

*Slajdy do wykładu*

Ryszard Zieliński

ESTYMATORY DYSTRYBUANTY Z ZADANĄ PRECYZJĄ  
OPARTE NA FUNKCJACH WIELOMIANOWYCH I SKLEJANYCH

Wydział Matematyki i Informatyki UAM 27 listopada 2008

Zakład Statystyki Matematycznej IMPAN 18 grudnia 2008


*Wyniki tu zaprezentowane pochodzą z pracy:*

Zbigniew Ciesielski i Ryszard Zieliński: Polynomial and spline estimators of the distribution function with prescribed accuracy.

Praca przyjęta do *Applicationes Mathematicae*


$X_1, X_2, \dots, X_n$  - iid rv  $\sim F$

$$F_n(x) = \frac{1}{n} \sum_{j=1}^n \mathbf{1}_{(-\infty, x]}(X_j)$$



$X_1, X_2, \dots, X_n$  - iid rv  $\sim F$


$$F_n(x) = \frac{1}{n} \sum_{j=1}^n \mathbf{1}_{(-\infty, x]}(X_j)$$



$$(\forall \varepsilon) \quad P_F \left\{ \sup_{x \in \mathbf{R}} |F_n(x) - F(x)| \geq \varepsilon \right\} \rightarrow 0$$

$X_1, X_2, \dots, X_n$  - iid rv  $\sim F$

$$F_n(x) = \frac{1}{n} \sum_{j=1}^n \mathbf{1}_{(-\infty, x]}(X_j)$$




$$(\forall \varepsilon) \quad P_F \left\{ \sup_{x \in \mathbf{R}} |F_n(x) - F(x)| \geq \varepsilon \right\} \rightarrow 0$$

$$(\forall \varepsilon)(\forall \eta)(\exists N)(\forall n \geq N)(\forall F \in \mathcal{F}) \quad P_F \left\{ \sup_{x \in \mathbf{R}} |F_n(x) - F(x)| \geq \varepsilon \right\} \leq \eta$$

$X_1, X_2, \dots, X_n$  – iid rv  $\sim F$

$$F_n(x) = \frac{1}{n} \sum_{j=1}^n \mathbf{1}_{(-\infty, x]}(X_j)$$




$$(\forall \varepsilon) \quad P_F \left\{ \sup_{x \in \mathbf{R}} |F_n(x) - F(x)| \geq \varepsilon \right\} \rightarrow 0$$

$$(\forall \varepsilon)(\forall \eta)(\exists N)(\forall n \geq N)(\forall F \in \mathcal{F}) \quad P_F \left\{ \sup_{x \in \mathbf{R}} |F_n(x) - F(x)| \geq \varepsilon \right\} \leq \eta$$

$$(\forall \varepsilon)(\forall \eta)(\exists N)(\forall n \geq N) \quad \sup_{F \in \mathcal{F}} P_F \left\{ \sup_{x \in \mathbf{R}} |F_n(x) - F(x)| \geq \varepsilon \right\} \leq \eta$$

# DVORETZKY-KIEFER-WOLFOWITZ



$$(\forall \varepsilon > 0)(\forall n)(\forall F \in \mathcal{F})$$

$$P_F \left\{ \sup_{x \in \mathbf{R}} |F_n(x) - F(x)| \geq \varepsilon \right\} \leq 2e^{-2n\varepsilon^2}$$

$\mathcal{F}$  - rodzina wszystkich dystrybuant ciągłych i ściśle rosnących

## DVORETZKY-KIEFER-WOLFOWITZ

$$(\forall \varepsilon > 0)(\forall n)(\forall F \in \mathcal{F})$$

$$P_F\left\{\sup_{x \in \mathbf{R}} |F_n(x) - F(x)| \geq \varepsilon\right\} \leq 2e^{-2n\varepsilon^2}$$

Birnbaum (1952) - tablice i przykład: *We wish to approximate  $F(x)$  empirically by  $F_N(x)$  so that the error is everywhere less than .15, on the 90% probability level. How large must be the sample  $N$ ? To answer this question, we find by interpolation in Table 1 that  $P\{D_{65}\} > .900$ , so that  $N = 65$  is sufficient.*

Dvoretzky et al. (1956):


$$(*) \quad P\left\{\sup_x |F_n(x) - F(x)| \geq \lambda\right\} \leq C \cdot \exp(-2n\lambda^2), C - \text{stała uniwersalna,}$$

Gaensler et al. (2006): " $C = 58$  works; the smallest  $C$  for which  $(*)$  holds is still unknown"

Massart, P. (1990). The tight constant in the Dvoretzky–Kiefer–Wolfowitz inequality. *Annals of Probability*, 18: 1269–1283

$$\varepsilon = 0.1, \quad \eta = 0.1 \quad \Rightarrow \quad n = 150$$

$$\varepsilon = 0.01, \quad \eta = 0.01 \quad \Rightarrow \quad n = 26492$$





1. ESTYMATORY JĄDROWE
2. ESTYMATORY WIELOMIANOWE
3. ESTYMATORY SPLAJNOWE



# 1. ESTYMATORY JĄDROWE

$$\widehat{F}_n(x) = \frac{1}{n} \sum_{j=1}^n K\left(\frac{x - X_j}{h_n}\right).$$

$$K(x) = \int_{-\infty}^x k(t)dt, \quad \widehat{f}_n(x) = \frac{1}{n} \sum_{j=1}^n \frac{1}{h_n} k\left(\frac{x - X_j}{h_n}\right)$$



## 1. ESTYMATORY JĄDROWE (c.d.)

TWIERDZENIE NEGATYWNE (Zieliński 2007): *Jeżeli*

–  $K$  jest dowolnym jądrem (zcałkowanym) takim, że  $0 < K(0) < 1$  oraz  $K^{-1}(t) < 0$  dla pewnego  $t \in (0, K(0))$

–  $(h_n, n = 1, 2, \dots)$  jest dowolnym ciągiem liczb dodatnich

to

istnieją takie  $\varepsilon > 0$  oraz  $\eta > 0$ ,

że dla każdego  $n$  znajdzie się rozkład  $F \in \mathcal{F}$  taki, że

$$P_F \left\{ \sup_{x \in \mathbf{R}} |\tilde{F}_n(x) - F(x)| \geq \varepsilon \right\} \geq \eta$$

DOWÓD

Wystarczy udowodnić, że

$$(\exists \varepsilon)(\exists \eta)(\forall n)(\exists F \in \mathcal{F}) \quad P\{\hat{F}_n(0) > F(0) + \varepsilon\} \geq \eta$$

Dowodzę, że


$$(\exists \varepsilon)(\exists \eta)(\forall n)(\exists F \in \mathcal{F}) \quad P\{\widehat{F}_n(0) > F(0) + \varepsilon\} \geq \eta$$

Ustalamy  $t \in (0, K(0))$ , takie że  $K^{-1}(t) < 0$

Ustalamy  $\varepsilon \in (0, t)$  oraz  $\eta \in (t - \varepsilon, 1)$ .

Dla ustalonych  $\varepsilon, \eta$  oraz  $n$  biorę  $F$  takie, że

$F(0) = t - \varepsilon$  and  $F(-h_n K^{-1}(t)) > \eta^{1/n}$ .



Wtedy

$$P_F\{X_j < -h_n K^{-1}(t)\} > \eta^{1/n} \quad \text{czyli} \quad P_F\left\{K\left(-\frac{X_j}{h_n}\right) > t\right\} > \eta^{1/n}$$

Ponieważ

$$\bigcap_{j=1}^n \left\{K\left(-\frac{X_j}{h_n}\right) > t\right\} \subset \left\{\frac{1}{n} \sum_{j=1}^n K\left(-\frac{X_j}{h_n}\right) > t\right\}$$

to

$$P_F\left\{\frac{1}{n} \sum_{j=1}^n K\left(-\frac{X_j}{h_n}\right) > t\right\} = P_F\left\{\underbrace{\frac{1}{n} \sum_{j=1}^n K\left(-\frac{X_j}{h_n}\right)}_{\widehat{F}_n(0)} > F(0) + \varepsilon\right\} > \eta$$

cbdo

## 1. ESTYMATORY JĄDROWE (c.d.)

TWIERDZENIE POZYTYWNE (Zieliński 2007)

(konstrukcja estymatora z losową szerokością okna)

$X_1, X_2, \dots, X_n$  - próba z rozkładu  $F \in \mathcal{F}$

$X_{1:n} \leq X_{2:n} \leq \dots \leq X_{n:n}$  - statystyka pozycyjna z tej próby

$$H_n = \min\{X_{j:n} - X_{j-1:n}, j = 2, 3, \dots, n\}$$

Estymator jądrowy

$$\tilde{F}_n(x) = \frac{1}{n} \sum_{j=1}^n K\left(\frac{x - X_j}{H_n}\right)$$

gdzie

$$K(t) = \begin{cases} 0, & \text{for } t \leq -1/2, \\ 1, & \text{for } t \geq 1/2, \end{cases}$$

$K(0) = 1/2$ ,  $K(t)$  ciągłe i niemalejące w  $(-1/2, 1/2)$ .

Wtedy

$$P_F\left\{\sup_{x \in \mathbf{R}} |\tilde{F}_n(x) - F(x)| \geq \varepsilon\right\} \leq 2e^{-2n(\varepsilon - 1/2n)^2}, \quad n > \frac{1}{2\varepsilon}, \quad F \in \mathcal{F}$$

## 1. ESTYMATORY JĄDROWE (c.d.)

TWIERDZENIE POZYTYWNE dowód

Dla  $k$  oraz  $j = 1, 2, \dots, n$  mamy

$$K\left(\frac{X_{k:n} - X_{j:n}}{H_n}\right) = \begin{cases} 0, & \text{for } \frac{X_{k:n} - X_{j:n}}{H_n} \leq -\frac{1}{2} \Leftrightarrow X_{j:n} > X_{k:n} + \frac{1}{2}H_n \Leftrightarrow j > k \\ \frac{1}{2}, & \text{for } t = 0 \\ 1, & \text{for } j < k \end{cases}$$

Zatem

$$\begin{aligned} \tilde{F}_n(X_{k:n}) &= \frac{1}{n} \sum_{j=1}^n K\left(\frac{X_{k:n} - X_{j:n}}{H_n}\right) = \frac{k-1}{n} + \frac{1}{2n} \\ &= F_n(X_{k-1:n}) + \frac{1}{2n} = F_n(X_{k:n}) - \frac{1}{2n} \end{aligned}$$

Więc, dla  $k = 1, 2, \dots, n$ , mamy  $|\tilde{F}_n(X_{k:n}) - F_n(X_{k:n})| = \frac{1}{2n}$ .

Dla  $k = 1, 2, \dots, n$ , mamy  $|\tilde{F}_n(X_{k:n}) - F_n(X_{k:n})| = \frac{1}{2n}$ .

Estymator jądrowy  $\tilde{F}_n(x)$  jest ciągły i rosnący, dystrybuanta empiryczna  $F_n(x)$  jest funkcją schodkową, więc  $|\tilde{F}_n(x) - F_n(x)| \leq \frac{1}{2n}$  dla wszystkich  $x \in (-\infty, \infty)$ .

Na mocy nierówności trójkąta

$$|\tilde{F}_n(x) - F(x)| \leq |F_n(x) - F(x)| + \frac{1}{2n}$$

otrzymujemy

$$P\{\sup_{x \in \mathbf{R}} |\tilde{F}_n(x) - F(x)| \geq \varepsilon\} \leq P\{\sup_{x \in \mathbf{R}} |F_n(x) - F(x)| + \frac{1}{2n} \geq \varepsilon\}$$

stąd nierówność DKW:

$$P\{\sup_{x \in \mathbf{R}} |\tilde{F}_n(x) - F(x)| \geq \varepsilon\} \leq 2e^{-2n(\varepsilon - 1/2n)^2}, \quad n > \frac{1}{2\varepsilon}$$

---


$$\begin{aligned} \varepsilon = 0.1, \quad \eta = 0.1 &\Rightarrow n = 150(F_n) \quad n = 160(\tilde{F}_n) \\ \varepsilon = 0.01, \quad \eta = 0.01 &\Rightarrow n = 26,492(F_n) \quad n = 26,592(\tilde{F}_n) \end{aligned}$$

## 2. ESTYMATORY WIELOMIANOWE (na $[0, 1]$ )

Wielomiany podstawowe na  $[0, 1]$ :


$$N_{i,m}(x) = \binom{m}{i} x^i (1-x)^{m-i}, \quad 0 \leq x \leq 1, \quad i = 0, 1, \dots, m; \quad m \geq 1$$

Operator (Ciesielski 1988)

$$T_m F(x) = \sum_{i=0}^m \int_0^1 (m+1) N_{i,m}(y) dF(y) \int_0^x N_{i,m}(z) dz$$

$T_m$  przekształca dystrybuanty na  $[0, 1]$ , ciągłe lub nie, w dystrybuanty na  $[0, 1]$ , które są wielomianami stopnia  $m+1$

Estymatorem dystrybuanty  $F$  jest  $F_{m,n} = T_m F_n$





TWIERDZENIE NEGATYWNE:

$$(\exists \varepsilon > 0)(\exists \eta > 0)(\forall m)(\forall n)(\exists F \in \mathcal{F})$$

$$P_F \left\{ \sup_{x \in \mathbf{R}} |F_{m,n}(x) - F(x)| > \varepsilon \right\} > \eta$$

DOWÓD

Z definicji operatora  $T_m$ :

$$F_{m,n}(x) = \frac{1}{n} \sum_{j=1}^n \sum_{i=0}^m N_{i,m}(X_j) \int_0^x (m+1)N_{i,m}(z) dz$$

Oznaczamy:

$$b(i, m, q) = \binom{m}{i} q^i (1-q)^{m-i}, \quad B(i, m, q) = \sum_{j=0}^i b(j, m, q)$$

oraz

$$I_x(p, q) = \frac{\Gamma(p+q)}{\Gamma(p)\Gamma(q)} \int_0^x t^{p-1} (1-t)^{q-1} dt.$$

Zapisuję estymator w postaci:

$$F_{m,n}(x) = \frac{1}{n} \sum_{j=1}^n \sum_{i=0}^m b(i, m, X_j) I_x(i+1, m-i+1).$$

Udowodnię, że dla wybranych  $\varepsilon$  oraz  $\eta$ , dla każdego  $n$  oraz dla każdego nieparzystego  $m$  istnieje rozkład  $F$  taki, że

$$(\#) \quad P_F \left\{ F_{m,n}\left(\frac{1}{2}\right) > F\left(\frac{1}{2}\right) + \varepsilon \right\} > \eta.$$

Wystarczą do tego bardzo grube oszacowania.

Weźmy dowolne  $\varepsilon \in (0, \frac{1}{16})$  oraz  $\eta \in (\varepsilon, 1)$ .

Jeżeli  $i \leq \frac{m-1}{2}$ , to  $I_{1/2}(i+1, m-i+1) \geq 1/2$ , więc

$$F_{m,n}\left(\frac{1}{2}\right) > \frac{1}{2} \frac{1}{n} \sum_{j=1}^n \sum_{i=0}^{(m-1)/2} b(i, m, X_j) = \frac{1}{2} \frac{1}{n} \sum_{j=1}^n B\left(\frac{m-1}{2}, m, X_j\right).$$

Ponieważ  $B\left(\frac{m-1}{2}, m, q\right)$  jest funkcją ciągłą argumentu  $q$ , malejącą,

$B\left(\frac{m-1}{2}, m, \frac{1}{2}\right) = \frac{1}{2}$ , więc dla danego  $\varepsilon \in (0, \frac{1}{16})$  istnieje  $\delta > 0$  takie, że

$$B\left(\frac{m-1}{2}, m, \frac{1}{2} + \delta\right) > 4\varepsilon.$$

Niech  $F$  będzie dystrybuantą taką, że

$$F\left(\frac{1}{2}\right) < \varepsilon \quad \text{oraz} \quad F\left(\frac{1}{2} + \delta\right) > \eta^{1/n}.$$

Ostatnia nierówność oznacza, że dla każdego  $j = 1, 2, \dots, n$ ,

$$P_F\{X_j < \frac{1}{2} + \delta\} > \eta^{1/n}$$

więc

$$P_F\{B\left(\frac{m-1}{2}, m, X_j\right) > 4\varepsilon\} > \eta^{1/n}.$$

Ale

$$\bigcap_{j=1}^n \left\{ B\left(\frac{m-1}{2}, m, X_j\right) > 4\varepsilon \right\} \subset \left\{ \frac{1}{n} \sum_{j=1}^n B\left(\frac{m-1}{2}, m, X_j\right) > 4\varepsilon \right\}$$

więc

$$P_F \left\{ \frac{1}{n} \sum_{j=1}^n B\left(\frac{m-1}{2}, m, X_j\right) > 4\varepsilon \right\} > \eta,$$

a stąd wynika (#), q.e.d.

A. Ograniczenie klasy  $\mathcal{F}$

B. Wykorzystanie operatora  $T_m$  do modyfikacji estymatora  $F_n$

## A. Ograniczenie klasy $\mathcal{F}$

=====

$\mathcal{F}_M$  - rodzina dystrybuant  $F \in \mathcal{F}$  o absolutnie ciągłych gęstościach  $f = F'$ , spełniających warunek

$$\int_0^1 |f'(x)|^2 dx \leq M$$

Przykład: jeżeli  $f$  jest pdf  $N(0, \sigma^2)$ , to  $\int_0^1 |f'(x)|^2 dx = (4\pi\sigma^4)^{-1}$

### TWIERDZENIE

Dla danych  $\varepsilon > 0$ ,  $\eta > 0$  oraz  $M$  istnieją  $m$  oraz  $n$  takie, że

$$(\forall F \in \mathcal{F}_M) \quad P_F\{\|F_{m,n} - F\|_\infty > \varepsilon\} < \eta$$

Liczby  $m$  oraz  $n$  można wyznaczyć efektywnie z wzorów:

$$\frac{2M}{m^{1/4}} < \varepsilon \quad \text{oraz} \quad 2 \exp\left(-2\frac{nM^2}{m^{1/2}}\right) < \eta$$

Dowód (szkic)

$$F_{m,n} - F = T_m F_n - T_m F + T_m F - F = T_m(F_n - F) + (T_m F - F)$$

$$\begin{aligned} \|F_{m,n} - F\| &\leq \|T_m\| \cdot \|F_n - F\| + \|(T_m F - F)\| \\ &\leq \|F_n - F\| + M \cdot m^{-1/4} \end{aligned} \quad (\bullet)$$

$$P_F\{\|F_{m,n} - F\| > \varepsilon\} \leq P_F\{\|F_n - F\| + \frac{M}{m^{1/4}} > \varepsilon\}$$

$$m : \frac{2M}{m^{1/4}} < \varepsilon \quad (!)$$

$$\begin{aligned} P_F\{\|F_{m,n} - F\| > \varepsilon\} &\leq P_F\{\|F_n - F\| > \frac{M}{m^{1/4}}\} \\ &\leq 2 \exp\left(-2n \frac{M^2}{m^{1/2}}\right) \end{aligned}$$

$$n : 2 \exp\left(-2 \frac{nM^2}{m^{1/2}}\right) < \eta$$

B. Wykorzystanie wielomianów  $N_{i,n}(x)$  do modyfikacji estymatora  $F_n$

=====

Wielomiany podstawowe na  $[0, 1]$ :

$$N_{i,m}(x) = \binom{m}{i} x^i (1-x)^{m-i}, \quad 0 \leq x \leq 1, \quad i = 0, 1, \dots, m; \quad m \geq 1$$

Definiujemy

$$\varphi_m(x) = (2m+1)N_{m,2m}(x) = (2m+1) \binom{2m}{m} x^m (1-x)^m, \quad 0 \leq x \leq 1, \quad m = 1, 2, \dots$$

$$\Phi_m(x) = \int_0^x \varphi_m(y) dy.$$

$$\Phi_m(x; [a, b]) = \Phi_m\left(\frac{x-a}{b-a}\right), \quad -\infty < a < b < +\infty$$

Definiujemy

$$X_{0:n} = \max\{0, X_{1:n} - (X_{2:n} - X_{1:n})\} = \max\{0, 2X_{1:n} - X_{2:n}\}$$

$$X_{n+1:n} = \min\{X_{n:n} + (X_{n:n} - X_{n-1:n}), 1\} = \min\{2X_{n:n} - X_{n-1:n}, 1\}$$

Konstruujemy estymator wielomianowy

$$\Phi_{m,n}(x) = \begin{cases} 0, & \text{for } x < X_{0:n}, \\ \frac{1}{n} \Phi_m(x; [X_{i-1:n}, X_{i:n}]) + F_n(X_{i-1:n}) - \frac{1}{2n}, & \text{for } X_{i-1:n} \leq x < X_{i:n}, \\ & i = 1, 2, \dots, n+1 \\ 1, & \text{for } x \geq X_{n+1:n}. \end{cases}$$

Własności estymatora  $\Phi_{m,n}(x)$ :

1.  $\Phi_{m,n}(x)$  jest dystrybuantą na  $[X_{0:n}, X_{n+1:n}]$
2.  $\Phi_{m,n}(X_{i:n}) = \frac{i}{n} - \frac{1}{2n} = F_n(X_{i:n}) - \frac{1}{2n}, \quad i = 1, 2, \dots, n$
3.  $\Phi_{m,n}(x) \in C^m(\mathbf{R})$
4.  $D^k \Phi_{m,n}(X_{i:n}) = 0$  for  $k = 1, 2, \dots, m$  and  $i = 1, 2, \dots, n$
5.  $\sup_{x \in \mathbf{R}} |\Phi_{m,n}(x) - F(x)| \leq \sup_{x \in \mathbf{R}} |F_n(x) - F(x)| + \frac{1}{2n}$

Nierówność DKW

$$P_F \left\{ \sup_{x \in \mathbf{R}} |\Phi_{m,n}(x) - F(x)| \geq \varepsilon \right\} \leq 2e^{-2n(\varepsilon - 1/2n)^2}$$

$$n > \frac{1}{2\varepsilon}, \quad F \in \mathcal{F}$$

### 3. ESTYMATORY SPLAJNOWE

Definiujemy  $B^{(r)}$  jako

#### **podstawowy symetryczny B-splajn stopnia $r$**

(podstawowa symetryczna funkcja gięta stopnia  $r$ , a symmetric cardinal B-spline of order  $r$ ) z węzłami  $\{i + r/2, i \in \mathcal{Z}\}$ ,

jeżeli

$$B^{(r)}(x) \geq 0, \quad x \in R,$$

$$\text{supp } B^{(r)} = [-r/2, r/2],$$

$B^{(r)}$  jest wielomianem stopnia  $r - 1$  na każdym przedziale

$$[j - r/2, j + 1 - r/2], \quad j = 0, 1, \dots, r - 1,$$

$B^{(r)} \in C^{(r-2)}(R)$  (dla  $r = 1$  jest to lewostronnie ciągła funkcja schodkowa)

Definicja probabilistyczna:

$B^{(r)}$  jest gęstością rozkładu prawdopodobieństwa sumy  $r$  niezależnych zmiennych losowych o jednakowym rozkładzie  $U(-1/2, 1/2)$



Wzór dla  $B^{(r)}(x) = P_{U(-1/2, 1/2)} \{U_1 + \dots + U_r \leq x\}$ :

$$B^{(r)}(x) = \begin{cases} 0, & \text{dla } x < -r/2, \\ \frac{1}{(r-1)!} \sum_{i=0}^{[x+r/2]} (-1)^i \binom{r}{i} \left(x + \frac{r}{2} - i\right)^{r-1}, & \text{dla } x \geq -r/2 \\ 0, & \text{dla } x > r/2 \end{cases}$$

$$\mathcal{B}^{(r)}(x) = \int_{-\infty}^x B^{(r)}(t) dt$$

$$\mathcal{B}^{(r)}(x) = \begin{cases} 0, & \text{dla } x < -r/2, \\ \frac{1}{r!} \sum_{i=0}^{[x+r/2]} (-1)^i \binom{r}{i} \left(x + \frac{r}{2} - i\right)^r, & \text{dla } x \geq -r/2 \\ 1, & \text{dla } x > r/2 \end{cases}$$

Dla danych  $r \geq 1$ ,  $h > 0$ ,  $i \in \mathcal{Z}$  oznaczamy

$$B_{h,i}^{(r)}(x) = B^{(r)}\left(\frac{x}{h} - i\right)$$

Dla danych  $r \geq 1$ ,  $1 \leq k \leq r$ ,  $r - k = 2\nu$ ,  $\nu$  – całkowite,  $i \in \mathcal{Z}$  oraz  $h > 0$  definiujemy operator (Ciesielski 1988, 1991)

$$T_h^{(k,r)}F(x) = \frac{1}{h} \sum_{i \in \mathcal{Z}} \int_R B_{h,i+\nu}^{(k)}(y) dF(y) \int_{-\infty}^x B_{h,i}^{(r)}(y) dy$$

Ten operator przeprowadza m.in. dystrybuanty (ciągłe lub skokowe) w dystrybuanty, które są splajnami stopnia  $r$ . Za estymator dystrybuanty, skonstruowany na podstawie dystrybuanty empirycznej  $F_n$ , przyjmujemy wartość tego operatora dla  $F_n$ .

Por: Wielomiany podstawowe na  $[0, 1]$ :

$$N_{i,m}(x) = \binom{m}{i} x^i (1-x)^{m-i}, \quad 0 \leq x \leq 1, \quad i = 0, 1, \dots, m; \quad m \geq 1$$

Operator

$$T_m F(x) = \sum_{i=0}^m \int_0^1 (m+1) N_{i,m}(y) dF(y) \int_0^x N_{i,m}(z) dz$$

Estymator splajnowy dla wybranych  $r \geq 1$ ,  $1 \leq k \leq r$ :

$$T_h^{(k,r)} F_n(x) = \sum_{i \in \mathcal{Z}} \left[ \frac{1}{n} \sum_{j=1}^n B^{(k)} \left( \frac{X_j}{h} - \left( i + \frac{r-k}{2} \right) \right) \right] \mathcal{B}^{(r)} \left( \frac{x}{h} - i \right)$$

Dla przypomnienia:

$$T_h^{(k,r)} F(x) = \frac{1}{h} \sum_{i \in \mathcal{Z}} \int_R B_{h,i+\nu}^{(k)}(y) dF(y) \int_{-\infty}^x B_{h,i}^{(r)}(y) dy$$

Klasy dystrybuant, dla których możemy dla tego estymatora podać nierówność typu DKW, konstruujemy w następujący sposób.

Definiujemy

$$\omega_1(F, \delta) = \sup_{|t| < \delta} \sup_x |F(x+t) - F(x)|$$

oraz

$$\omega_2(F, \delta) = \sup_{|t| < \delta} \sup_x |F(x+2t) - 2F(x+t) + F(x)|.$$

Niech  $\omega(h)$ ,  $h \in R^+$ , będzie modułem ciągłości, tzn. funkcją ciągłą, ograniczoną, niemalejącą,  $\omega(0) = 0$ . Dla danego modułu ciągłości  $\omega$ , zdefiniujmy dwie Hölderowskie klasy dystrybuant:

$$H_{\omega,1}^{(k,r)} = \{F \in \mathcal{F} : \omega_1(F, \frac{r+k}{2}h) \leq \omega(h)\}$$

$$H_{\omega,2}^{(k,r)} = \{F \in \mathcal{F} : (2(4 + (r+k)^2)\omega_2(F, h) \leq \omega(h)\}$$

W każdej z tych klas spełniona jest nierówność DKW, tzn. dla każdej z tych klas, dla każdego  $\varepsilon > 0$  oraz  $\eta > 0$  można wyznaczyć takie  $h > 0$  oraz  $N$ , że jeżeli  $n \geq N$ , to dla każdej dystrybuanty  $F \in H_{\omega,1}^{(k,r)}$ , lub odpowiednio dla każdej dystrybuanty  $F \in H_{\omega,2}^{(k,r)}$ ,

$$P_F\{\|T_h^{(k,r)} F_n - F\|_\infty > \varepsilon\} < \eta$$

Wystarczy wyznaczyć  $h$  oraz  $N$  takie, że

$$\omega(h) < \frac{\varepsilon}{2} \quad \text{oraz} \quad 2 \exp\left(-\frac{N\varepsilon^2}{2}\right) < \eta.$$