamma$  ma strukturę produktową  $\Gamma = \Theta \times E$ . Wtedy parametr oznaczamy  $\gamma = (\vartheta, \eta)$ . Taka sytuacja ma miejsce przy testowaniu hipotezy  $H_0 : \gamma \in \Theta_0 \times E$  przeciwko  $H_1 : \gamma \in \Theta_1 \times E$ , gdzie  $\Theta_0$  jest pewnym podzbiorem  $\Theta$ , a  $\Theta_1 = \Theta \setminus \Theta_0$ .

Nieokreślony przez hipotezę parametr  $\eta \in E$  nazywamy parametrem zakłócającym (ang. nuisance parameter). Jeśli  $\Theta \subset \mathbb{R}^k$ ,  $k \geq 1$ , oraz  $E$  jest podzbiorem przestrzeni nieskończenie wymiarowej, to mówimy o problemie semiparametrycznym.

Problemy nieparametryczne są ważnymi zagadnieniami wnioskowania statystycznego. Prawie cały nasz wykład poświęcimy tym zagadnieniom i metodom konstrukcji testów nieparametrycznych. Dla prostoty ograniczymy się do testów prawostronnych niezrandomizowanych (co nie jest istotnym ograniczeniem). Niech  $T_n = T(X_1, \dots, X_n)$  będzie statystyką o wartościach rzeczywistych.

**Definicja 1.** Testem prawostronnym hipotezy  $H_0$  przeciwko  $H_1$  (w modelu produktowym) określonym przez statystykę testową  $T_n$  na poziomie istotności  $\alpha \in (0, 1)$  nazywamy funkcję  $\mathbf{1}_{C_{t_\alpha}}$ , gdzie

$$C_t = \{(x_1, \dots, x_n) \in \mathcal{X}^n : T(x_1, \dots, x_n) > t\}, \quad t \in \mathbb{R},$$

$\mathbf{1}_A$  oznacza funkcję charakterystyczną zbioru  $A$ , a wartość krytyczna  $t_\alpha$  jest równa

$$t_\alpha = \inf\{t \in \mathbb{R} : \sup_{P \in \mathcal{P}_0} P^n(C_t) \leq \alpha\}.$$

Jeśli  $\mathbf{1}_{C_{t_\alpha}} = 1$ , to  $H_0$  odrzucamy, w przeciwnym wypadku  $H_0$  przyjmujemy. Liczbę  $\sup_{P \in \mathcal{P}_0} P^n(C_{t_\alpha})$  nazywamy rozmiarem testu  $T$  (czyli określonego przez statystykę  $T_n$ ). Definicję 1 można przeformułować na dowolne modele, wprowadzając oczywiste zmiany.

W wielu klasycznych problemach nieparametrycznych hipotezę zerową można sprowadzić do znikania pewnej funkcji. Zobaczymy to na kilku ważnych przykładach.

**Przykład 1.** (*testowanie zgodności na prostej*) Niech  $\mathcal{X} = \mathbb{R}$ ,  $\mathcal{P}$  będzie rodziną rozkładów na  $\mathbb{R}$ , a  $X_1, \dots, X_n$  próbą z rozkładu  $P \in \mathcal{P}$  o dystrybuancie  $F(x)$ . Dla ustalonego  $P_0 \in \mathcal{P}$  o ciągłej dystrybuancie  $F_0(x)$  rozważamy testowanie hipotezy prostej  $H_0 : P = P_0$  przeciwko  $H_1 : P \neq P_0$ . Oznaczmy  $g(x) = F(x) - F_0(x)$ . Wtedy równoważnie możemy napisać  $H_0 : g = 0$ . Zwykle rozważa się próbę transformowaną na odcinek  $[0, 1]$  przez nałożenie dystrybuanty hipotetycznej  $F_0(x)$ . Jeśli więc  $U_i = F_0(X_i)$ ,  $i = 1, \dots, n$ , to zmienne losowe  $U_i$  mają, przy prawdziwości hipotezy  $H_0$ , rozkład jednostajny na odcinku  $[0, 1]$  (por.

lemat na początku rozdziału 4) i zagadnienie sprowadza się do testowania jednostajności i rozstrzygnięcia czy transformowana funkcja  $g$ , czyli  $g \circ F_0^{-1}(t) = F \circ F_0^{-1}(t) - t$ ,  $t \in (0, 1)$ , znika. Temu problemowi poświęcony jest rozdział 4.

**Przykład 2.** (*testowanie niezależności*) Niech  $\mathcal{X} = \mathbb{R}^2$ , a  $\mathcal{P}$  będzie rodziną rozkładów na płaszczyźnie o ciągłych dystrybuantach brzegowych oznaczanych przez  $F(x)$  oraz  $G(y)$  i niech  $(X_1, Y_1), \dots, (X_n, Y_n)$  będzie próbą z rozkładu  $P \in \mathcal{P}$  o dystrybuancie  $H(x, y)$ . Rozważamy testowanie hipotezy o niezależności rozkładów brzegowych  $H_0 : H(x, y) = F(x)G(y)$ ,  $x, y \in \mathbb{R}$ . Oznaczmy  $g(x, y) = H(x, y) - F(x)G(y)$ . Wtedy równoważnie możemy napisać  $H_0 : g = 0$ . Analogicznie jak w poprzednim przykładzie, nałożenie dystrybuant brzegowych na obserwacje prowadzi do próby transformowanej  $(U_i, V_i) = (F(X_i), G(Y_i))$ ,  $i = 1, \dots, n$ , i problem sprowadza się do testowania niezależności na kwadracie jednostkowym. Równoważnie możemy napisać  $H_0 : g(F^{-1}(s), G^{-1}(t)) = C(s, t) - st \equiv 0$ , gdzie  $C(s, t) = H(F^{-1}(s), G^{-1}(t))$  jest funkcją łącznikową (ang. copula function). Nieokreślone przez hipotezę dystrybuanty brzegowe  $F, G$  są parametrami zakłócającymi w rozważanym problemie. Zagadnieniu testowania niezależności poświęcone są zad. 44-46 oraz ćwiczenie laboratoryjne 7.

**Przykład 3.** (*testowanie symetrii*) Niech  $\mathcal{X} = \mathbb{R}$ , a  $\mathcal{P}$  będzie rodziną rozkładów  $P$  na prostej o ciągłych dystrybuantach oznaczanych przez  $F(x)$ . Testujemy hipotezę  $H_0 : P$  jest symetryczny względem 0. Oznaczmy  $F_s(x) = \frac{1}{2}(F(x) + 1 - F(-x))$ . Rozkład  $P$  jest symetryczny względem 0 wtedy i tylko wtedy, gdy  $F - F_s = 0$ . Podobnie jak w poprzednich przykładach, transformujemy dane na odcinek jednostkowy przez nałożenie dystrybuanty  $F_s(x)$ . Wtedy  $F \circ F_s^{-1} = A$  jest funkcją absolutnie ciągłą na  $[0, 1]$  o pochodnej oznaczanej przez  $a$ . Zatem równoważnie testujemy hipotezę  $H_0 : g = 0$ , gdzie  $g(t) = a(t) - 1$ . Nieokreślona przez hipotezę  $H_0$  dystrybuanta  $F_s(x)$  jest parametrem zakłócającym.

Dwa następne przykłady dotyczą modeli, w których obserwacje mogą mieć różne rozkłady.

**Przykład 4.** (*testowanie stałości regresji*) Niech  $r(t)$ ,  $t \in [0, 1]$ , bę-

dzie nieznaną ciągłą funkcją (regresji) o całce równej 0. Obserwujemy proces stochastyczny  $X_t = m + r(t) + \sigma\varepsilon_t$ ,  $t \in [0, 1]$ , gdzie  $\varepsilon_t$  jest szumem losowym o średniej 0 i wariancji 1 i rozkładach jednowymiarowych o tej samej dystrybuancie  $F(x)$ . Wybieramy różne punkty  $t_1, \dots, t_n$  z odcinka jednostkowego i otrzymujemy próbę  $X_{t_1}, \dots, X_{t_n}$ . Zmienne losowe  $X_{t_i}$  mają na ogół rozkłady o różnych dystrybuantach  $F((x - m - r(t_i))/\sigma)$ . Testujemy hipotezę  $H_0 : r = 0$ . Temu zagadnieniu jest poświęcone ćwiczenie laboratoryjne 5.

**Przykład 5.** (*testowanie jednorodności, problem dwóch prób*) Niech  $n_1 = n_1(n)$ ,  $n_2 = n_2(n)$  będą ciągami liczb naturalnych, takimi że  $n_1 + n_2 = n$  i niech  $P, Q$  będą dwoma rozkładami na prostej o ciągłych dystrybuantach  $F(x), G(x)$ . Rozważamy model  $(\mathbb{R}^n, \mathcal{R}^n, P^{n_1} \times Q^{n_2})$ , próbę  $X_1, \dots, X_{n_1}, Y_1, \dots, Y_{n_2}$  i hipotezę  $H_0 : P = Q$ . Oznaczmy  $H_n(x) = (n_1F(x) + n_2G(x))/n$ . Po transformacji próby na odcinek  $(0, 1)$  za pomocą dystrybuanty  $H_n(x)$  różnica dystrybuant  $F(x) - G(x)$  przyjmuje postać  $g(t) = F \circ H_n^{-1}(t) - G \circ H_n^{-1}(t)$ ,  $t \in (0, 1)$ , i testujemy hipotezę  $H_0 : g = 0$ . Temu zagadnieniu są poświęcone zad. 33-42 oraz ćwiczenie laboratoryjne 6.

Powyższe przykłady problemów testowania i sprowadzenia ich do znikania pewnej funkcji tłumaczą podobieństwa konstrukcji testów w wielu istotnie różnych zagadnieniach. Jednak każde z nich ma swoją własną specyfikę wymagającą oddzielnego rozpatrzenia. Aby przedstawić możliwie szeroko ogólne idee konstrukcji testów, powtarzające się w różnych problemach, uczynimy to skupiając uwagę na testach zgodności.

W dalszym ciągu wykładu rozważamy wyłącznie modele produktowe.

## 2. Testowanie hipotez prostych

Rozważamy model  $(\mathcal{X}, \mathcal{A}, \mathcal{P})^n$ , gdzie  $\mathcal{P} = \{P_0, P_1\}$  i testowanie hipotez prostych  $H_0 : P = P_0$  przeciwko  $H_1 : P = P_1$ . Niech  $\lambda$  będzie miarą dominującą rozkłady  $P_0$  i  $P_1$ , np.  $\lambda = P_0 + P_1$ . Oznaczmy  $p_0 = dP_0/d\lambda$ ,  $p_1 = dP_1/d\lambda$  gęstości obu konkurujących rozkładów. Wówczas statystykę (logarytm ilorazu funkcji wiarygodności)

$$V_n = V(X_1, \dots, X_n) = \sum_{i=1}^n \log \frac{p_1(X_i)}{p_0(X_i)}$$

nazywamy statystyką Neymana-Pearsona, a test (prawostronny) oparty na niej testem Neymana-Pearsona (NP).

**Lemat Neymana-Pearsona.** Dla każdego  $\alpha \in (0, 1)$  test Neymana-Pearsona o rozmiarze  $\alpha$  jest najmocniejszym testem (niezrandomizowanym)  $H_0$  przeciwko  $H_1$ , tzn. dla każdego testu  $T$  o tym samym rozmiarze  $\alpha$  moc  $\beta_V(P_1)$  testu  $V$  jest nie mniejsza niż moc  $\beta_T(P_1)$  testu  $T$ , czyli  $\beta_V(P_1) \geq \beta_T(P_1)$ .

Dowód tego twierdzenia jest podany poniżej w ogólniejszej wersji jako twierdzenie 3. Można zapytać, jak duża jest ta największa moc  $\beta_V(P_1) = \beta_V(P_1, n)$ . Aby odpowiedzieć na to pytanie, określimy odległość (informację) Kullbacka-Leiblera rozkładu  $P_0$  od  $P_1$  wzorem

$$D(P_0||P_1) = D(p_0||p_1) = \int_{\mathcal{X}} p_0 \log \frac{p_0}{p_1} d\lambda \in [0, \infty],$$

gdy  $P_0$  jest absolutnie ciągła względem  $P_1$ , tj.  $P_0 \ll P_1$ , oraz  $+\infty$  w przeciwnym wypadku. Następujące twierdzenie zostało udowodnione przez Chernoffa (1956).

**Twierdzenie 1 (Lemat Steina).** Dla dowolnego  $\alpha \in (0, 1)$  i testu Neymana-Pearsona na poziomie istotności  $\alpha$  mamy

$$\lim_{n \rightarrow \infty} \frac{1}{n} \log(1 - \beta_V(P_1, n)) = -D(P_0||P_1).$$

Innymi słowy,  $\beta_V(P_1, n) = 1 - \exp\{-nD(P_0||P_1) + o(n)\}$ , czyli moc dąży wykładniczo do 1 i  $D(P_0||P_1)$  określa tempo wykładniczego zanikania prawdopodobieństwa błędu drugiego rodzaju. Człon  $o(n)$  zależy od przyjętego poziomu istotności i dla konkretnych wartości  $n$  wcale nie musi być mały w porównaniu z głównym członem.

**Dowód.** Oznaczmy przez  $t_{\alpha n}$  dokładną wartość krytyczną testu NP,  $A = \{V_n > t_{\alpha n}\}$  oraz dla dowolnego  $\varepsilon > 0$

$$B_\varepsilon = \{-nD(P_0||P_1) - n\varepsilon \leq V_n \leq -nD(P_0||P_1) + n\varepsilon\}.$$

Ponadto, dla  $j = 0, 1$  oznaczmy przez  $p_{jn}(x) = \prod_{i=1}^n p_j(x_i)$  gęstość łączną próby z rozkładu  $P_j$ . Wtedy  $V_n = \log(p_{1n}/p_{0n})$  i

$$E_0 V_n = n \int_{\mathcal{X}} p_0 \log \frac{p_1}{p_0} d\lambda = -nD(P_0||P_1).$$

Stąd i z prawa wielkich liczb Chinczyzna mamy  $P_0^n(B_\varepsilon^c) \rightarrow 0$ . Ponieważ  $\alpha \in (0, 1)$ , to  $t_{\alpha n} \leq -nD(P_0||P_1) + n\varepsilon$  dla dostatecznie dużych  $n$ . Z nierówności Markowa

$$\begin{aligned} 1 - \beta_V(P_1, n) &= P_1^n(A^c) = P_1^n\left(\frac{p_{1n}}{p_{0n}} \leq e^{t_{\alpha n}}\right) = P_1^n\left(\frac{p_{0n}}{p_{1n}} \geq e^{-t_{\alpha n}}\right) \\ &\leq e^{t_{\alpha n}} \int_{\mathcal{X}^n} \frac{p_{0n}}{p_{1n}} p_{1n} d\lambda^n = e^{t_{\alpha n}}, \end{aligned}$$

co łącznie z poprzednim oszacowaniem daje  $\log(1 - \beta_V(P_1)) \leq t_{\alpha n} \leq -nD(P_0||P_1) + n\varepsilon$ .

Z drugiej strony na zbiorze  $B_\varepsilon$  mamy  $p_{1n}/p_{0n} = e^{V_n} \geq e^{-nD(P_0||P_1) - n\varepsilon}$  i stąd

$$\begin{aligned} 1 - \beta_V(P_1, n) &\geq P_1^n(A^c \cap B_\varepsilon) = \int_{A^c \cap B_\varepsilon} p_{1n} d\lambda^n = \int_{A^c \cap B_\varepsilon} \frac{p_{1n}}{p_{0n}} p_{0n} d\lambda^n \\ &= e^{-nD(P_0||P_1) - n\varepsilon} P_0^n(A^c \cap B_\varepsilon) \geq e^{-nD(P_0||P_1) - n\varepsilon} (P_0^n(A^c) - P_0^n(B_\varepsilon^c)) \\ &\geq e^{-nD(P_0||P_1) - n\varepsilon} (1 - \alpha - o(1)), \end{aligned}$$

co daje  $\log(1 - \beta_V(P_1)) \geq -nD(P_0||P_1) - n\varepsilon + \log(1 - \alpha - o(1))$ . Z dowolności  $\varepsilon$  i powyższego oszacowania z góry wynika teza lematu.  $\square$

Dla zobrazowania wielkości prawdopodobieństwa błędu II rodzaju weźmiemy jako  $P_0$  rozkład jednostajny na  $[0,1]$ , a jako  $P_1$  rozkład beta z parametrami  $p = q = 1.5$ . Zatem  $p_0(t) \equiv 1$  oraz  $p_1(t) = \left(8\sqrt{t(1-t)}\right) / \pi$ ,  $t \in [0, 1]$ . Wtedy  $D(p_0||p_1) = \int_0^1 \log(\pi/\sqrt{64t(1-t)})dt \approx 0.0653$ . W tabeli poniżej podane są empiryczne prawdopodobieństwa błędów II rodzaju (w procentach) dla kilku poziomów istotności  $\alpha$  i kilku liczebności prób  $n$ , a w ostatnim wierszu wartości  $e^{-nD(P_0||P_1)}$ . Zauważmy, że wartości w ostatnim wierszu nie zależą od poziomu istotności, a rzeczywiste prawdopodobieństwo błędu istotnie od niego zależy.

Prawdopodobieństwa błędów II rodzaju dla testu NP w %

$n$	10	20	30	40	50	60	70	80	90	100
$\alpha = 0.3$	30	16	9	4.9	2.7	1.5	0.8	0.4	0.25	0.13
$\alpha = 0.25$	37	22	12	6.8	3.7	2.0	1.1	0.7	0.32	0.16
$\alpha = 0.2$	45	28	17	9.4	5.5	3.4	1.9	1.4	0.68	0.43
$\alpha = 0.1$	65	45	30	21.7	14.6	9.5	6.4	4.1	2.62	1.71
$\alpha = 0.05$	79	61	50	36.3	26.3	18.9	13.6	9.2	6.56	4.41
$e^{-nD(P_0  P_1)}$	52	27	14	7.3	3.8	2.0	1.0	0.5	0.28	0.15

Widać, że ostatni wiersz dość dobrze odpowiada prawdopodobieństwom błędów II rodzaju dla poziomu istotności 0.25, dużo większego niż stosowany w praktyce.

Ze względu na zamienność roli  $P_0$  i  $P_1$  oraz poziomu istotności i mocy testu prawdziwa jest dualna wersja lematu Steina.

**Twierdzenie 2.** Dla dowolnego  $\beta \in (0, 1)$  niech  $\alpha_V(P_0) = \alpha_V(P_0, n)$  będzie poziomem istotności testu NP, którego moc jest równa  $\beta$ . Wtedy

$$\lim_{n \rightarrow \infty} \frac{1}{n} \log \alpha_V(P_0, n) = -D(P_1||P_0).$$

Wróćmy teraz do dowodu lematu Neymana-Pearsona w ogólniejszej wersji. Niech  $\mathcal{P} = \{P_\gamma : \gamma \in \Gamma\}$  będzie pewną (niepustą) rodziną rozkładów na  $(\mathcal{X}, \mathcal{A})$ , przy czym  $P_0 \notin \mathcal{P}$ . Rozważamy testowanie hipotezy  $H_0 : P = P_0$  przeciwko  $H_1 : P \in \mathcal{P}$ . Przypuśćmy, że  $\Gamma$  ma strukturę miarową  $(\Gamma, \mathcal{B}, \omega)$ , gdzie  $\mathcal{B}$  jest  $\sigma$ -ciałem podzbiorów  $\Gamma$ , a  $\omega$  rozkładem a priori na  $(\Gamma, \mathcal{B})$ . Załóżmy ponadto, że dla pewnej miary dominującej  $\lambda$  mamy  $P_0 \ll \lambda$  oraz  $P_\gamma \ll \lambda$  dla wszystkich  $\gamma \in \Gamma$ . Oznaczmy  $p_\gamma = dP_\gamma/d\lambda$  oraz  $p_{\gamma n}(x) = \prod_{i=1}^n p_\gamma(x_i)$ . Rozważmy statystykę

$$V_n^* = \int_{\Gamma} \frac{p_{\gamma n}}{p_{0n}} d\omega(\gamma).$$

Test prawostronny  $V^*$  nazywamy optymalnym testem bayesowskim dla rozważanego problemu, gdyż prawdziwe jest następujące twierdzenie.

**Twierdzenie 3.** Dla dowolnego  $t > 0$  niech  $\alpha_t^* = P_0^n(V_n^* > t)$ , a  $\bar{\beta}_{\alpha_t^*}^* = \int_{\Gamma} P_{\gamma}^n(V_n^* > t) d\omega(\gamma)$  będzie mocą średnią testu  $V^*$  o rozmiarze  $\alpha_t^*$ . Wtedy dla dowolnego testu  $T$  hipotezy  $H_0$  przeciwko  $H_1$  o rozmiarze  $\alpha \in (0, 1)$  zachodzi relacja

$$t(\alpha - \alpha_t^*) + (\bar{\beta}_{\alpha_t^*}^* - \bar{\beta}_{\alpha}) \geq 0,$$

gdzie  $\bar{\beta}_{\alpha} = \int_{\Gamma} P_{\gamma}^n(T_n > t_{\alpha n}) d\omega(\gamma)$  jest mocą średnią testu  $T$ . W szczególności dla  $\alpha$  i  $t$  takich, że  $\alpha_t^* = \alpha$  mamy  $\bar{\beta}_{\alpha}^* \geq \bar{\beta}_{\alpha}$ , tzn. dla dowolnego ustalonego rozkładu a priori test  $V^*$  ma największą moc średnią wśród wszystkich testów o tym samym rozmiarze  $\alpha_t^*$ .

Zauważmy, że twierdzenie 1 jest szczególnym przypadkiem twierdzenia 3, gdy wybierzemy rozkład a priori  $\omega$  skoncentrowany na ustalonym punkcie zbioru  $\Gamma$ .

**Dowód.** Oznaczmy  $A_t^* = \{V_n^* > t\}$  oraz  $A = \{T_n > t_{\alpha n}\}$ . Wtedy mamy

$$\begin{aligned} & t(\alpha - \alpha_t^*) + (\bar{\beta}_{\alpha_t^*}^* - \bar{\beta}_{\alpha}) \\ &= t \int_A p_{0n} d\lambda^n - t \int_{A_t^*} p_{0n} d\lambda^n + \int_{A_t^*} \int_{\Gamma} p_{\gamma n} d\omega(\gamma) d\lambda^n - \int_A \int_{\Gamma} p_{\gamma n} d\omega(\gamma) d\lambda^n \\ &= \int_{A_t^*} \int_{\Gamma} \left( \frac{p_{\gamma n}}{p_{0n}} - t \right) p_{0n} d\omega(\gamma) d\lambda^n - \int_A \int_{\Gamma} \left( \frac{p_{\gamma n}}{p_{0n}} - t \right) p_{0n} d\omega(\gamma) d\lambda^n = \\ & \int_{A_t^* \cap A^c} \left( \int_{\Gamma} \frac{p_{\gamma n}}{p_{0n}} d\omega(\gamma) - t \right) p_{0n} d\lambda^n - \int_{A_t^* \cap A} \left( \int_{\Gamma} \frac{p_{\gamma n}}{p_{0n}} d\omega(\gamma) - t \right) p_{0n} d\lambda^n \geq 0, \end{aligned}$$

gdyż, z określenia  $V_n^*$ , na zbiorze  $A_t^*$  wyrażenie w nawiasie w pierwszej całce jest dodatnie, a w drugiej całce na zbiorze  $A_t^{*c}$  niedodatnie. To kończy dowód.  $\square$

Dla optymalnego testu bayesowskiego, przy odpowiedniej regularno-



ści modelu (szczegółowe sformułowanie pomijamy), prawdziwy jest odpowiednik lematu Steina w postaci  $\log(1 - \bar{\beta}_\alpha^*) = -D(p_{0n} || f_n) + O(1)$ , gdzie  $f_n(x) = \int_\Gamma p_{\gamma n}(x) d\omega(\gamma)$  (Clarke i Barron, 1990).

Można zapytać, jak duża jest różnica (strata) między średnią mocą optymalnego testu bayesowskiego i mocą testu NP skonstruowanego dla ustalonego rozkładu  $P_1 \in \mathcal{P}$ . Aby nieco przybliżyć odpowiedź na to pytanie, rozważmy skończoną rodzinę rozkładów  $\mathcal{P} = \{P_1, \dots, P_k\}$  o gęstościach  $p_j$ ,  $j = 1, \dots, k$ , takich że dla odpowiednio dobranego  $c$  funkcje  $c(p_j - p_0)$  tworzą układ ortonormalny względem  $P_0$ . Wtedy, mówiąc nie całkiem precyzyjnie, strata mocy w środkowym zakresie wyraża się przez entropię Shannona rozkładu a priori  $H(\omega) = -\sum_{j=1}^k w_j \log_2 w_j$ , gdzie  $w_j = \omega(\{j\})$ . Dokładniej, przy mocy testu NP w przedziale  $[0.5, 0.9]$  (tj. przy odpowiednio dobranym do liczebności próby współczynnika  $c$ ), zgrubne oszacowanie tej różnicy wynosi  $0.1H(\omega)$ . Przyjmując  $w_j = 1/k$ ,  $j = 1, \dots, k$ , czyli jednostajny rozkład a priori, strata średniej mocy do mocy testu NP wynosi ok.  $0.1 \log_2 k$ .