



# TESTOWANIE HIPOTEZY O KOMPLETNOŚCI ZBIORU ARGUMENTÓW

Paweł Szoltysek

A decorative vertical bar on the left side of the slide, featuring a gradient from dark blue to light orange, with several orange circles of varying sizes and a thin white vertical line.

# RELACJA PODOBIEŃSTWA I TESTOWANIE KOMPLETNOŚCI ZBIORU ARGUMENTÓW

# RELACJA PODOBIEŃSTWA - ZAŁOŻENIA

- Proces jest opisany za pomocą funkcji wymiarowej, wymiarowo niezmienniczej i jednorodnej

$$Z = \Phi(A_1, A_2, \dots, A_n, B_1, B_2, \dots, B_n)$$

- Proces, opisany tą samą funkcją, o argumentach równych wymiarom, jednak innych co do wartości:

$$\hat{Z} = \Phi(\hat{A}_1, \hat{A}_2, \dots, \hat{A}_n, \hat{B}_1, \hat{B}_2, \dots, \hat{B}_n)$$

Co można zapisać jako

$$A_i = \alpha_i \hat{A}_i, B_j = \beta_j \hat{B}_j, i = 1, 2, \dots, m, j = 1, 2, \dots, r$$



# RELACJA PODOBIEŃSTWA – STOSUNEK

Ile wynosi stosunek tych wartości?

$$\lambda = \frac{Z}{\hat{Z}}, \lambda \in \Pi_0$$

Z twierdzenia  $\pi$ :

$$Z = f(\varphi_1, \varphi_2, \dots, \varphi_r) \prod_{i=1}^m A_i^{a_i}, \varphi_j = \frac{B_j}{\prod_{i=1}^m A_i^{a_{ji}}}, j = 1, 2, \dots, r$$

$$\hat{Z} = f(\hat{\varphi}_1, \hat{\varphi}_2, \dots, \hat{\varphi}_r) \prod_{i=1}^m \hat{A}_i^{a_i}, \hat{\varphi}_j = \frac{\hat{B}_j}{\prod_{i=1}^m \hat{A}_i^{a_{ji}}}, j = 1, 2, \dots, r$$

Czyli

$$\lambda = \frac{f(\varphi_1, \varphi_2, \dots, \varphi_r)}{f(\hat{\varphi}_1, \hat{\varphi}_2, \dots, \hat{\varphi}_r)} \prod_{i=1}^m \alpha_i^{a_i}$$



## RELACJA PODOBIEŃSTWA – DEFINICJA

Dwie realizacje procesu są podobne, jeśli spełnione jest kryterium podobieństwa:

$$\hat{\varphi}_j = \varphi_j, j = 1, 2, \dots, r$$

Zauważmy, że wtedy nasz stosunek

$$\lambda = \prod_{i=1}^m \alpha_i^{a_i}$$

nie zależy od postaci funkcji  $f$ .



# RELACJA PODOBIEŃSTWA A TEZA O KOMPLETEŃNOŚCI ZBIORU ARGUMENTÓW

Z podobieństwa dwóch realizacji  $\hat{R}_p, \hat{R}_t$

$$f(\varphi_{1p}, \varphi_{2p}, \dots, \varphi_{rp}) = f(\varphi_{1t}, \varphi_{2t}, \dots, \varphi_{rt})$$

czyli

$$\frac{Z_{0p}}{\prod_{i=1}^m Z_{ip}^{a_i}} = \frac{Z_{0t}}{\prod_{i=1}^m Z_{it}^{a_i}}$$

Jeśli zbiór argumentów funkcji jest kompletny, możemy obliczyć  $Z_{0p}$ , a także  $Z_{0t}$ . Oznacza to zależność między wejściem i wyjściem.




# KOMPLETNOŚĆ ZBIORU ARGUMENTÓW

Zbiór argumentów funkcji wymiarowej, wymiarowo niezależnej i jednorodnej jest kompletnym opisem procesu wtedy i tylko wtedy gdy funkcja  $f$  jest różnowartościowa, i dla każdej pary podobnych realizacji procesu  $\hat{R}_p, \hat{R}_t$  zachowana jest równość

$$\frac{Z_{0p}}{\prod_{i=1}^m Z_{ip}^{a_i}} = \frac{Z_{0t}}{\prod_{i=1}^m Z_{it}^{a_i}}$$

Zachodzi także twierdzenie odwrotne do powyższego.





**RELACJA PODOBIENSTWA I  
TESTOWANIE KOMPLETNOŚCI  
ZBIORU ARGUMENTÓW W  
PRZYPADKU WYSTĄPIENIA  
BŁĘDÓW POMIARU**



## PROBLEMY Z BŁĘDAMI POMIARU

Mamy realizację  $R_t = (Z_{1t}, \dots, Z_{mt}, \dots, Z_{m+r}, Z_{0t})$

Mozemy ją opisać podobnie jak wcześniej:

$$R_t = (Z_{1t}, \dots, Z_{mt}, \varphi_{1t}, \dots, \varphi_{rt}, \varphi_{0t})$$

Realizacje są podobne, gdy

$$\varphi_{j1} = \varphi_{j2}, \quad j = 1, 2, \dots, r$$

Tak jednak nie będzie, ponieważ na pomiar wpływają błędy.

$$Z_{lt} = Z_{lt}^* + \Delta Z_l, \quad l = 0, 1, 2, \dots, m+r, \quad t = 0, 1, 2, \dots, q$$

Ustala się zwykle, że błąd ma rozkład normalny  $N(0, \sigma^2)$ . Jednocześnie, przez wzgląd na to, należy uznać, że  $\varphi_{jt}$  także jest zmienną losową.



# OKREŚLANIE PRZEDZIAŁÓW BŁĘDÓW

Możemy dla każdej realizacji znaleźć jednak taki przedział

$$[Z_{lt} - \Delta Z_l, Z_{lt} + \Delta Z_l], l = 0, 1, \dots, m + r, t = 1, 2, \dots, q$$

że wartość będzie należała do tego przedziału ze znanym, bliskim 1 prawdopodobieństwem. Znając te przedziały możemy zdefiniować podobnie takie przedziały dla  $[\varphi_{jt}^L, \varphi_{jt}^R]$ , też z prawdopodobieństwem bliskim 1.



# OKREŚLANIE METRYKI MIĘDZY RELACJAMI

Bierzemy gęstości wystąpień tych parametrów, dla wszystkich realizacji, i budujemy metrykę

$$d(f, g) = 1 - \int_R \min(f, g) x dx$$

Metryka ta opisuje odległość między dwiema realizacjami jako

$$d(f_1, f_2) \leq \varepsilon_j, j = 1, \dots, r$$

Tą metryką możemy podmienić warunek podobieństwa. Wartości epsilon są ustalane w sposób taki, by statystyczna ocena podobieństwa była później satysfakcjonująca.



# RELACJA PODOBIENSTWA

Aby określić które realizacje spełniają warunek podobieństwa, najpierw dzielimy je na klasy podobieństwa, a później oceniamy podobieństwo statystycznie w tych, czysto hipotetycznych klasach. W końcu, każdy taki zbiór jest ponownie dzielony, tym razem w relacji z parametrem  $f_i$ .

W tym momencie nasz warunek musi być sprawdzony statystycznie. Procedura ta jest podzielona na dwa kroki – badanie jakości przeprowadzonego dzielenia oraz obliczenie miary podobieństwa.



# SFORMUŁOWANIE HIPOTEZY O KOMPLETEŃNOŚCI ZBIORU

Postawmy hipotezę. W każdej hipotetycznej klasie podobieństwa wartości parametrów  $\varphi_j$  są stałe, jeśli tylko  $j$  jest ustalone (nie jest zmienna).

Tworzymy zredukowaną realizację złożoną z  $m+1$  parametrów potrzebnych do obliczenia wartości  $\varphi_j$

$$R_{jt}^e = (Z_{1t}, \dots, Z_{mt}, Z_{m+j,t}); t = 1, \dots, q$$

Każda wartość parametru  $\varphi_j$  odpowiada w przestrzeni  $R^{m+1}$   $m$ -wymiarowej hiperpłaszczyźnie

$$H_{\varphi_j} = \left\{ R_j^e = (Z_1, \dots, Z_m, Z_{m+j}) : \frac{Z_{m+j}}{\prod_{i=1}^m Z_i^{a_{ji}}} = \varphi_j \right\}$$



# TRANSFORMACJA ZMIENNYCH

Z hipotezy: wartości  $f_i$  z każdej klasy są sobie równe

Ta wartość (oznaczymy  $\varphi_j^l$ ) z kolei wyznacza nam nową hiperpłaszczyznę, którą mamy wyznaczyć.

Transformujemy zmienne  $Z$  umożliwiając linearyzację w sposób następujący:

$$L^j : R^{m+1} \rightarrow R^{m+1}$$

$$\dot{\varphi}_j = \dot{Z}_{m+j} - a_{j1}\dot{Z}_1 - \dots - a_{jm}\dot{Z}_m$$

Gdzie  $\dot{\varphi}_j = \ln \varphi_j$  opisuje konkretną hiperpłaszczyznę w przestrzeni  $R^{m+1}$ .



# MODYFIKACJA METRYKI EUKLIDESA

Jeśli hipoteza jest prawdziwa, wtedy wszystkie transformowane realizacje  $\dot{R}_{j_1}^e, \dots, \dot{R}_{j_{q_b}}^e$  leżały będą na tej samej hiperpłaszczyźnie określonej wartością  $\phi_j^l$ .

Opiszmy odchylenie kwadratowe parametru  $\phi_{j_b}$ :

$$Q(\phi_j) = \frac{1}{q_b} \sum_{t=1}^{q_b} d^2(\dot{R}_{j_t}, H_{\phi_{j_t}})$$

Ustalmy też zmodyfikowaną metrykę Euklidesa:

$$d(\dot{R}_{j_1}, \dot{R}_{j_2}) = \sqrt{\sum_{i=1}^m d_i (\dot{Z}_{i1} - \dot{Z}_{i2})^2 + d_{m+j} (\dot{Z}_{m+j,1} - \dot{Z}_{m+j,2})^2}$$



# ESTYMACJA REALIZACJI

Optymalna wartość  $\phi_{jb}^l$  zostanie uzyskana przez minimalizację odchylenia kwadratowego

$$\hat{\phi}_{jb}^l = \frac{1}{q_b} \sum_{t=1}^{q_b} \hat{\phi}_{jt}$$

Wartość ta jest niezależna od współczynników  $d$ .

Z hipotezy, realizacje z klasy należą do tej samej hiperprzestrzeni, więc korzystając z metryki

estymujemy realizację  $\dot{R}_{jt}^{*e} = \left( \dot{Z}_{1t} - \frac{D_t a_{j1}}{d_1}, \dots, \dot{Z}_{mt} - \frac{D_t a_{jm}}{d_m}, \dot{Z}_{m+j,t} - \frac{D_t}{d_{m+j}} \right)$

$$D_t = \frac{\left( \dot{Z}_{m+j,t} - \sum_{i=1}^m a_{ji} \dot{Z}_{it} - \hat{\phi}_j^l \right)}{\left( \sum_{i=1}^m \frac{a_{ji}}{d_i} + \frac{1}{d_{m+j}} \right)}$$





## ESTYMACJA WARTOŚCI Z

Używamy tu metryki  $d$  jako kryterium podobieństwa. W tym miejscu dokonujemy odwrotnej transformacji  $L$ , uzyskując estymowane wartości  $Z$  w naszej klasie. Wyglądają one następująco:

$$Z_{pb}^* = Z_{pt} \exp \left[ \frac{\left( \frac{a_p}{d_p} \right) \left( \dot{\phi}_{jt}^l - \dot{Z}_{m+j,t} + \sum_{i=1}^m a_{ji} \dot{Z}_{it} \right)}{\sum_{i=1}^m \frac{a_i^2}{d_i} + \frac{1}{d_{m+j}}} \right]$$



# KONSTRUKCJA POZIOMU UFNOŚCI

Jeśli hipoteza jest prawdziwa, możemy określić funkcję gęstości dla klasy, korzystając z rozkładu trójkątnego. Używamy do tego statystyki

$$V = -2 \sum_{b=1}^w \sum_{t=1}^{q_b} \ln \left\{ \int_{-\infty}^{\varphi_{jk}} f_{jk}(x) dx \right\}$$

Jeśli hipoteza jest prawdziwa, powyższa statystyka ma rozkład  $\chi^2$  z  $2(q - w_0)$  poziomami wolności. Z miary jakości podziału na klasy otrzymujemy rodzinę zbiorów

$$V_\alpha = \{x \in R : P(V > x) \leq \alpha\}, 0 \leq \alpha \leq 1$$

I wykorzystując statystykę, mamy poziom ufności

$$p(v_{cal}) = \inf \{ \alpha : v_{cal} \in V_\alpha \}$$



# OKREŚLENIE MIARY PODOBIEŃSTWA

Równanie to nazywane jest miarą podobieństwa  $\kappa(j)$  rozpatrywanego podziału realizacji  $R$ . Jeśli jest on poprawny, wartości  $f_i$  są stałe dla każdej klasy. Jeśli choćby jedna z nich miałaby nie spełniać tego założenia, hipoteza powinna być odrzucona.

Statystyka  $Q = \min\{\kappa(1), \dots, \kappa(r)\}$  może być więc użyta do testowania hipotezy o kompletności. Ogólnie, miara przyjmie postać

$$\kappa(R) = 1 - (1 - q_{cal})^r$$



# KOMPLETNOŚĆ ZBIORU

Tak określona miara podobieństwa charakteryzuje się następującymi własnościami dotyczącymi weryfikowania hipotezy o kompletności zbioru:

- $0 \leq \kappa(R) \leq 1$
- Dla  $\kappa(R) = 0$  hipoteza jest odrzucona, natomiast dla  $\kappa(R) = 1$  – zaakceptowana.
- Im większa miara podobieństwa, tym lepiej w sensie spełnienia warunku kompletności zbioru.

Wartości miary możemy zmieniać zmieniając wartości  $\varepsilon_j$ .

