

Modele probabilistyczne zjawisk losowych

Pojęcia podstawowe:

Zdarzenia elementarne: najprostsze zdarzenie mogące być wyróżnione dla danego doświadczenia losowego.

Ω - zbiór zdarzeń elementarnych.

Zdarzenie losowe: dowolny podzbiór zbioru zdarzeń elementarnych Ω

Rodzina zdarzeń losowych (σ -ciało podzbiorów zbioru zdarzeń elementarnych Ω) \mathcal{F} - rodzina podzbiorów zdarzeń elementarnych taka, że

$$\mathcal{F} \subseteq \Omega$$

jeżeli $A \in \mathcal{F}$ i $B \in \mathcal{F}$, to $A \cup B \in \mathcal{F}$

jeżeli $A \in \mathcal{F}$ i $B \in \mathcal{F}$, to $A \cap B \in \mathcal{F}$

jeżeli $A \in \mathcal{F}$, to $\bar{A} \in \mathcal{F}$

Prawdopodobieństwo zdarzenia losowego A : funkcja

rzeczywista $P(A)$ na rodzinie zdarzeń \mathcal{F} , taka że

1) dla każdego $A \in \mathcal{F}$, $P(A) \geq 0$

2) $P(\Omega)=1$

3) dla zdarzeń parami rozłącznych

$$P(A_1 \cup A_2 \dots) = P(A_1) + P(A_2) + \dots$$

Przestrzeń probabilistyczna: trójka uporządkowana

$(\Omega, \mathcal{F}, \mathbf{P})$. Określając przestrzeń probabilistyczną określamy model probabilistyczny danego zjawiska.

Zmienna losowa

Niech dana będzie przestrzeń probabilistyczna $(\Omega, \mathcal{F}, \mathbf{P})$. Funkcję X określoną na przestrzeni zdarzeń elementarnych Ω , o wartościach rzeczywistych oraz taką, że dla każdego $t \in \mathcal{R}$ zbiór

$$\{\omega \in \Omega: X(\omega) < t\}$$

jest zdarzeniem (czyli należy do \mathcal{F}) będziemy nazywać *zmienną losową*.

Interpretacja:

Zmienna losowa jest to funkcja przyporządkowująca podzbiorem zbioru zdarzeń elementarnych (zdarzeniom losowym) odpowiednie podzbiory liczb rzeczywistych.

Zmienne losowe oznaczamy **dużymi** literami; na przykład X .

To, co zaobserwujemy w konkretnym doświadczeniu nazywamy **realizacją zmiennej losowej** i oznaczamy **małą** literą; na przykład x .

Przykłady zmiennych losowych:

Przykład 1 (zmienna skokowa – skończony zbiór wartości)

Badanie jakości wyrobów. Każdy badany wyrób oceniamy jako zgodny lub niezgodny (wadliwy) z wymaganiami. Określmy zmienną

$$X(\omega) = \begin{cases} 1 & \text{jeśli } \omega \equiv \text{wyrób jest niezgodny} \\ 0 & \text{jeśli } \omega \equiv \text{wyrób jest zgodny} \end{cases}$$

Przykład 2 (zmienna ciągła – nieskończony zbiór wartości)

Badaniu podlega roczny zysk różnych firm. Firmy pobierane są do badań w sposób losowy. Zmienna losowa X przyjmuje dowolne wartości rzeczywiste (model !!!), przy czym dla poszczególnych wylosowanych firm wartości te są na ogół różne.

Przykład 3 (zmienna skokowa – nieskończony, ale przeliczalny zbiór wartości)

Operator telefonicznej sieci komórkowej analizuje dzienną liczbę połączeń. Niech $\Omega = \{\omega_1, \omega_2, \dots\}$ gdzie ω_i oznacza zdarzenie elementarne polegające na zaobserwowaniu i połączeń. Dzienna liczba połączeń opisana jest zmienną losową

$$X(\omega_i) = i, \quad i = 0, 1, 2, \dots$$

Rozkład prawdopodobieństwa

Rozkład prawdopodobieństwa zmiennej losowej X jest funkcją, która każdemu podzbiorowi możliwych wartości tej zmiennej przypisuje liczbę z domkniętego przedziału $[0,1]$.

Rozkład prawdopodobieństwa jest jednoznacznie określony funkcją, którą nazywamy dystrybuantą zmiennej losowej X definiowaną jako

$$F(x) = P(\{\omega \in \Omega: X(\omega) < x\}) = P(X < x)$$

Własności dystrybuanty:

1. $0 \leq F(x) \leq 1$, dla dowolnych $x \in \mathcal{R}$
2. $F(-\infty) = 0$, $F(\infty) = 1$
3. $F(x) \leq F(y)$, jeśli tylko $x < y$
4. $F(x^-) = F(x)$, gdzie $F(x^-)$ oznacza granicę lewostronną F w punkcie x (ciągłość lewostronna)

Uwaga: Jeśli jakaś funkcja F ma własności 1) - 4), to jest ona dystrybuantą jakiejś zmiennej losowej

Dystrybuanta dyskretnej (skokowej) zmiennej losowej X
dana jest zależnością:

$$F(x) = \sum_{x_i < x} P(X = x_i)$$

gdzie

$$P(X = x_i) = P(\{\omega \in \Omega: X(\omega) = x_i\}) = p_i, \quad \text{dla } x_i \in W$$

$$\sum_i p_i = 1,$$

jest tzw. **funkcją prawdopodobieństwa**.

Dystrybuanta ciągłej zmiennej losowej X dana jest
zależnością:

$$F(x) = \int_{-\infty}^x f(x) dx$$

gdzie **nieujemna funkcja $f(x)$, określona i całkowna do jedynki na całej osi** jest **funkcją gęstości (gęstością)** zmiennej losowej X .

Przykłady rozkładów prawdopodobieństwa

a) Rozkład dwupunktowy

$$X = \begin{cases} 0, & \text{zdarzenie nie zaszło} \\ 1, & \text{zdarzenie zaszło} \end{cases}$$

$$P(X = 1) = p, \quad P(X = 0) = 1 - p, \quad 0 \leq p \leq 1$$

b) Rozkład dwumianowy (Bernouillego)

$$P(X = k) = \binom{n}{k} p^k (1-p)^{n-k}, \quad 0 \leq p \leq 1, \quad k = 0, 1, \dots, n$$

gdzie

$$\binom{n}{k} = \frac{n!}{k!(n-k)!}$$

$$n! = 1 * 2 * \dots * (n-1) * n, \quad 0! = 1$$

c) Rozkład Poissona

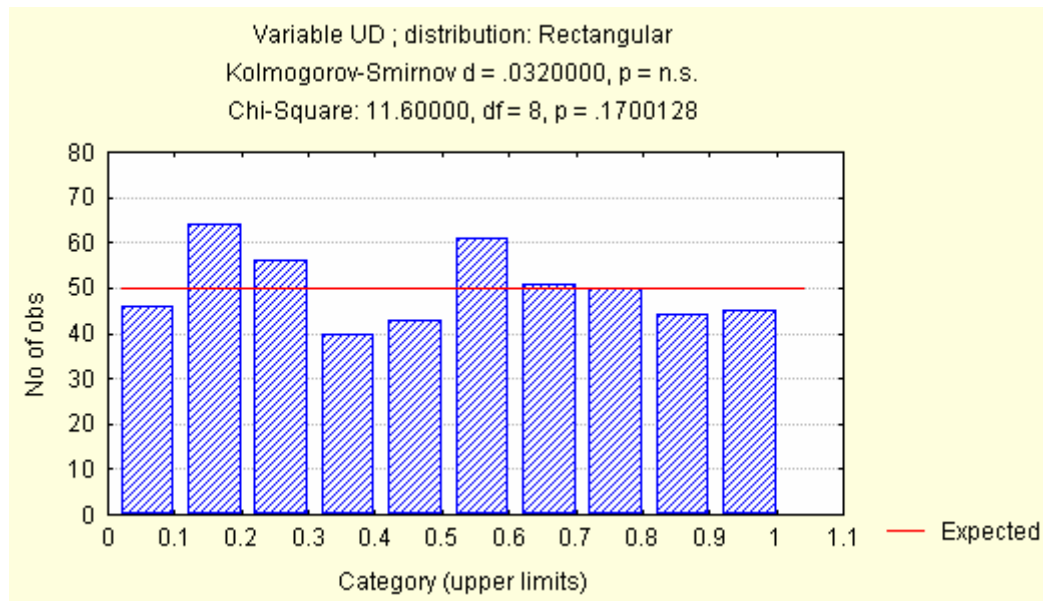
$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad \lambda > 0, \quad k = 0, 1, \dots$$

d) Rozkład geometryczny

$$P(X = k) = p(1-p)^{k-1}, \quad k = 1, 2, \dots$$

e) Rozkład jednostajny (równomierny).

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




f) Rozkład normalny (Gausa)

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right), \sigma > 0$$

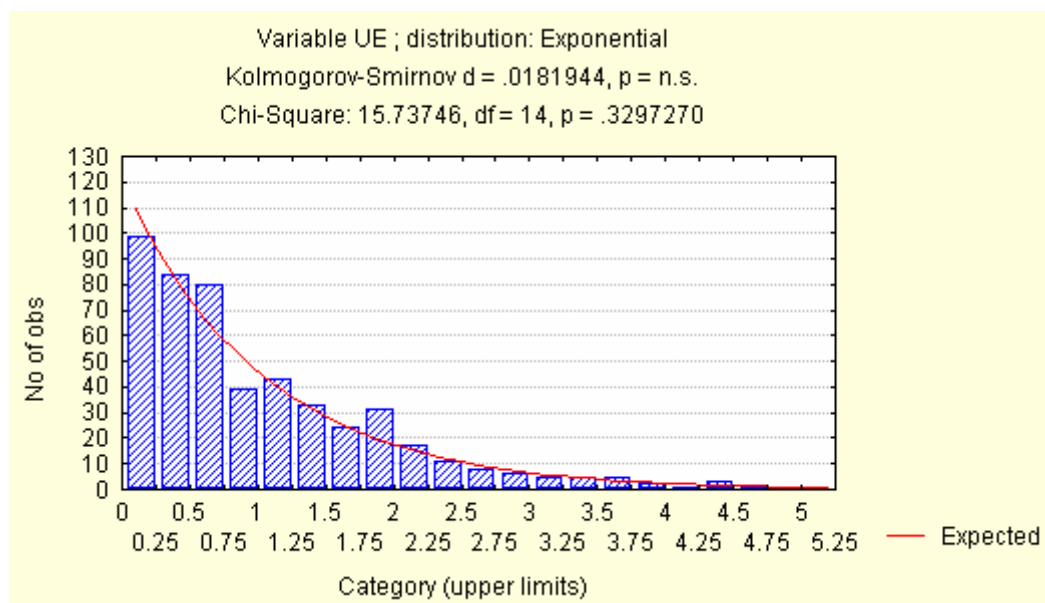
$$F(x) = \Phi\left(\frac{x-\mu}{\sigma}\right)$$

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x \exp\left(-\frac{1}{2}z^2\right) dz$$



g) Rozkład wykładniczy

$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & x \geq 0 \\ 0, & x < 0 \end{cases}$$



Charakterystyki liczbowe (*parametry*) rozkładów zmiennych losowych

Wartość oczekiwana

$$E(X) = \sum_{i=1}^n x_i P(X = x_i)$$

$$E(X) = \sum_{i=1}^{\infty} x_i P(X = x_i)$$

$$E(X) = \int_{-\infty}^{\infty} x f(x) dx$$

Wariancja

$$V(X) = \sum_{i=1}^n [x_i - E(X)]^2 P(X = x_i)$$

$$V(X) = \sum_{i=1}^{\infty} [x_i - E(X)]^2 P(X = x_i)$$

$$V(X) = \int_{-\infty}^{\infty} [x - E(X)]^2 f(x) dx$$

$$V(X) = E(X^2) - [E(X)]^2$$

Odchylenie standardowe

$$\sigma_X = \sigma = \sqrt{V(X)}$$

Wnioskowanie statystyczne o zjawiskach losowych

Przestrzeń statystyczna

Niech Ω oznacza przestrzeń zdarzeń elementarnych związanych z jakimś **eksperymentem losowym**. Wynik eksperymentu losowego możemy opisać trójką $(\Omega, \mathcal{F}, \mathcal{P})$ zwaną **przestrzenią statystyczną**, gdzie $\mathcal{P} = \{P_\theta, \theta \in \Theta\}$ jest **rodziną rozkładów prawdopodobieństwa** opisującą wynik eksperymentu., a Θ jest jakąś przestrzenią parametrów.

Zazwyczaj **nie znamy** rodziny rozkładów prawdopodobieństwa opisujących dany eksperyment losowy. Dokonujemy jednak często pewnego **założenia**, że jest to rodzina określonego typu (np. rodzina rozkładów normalnych) indeksowana parametrem, którego wartość należy do pewnej przestrzeni $\Theta \subseteq \mathcal{R}^k$. Mówimy wówczas, że eksperyment opisany jest *k-wymiarowym modelem parametrycznym*.

Jeżeli nie precyzujemy rodziny rozkładów prawdopodobieństwa (przestrzeń Θ nie może być przedstawiona jako podzbiór \mathcal{R}^k), to mówimy, że eksperyment opisany jest *modelem nieparametrycznym*.

Eksperyment statystyczny

X - obserwowana zmienna losowa

Obserwujemy **próbę losową o licznosci n elementów**.

$$X_1, X_2, \dots, X_n$$

Jeżeli tworzące próbę zmienne losowe X_1, X_2, \dots, X_n są *niezależne* i mają *ten sam rozkład*, to taką próbę nazywamy **próbą losową prostą**.

Niech $T=t(X_1, X_2, \dots, X_n)$ będzie pewną funkcją, której argumentami będą wyniki eksperymentu losowego. Funkcję tę będziemy nazywać **statystyką**.

Ponieważ wyniki eksperymentu losowego są **zmiennymi losowymi** każda **statystyka** jest też **zmienną losową** o rozkładzie prawdopodobieństwa uzależnionym od rozkładu prawdopodobieństwa obserwowanej zmiennej losowej X .

Przykłady statystyk

a) Średnia

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

b) Wariancja

Jeżeli wartość θ jest **nieznana**, to *wariancją* nazywamy statystykę

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

Zadania statystyki

Estymacja punktowa parametrów rozkładu prawdopodobieństwa

Estymacja punktowa - oszacowanie nieznanego parametru θ na podstawie **obserwacji** uzyskanych w rezultacie wykonania eksperymentu losowego. Oszacowanie podane jest jako **konkretna** wartość $\theta \in \Theta$.

Niech $T=t(X_1, X_2, \dots, X_n)$ będzie pewną funkcją, której argumentami będą wyniki eksperymentu losowego.

Zakładamy, że obserwowana w eksperymencie zmienna losowa X ma rozkład prawdopodobieństwa zależny od pewnego parametru $\theta \in \Theta$.

Każdą statystykę $T=t(X_1, X_2, \dots, X_n)$, która przyjmuje wartości z przestrzeni parametrów Θ będziemy nazywać estymatorem parametru $\theta \in \Theta$.

Własności estymatorów

a) Zgodność

Niech X_1, X_2, \dots będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie zależnym od parametru rzeczywistego $\theta \in \Theta$. Niech $\theta_n = \theta_n(X_1, X_2, \dots, X_n)$ będzie estymatorem parametru $\theta \in \Theta$ otrzymanym na podstawie obserwacji próby losowej X_1, X_2, \dots, X_n .

Mówimy, że **estymator θ_n jest zgodny**, jeżeli dla każdego $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P(|\theta_n - \theta| \geq \varepsilon) = 0$$

Własność zgodności oznacza, że dla dostatecznie dużych licznosci próby estymator przyjmuje z dużym prawdopodobieństwem wartości bliskie estymowanemu parametrowi θ .

b) Nieobciążoność

Niech $\theta_n = \theta_n(X_1, X_2, \dots, X_n)$ będzie estymatorem parametru $\theta \in \Theta$ otrzymanym na podstawie obserwacji próby losowej X_1, X_2, \dots, X_n . Jeżeli

$$E(\theta_n((X_1, X_2, \dots, X_n))) = \theta$$

to mówimy, że estymator θ_n jest nieobciążony.

Obciążeniem estymatora θ_n nazywamy wielkość $b(\theta) = E(\theta_n) - \theta$.

Jeżeli dla każdego $\theta \in \Theta$ obciążenie estymatora θ_n dąży do zera, przy $n \rightarrow \infty$, to estymator θ_n będziemy nazywać estymatorem asymptotycznie nieobciążonym.

c) Efektywność

Może być wiele estymatorów danego parametru θ , a spośród nich może być wiele estymatorów *nieobciążonych*. Estymatory te możemy porównywać między sobą porównując ich *wariancje*.

Estymator nieobciążony o **najmniejszej wariancji**, o ile taki istnieje, nazywamy estymatorem efektywnym.

Jeżeli własność efektywności uzyskujemy wtedy, gdy $n \rightarrow \infty$, to nieobciążony estymator θ_n będziemy nazywać estymatorem asymptotycznie efektywnym.

Estymacja metodą największej wiarygodności

Estymujemy nieznaną wartość parametru θ rozkładu prawdopodobieństwa zmiennej losowej X . Przez $p(x, \theta)$ oznaczmy odpowiednio gęstość rozkładu prawdopodobieństwa zmiennej losowej X , w przypadku, gdy jest ona typu ciągłego, albo też funkcję prawdopodobieństwa, w przypadku, gdy zmienna losowa X jest typu skokowego.

W przypadku obserwacji zmiennej losowej X w próbie losowej o liczności n tworzymy następującą **funkcję wiarygodności** eksperymentu

$$L(X_1, X_2, \dots, X_n, \theta) = p(X_1, \theta) \cdot p(X_2, \theta) \cdots p(X_n, \theta)$$

Poszukujemy takiego estymatora $\hat{\theta}$ nieznanego parametru θ , dla którego funkcja wiarygodności osiąga największą wartość.

Uzyskane w ten sposób estymatory nieznaną wartość parametru rozkładu prawdopodobieństwa nazywamy estymatorami największej wiarygodności. Są one przynajmniej asymptotycznie nieobciążone oraz asymptotycznie najefektywniejsze.

Estymatory największej wiarygodności parametrów rozkładu normalnego

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

$$\hat{\sigma} = S = \sqrt{\frac{\sum_{i=1}^n (X_i - \hat{\mu})^2}{n}}$$

Estymatorem **wariancji** σ^2 w rozkładzie normalnym jest

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

Można wykazać, że

$$E(\hat{\sigma}^2) = \frac{n-1}{n} \sigma^2$$

Wobec tego, można uzyskać *skorygowany* estymator wariancji w rozkładzie normalnym

$$\hat{\sigma}_0^2 = S_0^2 = \frac{n}{n-1} \hat{\sigma}^2 = \frac{\sum_{i=1}^n (X_i - \hat{\mu})^2}{n-1},$$

który jest estymatorem *nieobciążonym* wariancji σ^2 .

W przypadku konieczności oceny odchylenia standardowego korzystamy ze **skorygowanego odchylenia standardowego w próbie**

$$\hat{\sigma}_0 = S_0 = \sqrt{\frac{\sum_{i=1}^n (X_i - \hat{\mu})^2}{n-1}}$$

jako estymatora parametru σ .

Estymator $\hat{\mu}$ jest nieobciążonym estymatorem parametru μ , natomiast estymator $\hat{\sigma}_0$ jest obciążonym estymatorem parametru σ . Obciążenie to jest funkcją liczności próby n i maleje do zera, gdy n dąży do nieskończoności.

Estymacja przedziałowa parametrów rozkładów prawdopodobieństwa

Przedziały ufności

Niech będzie dana *próba losowa* (X_1, X_2, \dots, X_n) , której rozkład zależy od pewnego parametru rzeczywistego $\theta \in \Theta$. **Przedziałem ufności** dla parametru $\theta \in \Theta$ na poziomie ufności β ($0 < \beta < 1$) nazywamy przedział (θ_1, θ_2) , spełniający warunki:

- $\theta_1 = \theta_1(X_1, X_2, \dots, X_n)$ oraz $\theta_2 = \theta_2(X_1, X_2, \dots, X_n)$ są funkcjami próby losowej (X_1, X_2, \dots, X_n) , które *nie zależą* od θ ,
- dla każdego $\theta \in \Theta$,

$$P(\theta_1(X_1, \dots, X_n) < \theta < \theta_2(X_1, \dots, X_n)) = \beta$$

Granice przedziału losowego (θ_1, θ_2) są **zmiennymi losowymi**, takimi że **prawdopodobieństwo pokrycia przedziałem (θ_1, θ_2) nieznanego parametru θ wynosi β** .

Oznacza to, że w przypadku wykonania wielu eksperymentów mających na celu oszacowanie przedziałowe parametru θ w $100\beta\%$ przypadkach wyznaczony przedział ufności będzie zawierał θ .

Istnieje **wiele** przedziałów ufności spełniających powyższe warunki.

Interesuje nas zawsze znalezienie takiego przedziału, którego **długość**

$$l_n = \theta_2(X_1, X_2, \dots, X_n) - \theta_1(X_1, X_2, \dots, X_n)$$

jest **najmniejsza**.

Weryfikacja hipotez statystycznych (testowanie hipotez statystycznych)

Hipotezy statystyczne

Niech będzie dana *przestrzeń statystyczna* $(\Omega, \mathcal{F}, \mathcal{P})$, gdzie $\mathcal{P} = \{P_\theta, \theta \in \Theta\}$ jest **rodziną rozkładów prawdopodobieństwa** opisującą wynik eksperymentu, a Θ jest jakąś przestrzenią parametrów przy czym $\Theta_1 \cup \Theta_2 = \Theta$, $\Theta_1 \cap \Theta_2 = \emptyset$.

Stwierdzenie (**hipotezę statystyczną**) $\theta \in \Theta_1$ będziemy nazywać **hipotezą zerową** i będziemy zapisywać

$$H: \theta \in \Theta_1,$$

zaś stwierdzenie (**hipotezę statystyczną**) $\theta \in \Theta_2$ będziemy nazywać **hipotezą alternatywną** (dla hipotezy H) i będziemy zapisywać

$$K: \theta \in \Theta_2.$$

Hipotezę statystyczną nazywamy **prostą**, gdy zbiory Θ_1 oraz Θ_2 zawierają dokładnie po **jednym elemencie**, w przeciwnym razie mówimy o hipotezie **złożonej**.

Test statystyczny

Testem statystycznym nazywamy procedurę postępowania, która możliwym realizacjom próby losowej (X_1, X_2, \dots, X_n) określonej na przestrzeni statystycznej $(\Omega, \mathcal{F}, \mathcal{P})$ przypisuje decyzje odrzuć (albo przyjąć) weryfikowanej hipotezy.

W celu zbudowania *testu statystycznego* konstruujemy dwa dopełniające się zbiory W i W' ($W \cap W' = \emptyset$, $W \cup W' = \mathcal{R}$) oraz pewną statystykę $T = T(X_1, X_2, \dots, X_n)$ zwaną **statystyką testową**.

Decyzje podejmujemy w następujący sposób:

jeżeli $T = T(X_1, X_2, \dots, X_n) \in W$, to H odrzucamy;
jeżeli $T = T(X_1, X_2, \dots, X_n) \notin W$, to H przyjmujemy.

Zbiór W nazywamy *zbiorem krytycznym* (zbiorem odrzuceń hipotezy H), a zbiór W' nazywamy *zbiorem przyjęć*.

Jeżeli weryfikowaną hipotezę nie odrzucamy, to bezpieczniej jest powiedzieć, że *nie ma podstaw do jej odrzucenia*, niż mówić o przyjęciu hipotezy alternatywnej.

Błędy decyzji statystycznych

- odrzucamy weryfikowaną hipotezę H , gdy jest ona *prawdziwa*; jest to tzw. **błąd pierwszego rodzaju**;
- przyjmujemy weryfikowaną hipotezę H , gdy jest ona *falszywa*; jest to tzw. **błąd drugiego rodzaju**.

Błędne decyzje statystyczne podejmowane są z określonymi prawdopodobieństwami nazywanymi, odpowiednio, *prawdopodobieństwem błędu pierwszego rodzaju* oraz *prawdopodobieństwem błędu drugiego rodzaju*.

Zwykle ustalamy dopuszczalną wielkość prawdopodobieństwa błędu pierwszego rodzaju, którą nazywamy **poziomem istotności α** . Wśród testów spełniających wymaganie określone poziomem istotności poszukujemy takiego, by zminimalizowane zostało prawdopodobieństwo błędu drugiego rodzaju.

Testy zgodności

Testy zgodności służą do weryfikacji hipotez o postaci rozkładu prawdopodobieństwa.

Na podstawie wyników badania próby losowej X_1, X_2, \dots, X_n , której elementy mają rozkład prawdopodobieństwa o dystrybuancie F weryfikujemy hipotezę

$$H: F = F_0$$

gdzie F_0 jest zadaną dystrybuantą.

Testy zgodności są na ogół *testami nieparametrycznymi*, gdyż alternatywa ma zwykle postać: $K: F \neq F_0$.

Test zgodności chi-kwadrat Pearsona

Przyjmijmy, że wyniki obserwacji próby losowej *zostały pogrupowane w k rozłącznych klas*, o licznosciach n_1, n_2, \dots, n_k , przy czym $n_1 + n_2 + \dots + n_k = n$. Należy teraz przyjąć założony rozkład prawdopodobieństwa i dla tego rozkładu **wyznaczyć prawdopodobieństwa p_1, p_2, \dots, p_k** , że obserwowana zmienna losowa przyjmie wartość z danej klasy.

$$\chi_P^2 = \sum_{i=1}^k \frac{(n_i - np_i)^2}{np_i}$$

Jeżeli spełniony jest warunek $\min(n_1, n_2, \dots, n_k) > 5$ i **liczność próby jest duża (np. $n \geq 100$)**, to w przypadku słuszności weryfikowanej hipotezy rozkład prawdopodobieństwa statystyki χ_P^2 jest **rozkładem chi-kwadrat o $k-1$ stopniach swobody**.

Hipotezę o zgodności obserwacji z założonym rozkładem prawdopodobieństwa odrzucamy, gdy $\chi_P^2 > \chi_{1-\alpha, k-1}^2$ gdzie $\chi_{1-\alpha, k-1}^2$ jest kwantylem rzędu $1-\alpha$ w rozkładzie chi-kwadrat o $k-1$ stopniach swobody (tablice).

Test zgodności Kołmogorowa

Test zgodności Kołmogorowa wykorzystuje się w przypadku weryfikowania hipotez dla **rozkładów zmiennych losowych ciągłych**.

Niech $F_0(s)$ będzie założoną dystrybuantą (hipotetyczną), a $F_n(s)$ zaobserwowaną w próbie losowej X_1, X_2, \dots, X_n dystrybuantą empiryczną.

$$F_n(s) = \frac{1}{n} \sum_{i=1}^n I_{(-\infty, s)}(X_i)$$

Statystyką testową jest **statystyka Kołmogorowa**

$$D_n = \sup_{-\infty < s < \infty} |F_n(s) - F_0(s)|$$

Hipotezę o zgodności z założonym rozkładem prawdopodobieństwa odrzuca się, gdy zachodzi nierówność

$$D_n > d_n(1-\alpha),$$

gdzie $d_n(1-\alpha)$ jest kwantylem rzędu $1-\alpha$ (stabilizowanym) rozkładu prawdopodobieństwa statystyki D_n .

Dla dużych licznosci próby $n \geq 100$ hipotezę o zgodności z założonym rozkładem prawdopodobieństwa odrzuca się, gdy zachodzi nierówność $D_n > \lambda_{1-\alpha} / \sqrt{n}$, gdzie $\lambda_{1-\alpha}$ jest kwantylem rzędu $1-\alpha$ (stabilizowanym) rozkładu prawdopodobieństwa statystyki λ -Kołmogorowa.

Związek weryfikacji hipotez statystycznych z estymacją przedziałową


Hipotezy statystyczne weryfikuje się (testuje) na poziomie istotności α . **Przy budowie testu można wykorzystać pojęcie przedziału ufności.**

Hipotezę statystyczną na danym poziomie istotności α weryfikuje się porównując hipotetyczną (wymaganą) wartość parametru rozkładu prawdopodobieństwa z wyznaczonym na podstawie obserwacji z próbki **PRZEDZIAŁEM UFNOŚCI** na poziomie ufności $\beta=1-\alpha$ dla tego parametru.

Weryfikacja hipotezy typu $H: \mu = \mu_0$.

Przyjęcie hipotezy: $\mu_0 \in (\mu_1, \mu_2)$
 Odrzucenie hipotezy: $\mu_0 \in \{(-\infty, \mu_1) \cup (\mu_2, \infty)\}$

Wykorzystujemy **dwustronny** przedział ufności dla parametru μ na poziomie ufności β



Weryfikacja hipotezy typu $H: \mu \leq \mu_0$.


Hipoteza ta jest równoważna następującemu problemowi decyzyjnemu:

$$H: \mu = \mu_0 \quad K: \mu > \mu_0$$

Przyjęcie hipotezy: $\mu_0 \in (\mu_d, \infty)$

Odrzucenie hipotezy: $\mu_0 \notin (\mu_d, \infty)$

Wykorzystujemy **jednostronny (górny)** przedział ufności dla parametru μ na poziomie ufności β



Weryfikacja hipotezy typu $H: \mu \geq \mu_0$.

Hipoteza ta jest równoważna następującemu problemowi decyzyjnemu:

$$H: \mu = \mu_0 \quad K: \mu < \mu_0$$

Przyjęcie hipotezy: $\mu_0 \in (-\infty, \mu_g)$

Odrzucenie hipotezy: $\mu_0 \notin (-\infty, \mu_g)$

Wykorzystujemy **jednostronny (dolny)** przedział ufności dla parametru μ na poziomie ufności β

