



J. HOLZHEIMER (Wrocław)

## Estymacja parametrów procesu Galtona–Watsona

(Praca przyjęta do druku 18.04.1980)

**0. Wstęp.** Praca stanowi próbę przeglądu estymatorów parametrów najprostszego procesu gałązkowego — jednowymiarowego procesu Galtona–Watsona. Część pierwsza pracy zawiera opis matematyczny procesu oraz jego podstawowe własności. W części drugiej rozpatrywane są znane estymatory średniej w rozkładzie prawdopodobieństwa kreacji; część trzecia jest poświęcona estymacji prawdopodobieństw kreacji, a w części czwartej rozważa się problem estymacji wariancji.

Ze względu na odmienne zachowanie się procesu w zależności od średniej w rozkładzie prawdopodobieństwa kreacji zagadnienie estymacji parametrów rozpatruje się oddzielnie dla podkrytycznego, krytycznego i nadkrytycznego procesu Galtona–Watsona.

**1. Proces Galtona–Watsona.** Niech  $Z = (Z_n; n = 0, 1, \dots)$ ,  $Z_0 = 1$ , będzie ciągiem zmiennych losowych o wartościach całkowitych nieujemnych, stanowiącym proces Galtona–Watsona, tzn.

$$Z_{n+1} = \zeta_1^{(n)} + \zeta_2^{(n)} + \dots + \zeta_{Z_n}^{(n)}, \quad n \geq 0,$$

$$P(Z_1 = k) = p_k, \quad p_k \geq 0, \quad \sum_{k=0}^{\infty} p_k = 1,$$

gdzie  $\zeta_i^{(n)}$ ,  $i = 1, 2, \dots, Z_n$ , są zmiennymi losowymi wzajemnie niezależnymi, o rozkładzie  $Z_1$ , niezależnymi od  $Z_n$ .  $Z_{n+1} = 0$ , gdy  $Z_n = 0$ .

W dalszych częściach pracy będziemy się często odwoływali do popularnej interpretacji procesu Galtona–Watsona. Rozważmy populację indywiduów zdolnych do rozszczepiania się na indywidua tego samego typu. Załóżmy, że populacja indywiduów w chwili 0 składa się z  $Z_0$  indywiduów tworzących początkowe (zerowe) pokolenie. Każde indywiduum danej populacji jest tego samego typu oraz rozszczepia się niezależnie od pozostałych indywiduów zgodnie z rozkładem prawdopodobieństwa  $(p_k; k = 0, 1, \dots)$  nazywanym *rozkładem prawdopodobieństwa kreacji*. Potomkowie indywiduów pokolenia początkowego tworzą pierwsze pokolenie procesu Galtona–Watsona. Indywidua każdego pokolenia rozszczepiają się niezależnie od liczebności poprzednich pokoleń.

Przyjmijmy następujące oznaczenia dla wartości oczekiwanej i wariancji liczby bezpośrednich potomków danego indywiduum:

$$m = EZ_1, \quad \sigma^2 = \text{Var}(Z_1).$$

Dalej będziemy zakładali, że  $0 < \sigma^2 < +\infty$ .

Proces Galtona–Watsona  $Z$  nazywamy *podkrytycznym*, gdy  $m < 1$ , *krytycznym*, gdy  $m = 1$ , *nadkrytycznym*, gdy  $m > 1$ . Rozróżnienie tych trzech przypadków jest istotne przy rozważaniu asymptotyki procesu. Jeśli  $q = P(\lim_{n \rightarrow +\infty} Z_n = 0)$  oznacza

liczbę zwaną *prawdopodobieństwem wymarcia procesu*, to  $q = 1$ , gdy  $m \leq 1$ , natomiast  $q < 1$ , gdy  $m > 1$ .

Zachowanie się procesu  $Z$  zależy od parametru  $m$ , a więc jednym z podstawowych zadań statystyki procesów gałązkowych jest określenie dobrego (w pewnym sensie) estymatora tego parametru.

W przypadku nadkrytycznym nasz proces z prawdopodobieństwem 1 (z P.1) osiąga 0 dla dostatecznie dużych  $n$  lub wzrasta do  $+\infty$ , gdy  $n \rightarrow +\infty$ . Ta własność niestabilności procesu wydaje się być sprzeczna z zachowaniem się populacji biologicznych, które często dążą do stanu równowagi probabilistycznej. Z tego powodu rozważany model bez modyfikacji raczej nie nadaje się do opisu zjawisk występujących w populacjach biologicznych. Niemniej jednak statystyka tego procesu jest interesującym zagadnieniem, a przy tym może być punktem wyjścia do rozważania modeli zmodyfikowanych, jak na przykład procesu Galtona–Watsona z imigracją i procesu gałązkowego w losowym środowisku.

Rozważmy pytanie, przy jakich założeniach istnieje taki ciąg  $C = (C_n; n = 0, 1, \dots)$  stałych, że zachodzi zbieżność

$$\frac{Z_n}{C_n} \xrightarrow{P} W,$$

gdzie symbol  $\xrightarrow{P}$  oznacza zbieżność wg prawdopodobieństwa, a  $W$  niezdegenerowaną zmienną losową. C. C. Heyde rozwiązał ten problem pokazując (zob. [1] lub [11]), że zawsze istnieje taki ciąg  $C$ ,  $C_n \rightarrow +\infty$ ;  $C_{n+1}/C_n \rightarrow m$ , gdy  $n \rightarrow +\infty$ , że zmienne losowe  $W_n = Z_n/C_n$  dążą z P.1 do zmiennej losowej  $W$  z  $P(W > 0) = 1 - q$ . Jeżeli  $EZ_1 \log Z_1 < +\infty$ , to możemy wziąć  $C_n = m^n$ , w przeciwnym razie, jeżeli  $EZ_1 \log Z_1 = +\infty$ , to  $P(W = 0) = 1$ , czyli zmienna losowa  $W$  jest zdegenerowana.

Wprowadźmy oznaczenie  $S_n = Z_0 + Z_1 + \dots + Z_n$ . C. C. Heyde pokazał również, że

$$\frac{S_n}{1 + m + \dots + m^n} \rightarrow W \quad \text{z P.1.}$$

A. Badalbijew (zob. [2]) rozważał podwójnie indeksowany ciąg zmiennych losowych  $W_n^{(r)} = Z_n^{(r)}/rm^n$ , gdzie  $(Z_n^{(r)}; n = 0, 1, \dots)$  jest procesem Galtona–Watsona, dla którego  $Z_0^{(r)} = r$ . Udowodnił on następujące

TWIERDZENIE 1.1. (I) Jeżeli  $m < 1$  oraz  $r, n \rightarrow +\infty$  w taki sposób, że  $rm^n \rightarrow +\infty$ , to

$$\frac{Z_n^{(r)}}{rm^n} \xrightarrow{P} 1;$$

(II) jeżeli  $m = 1$  oraz  $r, n \rightarrow +\infty$  w taki sposób, że  $r/n \rightarrow +\infty$ , to

$$\frac{Z_n^{(r)}}{r} \xrightarrow{P} 1;$$

(III) jeżeli  $m > 1$  oraz  $r \rightarrow +\infty$ , to

$$\frac{Z_n^{(r)}}{rm^n} \xrightarrow{P} 1 \quad \text{dla każdego } n.$$

N. M. Yanev (zob. [16]) rozważył również zbieżność zmiennych losowych  $Z_n^{(r)}/r$  w przypadkach, gdy  $r/n \rightarrow 0$  oraz gdy  $n/r \rightarrow K$ ,  $0 < K < +\infty$ .

**2. Estymator Lotki-Nagajewa.** Rozważmy estymator średniej  $m$  oparty na próbie  $(Z_0 = 1, Z_1, \dots, Z_{n+1})$ , zdefiniowany w następujący sposób:

$$\bar{m} = \begin{cases} \frac{Z_{n+1}}{Z_n}, & Z_n > 0, \\ 1 & \text{w przeciwnym razie.} \end{cases}$$

Estymator ten był badany przez A. J. Lotkę oraz A. V. Nagajewa (zob. [14]). Właściwości asymptotyczne tego estymatora badał W. Bühler (zob. [3]). Pokazał on, że w przypadku nadkrytycznym

$$P(\sigma^{-1}(Z_n)^{1/2}(\bar{m} - m) \leq x | Z_n > 0) \rightarrow \Phi(x),$$

gdzie  $\Phi(x)$  jest dystrybuantą rozkładu normalnego ze średnią 0 i wariancją 1.

Zbiór  $A = (Z_n > 0, n = 0, 1, \dots)$  nazywamy *zbiorem nieochłaniania procesu Z*. Ponieważ  $P(A) = 1 - q$ , więc miara probabilistyczna  $P_A(\cdot) = P(\cdot | A)$  ma sens jedynie w przypadku nadkrytycznym. J. P. Dion uogólnił wynik W. Bühlera rozważając dowolne miary probabilistyczne  $Q$  absolutnie ciągłe względem miary  $P_A$  ( $Q \ll P_A$ ). Wprowadzenie miary  $Q$  jest próbą osłabienia założenia o niezależności rozszczepiania się indywiduów tej samej generacji. Oczywiście, założenie  $Q \ll P_A$  jest założeniem bardzo mocnym, ale pozwala ono rozważać populacje biologiczne, w których występuje zależność między rozszczepianiem indywiduów tej samej generacji. Rezultat J. P. Diona jest następujący:

TWIERDZENIE 2.1. Dla nadkrytycznego procesu Galtona-Watsona  $Z$  zachodzi

$$Q(\sigma^{-1}(Z_n)^{1/2}(\bar{m} - m) \leq x) \rightarrow \Phi(x),$$

$$Q(\sigma^{-1}m^{n/2}(\bar{m} - m) \leq x) \rightarrow \int_0^{\infty} \Phi(x\sqrt{y}) dS(y),$$

gdzie  $S(y) = P_A(W < y)$ , a  $W$  jest zmienną losową będącą granicą z P.1 zmiennych losowych  $Z_n/m^n$ .

J. P. Dion znalazł również przedział ufności dla  $m$ .

Można ponadto wykazać, że w przypadku nadkrytycznym  $\bar{m} \rightarrow m$  z P.1. na zbiorze  $A$ . Wynika to z rezultatu C. C. Heyde (zob. [11]). K. S. Crump i R. B. Howe wykazali, że  $E(\bar{m}|A) \rightarrow m$ , gdy  $n \rightarrow +\infty$ . Oznacza to, że estymator  $\bar{m}$  jest asymptotycznie nieobciążony na zbiorze  $A$ . Podane własności estymatora Lotki–Nagajewa dotyczą jedynie nadkrytycznego procesu Galtona–Watsona. A. Nagajew (zob. [14]) rozważał również asymptotykę  $\bar{m}$  w przypadku podkrytycznym i krytycznym pod warunkiem  $Z_n > 0$ .

Jest on określony jedynie na zbiorze niepochłaniania procesu, a więc jest niewygodny do praktycznych celów. Jak już zauważyliśmy poprzednio, można badać asymptotykę procesu Galtona–Watsona przy założeniu, że liczba indywiduów pokolenia zerowego  $r$  dąży do nieskończoności lub gdy zarówno  $r$ , jak i  $n$  dążą do nieskończoności. Takie podejście pozwala nie ograniczać się do zbioru ( $Z_n > 0$ ).

A. Badalbijew w [2] rozważał estymator  $m$  postaci

$$\bar{m}_r = \frac{Z_{n+1}^{(r)}}{1 + Z_n^{(r)}},$$

przy czym wykazał, że jest on mocno zgodny, tzn.  $\bar{m}_r \rightarrow m$  z P.1., gdy  $r \rightarrow +\infty$ , oraz badał asymptotykę tego estymatora.

**TWIERDZENIE 2.2.** (I) *Jeżeli  $m < 1$  oraz  $r, n \rightarrow +\infty$  w taki sposób, że  $rm^n \rightarrow +\infty$ , to*

$$P(\sigma^{-1}(rm^n)^{1/2}(\bar{m}_r - m) \leq x) \rightarrow \Phi(x);$$

(II) *jeżeli  $m = 1$  oraz  $r, n \rightarrow +\infty$  w taki sposób, że  $r/n \rightarrow +\infty$ , to*

$$P(\sigma^{-1}(r)^{1/2}(\bar{m}_r - m) \leq x) \rightarrow \Phi(x);$$

(III) *jeżeli  $m > 1$  oraz  $r \rightarrow +\infty$ , to*

$$P(\sigma^{-1}(rm^n)^{1/2}(\bar{m}_r - m) \leq x) \rightarrow \Phi(x)$$

dla każdego  $n$ .

Mocna zgodność estymatora  $\bar{m}$  wynika z faktu, że  $Z_n^{(r)}$  daje się przedstawić w postaci

$$Z_n^{(r)} = Z_{n,1} + Z_{n,2} + \dots + Z_{n,r},$$

gdzie  $Z_{n,i}$  jest liczbą indywiduów  $n$ -tego pokolenia, będących potomkami  $i$ -tego indywiduum pokolenia zerowego. Zmienne losowe ( $Z_{n,i}; i = 1, 2, \dots, r$ ) są niezależne o rozkładzie takim jak  $Z_n$ .

Twierdzenia 2.2 dowodzi się standardowymi metodami (zob. [14] lub [16]). Można również badać asymptotykę estymatora  $\bar{m}_r$ , gdy  $r \rightarrow +\infty$ .

2.1. *Estymator Harrisa.* T. Harris w pracy [10] udowodnił, że

$$\hat{m} = \frac{Z_1 + Z_2 + \dots + Z_{n+1}}{Z_0 + Z_1 + \dots + Z_n}$$

jest estymatorem największej wiarygodności parametru  $m$  opartym na próbie  $(Z_{jk}; j = 0, 1, \dots, n+1, k = 0, 1, \dots)$ , gdzie  $Z_{jk}$  oznacza liczbę indywidualów  $j$ -ej generacji mających  $k$  bezpośrednich potomków. Tamże Harris wykazał, że  $\hat{m} \rightarrow m$  z P.1 na zbiorze  $A$ . P. D. Feigin w pracy [9] udowodnił, że estymator ten jest również estymatorem największej wiarygodności opartym na próbie  $(Z_0 = 1, Z_1, \dots, Z_{n+1})$ . J. P. Dion udowodnił ponadto asymptotyczną normalność  $\hat{m}$  oraz podał przedział ufności dla  $m$ .

**TWIERDZENIE 2.3.** *Dla nadkrytycznego procesu Galtona-Watsona  $Z$  i dowolnej miary probabilistycznej  $Q \ll P_A$  mamy*

$$Q(\sigma^{-1}(S_n)^{1/2}(\hat{m}-m) \leq x) \rightarrow \Phi(x),$$

$$Q(\sigma^{-1}(1+m+\dots+m^n)^{1/2}(\hat{m}-m) \leq x) \rightarrow \int_0^{\infty} \Phi(x\sqrt{y})dS(y).$$

U w a g a. J. Scott w pracy [15] podał pewne centralne twierdzenie graniczne dla martyngałów, z którego jako wniosek otrzymuje przedstawione wyżej własności asymptotyczne estymatorów Lotki-Nagajewa i Harris'a.

Dowód twierdzenia 2.3 wynika z centralnego twierdzenia granicznego dla sum niezależnych zmiennych losowych o losowej liczbie składników (zob. [5], tw. 17.2), ze zbieżności

$$\frac{S_n}{1+m+\dots+m^n} \rightarrow W \quad \text{z P.1}$$

oraz z równości

$$\sigma^{-1}(S_n)^{1/2}(\hat{m}-m) = \sigma^{-1}(S_n)^{-1/2} \sum_{i=1}^{S_n} (\zeta_i - m),$$

gdzie  $(\zeta_i; i = 1, 2, \dots)$  jest ciągiem niezależnych zmiennych losowych o rozkładzie  $Z_1$ . Rozważanie estymatora  $\hat{m}$  na zbiorze  $A$  ma sens jedynie wtedy, gdy  $m > 1$ . W przypadku podkrytycznym i krytycznym interesujące byłoby rozważenie estymatora  $\hat{m}$  pod warunkiem  $Z_n > 0$ . N. M. Yanev w pracy [16] badał asymptotykę estymatora  $\hat{m}$  w przypadku, gdy  $r \rightarrow +\infty$  dla ustalonego  $n$  oraz gdy  $r, n \rightarrow +\infty$ .

**TWIERDZENIE 2.4.** *Jeżeli  $r \rightarrow +\infty$  dla ustalonego  $n$ , to*

- (I)  $\hat{m} \rightarrow m$  z P.1,  $E\hat{m} \rightarrow m$ , oraz  
 (II)  $\hat{m}$  jest asymptotycznie normalny, tzn.

$$P\left(\sigma^{-1}(r(1+m+\dots+m^n))^{1/2}(\hat{m}-m) \leq x\right) \rightarrow \Phi(x).$$

**TWIERDZENIE 2.5.** *Jeżeli  $r, n \rightarrow +\infty$ , to*

- (I)  $\hat{m} \xrightarrow{P} m$ ,  $E\hat{m} \rightarrow m$ ,  
 (II) jeżeli  $m < 1$ , to

$$P\left(\sigma^{-1}\left(\frac{r}{1-m}\right)^{1/2}(\hat{m}-m) \leq x\right) \rightarrow \Phi(x),$$

(III) jeżeli  $m = 1$  oraz  $r/n \rightarrow +\infty$ , to

$$P(\sigma^{-1}(rn)^{1/2}(\hat{m}-m) \leq x) \rightarrow \Phi(x),$$

(IV) jeżeli  $m > 1$  oraz  $E(Z_1^4) < +\infty$ , to

$$P\left(\sigma^{-1}\left(\frac{r(m^{n+1}-1)}{m-1}\right)^{1/2}(\hat{m}-m) \leq x\right) \rightarrow \Phi(x).$$

2.2. Inne estymatory średniej  $m$ . C. C. Heyde i J. Leslie w pracy [13] zaproponowali estymator średniej  $m$  oparty jedynie na liczebności  $n$ -tej generacji  $Z_n$ . Estymator ten ma postać

$$m^* = (Z_n)^{1/n}.$$

W przypadku nadkrytycznym estymator ten jest mocno zgodny na zbiorze  $A$  oraz zachodzi zbieżność

$$n(m^* - m) \rightarrow m \log W \quad \text{z } P_A.1.$$

3. Estymacja prawdopodobieństwa kreacji. Rozważając próbę  $(Z_{jk}; j = 0, 1, \dots, n+1, k = 0, 1, \dots)$ , T. Harris otrzymał estymatory największej wiarygodności dla prawdopodobieństw kreacji następującej postaci

$$\hat{p}_k = \frac{Z_{0k} + Z_{1k} + \dots + Z_{nk}}{S_n}, \quad k = 0, 1, \dots$$

J. Dion w pracy [7] udowodnił asymptotyczną normalność tych estymatorów.

TWIERDZENIE 3.1. Dla nadkrytycznego procesu Galtona-Watsona  $Z$  oraz dla dowolnej miary probabilistycznej  $Q \ll P_A$  zachodzi

$$Q\left(\left(\frac{S_n}{p_k(1-p_k)}\right)^{1/2}(\hat{p}_k - p_k) \leq x\right) \rightarrow \Phi(x),$$

$$Q\left(\left(\frac{1+m+\dots+m^n}{p_k(1-p_k)}\right)^{1/2}(\hat{p}_k - p_k) \leq x\right) \rightarrow \int_0^\infty \Phi(x/\sqrt{y}) dS(y).$$

U w a g a. Dion znalazł również przedział ufności dla danego  $p_k$ . Ponieważ nie jest znany rozkład łączny dla estymatorów prawdopodobieństw  $p_k, k = 0, 1, \dots$ , więc podanie łącznego przedziału ufności, tzn. dla wszystkich prawdopodobieństw  $p_k$ , nie może być brane pod uwagę.

Podobnie jak w przypadku estymatorów  $\bar{m}$ , i  $\hat{m}$ , można badać asymptotykę estymatorów  $\hat{p}_k$ , gdy  $r \rightarrow +\infty$  oraz  $r, n \rightarrow +\infty$ . Prawdziwe są następujące twierdzenia.

TWIERDZENIE 3.2. Jeżeli  $r \rightarrow +\infty$  dla ustalonego  $n$ , to

(I)  $\hat{p}_k \rightarrow p_k$  z P.1 oraz  $E\hat{p}_k \rightarrow p_k, k = 0, 1, \dots$ ,

(II)  $P\left(\left(\frac{r(1+m+\dots+m^n)}{p_k(1-p_k)}\right)^{1/2}(\hat{p}_k - p_k) \leq x\right) \rightarrow \Phi(x).$

TWIERDZENIE 3.3. Jeżeli  $r, n \rightarrow +\infty$ , to:

$$(I) \hat{p}_k \xrightarrow{P} p_k, E\hat{p}_k \rightarrow p_k, k = 0, 1, \dots,$$

(II) jeżeli  $m < 1$ , to

$$P\left(\left(\frac{r}{p_k(1-p_k)(1-m)}\right)^{1/2} (\hat{p}_k - p_k) \leq x\right) \rightarrow \Phi(x),$$

(III) jeżeli  $m = 1$  oraz  $r/n \rightarrow +\infty$ , to

$$P\left(\left(\frac{rn}{p_k(1-p_k)}\right)^{1/2} (\hat{p}_k - p_k) \leq x\right) \rightarrow \Phi(x),$$

(IV) jeżeli  $m > 1$  oraz  $E(Z_1^4) < +\infty$ , to

$$P\left(\left(\frac{r(m^{n+1}-1)}{p_k(1-p_k)(m-1)}\right)^{1/2} (\hat{p}_k - p_k) \leq x\right) \rightarrow \Phi(x).$$

Dowody tych twierdzeń są standardowe; wymagają jedynie pewnych modyfikacji dowodu N. M. Yaneva (zob. [16]) dla  $\hat{m}$ . Wykorzystuje się m.in. fakt, że

$$Z_{0k}^{(r)} + Z_{1k}^{(r)} + \dots + Z_{nk}^{(r)} = \sum_{j=1}^{S_n^{(r)}} T_j^{(k)},$$

gdzie  $(T_j^{(k)}; j = 1, 2, \dots)$ ,  $k = 0, 1, \dots$ , jest ciągiem zmiennych losowych zdefiniowanych w następujący sposób:

$$T_j^{(k)} = \begin{cases} 1, & \text{gd } \zeta_j = k, \\ 0 & \text{w przeciwnym razie,} \end{cases}$$

a  $S_n^{(r)} = Z_0^{(r)} + Z_1^{(r)} + \dots + Z_n^{(r)}$ ;  $(\zeta_j; j = 1, 2, \dots)$  jest ciągiem niezależnych zmiennych losowych o rozkładzie  $Z_1$ .

Można rozważyć estymatory prawdopodobieństw kreacji oparte na próbie  $(Z_{nk}; k = 0, 1, \dots)$  postaci

$$\bar{p}_k = \frac{Z_{nk}}{Z_n}, \quad k = 0, 1, \dots$$

Estymatory te są asymptotycznie normalne.

TWIERDZENIE 3.4. Dla nadkrytycznego procesu Galtona-Watsona  $Z$  oraz dla dowolnej miary probabilistycznej  $Q \ll P_A$  mamy

$$Q\left(\left(\frac{Z_n}{p_k(1-p_k)}\right)^{1/2} (\bar{p}_k - p_k) \leq x\right) \rightarrow \Phi(x),$$

$$Q\left(\left(\frac{m^n}{p_k(1-p_k)}\right)^{1/2} (\bar{p}_k - p_k) \leq x\right) \rightarrow \int_0^\infty \Phi(x\sqrt{y}) dS(y).$$

W dowodzie korzystamy z faktu, że  $Z_{nk}$  daje się przedstawić w postaci  $Z_{nk} = \sum_{j=1}^{Z_n} T_j^{(k)}$ . Teza twierdzenia wynika z równości

$$\frac{(Z_n)^{1/2}}{(\text{Var}(T_j^{(k)}))^{1/2}} (\bar{p}_k - p_k) = \frac{Z_n^{-1/2}}{(\text{Var}(T_j^{(k)}))^{1/2}} \sum_{j=1}^{Z_n} (T_j^{(k)} - p_k)$$

oraz z centralnego twierdzenia granicznego dla sum niezależnych zmiennych losowych o losowej liczbie składników (zob. [5], tw. 12.2).

Rozważmy próbę  $(Z_{jk}^{(r)}; j = 0, 1, \dots, n, k = 0, 1, \dots)$ , gdzie  $Z_{jk}^{(r)}$  jest liczbą indywidualów  $j$ -tego pokolenia mających  $k$  bezpośrednich potomków, przy założeniu, że  $Z_0^{(r)} = r$ . Można zaproponować estymatory prawdopodobieństw kreacji wykorzystując znajomość  $n$ -tego pokolenia procesu

$$\bar{p}_k^{(r)} = \frac{Z_{nk}^{(r)}}{1 + Z_n^{(r)}}, \quad k = 0, 1, \dots$$

Estymatory te są mocno zgodne, tzn.  $\bar{p}_k^{(r)} \rightarrow p_k$  z P.1, gdy  $r \rightarrow +\infty$  dla  $k = 0, 1, \dots$ . Ponadto zachodzi

**Twierdzenie 3.5.**

(I) Jeżeli  $m < 1$  oraz  $r, n \rightarrow +\infty$  w taki sposób, że  $rm^n \rightarrow +\infty$ , to

$$P\left(\left(\frac{rm^n}{p_k(1-p_k)}\right)^{1/2} (\bar{p}_k^{(r)} - p_k) \leq x\right) \rightarrow \Phi(x),$$

(II) jeżeli  $m = 1$  oraz  $r, n \rightarrow +\infty$  w taki sposób, że  $r/n \rightarrow +\infty$ , to

$$P\left(\left(\frac{r}{p_k(1-p_k)}\right)^{1/2} (\bar{p}_k^{(r)} - p_k) \leq x\right) \rightarrow \Phi(x),$$

(III) jeżeli  $m > 1$  oraz  $r \rightarrow +\infty$ , to

$$P\left(\left(\frac{rm^n}{p_k(1-p_k)}\right)^{1/2} (\bar{p}_k^{(r)} - p_k) \leq x\right) \rightarrow \Phi(x),$$

dla każdego  $n$ .

W dowodzie korzystamy z równości  $Z_{nk}^{(r)} = \sum_{j=1}^{Z_n^{(r)}} T_j^{(k)}$ , gdzie  $(T_j^{(k)})$  jest ciągiem zmiennych losowych zdefiniowanym jak w dowodzie twierdzenia 3.2. Mocna zgodność estymatora wynika z równości

$$Z_{nk}^{(r)} = Z_{nk,1} + Z_{nk,2} + \dots + Z_{nk,r},$$

gdzie  $(Z_{nk,i}; i = 1, 2, \dots, r)$  jest ciągiem niezależnych zmiennych losowych o rozkładzie takim, jak  $Z_{nk}$ , oraz stąd, że

$$E(Z_{nk}) = E\left\{E\left(\sum_{j=1}^{Z_n} T_j^{(k)} \mid Z_n\right)\right\} = p_k m^n.$$



#### 4. Estymacja wariancji.

4.1. *Estymacja wariancji przy znanej średniej.* Niech

$$\tau_k = \left( \frac{Z_{k+1}}{Z_k} - m \right)^2 Z_k, \quad k = 0, 1, \dots$$

J. P. Dion w [8] zaproponował estymator wariancji  $\sigma^2$  postaci

$$\bar{\sigma}_n^2 = \frac{1}{n+1} \sum_{k=0}^n \tau_k,$$

oraz podał jego podstawowe własności.

**TWIERDZENIE 4.1.** *Niech  $Z$  będzie nadkrytycznym procesem Galtona–Watsona, dla którego  $p_0 = 0$  oraz  $E(Z_1^4) < +\infty$ . Wówczas*

$$E(\bar{\sigma}_n^2) = \sigma^2,$$

$$\text{Var}(\bar{\sigma}_n^2) = (n+1)^{-1} \left[ 2\sigma^4 + (n+1)^{-1} (\text{Var}(Z_1 - m)^2 - 2\sigma^4) \sum_{k=0}^n E(Z_k^{-1}) \right].$$

Estymator  $\bar{\sigma}_n^2$  jest więc nieobciążony, a jego słaba zgodność wynika z wyrażenia na wariancję i z nierówności Czebyszewa. Dion udowodnił również asymptotyczną normalność tego estymatora.

**TWIERDZENIE 4.2.** *Niech  $Z$  będzie nadkrytycznym procesem Galtona–Watsona, dla którego  $p_0 = 0$  oraz  $E(Z_1^6) < +\infty$ . Wówczas*

$$P\left( \bar{\sigma}^2 \left( \frac{n+1}{2} \right)^{1/2} (\bar{\sigma}_n^2 - \sigma^2) \leq x \right) \rightarrow \Phi(x).$$

4.2. *Estymacja wariancji przy nieznannej średniej.* Dla estymacji wariancji przy nieznannej średniej Dion w pracy [8] zaproponował estymator postaci

$$\tilde{\sigma}_n^2 = \frac{1}{n+1} \sum_{k=0}^n Z_k \left( \frac{Z_{k+1}}{Z_k} - \hat{m} \right)^2.$$

Warto zauważyć, że C. C. Heyde w pracy [12] rozważał estymator tej postaci, ale w miejscu estymatora Harrisa  $\hat{m}$  występował estymator Lotki–Nagajewa  $\bar{m}$ . Słaba zgodność estymatora  $\tilde{\sigma}_n^2$  wynika z następującego twierdzenia.

**TWIERDZENIE 4.3.** *Niech  $Z$  będzie nadkrytycznym procesem Galtona–Watsona, dla którego  $p_0 = 0$ ,  $E(Z_1^4) < +\infty$ . Wówczas*

$$|\bar{\sigma}_n^2 - \tilde{\sigma}_n^2| (1+n)^{1-\varepsilon} \xrightarrow{P} 0 \quad \text{dla każdego } \varepsilon > 0.$$

Można ten wynik rozszerzyć na przypadek dowolnej miary probabilistycznej  $Q \ll P$ . Dowód wynika z pracy Diona ([7], tw. 3). Przedstawione estymatory wariancji

są rozważane jedynie w przypadku  $p_0 = 0$ . Okazuje się przy tym, że nie można rozszerzyć własności tych estymatorów na zbiór niepochłaniania  $A$  metodami, które były stosowane przy rozważaniu estymatorów  $\hat{m}$  i  $\bar{m}$ . Ciekawe byłoby rozwiązanie asymptotyki tych estymatorów na zbiorze  $A$  w ogólnej sytuacji, gdy  $p_0 > 0$ .

Dion w pracy [8] wykazał, że estymator największej wiarygodności dla wariancji  $\sigma^2$  oparty na próbie  $(Z_{jk}; j = 0, 1, \dots, n+1, k = 0, 1, \dots)$  ma postać

$$\hat{\sigma}_n^2 = \sum_{k=0}^{\infty} (k - \hat{m})^2 \hat{p}_k.$$

Asymptotyczna normalność estymatora  $\hat{\sigma}_n^2$  wynika z następującego twierdzenia.

**TWIERDZENIE 4.4.** *Jeżeli  $Z$  jest nadkrytycznym procesem Galtona–Watsona oraz  $E(Z_1^4) < +\infty$ , to dla miary probabilistycznej  $Q \ll P_A$  zachodzi*

$$Q\left(\left(\frac{S_n}{\text{Var}(Z_1 - m)^2}\right)^{1/2} (\hat{\sigma}_n^2 - \sigma^2) \leq x\right) \rightarrow \Phi(x),$$

$$Q\left(\left(\frac{1+m+\dots+m^n}{\text{Var}(Z_1 - m)^2}\right)^{1/2} (\hat{\sigma}_n^2 - \sigma^2) \leq x\right) \rightarrow \int_0^{\infty} \Phi(x\sqrt{y}) dS(y).$$

Wykorzystując estymatory  $\bar{p}_k$  można zaproponować estymator dla wariancji z nieznaną średnią, mianowicie

$$\underline{\sigma}_n^2 = \sum_{k=0}^{\infty} (k - \bar{m})^2 \bar{p}_k.$$

Zachodzi wówczas następujące

**TWIERDZENIE 4.5.** *Przy założeniach twierdzenia 4.4 zachodzą zbieżności*

$$Q\left(\left(\frac{Z_n}{\text{Var}(Z_1 - m)^2}\right)^{1/2} (\sigma_n^2 - \sigma^2) \leq x\right) \rightarrow \Phi(x),$$

$$Q\left(\left(\frac{m^n}{\text{Var}(Z_1 - m)^2}\right)^{1/2} (\sigma_n^2 - \sigma^2) \leq x\right) \rightarrow \int_0^{\infty} \Phi(x\sqrt{y}) dS(y).$$

Dowód jest analogiczny do dowodu twierdzenia 4.4.

Można badać asymptotykę estymatora największej wiarygodności dla wariancji  $\hat{\sigma}_n^2$ , gdy  $r, n \rightarrow +\infty$ . Zachodzi następujące

**TWIERDZENIE 4.6.** *Jeżeli  $E(Z_1^4) < +\infty$  oraz  $r, n \rightarrow +\infty$ , to*

(I) *jeżeli  $m < 1$ , to*

$$P\left(\left(\frac{r}{\text{Var}(Z_1 - m)^2(1 - m)}\right)^{1/2} (\hat{\sigma}_n^2 - \sigma^2) \leq x\right) \rightarrow \Phi(x),$$

(II) jeżeli  $m = 1$  oraz  $r/n \rightarrow +\infty$ , to

$$P\left(\left(\frac{rn}{\text{Var}(Z_1 - m)^2}\right)^{1/2} (\hat{\sigma}_n^2 - \sigma^2) \leq x\right) \rightarrow \Phi(x),$$

(III) jeżeli  $m > 1$ , to

$$P\left(\left(\frac{r(m^{n+1} - 1)}{\text{Var}(Z_1 - m)^2(m - 1)}\right)^{1/2} (\hat{\sigma}^2 - \sigma^2) \leq x\right) \rightarrow \Phi(x).$$

D o w ó d. Za pomocą bezpośrednich rachunków można sprawdzić, że

$$\left|\hat{\sigma}_n^2 - \sum_{k=0}^{\infty} (k-m)^2 \hat{p}_k\right| (S_n^{(r)})^{1/2} \xrightarrow{P} 0.$$

Stąd wynika, że wystarczy wykazać prawdziwość tezy dla estymatora  $^*\sigma_n^2 = \sum_{k=0}^{\infty} (k-m)^2 \hat{p}_k$ . Estymator  $^*\sigma_n^2$  daje się przedstawić w postaci

$$^*\sigma_n^2 = \frac{1}{S_n^{(r)}} \sum_{i=1}^{S_n^{(r)}} (\zeta_i - m)^2,$$

gdzie  $S_n^{(r)} = Z_0^{(r)} + Z_1^{(r)} + \dots + Z_n^{(r)}$ , a  $(\zeta_i; i = 1, 2, \dots)$  jest ciągiem niezależnych zmiennych losowych o rozkładzie  $Z_1$ . Dalej dowód przeprowadza się standardowymi metodami (zob. [16]).

#### Prace cytowane

- [1] K. B. Athreya, P. E. Ney, *Branching processes*, Springer, Berlin 1972.
- [2] A. Badalbajew, *Some properties of an estimate of the mean of a branching process*, Fan, Task. G. U. Taszkent 1977.
- [3] W. J. Bühler, *Ein zentraler Grenzwertsatz für Verzweigungsprozesse*, Z. Wahrscheinlichkeitstheorie verw. Geb. 11 (1969), 139–141.
- [4] P. Billingsley, *Statistical inference for Markov processes*, Chicago, 1961.
- [5] —, *Convergence of probability measures*, Wiley, New York 1968.
- [6] K. S. Crump, R. B. Howe, *Nonparametric estimation of the age of a Galton-Watson branching process*, Biometrika 59 (1972), 533–538.
- [7] J. P. Dion, *Estimation of the mean and the initial probabilities of a branching process*, J. Appl. Prob. 11 (1974), 687–694.
- [8] —, *Estimation of the variance of a branching process*, Ann. Statist. 3 (1975), 1183–1187.
- [9] P. D. Feigin, *A note on maximum likelihood estimation for simple branching process*, Austr. J. Statist. 19 (1977), 152–154.
- [10] T. E. Harris, *Branching processes*, Ann. Math. Statist. 19 (1948), str. 474–494.
- [11] C. C. Heyde, *Extension of a result of Seneta for the supercritical Galton-Watson process*, ibidem 41 (1970), 739–742.

- [12] —, *On estimating the variance of the offspring distribution in a simple branching process*, Adv. Appl. Prob. 3 (1974), 421–433.
  - [13] C. C. Heyde, J. R. Leslie, *Improved classical limit analogues for Galton–Watson process with or without immigration*, Bull. Austr. Math. Soc. 5 (1971), 145–155.
  - [14] A. V. Nagajew, *On estimating the expected number of direct descendants of a particle in a branching process*, Theor. Prob. Appl. 12 (1967), 312–320.
  - [15] J. Scott, *A central limit theorem for martingales and an application to branching process*, Stoch. Proc. Appl. Vol. 6, No 3 (1978), 89–94.
  - [16] N. M. Yanev, *On the statistics of branching processes*, Theor. Prob. Appl. 20 (1975), 505–515.
-