

# Uogólniony indeks Hirscha a dwupróbkowe testy dla rodziny rozkładów Pareto II rodzaju

Marek Gągolewski<sup>1,2</sup>, Przemysław Grzegorzewski<sup>2,1</sup>  
{gagolews,pgrzeg}@ibspan.waw.pl

XXXV Konferencja **Statystyka Matematyczna**  
Wisła, 7–11 grudnia 2009 r.



<sup>1</sup> Instytut Badań Systemowych  
Polska Akademia Nauk




<sup>2</sup> Wydział Matematyki  
i Nauk Informatycznych  
Politechnika Warszawska

# Plan referatu


- Ogólny problem oceny twórców
- Wskaźniki bibliometryczne
- Problem oceny w interpretacji statystycznej
- $\kappa$ -pozycje i ich estymacja
- Testy do porównywania dwóch prób
- Podsumowanie i problemy otwarte

# Problem oceny twórców




Przeliczalny zbiór **jednostek** (dzieł, produktów):  $J = \{j_1, j_2, \dots\}$ .

# Problem oceny twórców



Przeliczalny zbiór **jednostek** (dzieł, produktów):  $J = \{j_1, j_2, \dots\}$ .  
**Funkcja oceny jednostek**  $v : J \rightarrow [0, \infty)$ .

# Problem oceny twórców



Przeliczalny zbiór **jednostek** (dzieł, produktów):  $J = \{j_1, j_2, \dots\}$ .


**Funkcja oceny jednostek**  $v : J \rightarrow [0, \infty)$ .

**Zbiór twórców** (autorów, producentów)  $\mathcal{A} = \{A_1, \dots, A_m\}$

— pewna rodzina podzbiorów  $J$ :  $(A_1, \dots, A_m \subseteq J)$ .

Modelem opisywanej rzeczywistości jest trójka  $(J, \mathcal{A}, v)$ .

# Problem oceny twórców



Przeliczalny zbiór **jednostek** (dzieł, produktów):  $J = \{j_1, j_2, \dots\}$ .

**Funkcja oceny jednostek**  $v : J \rightarrow [0, \infty)$ .

**Zbiór twórców** (autorów, producentów)  $\mathcal{A} = \{A_1, \dots, A_m\}$

— pewna rodzina podzbiorów  $J$ :  $(A_1, \dots, A_m \subseteq J)$ .

Modelem opisywanej rzeczywistości jest trójka  $(J, \mathcal{A}, v)$ .

- ①
  - $J$  — artykuły w recenzowanych czasopismach,
  - $\mathcal{A}$  — pracownicy naukowci,
  - $v$  — liczba cytowań,
  
- ②
  - $J$  — artykuły w recenzowanych czasopismach,
  - $\mathcal{A}$  — instytucje naukowe,
  - $v$  — punkty z listy czasopism punktowanych MNiSW,
  
- ③
  - $J$  — strony internetowe,
  - $\mathcal{A}$  — portale (serwisy WWW),
  - $v$  — liczba odwiedzin,
  
- ④
  - $J$  — dzieła sztuki,
  - $\mathcal{A}$  — artyści,
  - $v$  — cena dzieła na aukcji.

- ①
  - $J$  — artykuły w recenzowanych czasopismach,
  - $\mathcal{A}$  — pracownicy naukowci,
  - $v$  — liczba cytowań,
  
- ②
  - $J$  — artykuły w recenzowanych czasopismach,
  - $\mathcal{A}$  — instytucje naukowe,
  - $v$  — punkty z listy czasopism punktowanych MNiSW,
  
- ③
  - $J$  — strony internetowe,
  - $\mathcal{A}$  — portale (serwisy WWW),
  - $v$  — liczba odwiedzin,
  
- ④
  - $J$  — dzieła sztuki,
  - $\mathcal{A}$  — artyści,
  - $v$  — cena dzieła na aukcji.



- ①
  - $J$  — artykuły w recenzowanych czasopismach,
  - $\mathcal{A}$  — pracownicy naukowci,
  - $v$  — liczba cytowań,
  
- ②
  - $J$  — artykuły w recenzowanych czasopismach,
  - $\mathcal{A}$  — instytucje naukowe,
  - $v$  — punkty z listy czasopism punktowanych MNiSW,
  
- ③
  - $J$  — strony internetowe,
  - $\mathcal{A}$  — portale (serwisy WWW),
  - $v$  — liczba odwiedzin,
  
- ④
  - $J$  — dzieła sztuki,
  - $\mathcal{A}$  — artyści,
  - $v$  — cena dzieła na aukcji.

- ①
  - $J$  — artykuły w recenzowanych czasopismach,
  - $\mathcal{A}$  — pracownicy naukowci,
  - $v$  — liczba cytowań,
  
- ②
  - $J$  — artykuły w recenzowanych czasopismach,
  - $\mathcal{A}$  — instytucje naukowe,
  - $v$  — punkty z listy czasopism punktowanych MNiSW,
  
- ③
  - $J$  — strony internetowe,
  - $\mathcal{A}$  — portale (serwisy WWW),
  - $v$  — liczba odwiedzin,
  
- ④
  - $J$  — dzieła sztuki,
  - $\mathcal{A}$  — artyści,
  - $v$  — cena dzieła na aukcji.

- ①
  - $J$  — artykuły w recenzowanych czasopismach,
  - $\mathcal{A}$  — pracownicy naukowci,
  - $v$  — liczba cytowań,
  
- ②
  - $J$  — artykuły w recenzowanych czasopismach,
  - $\mathcal{A}$  — instytucje naukowe,
  - $v$  — punkty z listy czasopism punktowanych MNiSW,
  
- ③
  - $J$  — strony internetowe,
  - $\mathcal{A}$  — portale (serwisy WWW),
  - $v$  — liczba odwiedzin,
  
- ④
  - $J$  — dzieła sztuki,
  - $\mathcal{A}$  — artyści,
  - $v$  — cena dzieła na aukcji.

# Problem

Na podstawie informacji zawartych w  $(J, \mathcal{A}, \nu)$  dokonać „oceny” twórców z  $\mathcal{A}$ .

Co oceniać?

- jakość wytworów
- produktywność

Rozpatrujemy twórców cechujących się tą samą produktywnością.

$\omega^{(n)} : [0, \infty)^n \rightarrow [0, \infty)$  jest **funkcją agregującą**, jeśli spełnia następujące warunki (zob. Grabisch i in., 2009):

- $\omega^{(n)}(0, \dots, 0) = 0$ ,
- jest niemalejąca ze względu na każdą zmienną.

# Problem

Na podstawie informacji zawartych w  $(J, \mathcal{A}, \nu)$  dokonać „oceny” twórców z  $\mathcal{A}$ .

Co oceniać?

- jakość wytworów
- produktywność

Rozpatrujemy twórców cechujących się tą samą produktywnością.

$\omega^{(n)} : [0, \infty)^n \rightarrow [0, \infty)$  jest **funkcją agregującą**, jeśli spełnia następujące warunki (zob. Grabisch i in., 2009):

- $\omega^{(n)}(0, \dots, 0) = 0$ ,
- jest niemalejąca ze względu na każdą zmienną.

# Problem

Na podstawie informacji zawartych w  $(J, \mathcal{A}, \nu)$  dokonać „oceny” twórców z  $\mathcal{A}$ .

Co oceniać?

- jakość wytworów
- produktywność

Rozpatrujemy twórców cechujących się tą samą produktywnością.

$\omega^{(n)} : [0, \infty)^n \rightarrow [0, \infty)$  jest **funkcją agregującą**, jeśli spełnia następujące warunki (zob. Grabisch i in., 2009):

- $\omega^{(n)}(0, \dots, 0) = 0$ ,
- jest niemalejąca ze względu na każdą zmienną.

# Problem

Na podstawie informacji zawartych w  $(J, \mathcal{A}, \nu)$  dokonać „oceny” twórców z  $\mathcal{A}$ .

Co oceniać?

- jakość wytworów
- produktywność

Rozpatrujemy twórców cechujących się tą samą produktywnością.

$\omega^{(n)} : [0, \infty)^n \rightarrow [0, \infty)$  jest **funkcją agregującą**, jeśli spełnia następujące warunki (zob. Grabisch i in., 2009):

- $\omega^{(n)}(0, \dots, 0) = 0$ ,
- jest niemalejąca ze względu na każdą zmienną.

# Problem

Na podstawie informacji zawartych w  $(J, \mathcal{A}, \nu)$  dokonać „oceny” twórców z  $\mathcal{A}$ .

Co oceniać?

- jakość wytworów
- produktywność

Rozpatrujemy twórców cechujących się tą samą produktywnością.

$\omega^{(n)} : [0, \infty)^n \rightarrow [0, \infty)$  jest **funkcją agregującą**, jeśli spełnia następujące warunki (zob. Grabisch i in., 2009):

- $\omega^{(n)}(0, \dots, 0) = 0$ ,
- jest niemalejąca ze względu na każdą zmienną.



# Problem

Na podstawie informacji zawartych w  $(J, \mathcal{A}, \nu)$  dokonać „oceny” twórców z  $\mathcal{A}$ .

Co oceniać?

- jakość wytworów
- produktywność

Rozpatrujemy twórców cechujących się tą samą produktywnością.

$\omega^{(n)} : [0, \infty)^n \rightarrow [0, \infty)$  jest **funkcją agregującą**, jeśli spełnia następujące warunki (zob. Grabisch i in., 2009):

- $\omega^{(n)}(0, \dots, 0) = 0$ ,
- jest niemalejąca ze względu na każdą zmienną.

# Wskaźniki bibliometryczne

Przykładowe funkcje agregujące („wskaźniki bibliometryczne”):

- łączna liczba dzieł,
- średnia ocena jakości dzieł,
- indeks  $h$  (Hirsch, 2005)
- indeks  $g$  (Egghe, 2006)
- indeks  $w$  (Woeginger, 2008)
- indeksy „geometryczne” (Gągolewski, Grzegorzewski, 2009)
- .....

# Wskaźniki bibliometryczne

Przykładowe funkcje agregujące („wskaźniki bibliometryczne”):

- łączna liczba dzieł,
- średnia ocena jakości dzieł,
- indeks  $h$  (Hirsch, 2005)
- indeks  $g$  (Egghe, 2006)
- indeks  $w$  (Woeginger, 2008)
- indeksy „geometryczne” (Gągolewski, Grzegorzewski, 2009)
- .....

# Indeks Hirscha

„Autor  $n$  prac ma indeks o wartości  $h$ , jeżeli  $h$  jego prac otrzymało co najmniej  $h$  cytowań, a pozostałe z jego  $n - h$  prac otrzymało co najwyżej  $h$  cytowań.”

## Definicja

**Indeksem Hirscha** nazywamy funkcję  $h : [0, \infty)^n \rightarrow [0, \infty)$  taką, że

$$h(\mathbf{x}) = \begin{cases} \max\{i : x_{n+1-i:n} \geq i, i = 1, 2, \dots, n\} & \text{gdy } x_{n:n} > 0, \\ 0 & \text{w p.p.} \end{cases}$$

Np.  $h(5, 4, 3, 3, 3, 1) = 3$ .

Np.  $h(10, 10, 10, 10, 0, 0, 0, 0) = 4$ .

# Indeks Hirscha

„Autor  $n$  prac ma indeks o wartości  $h$ , jeżeli  $h$  jego prac otrzymało co najmniej  $h$  cytowań, a pozostałe z jego  $n - h$  prac otrzymało co najwyżej  $h$  cytowań.”

## Definicja

**Indeksem Hirscha** nazywamy funkcję  $h : [0, \infty)^n \rightarrow [0, \infty)$  taką, że

$$h(\mathbf{x}) = \begin{cases} \max\{i : x_{n+1-i:n} \geq i, i = 1, 2, \dots, n\} & \text{gdy } x_{n:n} > 0, \\ 0 & \text{w p.p.} \end{cases}$$

Np.  $h(5, 4, 3, 3, 3, 1) = 3$ .

Np.  $h(10, 10, 10, 10, 0, 0, 0, 0) = 4$ .

# Indeks Hirscha

„Autor  $n$  prac ma indeks o wartości  $h$ , jeżeli  $h$  jego prac otrzymało co najmniej  $h$  cytowań, a pozostałe z jego  $n - h$  prac otrzymało co najwyżej  $h$  cytowań.”

## Definicja

**Indeksem Hirscha** nazywamy funkcję  $h : [0, \infty)^n \rightarrow [0, \infty)$  taką, że

$$h(\mathbf{x}) = \begin{cases} \max\{i : x_{n+1-i:n} \geq i, i = 1, 2, \dots, n\} & \text{gdy } x_{n:n} > 0, \\ 0 & \text{w p.p.} \end{cases}$$

Np.  $h(5, 4, 3, 3, 3, 1) = 3$ .

Np.  $h(10, 10, 10, 10, 0, 0, 0, 0) = 4$ .

# Interpretacja statystyczna

Rozważmy  $\mathbf{X} = (X_1, \dots, X_n)$  i.i.d.  $F$ , gdzie  $F$  – dystrybuanta ciągła, ściśle rosnąca na  $[0, \infty)$ ,  $F(x) = 0$  dla  $x < 0$ .

Interpretacja:

$X_i$  — ocena jakości  $i$ -tego dzieła

$F$  określa zdolności do wytwarzania dzieł o jakości właściwej każdemu twórcy

## Przykład

Dla  $P2(k, s)$ ,  $k > 0$ ,  $s \geq 1$

$$F(x) = 1 - \left( \frac{s}{s+x} \right)^k$$

dla  $x > 0$  (Burrell, 2008; Glänzel, 2008).

# Interpretacja statystyczna

Rozważmy  $\mathbf{X} = (X_1, \dots, X_n)$  i.i.d.  $F$ , gdzie  $F$  – dystrybuanta ciągła, ściśle rosnąca na  $[0, \infty)$ ,  $F(x) = 0$  dla  $x < 0$ .

Interpretacja:

$X_i$  — ocena jakości  $i$ -tego dzieła

$F$  określa zdolności do wytwarzania dzieł o jakości właściwej każdemu twórcy

## Przykład

Dla  $P2(k, s)$ ,  $k > 0$ ,  $s \geq 1$

$$F(x) = 1 - \left( \frac{s}{s+x} \right)^k$$

dla  $x > 0$  (Burrell, 2008; Glänzel, 2008).



# Interpretacja statystyczna

Rozważmy  $\mathbf{X} = (X_1, \dots, X_n)$  i.i.d.  $F$ , gdzie  $F$  – dystrybuanta ciągła, ściśle rosnąca na  $[0, \infty)$ ,  $F(x) = 0$  dla  $x < 0$ .

Interpretacja:

$X_i$  — ocena jakości  $i$ -tego dzieła

$F$  określa zdolności do wytwarzania dzieł o jakości właściwej każdemu twórcy

## Przykład

Dla  $P2(k, s)$ ,  $k > 0$ ,  $s \geq 1$

$$F(x) = 1 - \left( \frac{s}{s+x} \right)^k$$

dla  $x > 0$  (Burrell, 2008; Glänzel, 2008).

## Definicja

**Komplementarną funkcją kwantylową** zmiennej losowej o dystrybucanie  $F$  nazywamy funkcję  $K : (0, 1) \rightarrow [0, \infty)$  daną wzorem

$$K(x) = (1 - F(x))^{-1}.$$

Oczywiście  $K(x) = R^{-1}(x)$ .

## Definicja

**Funkcją kontrolną** nazywamy dowolną funkcję  $\kappa : [0, 1] \rightarrow \mathbb{R}$ , która jest ciągła, niemalejąca i taka, że  $\kappa(0) \leq 0$ ,  $\kappa(1) > 0$ .

## Definicja

**Komplementarną funkcją kwantylową** zmiennej losowej o dystrybucanie  $F$  nazywamy funkcję  $K : (0, 1) \rightarrow [0, \infty)$  daną wzorem

$$K(x) = (1 - F(x))^{-1}.$$

Oczywiście  $K(x) = R^{-1}(x)$ .

## Definicja

**Funkcją kontrolną** nazywamy dowolną funkcję  $\kappa : [0, 1] \rightarrow \mathbb{R}$ , która jest ciągła, niemalejąca i taka, że  $\kappa(0) \leq 0$ ,  $\kappa(1) > 0$ .

## Definicja

**Komplementarną funkcją kwantylową** zmiennej losowej o dystrybucanie  $F$  nazywamy funkcję  $K : (0, 1) \rightarrow [0, \infty)$  daną wzorem

$$K(x) = (1 - F(x))^{-1}.$$

Oczywiście  $K(x) = R^{-1}(x)$ .

## Definicja


**Funkcją kontrolną** nazywamy dowolną funkcję  $\kappa : [0, 1] \rightarrow \mathbb{R}$ , która jest ciągła, niemalejąca i taka, że  $\kappa(0) \leq 0$ ,  $\kappa(1) > 0$ .

# $\kappa$ -pozycje

## Definicja

$\kappa$ -pozycją dla rozkładu danego dystrybuantą  $F$  przy funkcji kontrolnej  $\kappa$  nazywamy liczbę  $p_\kappa \in (0, 1)$  będącą rozwiązaniem równania

$$\kappa(p_\kappa) = K(p_\kappa).$$



## Równoważne definicje κ-pozycji:

- κ-pozycją dla rozkładu danego dystrybuantą  $F$  nazywamy liczbę  $p_\kappa \in (0, 1)$  będącą rozwiązaniem równania

$$1 - p_\kappa = F(\kappa(p_\kappa)) \stackrel{\text{ozn.}}{=} F \circ \kappa(p_\kappa).$$

- κ-pozycją dla rozkładu danego dystrybuantą  $F$  nazywamy liczbę  $p_\kappa \in (0, 1)$  będącą rozwiązaniem równania

$$1 - p_\kappa = P(\kappa^{-1}(X_i) \leq p_\kappa).$$

### Uwaga

Przy podanych założeniach κ-pozycja zawsze istnieje i jest wyznaczona jednoznacznie.

## Równoważne definicje κ-pozycji:

- κ-pozycją dla rozkładu danego dystrybuantą  $F$  nazywamy liczbę  $p_\kappa \in (0, 1)$  będącą rozwiązaniem równania

$$1 - p_\kappa = F(\kappa(p_\kappa)) \stackrel{\text{ozn.}}{=} F \circ \kappa(p_\kappa).$$

- κ-pozycją dla rozkładu danego dystrybuantą  $F$  nazywamy liczbę  $p_\kappa \in (0, 1)$  będącą rozwiązaniem równania

$$1 - p_\kappa = P(\kappa^{-1}(X_i) \leq p_\kappa).$$

## Uwaga

Przy podanych założeniach κ-pozycja zawsze istnieje i jest wyznaczona jednoznacznie.

Równoważne definicje  $\kappa$ -pozycji:

- $\kappa$ -pozycją dla rozkładu danego dystrybuantą  $F$  nazywamy liczbę  $p_\kappa \in (0, 1)$  będącą rozwiązaniem równania

$$1 - p_\kappa = F(\kappa(p_\kappa)) \stackrel{\text{ozn.}}{=} F \circ \kappa(p_\kappa).$$

- $\kappa$ -pozycją dla rozkładu danego dystrybuantą  $F$  nazywamy liczbę  $p_\kappa \in (0, 1)$  będącą rozwiązaniem równania

$$1 - p_\kappa = P(\kappa^{-1}(X_i) \leq p_\kappa).$$

## Uwaga

Przy podanych założeniach  $\kappa$ -pozycja zawsze istnieje i jest wyznaczona jednoznacznie.



Równoważne definicje  $\kappa$ -pozycji:

- $\kappa$ -pozycją dla rozkładu danego dystrybuantą  $F$  nazywamy liczbę  $p_\kappa \in (0, 1)$  będącą rozwiązaniem równania

$$1 - p_\kappa = F(\kappa(p_\kappa)) \stackrel{\text{ozn.}}{=} F \circ \kappa(p_\kappa).$$

- $\kappa$ -pozycją dla rozkładu danego dystrybuantą  $F$  nazywamy liczbę  $p_\kappa \in (0, 1)$  będącą rozwiązaniem równania

$$1 - p_\kappa = P(\kappa^{-1}(X_i) \leq p_\kappa).$$

## Uwaga

Przy podanych założeniach  $\kappa$ -pozycja zawsze istnieje i jest wyznaczona jednoznacznie.

## Przykład

Dla  $P_2(1, 1)$  i  $\kappa(x) = x$  zachodzi

$$p_\kappa = \frac{\sqrt{5} - 1}{2} = \frac{1}{\varphi} = \varphi - 1 \simeq 0,618034.$$

## Przykład

Dla dowolnego  $F$  i  $\kappa \equiv F^{-1}$  zachodzi

$$p_\kappa = 0,5.$$

## Przykład

Dla  $P_2(1, 1)$  i  $\kappa(x) = x$  zachodzi

$$p_\kappa = \frac{\sqrt{5} - 1}{2} = \frac{1}{\varphi} = \varphi - 1 \simeq 0,618034.$$

## Przykład

Dla dowolnego  $F$  i  $\kappa \equiv F^{-1}$  zachodzi

$$p_\kappa = 0,5.$$

# Estymacja $\kappa$ -pozycji

## Definicja

Dyskretnym  $\kappa$ -indeksem pozycyjnym nazywamy statystykę

$$\begin{aligned}\hat{p}_\kappa(\mathbf{X}) &= \frac{1}{n} \arg \max_{i=0, \dots, n} \{X_{n-i+1:n} \geq \kappa(i/n)\} \\ &= \frac{1}{n} \arg \max_{i=0, \dots, n} \{\#\{X_k : X_k \geq \kappa(i/n)\} \geq i\}.\end{aligned}$$

# Estymacja $\kappa$ -pozycji

## Definicja

Dyskretnym  $\kappa$ -indeksem pozycyjnym nazywamy statystykę

$$\begin{aligned}\hat{p}_\kappa(\mathbf{X}) &= \frac{1}{n} \arg \max_{i=0, \dots, n} \{X_{n-i+1:n} \geq \kappa(i/n)\} \\ &= \frac{1}{n} \arg \max_{i=0, \dots, n} \{\#\{X_k : X_k \geq \kappa(i/n)\} \geq i\}.\end{aligned}$$

# Estymacja κ-pozycji

## Lemat 1

*Rozkład  $\hat{p}_\kappa$  opisany jest dystrybuantą*

$$\begin{aligned} F_{\hat{p}_\kappa}(p) &= 1 - \sum_{i=\lfloor pn+1 \rfloor}^n \binom{n}{i} \left[ 1 - F \circ \kappa \left( \frac{\lfloor pn+1 \rfloor}{n} \right) \right]^i \left[ F \circ \kappa \left( \frac{\lfloor pn+1 \rfloor}{n} \right) \right]^{n-i} \\ &= I \left( F \circ \kappa \left( \frac{\lfloor pn+1 \rfloor}{n} \right); n - \lfloor pn \rfloor, \lfloor pn \rfloor + 1 \right) \end{aligned}$$

*dla  $p \in (0, 1)$ , przy czym  $I(p; a, b)$  oznacza regularyzowaną niekompletną funkcję beta, natomiast  $\lfloor x \rfloor = \max\{i \in \mathbb{Z} : i \leq x\}$ .*

# Estymacja $\kappa$ -pozycji

## Stwierdzenie 2

$\hat{p}_\kappa$  jest estymatorem asymptotycznie nieobciążonym  $p_\kappa$  oraz  $\text{Var } \hat{p}_\kappa \rightarrow 0$ .

## Lemat 3

Niech  $\mathbf{X} = (X_1, \dots, X_n)$  i.i.d. F. Wówczas dla funkcji kontrolnej  $\kappa(x) = xn$  zachodzi

$$h(\mathbf{X}) = n \hat{p}_\kappa(\mathbf{X}) = \max\{i = 0, \dots, n : X_{n-i+1:n} \geq i\}.$$

# Estymacja $\kappa$ -pozycji

## Stwierdzenie 2

$\hat{p}_\kappa$  jest estymatorem asymptotycznie nieobciążonym  $p_\kappa$  oraz  $\text{Var } \hat{p}_\kappa \rightarrow 0$ .

## Lemat 3

Niech  $\mathbf{X} = (X_1, \dots, X_n)$  i.i.d. F. Wówczas dla funkcji kontrolnej  $\kappa(x) = xn$  zachodzi

$$h(\mathbf{X}) = n \hat{p}_\kappa(\mathbf{X}) = \max\{i = 0, \dots, n : X_{n-i+1:n} \geq i\}.$$



# Estymacja $\kappa$ -pozycji

## Stwierdzenie 4 (O aproksymacji)

Jeśli  $F \circ \kappa$  jest funkcją analityczną w punkcie  $p_\kappa$  i dla każdego  $p$  w dowolnie małym otoczeniu  $p_\kappa$  zachodzi  $(p - p_\kappa)^2 (F \circ \kappa)''(p) \simeq 0$  oraz  $(p - p_\kappa) \delta (1 - 2p_\kappa + (p - p_\kappa) \delta) \simeq 0$ , to dla  $n \rightarrow \infty$

$$F_{\hat{p}_\kappa}(p) \simeq \Phi \left( \frac{p - p_\kappa}{\sqrt{\frac{p_\kappa(1-p_\kappa)}{n(1+\delta)^2}}} \right),$$

gdzie  $\delta := (F \circ \kappa)'(p_\kappa) = f(\kappa(p_\kappa)) \kappa'(p_\kappa)$ , a  $\Phi$  jest dystrybuantą  $N(0, 1)$ .

# Testy do porównywania dwóch prób

**X** —  $n$ -elementowa próba i.i.d.  $F$ .

**Y** —  $n$ -elementowa próba i.i.d.  $G$ .

Jesteśmy zainteresowani konstrukcją (nieparametrycznego) testu  $\varphi$  na poziomie istotności  $\alpha$  do weryfikacji

$$H_0 : F = G$$

względem

$$K : F \succ G.$$

# Testy do porównywania dwóch prób

$X$  —  $n$ -elementowa próba i.i.d.  $F$ .

$Y$  —  $n$ -elementowa próba i.i.d.  $G$ .

Jesteśmy zainteresowani konstrukcją (nieparametrycznego) testu  $\varphi$  na poziomie istotności  $\alpha$  do weryfikacji

$$H_0 : F = G$$

względem

$$K : F \succ G.$$

Dla  $F = G$  i dostatecznie dużych  $n$  mamy

$$T = \sqrt{\frac{n}{2\sigma_{\kappa,F}^2}} (\hat{p}_{\kappa}(\mathbf{X}) - \hat{p}_{\kappa}(\mathbf{Y})) \sim N(0, 1),$$

gdzie

$$\sigma_{\kappa,F}^2 = \frac{p_{\kappa,F}(1 - p_{\kappa,F})}{(1 + \delta_{\kappa,F})^2}$$

oraz  $\delta_{\kappa,F} := (F \circ \kappa)'(p_{\kappa,F})$ .

$H_0$  odrzucamy, gdy  $T > z_{1-\alpha}$ .

Dalej  $F$  — dystrybuanta  $P_2(k_1, s)$ ,  $G$  — dystrybuanta  $P_2(k_2, s)$ .  
 $s \geq 1$  — ustalone (znane).

Mamy  $k_1 < k_2 \Rightarrow F \succ G$ .

$\kappa(x) = nx$  („indeks Hirscha”).

Dalej  $F$  — dystrybuanta  $P_2(k_1, s)$ ,  $G$  — dystrybuanta  $P_2(k_2, s)$ .  
 $s \geq 1$  — ustalone (znane).

Mamy  $k_1 < k_2 \Rightarrow F \succ G$ .

$\kappa(x) = nx$  („indeks Hirscha”).

Dalej  $F$  — dystrybuanta  $P_2(k_1, s)$ ,  $G$  — dystrybuanta  $P_2(k_2, s)$ .  
 $s \geq 1$  — ustalone (znane).

Mamy  $k_1 < k_2 \Rightarrow F \succ G$ .

$\kappa(x) = nx$  („indeks Hirscha”).

## Testy do porównania:

- ① Test Manna-Whitney'a-Wilcoxona,
- ② Test Kołmogorowa-Smirnowa,
- ③ Test parametryczny oparty na ilorazie wiarygodności.  
Statystyka testowa

$$T = \frac{\sum_{i=1}^n \ln(s + X_i) - n \ln s}{\sum_{i=1}^n \ln(s + Y_i) - n \ln s} \stackrel{H_0}{\sim} F[2n, 2n].$$

$H_0$  odrzucamy, gdy  $T > \mathcal{F}_{1-\alpha}^{[2n, 2n]}$ .



Testy do porównania:

- ① Test Manna-Whitney'a-Wilcoxona,
- ② Test Kołmogorowa-Smirnowa,
- ③ Test parametryczny oparty na ilorazie wiarygodności.  
Statystyka testowa

$$T = \frac{\sum_{i=1}^n \ln(s + X_i) - n \ln s}{\sum_{i=1}^n \ln(s + Y_i) - n \ln s} \stackrel{H_0}{\sim} F[2n, 2n].$$

$H_0$  odrzucamy, gdy  $T > \mathcal{F}_{1-\alpha}^{[2n, 2n]}$ .

Testy do porównania:

- ① Test Manna-Whitney'a-Wilcoxona,
- ② Test Kołmogorowa-Smirnowa,
- ③ Test parametryczny oparty na ilorazie wiarygodności.  
Statystyka testowa

$$T = \frac{\sum_{i=1}^n \ln(s + X_i) - n \ln s}{\sum_{i=1}^n \ln(s + Y_i) - n \ln s} \stackrel{H_0}{\sim} F[2n, 2n].$$


$H_0$  odrzucamy, gdy  $T > \mathcal{F}_{1-\alpha}^{[2n, 2n]}$ .

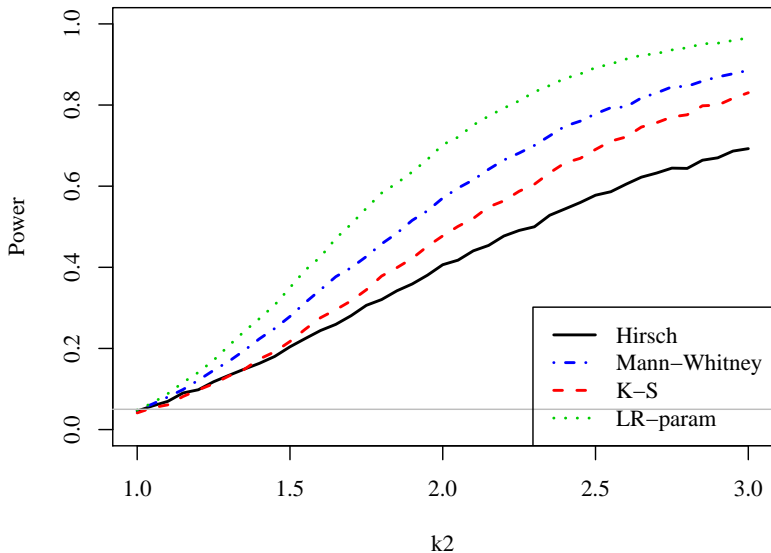
Testy do porównania:


- ① Test Manna-Whitney'a-Wilcoxona,
- ② Test Kołmogorowa-Smirnowa,
- ③ Test parametryczny oparty na ilorazie wiarygodności.  
Statystyka testowa


$$T = \frac{\sum_{i=1}^n \ln(s + X_i) - n \ln s}{\sum_{i=1}^n \ln(s + Y_i) - n \ln s} \stackrel{H_0}{\sim} F_{[2n, 2n]}.$$


$H_0$  odrzucamy, gdy  $T > \mathcal{F}_{1-\alpha}^{[2n, 2n]}$ .

**$k_1=1, s=2, n=10, MC=10000, \alpha=0.05$** 


**$k_1=1, s=2, n=20, MC=10000, \alpha=0.05$** 


**$k_1=1, s=2, n=50, MC=10000, \alpha=0.05$** 


**$k_1=1, s=2, n=100, MC=10000, \alpha=0.05$** 


**$k_1=1, s=2, n=250, MC=10000, \alpha=0.05$** 




**$k_1=0.3$ ,  $s=5$ ,  $n=10$ ,  $MC=10000$ ,  $\alpha=0.05$** 

**$k_1=0.3$ ,  $s=5$ ,  $n=20$ ,  $MC=10000$ ,  $\alpha=0.05$** 

**$k_1=0.3$ ,  $s=5$ ,  $n=50$ ,  $MC=10000$ ,  $\alpha=0.05$** 

**$k_1=0.3$ ,  $s=5$ ,  $n=100$ ,  $MC=10000$ ,  $\alpha=0.05$** 

**$k_1=0.3$ ,  $s=5$ ,  $n=250$ ,  $MC=10000$ ,  $\alpha=0.05$** 

# Podsumowanie i problemy otwarte

- Jakie własności statystyczne miałyby estymatory  $\kappa$ -pozycji zbudowane dla innych funkcji kontrolnych  $\kappa$ ?
- Czy testy budowane na tych estymatorach miałyby lepszą moc niż test wykorzystujący estymator rozważany w tej pracy?
- Dla jakiej funkcji kontrolnej (być może z określonej rodziny funkcji) otrzymalibyśmy test o maksymalnej mocy?
- .....

# Podsumowanie i problemy otwarte

- Jakie własności statystyczne miałyby estymatory  $\kappa$ -pozycji zbudowane dla innych funkcji kontrolnych  $\kappa$ ?
- Czy testy budowane na tych estymatorach miałyby lepszą moc niż test wykorzystujący estymator rozważany w tej pracy?
- Dla jakiej funkcji kontrolnej (być może z określonej rodziny funkcji) otrzymalibyśmy test o maksymalnej mocy?
- .....

# Podsumowanie i problemy otwarte

- Jakie własności statystyczne miałyby estymatory  $\kappa$ -pozycji zbudowane dla innych funkcji kontrolnych  $\kappa$ ?
- Czy testy budowane na tych estymatorach miałyby lepszą moc niż test wykorzystujący estymator rozważany w tej pracy?
- Dla jakiej funkcji kontrolnej (być może z określonej rodziny funkcji) otrzymalibyśmy test o maksymalnej mocy?
- .....



# Podsumowanie i problemy otwarte

- Jakie własności statystyczne miałyby estymatory  $\kappa$ -pozycji zbudowane dla innych funkcji kontrolnych  $\kappa$ ?
- Czy testy budowane na tych estymatorach miałyby lepszą moc niż test wykorzystujący estymator rozważany w tej pracy?
- Dla jakiej funkcji kontrolnej (być może z określonej rodziny funkcji) otrzymalibyśmy test o maksymalnej mocy?
- .....

# Podsumowanie i problemy otwarte

- Jakie własności statystyczne miałyby estymatory  $\kappa$ -pozycji zbudowane dla innych funkcji kontrolnych  $\kappa$ ?
- Czy testy budowane na tych estymatorach miałyby lepszą moc niż test wykorzystujący estymator rozważany w tej pracy?
- Dla jakiej funkcji kontrolnej (być może z określonej rodziny funkcji) otrzymalibyśmy test o maksymalnej mocy?
- .....

Dziękujemy za uwagę.

# Literatura

- Q. Burrell. On the h-index, the size of the Hirsch core and Jin's A-index. *Journal of Informetrics* 1, 170–177.
- Q. Burrell (2008). Extending Lotkaian informetrics. *Information Processing & Management* 44, 1794–1807.
- A. DasGupta (2008). *Asymptotic theory of statistics and probability*. Springer Verlag, New York.
- W. Glänzel (2008). On some new bibliometric applications of statistics related to the h-index. *Scientometrics* 77(1), 187–196.
- L. Egghe (2006). Theory and practise of the g-index. *Scientometrics* 69(1), 131–152.

- M. Gągolewski, P. Grzegorzewski (2009). A geometric approach to the construction of scientific impact indices. *Scientometrics* 81(3), 617–634.
- M. Grabisch, E. Pap, J. Marichal, R. Mesiar (2009). *Aggregation Functions*, Cambridge.
- J. E. Hirsch (2005). An index to quantify individual's scientific research output. *PNAS* 102(46), 16569–16572.
- R. J. Hyndman, Y. Fan (1996). Sample quantiles in statistical packages. *American Statistician*, 50(4), 361–365.
- G. J. Woeginger (2008). An axiomatic characterization of the Hirsch-index. *Mathematical Social Sciences* 56(2), 224–232.