

POLITECHNIKA WROCŁAWSKA  
WYDZIAŁ PODSTAWOWYCH PROBLEMÓW  
TECHNIKI

---

KIERUNEK: Matematyka

SPECJALNOŚĆ: Statystyka matematyczna

PRACA DYPLMOWA

**Estymacja parametrów rozkładu na  
podstawie danych otrzymywanych w  
chwilach losowych**

**Tomasz Suchocki**

PROMOTOR: dr Alicja Jokiel-Rokita

---

WROCŁAW, czerwiec 2006

# Spis treści

<b>Wstęp</b>	<b>3</b>
<b>1 Model oraz ogólne założenia</b>	<b>5</b>
<b>2 Estymacja parametru <math>\theta</math> przy ważonej kwadratowej funkcji straty</b>	<b>9</b>
2.1 Estymacja parametru $\theta$ w przypadku, gdy dystrybuanta $G$ zmiennych losowych $U_1, U_2, \dots, U_n$ jest znana . . . . .	10
2.2 Estymacja parametru $\theta$ w przypadku, gdy dystrybuanta $G$ zmiennych losowych $U_1, U_2, \dots, U_n$ nie jest znana . . . . .	18
2.3 Przykład . . . . .	20
<b>3 Estymacja średniej z rozkładu normalnego przy funkcji straty LINEX</b>	<b>23</b>
3.1 Estymacja średniej z rozkładu normalnego w przypadku, gdy dystrybuanta $G$ zmiennych losowych $U_1, U_2, \dots, U_n$ jest znana . . . . .	23
3.2 Estymacja średniej z rozkładu normalnego w przypadku, gdy dystrybuanta $G$ zmiennych losowych $U_1, U_2, \dots, U_n$ nie jest znana . . . . .	26
3.3 Przykład . . . . .	27
<b>4 Estymacja średniej z rozkładu normalnego przy funkcji straty „reflected normal”</b>	<b>29</b>
4.1 Przykład . . . . .	32

Spis treści 2

---

**Bibliografia** **36**

# Spis rysunków

3.1	Wykres funkcji straty LINEX . . . . .	24
3.2	Wykres funkcji straty LINEX dla $a = 2$ i $b = 1$ . . . . .	27
4.1	Wykres funkcji straty „reflected normal” . . . . .	30
4.2	Wykres funkcji straty „reflected normal” dla $K = 2$ i $\gamma = 1$ . . . . .	33

# Wstęp

W pracy przedstawiono metody wyznaczania planów sekwencyjnych w przypadku estymacji parametru rzeczywistego na podstawie danych otrzymywanych w chwilach losowych.

Praca składa się z 4 rozdziałów.

W rozdziale pierwszym został omówiony i przedstawiony model, którym będziemy posługiwać się w dalszej części pracy. Zostały zaprezentowane również definicje i fakty, które wykorzystywane będą w następnych rozdziałach.

W rozdziale drugim został przedstawiony problem wyznaczania optymalnego planu sekwencyjnego dla pewnej klasy rozkładów pochodzących z wykładniczej rodziny rozkładów oraz dla kwadratowej funkcji straty z wagą. Plany wyznaczyliśmy w przypadkach, gdy

- rozkład chwil pojawiania się danych jest znany,
- rozkład chwil pojawiania się danych jest rozkładem wykładniczym z nieznanym parametrem, o którym zakładamy, że ma rozkład a priori gamma.

Problematyka zawarta w tym rozdziale rozpatrywana była w pracy Magiery (1982).

W rozdziale trzecim omówiliśmy problem wyznaczenia optymalnego planu sekwencyjnego w przypadku estymacji średniej rozkładu normalnego, gdy za funkcję straty związaną z błędem estymacji przyjmujemy asymetryczną funkcję straty LINEX. Ponownie wyznaczyliśmy dwie klasy optymalnych planów sekwencyjnych dla znanego i nieznanego rozkładu zmiennych, będących chwilami pojawiania się danych.

W ostatnim rozdziale wyznaczyliśmy optymalne plany sekwencyjne w estymacji średniej rozkładu normalnego przyjmując ograniczoną funkcję straty („re-

flected normal”). Przedstawione w tym rozdziale rezultaty uzyskane zostały przy wykorzystaniu tych samych metod co w rozdziale drugim i trzecim.

# Rozdział 1

## Model oraz ogólne założenia

Niech  $(\Omega, \mathcal{F}, P)$  będzie przestrzenią probabilistyczną. Przez  $(\mathcal{X}, \mathcal{B})$  oznaczymy przestrzeń mierzalną, gdzie  $\mathcal{X} \subseteq \mathbf{R}$ , a  $\mathcal{B}$  jest borelowskim  $\sigma$ -ciałem podzbiorów  $\mathcal{X}$ . Rozważmy niezależne zmienne losowe  $X_1, X_2, \dots, X_n$  zdefiniowane na  $(\Omega, \mathcal{F}, P)$  o wartościach w  $(\mathcal{X}, \mathcal{B})$  o jednakowym rozkładzie  $P_\theta \in \mathcal{P} = \{P_\theta : \theta \in \Theta\}$ . Załóżmy, że  $\Theta$  jest przedziałem otwartym, a wszystkie rozkłady  $P_\theta \in \mathcal{P} = \{P_\theta : \theta \in \Theta\}$  są absolutnie ciągłe względem  $\sigma$ -skończonej miary określonej na  $(\mathcal{X}, \mathcal{B})$  oraz, że  $E_\theta(X_i^2) < \infty$  dla każdego  $\theta \in \Theta$ . Załóżmy, że zmienne losowe  $X_i$  są obserwowane w chwilach  $t_i$ , gdzie  $t_i = U_{i:n}$  ( $i$ -ta statystyka pozycyjna),  $i = 1, 2, \dots, n$ . Dodatkowo załóżmy, że  $U_1, U_2, \dots, U_n$  są niezależnymi zmiennymi losowymi o tym samym rozkładzie zadanym dystrybuantą  $G$  oraz, że  $U_1, U_2, \dots, U_n$  są niezależne od  $X_1, X_2, \dots, X_n$ .

Rozpatrzmy problem sekwencyjnej estymacji bayesowskiej parametru  $\theta$ , przy założeniu, że  $\theta$  ma rozkład a priori  $\pi$ , gdzie wszystkie parametry tego rozkładu są znane.

Niech

$$k(t) = \sum_{i=1}^n \mathbf{1}_{[0,t]}(U_i), \quad (1.1)$$

oznacza liczbę obserwacji dostępną do chwili  $t$  włącznie oraz niech

$$\mathcal{F}_t = \sigma\{k(s), s \leq t, X_1, X_2, \dots, X_{k(t)}\}, \quad (1.2)$$

oznacza informację dostępną w chwili  $t$ . Niech  $\mathcal{D}$  będzie klasą funkcji  $d$ ,  $\mathcal{F}_t$  mierzalnych, których wartości, dla konkretnej realizacji będziemy przyjmować za oszacowanie parametru  $\theta$ .

Przy założeniu, że obserwacje zatrzymamy w chwili  $t$ , całkowita strata jaką poniesiemy będzie określona następującym wzorem

$$L_t(\theta, d) = L(\theta, d) + c_A k(t) + c(t), \quad (1.3)$$

gdzie  $\theta$  jest prawdziwą wartością szacowanego parametru, a  $d$  estymatorem tegoż parametru. Ponadto

1.  $L(\theta, d)$  jest stratą związaną z błędem estymacji parametru  $\theta$ ,
2.  $c_A$  jest kosztem związanym z otrzymaniem pojedynczej obserwacji,
3.  $c(t)$  jest kosztem związanym z prowadzeniem obserwacji do chwili  $t$ .

Założmy, że funkcja  $c(t)$  jest różniczkowalna, wypukła oraz  $c(0) = 0$ .

Za czas zatrzymania, będziemy uważać zmienną losową  $\tau$ , dla której prawdopodobieństwo  $P_\theta(0 \leq \tau < \infty) = 1$  dla każdej wartości parametru  $\theta \in \Theta$  oraz  $\{\tau < t\} \in \mathcal{F}_t$  dla każdego  $t \geq 0$ . Parę  $\delta = (\tau, d(\tau))$  nazywamy procedurą sekwencyjną, natomiast funkcję  $R(\theta, \delta)$ , określoną następującym wzorem

$$R(\theta, \delta) = E_\theta[L_\tau(\theta, d(\tau))], \quad (1.4)$$

funkcją ryzyka procedury  $\delta$ .

Bedziemy rozważać jedynie te procedury sekwencyjne  $\delta$ , dla których funkcja  $R(\theta, \delta) < \infty$  dla każdego  $\theta \in \Theta$ .

Wprowadźmy zmienną losową  $Y$  o wartościach  $\theta \in \Theta$ . Niech  $\mathcal{M}$  oznacza  $\sigma$ -ciało podzbiorów  $\Theta$ , a  $\pi$  rozkład a priori zmiennej losowej  $Y$  na przestrzeni mierzalnej  $(\Theta, \mathcal{M})$ . Zakładamy, że  $Y = \theta$ . Ryzykiem bayesowskim procedury sekwencyjnej  $\delta = (\tau, d(\tau))$  względem rozkładu a priori  $\pi$  nazywamy

$$r(\pi, \delta) = E^\pi[R(\theta, \delta)] = \int_{\Theta} R(\theta, \delta) d\pi(\theta). \quad (1.5)$$

Przez  $\pi$  będziemy rozumieć zarówno rozkład a priori parametru  $\theta$  jak i jego funkcję gęstości prawdopodobieństwa.

Jeżeli dla rozkładu a priori  $\pi$ , rozkład a posteriori  $\pi_t = (\pi | \mathcal{F}_t)$  względem  $\mathcal{F}_t$  jest dobrze określony, to ryzyko a posteriori dla procedury sekwencyjnej  $\delta = (\tau, d(\tau))$  ma postać

$$\tilde{R}(\pi, d(\tau)) = E^{\pi_t}[L_\tau(\theta, d(\tau))] = \int_{\Theta} L_\tau(\theta, d(\tau)) d\pi_t(\theta | x). \quad (1.6)$$

W dalszej części pracy wyznaczymy bayesowską procedurę estymacji parametru  $\theta$  przy powyższych założeniach, tzn. parę  $\delta^* = (\tau^*, d^*(\tau^*))$ , która minimalizuje ryzyko bayesowskie postaci (1.5) po wszystkich chwilach zatrzymania  $\tau$  i estymatorach  $d(\tau)$ , tzn.

$$r(\pi, \delta^*) = \inf_{\delta} r(\pi, \delta).$$

Wiadomo, że rozwiązanie tego problemu składa się z dwóch etapów:

1. wyznaczenie estymatora bayesowskiego dla dowolnej chwili zatrzymania  $\tau$ ;
2. wyznaczenie optymalnej chwili zatrzymania  $\tau^*$ , która minimalizuje (po wszystkich chwilach zatrzymania) wartość oczekiwaną całkowitej straty (ryzyko a posteriori postaci (1.6) związane z wyznaczonym w punkcie 1 estymatorem). (Metody wyznaczania optymalnej chwili zatrzymania przedstawił Ross (1971)).

Niech  $h$  oznacza funkcję rzeczywistą określoną na zbiorze  $E_n = \{0, 1, \dots, n\}$ , taką że  $0 \leq h(k) < \infty$  dla każdego  $k \in E_n$  oraz niech

$$\mathcal{L}_h(t) = \mathcal{L}_h(k(t), t) = h(k(t)) + c(t),$$

$t \geq 0$ , oznacza stratę związaną z zatrzymaniem obserwacji w chwili  $t$ . Będziemy rozpatrywać jedynie te procedury sekwencyjne, które spełniają tzw. przypadek monotoniczny, który zakłada, że jeżeli  $\mathcal{L}_h$  pierwszy raz zacznie przyjmować niesatysfakcjonujące nas wyniki to już zawsze będzie je przyjmowała. Jeżeli  $\mathcal{L}_h(t)$  spełnia przypadek monotoniczny, wtedy optymalną chwilę zatrzymania łatwo uzyskać z tożsamości Dynkina

$$E[\mathcal{L}_h(\tau)] - h(k(0)) = E \left\{ \int_0^\tau [\mathcal{A}_t h(k(t)) + c'(t)] dt \right\}, \quad (1.7)$$

gdzie  $\mathcal{A}_t h(k(t))$  jest operatorem infinitezimalnym, tzn.

$$\mathcal{A}_t h(k(t)) = \lim_{\Delta \rightarrow 0^+} \frac{E[h(k(t + \Delta)) - h(k(t)) | k(t) = k]}{\Delta}, \quad (1.8)$$

która zachodzi dla chwil zatrzymania  $\tau$  względem  $\mathcal{F}_t$ , takich że  $E(\tau) < \infty$  oraz funkcji  $h$  należących do dziedziny operatora infinitezimalnego (zobacz Dynkin (1965), Aven, Jensen (1999) oraz Shapiro i Wardrop (1980)).

Problematyka ta została zapoczątkowana przez Starra i in. (1976), a następnie rozwinięta i uogólniona przez Magierę (1982) i Jokiel-Rokitę, Magierę (1999).

## Rozdział 2

# Estymacja parametru $\theta$ przy ważonej kwadratowej funkcji straty

W rozdziale tym zakładamy, że rozkłady  $P_\theta \in \mathcal{P} = \{P_\theta : \theta \in \Theta\}$  należą do wykładniczej rodziny rozkładów  $\mathcal{E}(\theta, \alpha)$ , definiowanej następująco:

Za  $\mathcal{E}(\theta, \alpha)$  będziemy uważać rodzinę rozkładów  $P_\theta \in \mathcal{P} = \{P_\theta : \theta \in \Theta\}$ , dla której gęstość prawdopodobieństwa względem  $\sigma$ -skończonej miary  $\nu$  wyraża się wzorem

$$\frac{dP_\theta}{d\nu}(x) = p(x; \theta, \alpha) = s(x, \alpha) \exp[\alpha w_1(\theta) + x w_2(\theta)], \quad (2.1)$$

gdzie  $\alpha$  jest stałą dodatnią,  $s(x, \alpha)$  funkcją nieujemną, mierzalną, niezależną od parametru  $\theta$  oraz  $w_1(\theta)$  i  $w_2(\theta)$  są funkcjami określonymi na  $\Theta$ , dwukrotnie różniczkowalnymi w zbiorze  $\Theta$  z pierwszymi pochodnymi  $w_1'(\theta)$ ,  $w_2'(\theta)$  takimi, że  $w_2'(\theta) > 0$  i  $\frac{w_1'(\theta)}{w_2'(\theta)}$  jest ściśle malejąca na  $\Theta$ .

**Fakt 2.1** *Wartość oczekiwana i wariancja zmiennych losowych  $X_i$ ,  $i = 1, 2, \dots, n$ , o rozkładzie zadanym przez (2.1) wyraża się wzorem*

$$E_\theta(X_i) = -\alpha \frac{w_1'(\theta)}{w_2'(\theta)} \quad (2.2)$$

*i*

$$\text{Var}_\theta(X_i) = -\frac{\alpha}{w_2'(\theta)} \frac{d}{d\theta} \left[ \frac{w_1'(\theta)}{w_2'(\theta)} \right]. \quad (2.3)$$

**Dowód:**

Podstawiając  $w_2(\theta) := \lambda$  otrzymujemy jednoparametrową rodzinę wykładniczą rozkładów w postaci kanonicznej o gęstości postaci

$$p(x; \theta, \alpha) = s(x, \alpha) \exp[\alpha w_1(\theta) + x w_2(\theta)] = s(x, \alpha) \exp\{\lambda x - [-\alpha w_1(w_2^{-1}(\lambda))]\},$$

gdzie  $T(X) = x$ ,  $\Phi(\lambda) = -\alpha w_1(w_2^{-1}(\lambda))$ , a nieznanym parametrem jest parametr  $\lambda$ . Korzystając z twierdzenia o postaci wartości oczekiwanej i wariancji zmiennej losowej należącej do naturalnej rodziny wykładniczej rozkładów (zobacz np. Magiera (2002), Twierdzenie 2.16) mamy

$$E_\theta(X_i) = \frac{d}{d\lambda} \Phi(\lambda) = -\frac{d}{d\lambda} \alpha w_1(w_2^{-1}(\lambda)) = -\alpha \frac{w_1'(\theta)}{w_2'(\theta)},$$

oraz

$$\text{Var}_\theta(X_i) = \frac{d^2}{d\lambda^2} \Phi(\lambda) = \frac{d}{d\lambda} \left( -\alpha \frac{w_1'(w_2^{-1}(\lambda))}{w_2'(w_2^{-1}(\lambda))} \right) = -\frac{\alpha}{w_2'(\theta)} \frac{d}{d\theta} \frac{w_1'(\theta)}{w_2'(\theta)}.$$

□

Do rodziny  $\mathcal{E}(\theta, \alpha)$  należą między innymi rozkład normalny  $\mathcal{N}(\alpha\theta, \alpha)$  dla  $\theta \in (-\infty, \infty)$ , rozkład gamma  $\mathcal{G}(\theta^{-1}, \alpha)$ , Poissona  $\mathcal{P}(\alpha\theta)$  dla  $\theta \in (0, \infty)$ .

## 2.1 Estymacja parametru $\theta$ w przypadku, gdy dystrybuanta $G$ zmiennych losowych $U_1, U_2, \dots, U_n$ jest znana

Problemy poruszane w tym podrozdziale zostały rozwiązane i opisane w pracy Magiery (1982).

Niech  $\Theta$  będzie otwartym przedziałem  $(a, b) \in \mathbf{R}$ . Chcemy znaleźć optymalną procedurę sekwencyjną  $\delta^* = (\tau^*, d^*(\tau^*))$  dla  $\theta \in \Theta$  bazującą na niezależnych zmiennych losowych  $X_1, X_2, \dots, X_n$  o rozkładzie  $P_\theta \in \mathcal{E}(\theta, \alpha)$  spełniającym następujące postulaty:

1. dla każdego  $\theta \in \Theta$

$$\theta = -\frac{w_1'(\theta)}{w_2'(\theta)}; \quad (2.4)$$

2. istnieje stała  $\beta \geq 0$  taka, że

$$\int_{\Theta} \exp[\alpha w_1(\theta) + x w_2(\theta)] d\theta = \frac{1}{(\alpha - \beta)s(x, \alpha)} \quad (2.5)$$

zachodzi dla każdego  $\alpha > \beta$  i  $x \in \mathcal{X}$  takiego, że  $s(x, \alpha) > 0$ ;

3. dla każdego  $\alpha > \beta$  oraz  $x \in \mathcal{X}$  poza  $x = \inf \mathcal{X}$ ,

$$\lim_{\theta \rightarrow a^+} \exp[\alpha w_1(\theta) + x w_2(\theta)] = \lim_{\theta \rightarrow b^-} \exp[\alpha w_1(\theta) + x w_2(\theta)] \quad (2.6)$$

i

$$\lim_{\theta \rightarrow a^+} \theta \exp[\alpha w_1(\theta) + x w_2(\theta)] = \lim_{\theta \rightarrow b^-} \theta \exp[\alpha w_1(\theta) + x w_2(\theta)]. \quad (2.7)$$

Przyjmujemy, że  $\pi(\theta)$  jest postaci

$$\pi(\theta) = \alpha_0 p(\gamma; \theta, \alpha_0 + \beta) = \alpha_0 s(\gamma, \alpha_0 + \beta) \exp[(\alpha_0 + \beta)w_1(\theta) + \gamma w_2(\theta)], \quad (2.8)$$

gdzie  $\alpha_0 > 0$  i  $\gamma$  są znanymi stałymi, natomiast funkcja  $s$  przyjmuje jedynie wartości dodatnie. Zauważmy, że  $\pi(\theta)$  jest gęstością prawdopodobieństwa na  $\Theta$ , gdyż

$$\int_{\Theta} \pi(\theta) d\theta = 1.$$

Na podstawie (2.5) mamy

$$\begin{aligned} \int_{\Theta} \pi(\theta) d\theta &= \alpha_0 s(\gamma, \alpha_0 + \beta) \int_{\Theta} \exp[(\alpha_0 + \beta)w_1(\theta) + \gamma w_2(\theta)] d\theta \\ &= \alpha_0 s(\gamma, \alpha_0 + \beta) \frac{1}{(\alpha_0 + \beta - \beta)s(\gamma, \alpha_0 + \beta)} = 1. \end{aligned}$$

Niech  $\mathcal{E}_0(\alpha_0, \gamma)$  oznacza rodzinę rozkładów prawdopodobieństwa na  $\Theta$  z funkcją gęstości postaci (2.8), wtedy otrzymujemy następujący lemat.

**Lemat 2.1** *Niech  $P_\theta \in \mathcal{E}(\theta, \alpha)$  oraz niech zachodzi (2.5). Jeżeli  $\pi \in \mathcal{E}_0(\alpha_0, \gamma)$ , wtedy*

$$\pi_t \in \mathcal{E}_0\left(\alpha_0 + \alpha k(t), \gamma + \sum_{i=1}^{k(t)} X_i\right). \quad (2.9)$$

**Dowód:**

Wiemy, że

$$\pi_t(\theta) = \frac{\prod_{i=1}^{k(t)} p(x; \theta, \lambda) \cdot \pi(\theta)}{m(x)},$$

gdzie

$$m(x) = \int_{\Theta} \prod_{i=1}^{k(t)} p(x; \theta, \lambda) \cdot \pi(\theta) d\theta$$

Ze wzorów (2.1) i (2.8) mamy

$$\pi_t(\theta) = \frac{\exp [(\alpha_0 + \beta + \alpha k(t))w_1(\theta) + (\gamma + \sum_{i=1}^{k(t)} X_i)w_2(\theta)]}{\int_{\Theta} \exp [(\alpha_0 + \beta + \alpha k(t))w_1(\theta) + (\gamma + \sum_{i=1}^{k(t)} X_i)w_2(\theta)] d\theta}.$$

Wykorzystując (2.5) otrzymujemy

$$\begin{aligned} \pi_t(\theta) = & [\alpha_0 + \alpha k(t)]s(\gamma + \sum_{i=1}^{k(t)} X_i, \alpha_0 + \beta + \alpha k(t)) \exp \left[ (\alpha_0 + \beta + \alpha k(t))w_1(\theta) \right. \\ & \left. + (\gamma + \sum_{i=1}^{k(t)} X_i)w_2(\theta) \right], \end{aligned}$$

co daje tezę lematu.

□

**Wniosek 2.1** *Dla dowolnej chwili zatrzymania  $\tau$*

$$\pi_{\tau} \in \mathcal{E}_0(\alpha_0 + \alpha k(\tau), \gamma + \sum_{i=1}^{k(\tau)} X_i). \quad (2.10)$$

Wniosek wynika z Lematu 2.1 oraz mocnego prawa Markowa.

Na podstawie (2.4) i (2.6) otrzymujemy następujące zależności

$$\begin{aligned} & \alpha \int_{\Theta} \theta w_2'(\theta) \exp [\alpha w_1(\theta) + x w_2(\theta)] d\theta \\ & = x \int_{\Theta} w_2'(\theta) \exp [\alpha w_1(\theta) + x w_2(\theta)] d\theta \end{aligned} \quad (2.11)$$

oraz

$$\begin{aligned} & \int_{\Theta} \theta(x - \alpha\theta)w_2'(\theta) \exp[\alpha w_1(\theta) + xw_2(\theta)]d\theta \\ &= - \int_{\Theta} \exp[\alpha w_1(\theta) + xw_2(\theta)]d\theta. \end{aligned} \quad (2.12)$$

Z (2.5), (2.11) oraz (2.12) mamy

$$\int_{\Theta} (x - \alpha\theta)^2 w_2'(\theta) \exp[\alpha w_1(\theta) + xw_2(\theta)]d\theta = \frac{\alpha}{(\alpha - \beta)s(x, \alpha)}. \quad (2.13)$$

Założmy, że strata  $L(\theta, d)$  związana z błędem estymacji parametru  $\theta$  jest postaci

$$L(\theta, d) = w_2'(\theta)(\theta - d)^2. \quad (2.14)$$

**Lemat 2.2** Niech  $P_\theta \in \mathcal{E}(\theta, \alpha)$  oraz niech zachodzą warunki (2.4), (2.5) oraz (2.6). Wtedy dla funkcji straty określonej przez (2.14) i dowolnej chwili zatrzymania  $\tau$  estymator bayesowski  $d^*(\tau)$  parametru  $\theta$  względem rozkładu a priori  $\pi$  ma postać

$$d^*(\tau) = \frac{\gamma + \sum_{i=1}^{k(\tau)} X_i}{\alpha_0 + \beta + \alpha k(\tau)}, \quad (2.15)$$

a ryzyko a posteriori jest postaci

$$\tilde{R}(\pi, d(\tau)) = \frac{1}{\alpha_0 + \alpha k(\tau) + \beta}. \quad (2.16)$$

**Dowód:**

Wiemy, że estymator bayesowski parametru  $\theta$  przy kwadratowej funkcji straty z wagą wyznacza się ze wzoru (zobacz np. Krzyśko (1998), Twierdzenie 5.9).

$$d^*(\tau) = \frac{\int_{\Theta} \theta w_2'(\theta) \pi_t d\theta}{\int_{\Theta} w_2'(\theta) \pi_t d\theta}$$

Oznaczmy przez

$$\begin{aligned} \alpha_t &= \alpha_0 + \alpha k(t), \\ \gamma_t &= \gamma + \sum_{i=1}^{k(t)} X_i. \end{aligned}$$

Korzystając z tego, że  $\pi_t \in \mathcal{E}_0(\alpha_t, \gamma_t)$  mamy

$$d^*(\tau) = \frac{\int_{\Theta} \theta w_2'(\theta) \exp [(\alpha_t + \beta)w_1(\theta) + \gamma_t w_2(\theta)] d\theta}{\int_{\Theta} w_2'(\theta) \exp [(\alpha_t + \beta)w_1(\theta) + \gamma_t w_2(\theta)] d\theta}.$$

Następnie korzystając ze wzoru (2.11) otrzymujemy postać (2.15) estymatora  $d^*(\tau)$ .

Wiemy, że

$$\begin{aligned} \tilde{R}(\pi, d^*(\tau)) &= E^{\pi_t}[L_{\tau}(\theta, d^*(\tau))] = E^{\pi_t}[w_2'(\theta)(d^*(\tau) - \theta)^2] \\ &= \int_{\Theta} \left( \frac{\gamma_t}{\alpha_t + \beta} - \theta \right)^2 w_2'(\theta) [\alpha_t s(\gamma_t, \alpha_t + \beta)] \exp [(\alpha_t + \beta)w_1(\theta) + \gamma_t w_2(\theta)] d\theta \\ &= \frac{\alpha_t s(\gamma_t, \alpha_t + \beta)}{(\alpha_t + \beta)^2} \int_{\Theta} (\gamma_t - (\alpha_t + \beta)\theta)^2 w_2'(\theta) \exp [(\alpha_t + \beta)w_1(\theta) + \gamma_t w_2(\theta)] d\theta. \end{aligned}$$

Na mocy (2.13) mamy

$$\tilde{R}(\pi, d^*(\tau)) = \frac{\alpha_t s(\gamma_t, \alpha_t + \beta)(\alpha_t + \beta)}{(\alpha_t + \beta)^2 s(\gamma_t, \alpha_t + \beta) \alpha_t} = \frac{1}{\alpha_t + \beta},$$

co kończy dowód. □

Z powyższego lematu wynika, że problem sprowadza się do wyznaczenia takiej chwili zatrzymania  $\tau^*$ , która będzie minimalizowała wartość oczekiwaną całkowitej straty

$$E \left[ \frac{1}{\alpha_0 + \alpha k(\tau) + \beta} + c_A k(\tau) + c(\tau) \right], \quad (2.17)$$

po wszystkich chwilach zatrzymania  $\tau$ .

Niech  $G$  będzie dystrybuantą niezależnych zmiennych losowych  $U_1, U_2, \dots, U_n$ . Zakładamy, że  $G(0) = 0$ ,  $G(t) > 0$  dla  $t > 0$  oraz, że  $G$  jest absolutnie ciągła oraz posiada funkcję gęstości  $g$ , która jest prawostronnie różniczkowalna na przedziale  $(0, \infty)$ . Klasę takich dystrybuant oznaczmy przez  $\mathcal{G}$ . Niech  $\xi = \sup\{t : G(t) < 1\}$  oraz niech  $\rho(z) = g(z)[1 - G(z)]^{-1}$ ,  $0 \leq z < \xi$  oznacza funkcję intensywności awarii.

**Fakt 2.2** Niech  $G \in \mathcal{G}$ ,  $\xi = \sup \{t : G(t) < 1\}$  oraz niech  $\rho(z) = g(z)[1 - G(z)]^{-1}$ ,  $0 \leq z < \xi$  oznacza funkcję intensywności awarii. Wtedy  $k(t)$ ,  $0 \leq t < \xi$ , jest niestacjonarnym łańcuchem Markowa ze względu na  $\mathcal{F}_t$ ,  $0 \leq t < \xi$ , z operatorem infinitesimalnym

$$\mathcal{A}_t(h(k)) = (n - k)\rho(t)[h(k + 1) - h(k)], \quad (2.18)$$

dla  $k \in E_n = \{0, 1, \dots, n\}$  i wszystkich rzeczywistych funkcji  $h$  na  $E_n$ .

**Dowód:**

Stąd, że  $\forall t \geq 0$  oraz  $\forall i \in \mathbb{N}$  mamy

$$\mathbf{1}(U_i \leq t) = \begin{cases} 0 & \text{z prawdopodobieństwem } 1 - G(t), \\ 1 & \text{z prawdopodobieństwem } G(t), \end{cases}$$

to zmienna losowa  $k(t) = \sum_{i=1}^n \mathbf{1}(U_i \leq t)$  ma rozkład Bernoulliego  $\mathcal{B}(n, G(t))$ .  $\forall \epsilon > 0$  zmienna losowa  $k(t + \epsilon)$  ma rozkład Bernoulliego  $\mathcal{B}(n, G(t + \epsilon))$ , tak więc proces  $k(t)$  jest niestacjonarny, gdyż jest „czuły” na przesunięcie ( $k(t)$  ma inny rozkład niż  $k(t + \epsilon)$ ).

Aby udowodnić, że  $k(t)$  jest łańcuchem Markowa musimy pokazać, że dla  $\forall l$  oraz  $s_1 \leq s_2 \leq \dots, \leq s_l \leq t$  oraz  $k_1 \leq k_2 \leq \dots, \leq k_l \leq n$  zachodzi

$$P(k(t) = k \mid k(s_l) = k_l, k(s_{l-1}) = k_{l-1}, \dots, k(s_1) = k_1) = P(k(t) = k \mid k(s_l) = k_l).$$

Korzystając ze wzoru Bayesa oraz z postaci rozkładu łącznego  $(k(t), k(s_1), \dots, k(s_l))$  oraz  $(k(s_1), \dots, k(s_l))$  mamy

$$\begin{aligned} & P(k(t) = k \mid k(s_l) = k_l, k(s_{l-1}) = k_{l-1}, \dots, k(s_1) = k_1) \\ &= \frac{P(k(t) = k, k(s_1) = k_1, \dots, k(s_l) = k_l)}{P(k(s_1) = k_1, \dots, k(s_l) = k_l)} = \frac{\binom{n}{k_1} \binom{n-k_1}{k_2-k_1} \cdots \binom{n-k_l}{k-k_l}}{\binom{n}{k_1} \binom{n-k_1}{k_2-k_1} \cdots \binom{n-k_{l-1}}{k_l-k_{l-1}}} \\ & \times \frac{[G(s_1)]^{k_1} \cdots [G(s_l) - G(s_{l-1})]^{k_l-k_{l-1}} [G(t) - G(s_l)]^{k-k_l} [1 - G(t)]^{n-k}}{[G(s_1)]^{k_1} \cdots [G(s_l) - G(s_{l-1})]^{k_l-k_{l-1}} [1 - G(s_l)]^{n-k_l}} \\ &= \frac{\binom{n-k_l}{k-k_l} [G(t) - G(s_l)]^{k-k_l} [1 - G(t)]^{n-k}}{[1 - G(s_l)]^{n-k_l}} \\ &= \frac{\binom{n}{k_l} \binom{n-k_l}{k-k_l} [G(s_l)]^{k_l} [G(t) - G(s_l)]^{k-k_l} [1 - G(t)]^{n-k}}{\binom{n}{k_l} [G(s_l)]^{k_l} [1 - G(s_l)]^{n-k_l}} \end{aligned}$$

$$= \frac{P(k(t) = k, k(s_l) = k_l)}{P(k(s_l) = k_l)} = P(k(t) = k \mid k(s_l) = k_l).$$

Tak więc pokazaliśmy, że proces  $k(t)$  jest niestacjonarnym łańcuchem Markowa. Wyprowadzimy teraz wzór na postać operatora infinitezimalnego procesu  $k(t)$ . W tym celu ustalmy  $k \in \{0, 1, \dots, n\}$ . Jest oczywiste, że

$$\begin{aligned} E[h(k(t+s)) - h(k) \mid k(t) = k] &= \sum_{i=k+1}^n [h(i) - h(k)] P(k(t+s) = i \mid k(t) = k) \\ &= [h(k+1) - h(k)] P(k(t+s) = k+1 \mid k(t) = k) \\ &\quad + \sum_{i=k+2}^n [h(i) - h(k)] P(k(t+s) = i \mid k(t) = k) \\ &= [h(k+1) - h(k)] (n-k) \frac{G(t+s) - G(t)}{1 - G(t)} \left[ \frac{1 - G(t+s)}{1 - G(t)} \right]^{n-k-1} \\ &\quad + \sum_{i=k+2}^n [h(i) - h(k)] P(k(t+s) = i \mid k(t) = k) \\ &\leq [h(k+1) - h(k)] (n-k) \frac{G(t+s) - G(t)}{1 - G(t)} \left[ \frac{1 - G(t+s)}{1 - G(t)} \right]^{n-k-1} \\ &\quad + 2 \sup_{i \leq n} |h(i)| P(k(t+s) \geq k+2 \mid k(t) = k) \\ &= [h(k+1) - h(k)] (n-k) \frac{G(t+s) - G(t)}{1 - G(t)} \left[ \frac{1 - G(t+s)}{1 - G(t)} \right]^{n-k-1} \\ &\quad + 2 \sup_{i \leq n} |h(i)| \left\{ 1 - \left[ \frac{1 - G(t+s)}{1 - G(t)} \right]^{n-k} \left[ 1 - (n-k) \frac{G(t+s) - G(t)}{[1 - G(t+s)]} \right] \right\}. \end{aligned}$$

Łatwo zauważyć, że

$$\lim_{s \rightarrow 0^+} \frac{E[h(k(t+s)) - h(k) \mid k(t) = k]}{s} = (n-k) [h(k+1) - h(k)] \rho(t),$$

co dowodzi tezę lematu. □

Problem sprowadził się zatem do znalezienia optymalnej chwili zatrzymania pewnej funkcji niestacjonarnego łańcucha Markowa. W naszym przypadku funkcją tą jest

$$h(k(t)) = \frac{1}{\alpha_0 + \alpha k(t) + \beta} + c_A k(t).$$

**Twierdzenie 2.1** *Założmy, że  $G \in \mathcal{G}$  oraz  $G$  ma nierosnącą funkcję intensywności awarii  $\rho$ . Jeśli  $\pi \in \mathcal{E}(\alpha_0, \gamma)$ ,  $0 < \alpha_0 < \infty$ , wtedy  $\delta^* = (\tau^*, d^*(\tau^*))$ , gdzie*

$$\begin{aligned} \tau^* &= \inf\{t \geq 0 : [n - k(t)]\rho(t)\{\alpha - c_A\{\alpha_0 + \beta + \alpha[k(t) + 1]\}\{\alpha_0 + \beta + \alpha k(t)\}\} \\ &\leq c'(t)\{\alpha_0 + \beta + \alpha[k(t) + 1]\}\{\alpha_0 + \beta + \alpha k(t)\}\}, \end{aligned} \quad (2.19)$$

a  $d^*(\tau^*)$  ma postać (2.15) jest bayesowskim planem sekwencyjnym.

**Dowód:**

Pokażemy, że przy powyższych założeniach

$$\tau^* = \{t \geq 0 : \mathcal{A}_t h[k(t)] + c'(t) \geq 0\}$$

jest optymalną chwilą zatrzymania, co przy operatorze infinitezymalnym postaci (2.18) da nam tezę twierdzenia. Korzystając z tożsamości Dynkina wiemy, że dla dowolnej chwili zatrzymania  $\tau$  zachodzi

$$E(h[k(\tau)] + c(\tau)) - h(0) = E\left\{\int_0^\tau (\mathcal{A}_t h[k(t)] + c'(t))dt\right\}.$$

Przy założeniu, że  $\rho(t)$  jest nierosnąca, operator infinitezymalny  $\mathcal{A}_t h(k(t)) = (n - k(t)) [h(k(t) + 1) - h(k(t))] \rho(t)$  jest nierosnącą funkcją  $t$ . Zatem dla dowolnej chwili zatrzymania  $\tau$  mamy

$$\begin{aligned} &E(h[k(\tau^*)] + c(\tau^*)) - E(h[k(\tau)] + c(\tau)) \\ &= \int_{\{\tau^* > \tau\}} \left\{ \int_\tau^{\tau^*} (\mathcal{A}_t h[k(t)] + c'(t))dt \right\} dP - \int_{\{\tau > \tau^*\}} \left\{ \int_{\tau^*}^\tau (\mathcal{A}_t h[k(t)] + c'(t))dt \right\} dP \leq 0, \end{aligned}$$

co daje nam optymalność chwili zatrzymania  $\tau^*$ .

□

## 2.2 Estymacja parametru $\theta$ w przypadku, gdy dystrybuanta $G$ zmiennych losowych $U_1, U_2, \dots, U_n$ nie jest znana

Rozważmy problem wyznaczenia optymalnej procedury sekwencyjnej  $\delta^* = (\tau^*, d^*(\tau^*))$ , przy założeniu, że  $U_1, U_2, \dots, U_n$  tworzą ciąg niezależnych zmiennych losowych o jednakowym rozkładzie zadany dystrybuantą  $G$  pochodzącą z rozkładu wykładniczego zależnego od nieznanego parametru  $w$ , gdzie  $W = w$  jest zmienną losową posiadającą rozkład a priori gamma  $\mathcal{G}(\nu, \lambda)$ . Dla  $w > 0$  gęstość zmiennej losowej  $W$  ma postać

$$\zeta(w) = \frac{\lambda^\nu}{\Gamma(\nu)} w^{\nu-1} \exp(-\lambda w). \quad (2.20)$$

**Fakt 2.3** *Rozkład a posteriori zmiennej losowej  $W$  względem  $\mathcal{F}_t$  jest rozkładem gamma  $\mathcal{G}(\nu_t, \lambda_t)$ , gdzie*

$$\nu_t = \nu + k(t) \quad i \quad \lambda_t = \lambda + \sum_{j=1}^{k(t)} t_j + [n - k(t)]t. \quad (2.21)$$

**Dowód:**

Niech  $g_w$  i  $G_w$  oznaczają odpowiednio funkcję gęstości i dystrybuantę zmiennych losowych  $U_1, U_2, \dots, U_n$ , pod warunkiem, że  $w$  jest znanym parametrem. Przy założeniu, że  $U_i \sim \mathcal{E}(w)$  mamy

$$g_w(t) = w \exp(-wt) \mathbf{1}_{(0, \infty)}(t),$$

$$G_w(t) = 1 - \exp(-wt), \quad t \geq 0.$$

Zatem rozkład a posteriori  $\pi_t(W | \mathcal{F}_t)$  zmiennej losowej  $W = w$  ma gęstość postaci

$$\begin{aligned}
\pi(w | \mathcal{F}_t) &= \pi(w | t_1, \dots, t_n, k(t) = k) \\
&= \frac{ng_w(t_1)(n-1)g_w(t_2) \dots (n-k+1)g_w(t_k)[1-G_w(t)]^{n-k}\zeta(w)}{\int_0^\infty ng_w(t_1)(n-1)g_w(t_2) \dots (n-k+1)g_w(t_k)[1-G_w(t)]^{n-k}\zeta(w)dw} \\
&= \frac{w^k \exp[-w(\sum_{i=1}^k t_i + (n-k)t)]w^{\nu-1} \exp(-\lambda w)}{\int_0^\infty w^k \exp[-w(\sum_{i=1}^k t_i + (n-k)t)]w^{\nu-1} \exp(-\lambda w)dw} \\
&= \frac{w^{\nu+k-1} \exp[-(\sum_{i=1}^k t_i + (n-k)t + \lambda)w]}{\int_0^\infty w^{\nu+k-1} \exp[-(\sum_{i=1}^k t_i + (n-k)t + \lambda)w]} \\
&= \frac{(\sum_{i=1}^k t_i + (n-k)t + \lambda)^{k+\nu}}{\int_0^\infty w^{k+\nu-1} \exp(-w)dw} w^{\nu+k-1} \exp[-(\sum_{i=1}^k t_i + (n-k)t + \lambda)w] \\
&= \frac{(\sum_{i=1}^k t_i + (n-k)t + \lambda)^{k+\nu}}{\Gamma(k+\nu)} w^{\nu+k-1} \exp[-(\sum_{i=1}^k t_i + (n-k)t + \lambda)w].
\end{aligned}$$

Tak więc rozkład a posteriori  $\pi_t$  jest rozkładem gamma z parametrami  $\nu_t = \nu + k(t)$  i  $\lambda_t = \lambda + \sum_{i=1}^{k(t)} t_i + (n-k(t))t$ , co kończy dowód. □

Oznaczmy parametry rozkładu a priori (2.20) odpowiednio przez  $\nu_0$  i  $\lambda_0$ .

**Fakt 2.4** *Proces stochastyczny  $(\nu_t, \lambda_t)$ ,  $t \geq 0$  o wartościach w zbiorze  $\{\nu_0, \nu_0 + 1, \dots, \nu_0 + n\} \times (0, \infty)$  jest stacjonarnym łańcuchem Markowa ze względu na  $\mathcal{F}_t$  oraz jego operator infinitesimalny jest postaci*

$$\mathcal{A}H(\nu, \lambda) = [H(\nu + 1, \lambda) - H(\nu, \lambda)](m - \nu)\nu\lambda^{-1} + (m - \nu)H'_\lambda(\nu, \lambda), \quad (2.22)$$

gdzie  $m = \nu_0 + n$ . Dziedzina operatora  $\mathcal{A}$  zawiera wszystkie funkcje  $H$ , które są różniczkowalne w sposób ciągły względem  $\lambda$  dla każdego  $\nu$ .

**Dowód:**

Dowód faktu, który można znaleźć w pracy Stadje (1990) pomijamy. □

Niech strata związana z obserwacją procesu  $(\nu_t, \lambda_t)$ ,  $t \geq 0$ , do chwili  $t$  będzie postaci

$$L(t) = L(\nu_t, \lambda_t, t) = h(\nu_t) + c(t), \quad (2.23)$$

gdzie  $h(\nu)$  jest funkcją określoną na  $\{\nu_0, \nu_0 + 1, \dots, \nu_0 + n\}$ , taką że  $0 \leq h(\nu) < \infty$  dla  $\nu \geq \nu_0$ . Jeżeli funkcja  $[h(\nu) - h(\nu + 1)](m - \nu)\nu$  jest nierosnąca dla  $\nu = \nu_0, \nu_0 + 1, \dots, \nu_0 + n - 1$ , wtedy używając tych samych metod co w Rozdziale 2.1 otrzymujemy, że chwila zatrzymania

$$\tau^* = \inf\{t \geq 0 : \mathcal{A}h(\nu_t) + c'(t) \geq 0\}, \quad (2.24)$$

jest optymalna. W szczególności, dla

$$h(\nu_t) = \frac{1}{\alpha_0 + \alpha k(t) + \beta} + c_A k(t) = \frac{1}{\alpha_0 + \alpha(\nu_t - \nu_0) + \beta} + c_A(\nu_t - \nu_0) \quad (2.25)$$

mamy następujące twierdzenie.

**Twierdzenie 2.2** *Niech rozkład prawdopodobieństwa zmiennych losowych  $U_1, U_2, \dots, U_n$  spełnia warunki zapisane powyżej oraz niech  $\nu_0 \leq n$ . Wtedy  $\delta^* = (\tau^*, d^*(\tau^*))$ , gdzie*

$$\begin{aligned} \tau^* &= \inf\{t \geq 0 : (m - \nu_t)\nu_t\lambda_t^{-1}\{\alpha - c_A\{\alpha + \beta + \alpha[k(t) + 1]\}\{\alpha + \beta + \alpha k(t)\}\} \\ &\leq c'(t)\{\alpha + \beta + \alpha[k(t) + 1]\}\{\alpha + \beta + \alpha k(t)\}\}, \end{aligned} \quad (2.26)$$

a estymator  $d^*(\tau^*)$  ma postać (2.15), jest bayesowskim planem sekwencyjnym.

## 2.3 Przykład

Niech  $X_1, X_2, \dots, X_n$  będą niezależnymi zmiennymi losowymi mającymi jednakowy rozkład Poissona z parametrem  $\alpha\theta$ , wtedy

$$p(x; \theta, \alpha) = \frac{(\alpha\theta)^x}{x!} \exp(-\alpha\theta) = \frac{\alpha^x}{x!} \exp[\alpha(-\theta) + x \ln(\theta)],$$

gdzie  $x \in \mathbb{N}$ .

Niech  $\alpha=1$ . Wtedy  $s(x, 1) = \frac{1}{x!}$ ,  $w_1(\theta) = -\theta$  oraz  $w_2(\theta) = \ln(\theta)$ . Widać, że funkcja  $s(x, 1)$  jest funkcją nieujemną, mierzalną i niezależną od parametru  $\theta$  oraz, że funkcje

$w_1(\theta)$  i  $w_2(\theta)$  są funkcjami dwukrotnie różniczkowalnymi w zbiorze  $\Theta = (0, \infty)$  z pierwszymi pochodnymi  $w_1(\theta)'$ ,  $w_2(\theta)'$  takimi, że  $w_2(\theta)' > 0$  oraz  $\frac{w_1(\theta)'}{w_2(\theta)'}$  jest ściśle malejącą funkcją  $\theta$ .

Pokażemy, że spełnione są postulaty dotyczące rozkładu  $P_\theta \in \mathcal{E}(\theta, \alpha)$ . Mianowicie

1.  $-\frac{w_1'(\theta)}{w_2'(\theta)} = \theta$ ,

2. skoro

$$\int_{\Theta} \frac{1}{x!} \exp[-\theta + x \ln(\theta)] = 1,$$

to

$$\int_{\Theta} \exp[-\theta + x \ln(\theta)] = x! = \frac{1}{s(x, 1)(1 - 0)},$$

czyli parametr  $\beta = 0$ ,

- 3.

$$\lim_{\theta \rightarrow 0^+} \exp[-\theta + x \ln(\theta)] = 0$$

oraz

$$\lim_{\theta \rightarrow \infty} \exp[-\theta + x \ln(\theta)] = \lim_{\theta \rightarrow \infty} \frac{\theta^x}{\exp(\theta)} = 0,$$

czyli

$$\lim_{\theta \rightarrow 0^+} \exp[-\theta + x \ln(\theta)] = \lim_{\theta \rightarrow \infty} \exp[-\theta + x \ln(\theta)],$$

- 4.

$$\lim_{\theta \rightarrow 0^+} \theta \exp[-\theta + x \ln(\theta)] = \lim_{\theta \rightarrow 0^+} \exp[-\theta + (x + 1) \ln(\theta)] = 0$$

oraz

$$\lim_{\theta \rightarrow \infty} \theta \exp[-\theta + x \ln(\theta)] = \lim_{\theta \rightarrow \infty} \frac{\theta^{x+1}}{\exp(\theta)} = 0,$$

czyli

$$\lim_{\theta \rightarrow 0^+} \theta \exp[-\theta + x \ln(\theta)] = \lim_{\theta \rightarrow \infty} \theta \exp[-\theta + x \ln(\theta)].$$

Za rozkład a priori  $\pi$  parametru  $\theta$  przyjmujemy rozkład, którego funkcja gęstości prawdopodobieństwa wyraża się wzorem  $\alpha_0 p(\gamma, \theta, \alpha_0 + \beta)$ , gdzie  $\gamma = 4$ ,  $\alpha_0 = 2$  oraz

$\beta = 0$ . Tak więc, funkcja gęstości prawdopodobieństwa dla rozkładu a priori  $\pi$  parametru  $\theta$  ma postać

$$\alpha_0 p(\gamma, \theta, \alpha_0 + \beta) = \frac{\alpha_0^{\gamma+1}}{\gamma!} \exp[\alpha_0(-\theta) + \gamma \ln(\theta)] = \frac{4}{3} \exp[-2\theta + 4 \ln(\theta)].$$

Na podstawie Lematu 2.2 wyznaczamy postać estymatora  $d^*(\tau)$  określonego wzorem (2.15) i ryzyka a posteriori  $\tilde{R}(\pi, d^*(\tau))$  określonego wzorem (2.16), mianowicie

$$d^*(\tau) = \frac{4 + \sum_{i=1}^{k(\tau)} X_i}{2 + k(\tau)}$$

i

$$\tilde{R}(\pi, d^*(\tau)) = \frac{1}{2 + k(\tau)}.$$

Czyli musimy wyznaczyć taką optymalną chwilę zatrzymania  $\tau^*$ , która będzie minimalizowała wartość oczekiwaną całkowitej straty

$$E \left[ \frac{1}{2 + k(\tau)} + c_A k(\tau) + c(\tau) \right],$$

po wszystkich chwilach zatrzymania  $\tau$ , przy założeniu, że  $c_A = \frac{1}{100}$ , a  $c(t) = \frac{t^2}{2}$ .

**1.** Zakładamy, że dystrybuanta  $G$  zmiennych losowych  $U_1, U_2, \dots, U_n$  jest znana i pochodzi z rozkładu wykładniczego z parametrem  $\lambda = 1$ . Wtedy optymalna chwila zatrzymania  $\tau^*$  wyznaczona na podstawie Twierdzenia 2.1 ma postać

$$\tau^* = \inf \left\{ t \geq 0 : [n - k(t)] \left[ 1 - \frac{1}{100} (3 + k(t))(2 + k(t)) \right] \leq t(3 + k(t))(2 + k(t)) \right\}.$$

**2.** Zakładamy, że dystrybuanta  $G$  zmiennych losowych  $U_1, U_2, \dots, U_n$  jest zadana rozkładem wykładniczym z nieznanym parametrem  $\lambda = w$ , gdzie zmienna losowa  $W = w$  ma rozkład a priori gamma  $\mathcal{G}(2, 3)$ . Wtedy optymalna chwila zatrzymania  $\tau^*$  wyznaczona na podstawie Twierdzenia 2.2 ma postać

$$\tau^* = \inf \left\{ t \geq 0 : [n - k(t)] \frac{2 + k(t)}{3 + \sum_{j=1}^{k(t)} U_j + [n - k(t)]t} \left[ 1 - \frac{1}{100} (3 + k(t))(2 + k(t)) \right] \leq t(3 + k(t))(2 + k(t)) \right\}.$$

## Rozdział 3

# Estymacja średniej z rozkładu normalnego przy funkcji straty LINEX

### 3.1 Estymacja średniej z rozkładu normalnego w przypadku, gdy dystrybuanta $G$ zmiennych losowych $U_1, U_2, \dots, U_n$ jest znana

Niech  $X_1, X_2, \dots, X_n$  będą niezależnymi zmiennymi losowymi o jednakowym rozkładzie normalnym o nieznannej średniej  $\theta$  i znanej wariancji  $\sigma^2$ . Zmienna losowa  $\theta$  posiada rozkład a priori  $\pi$ , będący rozkładem normalnym o znanej średniej  $\mu$  i znanej wariancji  $\eta^2$ .

Za funkcję straty związaną z błędem estymacji nieznanego parametru  $\theta$  przyjmujemy funkcję straty LINEX, wyrażającą się wzorem

$$L(\theta, d) = b\{\exp[a(\theta - d)] - a(\theta - d) - 1\}, \quad (3.1)$$

gdzie  $a \neq 0$ , a  $b > 0$ . Funkcja straty LINEX jest asymetryczną funkcją różnicy  $\theta - d$ . Rysunek 3.1 przedstawia wykresy funkcji LINEX dla różnych wartości parametru  $a$  i dla  $b = 1$ . W dalszej części tego rozdziału bez straty ogólności będziemy przyjmować, że  $b = 1$ .

Rysunek 3.1: Wykres funkcji straty LINEX

Oznaczmy

$$Y_t = \sum_{i=1}^{k(t)} X_i \quad . \quad (3.2)$$

**Lemat 3.1** Dla dowolnej chwili zatrzymania  $\tau$ , bayesowski estymator  $d^*(\tau)$  parametru  $\theta$  ze względu na rozkład a priori  $\pi$  pod warunkiem  $\mathcal{F}_\tau$  jest postaci

$$d^*(\tau) = \frac{1}{\eta^2 k(\tau) + \sigma^2} (\sigma^2 \mu + \eta^2 Y_\tau + \frac{1}{2} a \sigma^2 \eta^2), \quad (3.3)$$

a jego ryzyko a posteriori wynosi

$$E[L(\theta, d^*(\tau)) \mid \mathcal{F}_\tau] = \frac{1}{2} a^2 \frac{\sigma^2 \eta^2}{\eta^2 k(\tau) + \sigma^2}. \quad (3.4)$$

**Dowód:**

Niech  $t$  będzie ustaloną chwilą zatrzymania obserwacji. Wówczas rozkład a posteriori  $\pi_t$  parametru  $\theta$  przy danym  $\mathcal{F}_t$  jest rozkładem normalnym  $\mathcal{N}(\mu_t, \eta_t^2)$ , gdzie

$$\mu_t = \frac{\sigma^2}{\eta^2 k(t) + \sigma^2} \mu + \frac{\eta^2}{\eta^2 k(t) + \sigma^2} Y_t$$

i

$$\eta_t^2 = \frac{\sigma^2 \eta^2}{\eta^2 k(t) + \sigma^2}.$$

Postać estymatora  $d^*(\tau)$  otrzymamy z formuły Zellnera. Mianowicie

$$\begin{aligned} d^*(t) &= \frac{1}{a} \ln \left\{ E^{\pi_t} [\exp(a\theta)] \right\} = \frac{1}{a} \ln \left\{ \int_{\Theta} \exp(a\theta) \frac{1}{\sqrt{2\pi\eta_t^2}} \exp\left(-\frac{(\theta - \mu_t)^2}{2\eta_t^2}\right) d\theta \right\} \\ &= \frac{1}{a} \ln \left\{ \frac{1}{\sqrt{2\pi\eta_t^2}} \int_{\Theta} \exp\left(-\frac{(\theta - (\mu_t + a\eta_t^2))^2 - a^2\eta_t^4 - 2\mu_t a\eta_t^2}{2\eta_t^2}\right) \right\} \\ &= \frac{1}{a} \ln \left\{ \exp\left(\frac{1}{2} a^2 \eta_t^2\right) + a\mu_t \right\} = \frac{1}{2} a \eta_t^2 + \mu_t. \end{aligned}$$

Ryzyko a posteriori wynosi

$$\begin{aligned}
 E[L(\theta, d^*(t)) \mid \mathcal{F}_t] &= E^{\pi_t} \{ \exp [a(\theta - d^*(t))] - a(\theta - d^*(t)) - 1 \} \\
 &= \exp(-ad^*(t)) E^{\pi_t} (\exp(a\theta)) - aE^{\pi_t}(\theta) + ad^*(t) - 1 \\
 &= \exp\left(-a\mu_t - \frac{1}{2}a^2\eta_t^2\right) \exp\left(a\mu_t + \frac{1}{2}a^2\eta_t^2\right) - a\mu_t + a\mu_t + \frac{1}{2}a^2\eta_t^2 - 1 \\
 &= \frac{1}{2}a^2\eta_t^2 = \frac{1}{2}a^2 \frac{\sigma^2\eta^2}{\eta^2k(t) + \sigma^2}.
 \end{aligned}$$

□

Oznaczmy przez  $\epsilon = \frac{\sigma^2}{\eta^2}$ . Z powyższego lematu wynika, że problem sprowadza się do wyznaczenia takiej chwili zatrzymania  $\tau^*$ , która będzie minimalizowała wartość oczekiwaną całkowitej straty

$$E \left[ \frac{1}{2}a^2 \frac{\sigma^2}{k(\tau) + \epsilon} + c_A k(\tau) + c(\tau) \right], \quad (3.5)$$

po wszystkich chwilach zatrzymania  $\tau$ .

Ponownie niech  $G$  będzie dystrybuantą niezależnych zmiennych losowych  $U_1, U_2, \dots, U_n$ . Zakładamy, że  $G(0) = 0$ ,  $G(t) > 0$  dla  $t > 0$  oraz, że  $G$  jest absolutnie ciągła oraz posiada funkcję gęstości  $g$ , która jest prawostronnie różniczkowalna na przedziale  $(0, \infty)$ . Klasę takich dystrybuant będziemy oznaczać przez  $\mathcal{G}$ . Niech  $\xi = \sup\{t : G(t) < 1\}$  oraz niech  $\rho(z) = g(z)[1 - G(z)]^{-1}$ ,  $0 \leq z < \xi$  oznacza funkcję intensywności awarii.

Analogicznie do Rozdziału 2 stwierdzamy, że  $k(t)$  jest niestacjonarnym łańcuchem Markowa ze względu na  $\mathcal{F}_t$  z operatorem infinitezymalnym postaci (2.18).

**Twierdzenie 3.1** *Założmy, że  $G \in \mathcal{G}$  ma nierosnącą funkcję intensywności awarii  $\rho(t)$ . Wtedy  $\delta^*(\tau^*, d^*(\tau^*))$ , gdzie*

$$\tau^* = \inf \left\{ t : [n - k(t)]\rho(t) \left\{ \frac{a^2\sigma^2}{2[(k(t) + 1) + \epsilon][k(t) + \epsilon]} - c_A \right\} \leq c'(t) \right\}, \quad (3.6)$$

*a estymator  $d^*(\tau^*)$  ma postać (3.3), jest bayesowskim planem sekwencyjnym.*

**Dowód:**

Dowód twierdzenia, który można przeprowadzić w sposób analogiczny do dowodu Twierdzeniu 2.1 pomijamy.

□

## 3.2 Estymacja średniej z rozkładu normalnego w przypadku, gdy dystrybuanta $G$ zmiennych losowych $U_1, U_2, \dots, U_n$ nie jest znana

**Twierdzenie 3.2** *Niech rozkład prawdopodobieństwa zmiennych losowych  $U_1, U_2, \dots, U_n$  spełnia warunki zapisane w Podrozdziale 2.2 oraz niech  $\nu \leq n$ . Wtedy  $\delta^* = (\tau^*, d^*(\tau^*))$ , gdzie*

$$\tau^* = \inf \left\{ t : [n - k(t)] \nu_t \lambda_t^{-1} \left\{ \frac{a^2 \sigma^2}{2[(k(t) + 1) + \epsilon][k(t) + \epsilon]} - c_A \right\} \leq c'(t) \right\}, \quad (3.7)$$

*a estymator  $d^*(\tau^*)$  ma postać (3.3) jest bayesowskim planem sekwencyjnym.*

### Dowód:

Dowód twierdzenia, który można przeprowadzić w sposób analogiczny do dowodu Twierdzeniu 2.2 pomijamy.

□

## 3.3 Przykład

Będziemy zakładać, że  $X_1, X_2, \dots, X_n$  mają jednakowy rozkład normalny o nieznannej średniej  $\theta$  i znanej wariancji 1 oraz, że zmienna losowa  $\theta$  ma rozkład normalny o średniej 0 i wariancji 1.

Za funkcję straty związaną z błędem estymacji parametru  $\theta$  przyjmujemy funkcję straty LINEX z parametrami  $a = 2$  i  $b = 1$ . Rysunek 3.2 przedstawia wykres tej funkcji jako funkcji różnicy  $\theta - d$ .

Rysunek 3.2: Wykres funkcji straty LINEX dla  $a = 2$  i  $b = 1$

Na podstawie **Lematu 3.1** wyznaczamy postać estymatora bayesowskiego  $d^*(\tau)$  oraz jego ryzyko a posteriori  $E[L(\theta, d^*(\tau)/\mathcal{F}_t)]$ , mianowicie

$$d^*(\tau) = \frac{\sum_{i=1}^{k(\tau)} X_i + 1}{k(\tau) + 1}$$

oraz

$$E[L(\theta, d^*(\tau)/\mathcal{F}_t)] = \frac{2}{k(\tau) + 1}.$$

Czyli musimy wyznaczyć taką optymalną chwilę zatrzymania  $\tau^*$ , która będzie minimalizowała wartość oczekiwaną całkowitej straty

$$E \left[ \frac{2}{k(\tau) + 1} + c_A k(\tau) + c(\tau) \right],$$

po wszystkich chwilach zatrzymania  $\tau$ . W naszym przypadku  $c_A = \frac{1}{100}$ , a  $c(t) = \frac{t^2}{2}$ .

**1.** Zakładamy, że dystrybuanta  $G$  zmiennych losowych  $U_1, U_2, \dots, U_n$  jest znana i pochodzi z rozkładu wykładniczego z parametrem  $\lambda = 1$ . Wtedy optymalna chwila zatrzymania  $\tau^*$  wyznaczona na podstawie Twierdzenia 3.1 ma postać

$$\tau^* = \inf \left\{ t \geq 0 : [n - k(t)] \left\{ \frac{2}{(k(t) + 2)(k(t) + 1)} - \frac{1}{100} \right\} \leq t \right\}.$$

**2.** Zakładamy, że dystrybuanta  $G$  zmiennych losowych  $U_1, U_2, \dots, U_n$  jest zadana rozkładem wykładniczym z nieznanym parametrem  $\lambda = w$ , gdzie zmienna losowa  $W = w$  ma rozkład a priori gamma  $\mathcal{G}(2, 3)$ . Wtedy optymalna chwila zatrzymania  $\tau^*$  wyznaczona na podstawie Twierdzenia 3.2 ma postać

$$\tau^* = \inf \left\{ t \geq 0 : \frac{[n - k(t)][2 + k(t)]}{3 + \sum_{j=1}^{k(t)} U_j + [n - k(t)]t} \left[ \frac{2}{(k(t) + 2)(k(t) + 1)} - \frac{1}{100} \right] \leq t \right\}.$$

## Rozdział 4

# Estymacja średniej z rozkładu normalnego przy funkcji straty „reflected normal”

Niech  $X_1, X_2, \dots, X_n$  będą niezależnymi zmiennymi losowymi o jednakowym rozkładzie normalnym o nieznannej średniej  $\theta$  i znanej wariancji  $\sigma^2$ . Zmienna losowa  $\theta$  posiada rozkład a priori  $\pi$ , będący rozkładem normalnym o znanej średniej  $\mu$  i znanej wariancji  $\eta^2$ .

Analogicznie do Rozdziału 2 sformułujemy twierdzenia o postaci planu sekwencyjnego. Tym razem za funkcję straty związaną z błędem estymacji nieznanego parametru  $\theta$  przyjmujemy funkcję straty „reflected normal”, wyrażającą się wzorem

$$L(\theta, d) = K \left\{ 1 - \exp \left[ -\frac{(d - \theta)^2}{2\gamma^2} \right] \right\}, \quad (4.1)$$

gdzie  $\gamma > 0$  i  $K > 0$ . Współczynnik  $K$  nazywany jest parametrem maksymalnej straty. Rysunek 4.1 przedstawia wykres funkcji straty „reflected normal” jako funkcji różnicy  $\theta - d$  dla przykładowych wartości parametrów  $\gamma$  i  $K$ .

Rysunek 4.1: Wykres funkcji straty „reflected normal”

**Lemat 4.1** Dla dowolnej chwili zatrzymania  $\tau$ , bayesowski estymator  $d^*(\tau)$  parametru  $\theta$  ze względu na rozkład a priori  $\pi$  pod warunkiem  $\mathcal{F}_\tau$  jest postaci

$$d^*(\tau) = E^{\pi_t}(\theta) = \mu_\tau = \frac{\sigma^2}{\eta^2 k(\tau) + \sigma^2} \mu + \frac{\eta^2}{\eta^2 k(\tau) + \sigma^2} Y_\tau, \quad (4.2)$$

gdzie  $Y_\tau$  jest postaci (3.2), a jego ryzyko a posteriori wynosi

$$E[L(\theta, d^*(\tau)) | \mathcal{F}_\tau] = K \left( 1 - \frac{\gamma}{\sqrt{\frac{\eta^2 \sigma^2}{k(\tau) \eta^2 + \sigma^2} + \gamma^2}} \right). \quad (4.3)$$

**Dowód:**

Niech  $t$  będzie ustaloną chwilą zatrzymania. Wówczas rozkład a posteriori  $\pi_t$  parametru  $\theta$  przy danym  $\mathcal{F}_t$  jest rozkładem normalnym  $\mathcal{N}(\mu_t, \eta_t^2)$ , gdzie

$$\mu_t = \frac{\sigma^2}{\eta^2 k(t) + \sigma^2} \mu + \frac{\eta^2}{\eta^2 k(t) + \sigma^2} Y_t$$

i

$$\eta_t^2 = \frac{\sigma^2 \eta^2}{\eta^2 k(t) + \sigma^2}.$$

Musimy najpierw wyznaczyć postać ryzyka a posteriori dla dowolnego estymatora  $d$ , wtedy estymatorem optymalnym  $d^*$  będzie ten estymator  $d$ , który minimalizuje to ryzyko. Mianowicie

$$\begin{aligned} E^{\pi_t} L(\theta, d) &= K - E^{\pi_t} \left[ \exp \left( -\frac{(\theta - d)^2}{2\gamma^2} \right) \right] \\ &= K - \frac{1}{\sqrt{2\pi\eta_t}} \int_{-\infty}^{\infty} \exp \left( -\frac{(\theta - d)^2}{2\gamma^2} \right) \exp \left( -\frac{(\theta - \mu_t)^2}{2\eta_t^2} \right) d\theta \\ &= K - \frac{1}{\sqrt{2\pi\eta_t}} \int_{-\infty}^{\infty} \exp \left( -\frac{\theta^2 \eta_t^2 - 2\theta d \eta_t^2 + d^2 \eta_t^2 + \theta^2 \gamma^2 - 2\theta \mu_t \gamma^2 + \mu_t^2 \gamma^2}{2\gamma^2 \eta_t^2} \right) d\theta \\ &= K - \frac{1}{\sqrt{2\pi\eta_t}} \int_{-\infty}^{\infty} \exp \left( -\frac{\theta^2 (\eta_t^2 + \gamma^2) - 2\theta (d \eta_t^2 + \mu_t \gamma^2) + d^2 \eta_t^2 + \mu_t^2 \gamma^2}{2\gamma^2 \eta_t^2} \right) d\theta \\ &= K - \gamma \sqrt{\eta_t^2 + \gamma^2} \exp \left( -\frac{(d - \mu_t)^2}{2(\eta_t^2 + \gamma^2)} \right). \end{aligned}$$

Łatwo zauważyć, że powyższe wyrażenie jest minimalizowane dla  $d = \mu_t$ , co potwierdza tezę lematu dotyczącą postaci estymatora  $d^*$ . Ryzyko a posteriori wynosi

$$\begin{aligned}
 E[L(\theta, d^*(t)) | \mathcal{F}_t] &= KE^{\pi_t} \left\{ 1 - \exp\left(-\frac{(\mu_t - \theta)^2}{2\gamma^2}\right) \right\} \\
 &= K \left\{ 1 - \int_{-\infty}^{\infty} \exp\left(-\frac{(\mu_t - \theta)^2}{2\gamma^2}\right) \frac{1}{\sqrt{2\pi\eta_t}} \exp\left(-\frac{(\theta - \mu_t)^2}{2\eta_t^2}\right) d\theta \right\} \\
 &= K \left\{ 1 - \frac{1}{\sqrt{2\pi\eta_t}} \int_{-\infty}^{\infty} \exp\left(-\frac{\eta_t^2(\theta - \mu_t)^2 + \gamma^2(\theta - \mu_t)^2}{2\eta_t^2\gamma^2}\right) d\theta \right\} \\
 &= K - \frac{K\gamma}{\sqrt{\eta_t^2 + \gamma^2}} = K \left( 1 - \frac{\gamma}{\sqrt{\frac{\eta_t^2\sigma^2}{k(t)\eta^2 + \sigma^2} + \gamma^2}} \right).
 \end{aligned}$$

□

**Twierdzenie 4.1** *Założmy, że  $G \in \mathcal{G}$  ma nierosnącą funkcję intensywności awarii  $\rho(t)$ . Wtedy  $\delta^*(\tau^*, d^*(\tau^*))$ , gdzie*

$$\tau^* = \inf \left\{ t \geq 0 : \frac{1}{\sqrt{\frac{\eta^2 \sigma^2}{\eta^2(k(t)+1)+\sigma^2} + \gamma^2}} - \frac{1}{\sqrt{\frac{\eta^2 \sigma^2}{\eta^2 k(t)+\sigma^2} + \gamma^2}} - c_A \leq \frac{c'(t)}{K \gamma \rho(t)[n - k(t)]} \right\},$$

*a estymator  $d^*(\tau^*)$  ma postać (4.2), jest bayesowskim planem sekwencyjnym.*

**Dowód:**

Dowód twierdzenia, który można przeprowadzić w sposób analogiczny do dowodu Twierdzeniu 2.1 pomijamy. □

**Twierdzenie 4.2** *Niech rozkład prawdopodobieństwa zmiennych losowych  $U_1, U_2, \dots, U_n$  spełnia warunki zapisane w Podrozdziale 2.2 oraz niech  $\nu \leq n$ . Wtedy  $\delta^* = (\tau^*, d^*(\tau^*))$ , gdzie*

$$\tau^* = \inf \left\{ t \geq 0 : \frac{1}{\sqrt{\frac{\eta^2 \sigma^2}{\eta^2(k(t)+1)+\sigma^2} + \gamma^2}} - \frac{1}{\sqrt{\frac{\eta^2 \sigma^2}{\eta^2 k(t)+\sigma^2} + \gamma^2}} - c_A \leq \frac{c'(t)\lambda_t}{K \gamma \nu_t[n - k(t)]} \right\}$$

*a estymator  $d^*(\tau^*)$  ma postać (4.2), jest bayesowskim planem sekwencyjnym.*

**Dowód:**

Dowód twierdzenia, który można przeprowadzić w sposób analogiczny do dowodu Twierdzeniu 2.2 pomijamy. □

## 4.1 Przykład

Będziemy zakładać, że  $X_1, X_2, \dots, X_n$  mają jednakowy rozkład normalny o nieznannej średniej  $\theta$  i znanej wariancji 1 oraz, że zmienna losowa  $\theta$  ma rozkład normalny o średniej 0 i wariancji 1.

Za funkcję straty związaną z błędem estymacji parametru  $\theta$  przyjmujemy symetryczną funkcję straty „reflected normal” z parametrami  $K = 2$  i  $\gamma = 1$ . Rysunek 4.2 przedstawia wykres tej funkcji jako funkcji różnicy  $\theta - d$ .

Rysunek 4.2: Wykres funkcji straty „reflected normal” dla  $K = 2$  i  $\gamma = 1$

Na podstawie **Lematu 4.1** wyznaczamy postać estymatora bayesowskiego  $d^*(\tau)$  oraz jego ryzyko a posteriori  $E[L(\theta, d^*(\tau) | \mathcal{F}_t)]$ , mianowicie

$$d^*(\tau) = \frac{\sum_{i=1}^{k(\tau)} x_i}{k(\tau) + 1}$$

oraz

$$E[L(\theta, d^*(\tau) | \mathcal{F}_t)] = 2 \left( 1 - \sqrt{\frac{k(\tau)}{k(\tau) + 1}} \right).$$

Czyli musimy wyznaczyć taką optymalną chwilę zatrzymania  $\tau^*$ , która będzie minimalizowała wartość oczekiwaną całkowitej straty

$$E \left[ 2 \left( 1 - \sqrt{\frac{k(\tau)}{k(\tau) + 1}} \right) + c_A k(\tau) + c(\tau) \right],$$

po wszystkich chwilach zatrzymania  $\tau$ . W naszym przypadku  $c_A = \frac{1}{100}$ , a  $c(t) = \frac{t^2}{2}$ .

**1.** Zakładamy, że dystrybuanta  $G$  zmiennych losowych  $U_1, U_2, \dots, U_n$  jest znana i pochodzi z rozkładu wykładniczego z parametrem  $\lambda = 1$ . Wtedy optymalna chwila zatrzymania  $\tau^*$  wyznaczona na podstawie Twierdzenia 4.1 ma postać

$$\tau^* = \inf \left\{ t \geq 0 : [n - k(t)] \left[ \sqrt{\frac{k(\tau) + 2}{k(\tau) + 3}} - \sqrt{\frac{k(\tau) + 1}{k(\tau) + 2}} - \frac{1}{100} \right] \leq \frac{t}{2} \right\}.$$

**2.** Zakładamy, że dystrybuanta  $G$  zmiennych losowych  $U_1, U_2, \dots, U_n$  jest zadana rozkładem wykładniczym z nieznanym parametrem  $\lambda = w$ , gdzie zmienna losowa  $W = w$  ma rozkład a priori gamma  $\mathcal{G}(2, 3)$ . Wtedy optymalna chwila zatrzymania  $\tau^*$  wyznaczona na podstawie Twierdzenia 4.2 ma postać

$$\tau^* = \inf \left\{ t \geq 0 : \frac{[n - k(t)][2 + k(t)]}{3 + \sum_{j=1}^{k(t)} U_j + [n - k(t)]t} \left[ \sqrt{\frac{k(\tau) + 2}{k(\tau) + 3}} - \sqrt{\frac{k(\tau) + 1}{k(\tau) + 2}} - \frac{1}{100} \right] \leq \frac{t}{2} \right\}.$$

# Bibliografia

- [1] Aven, T. i Jensen, U. (1999). Stochastic models in reliability. *Springer*.
- [2] Dynkin, E. B. (1965). Markov Processes. *Springer*.
- [3] Fisz, M. (1967). Rachunek prawdopodobieństwa i statystyka matematyczna. *Państwowe Wydawnictwo Naukowe*.
- [4] Jokiel-Rokita, A. i Magiera, R. (1999). Estimation with delayed observations for multinomial distribution. *Statistics* **32**, 353–367.
- [5] Krzyśko, M. (1996). Statystyka Matematyczna. *Wydawnictwo Naukowe Uniwersytetu im. Adama Mickiewicza w Poznaniu*.
- [6] Krzyśko, M. (1998). Statystyka Matematyczna, Tom II, Statystyczne funkcje decyzyjne. *Wydawnictwo Naukowe Uniwersytetu im. Adama Mickiewicza w Poznaniu*.
- [7] Magiera, R. (1982). Estimation with delayed observations. *Zastosowania Matematyki* **17**, 249–258.
- [8] Magiera, R. (2002). Modele i metody statystyki matematycznej. *Oficyna Wydawnicza GiS, Wrocław*.
- [9] Ross, S. M. (1971). Infinitesimal look-ahead stopping rules. *The Annals of Statistics* **42**, 297–303.
- [10] Shapiro, C. P. i Wardrop, R. L. (1980). Dynkin's identity applied to Bayes sequential estimation of a Poisson process rate. *The Annals of Statistics* **8**, 171–182.

- 
- [11] Stadjje, W. (1990). A Sequential Estimation Procedure for the parameter of an Exponential Distribution. *Statistics* **21**, 239–250.
- [12] Starr, N., Wardrop, R. i Woodroofe, M. (1976). Estimating a mean from delayed observations. *Z. Wahrscheinlichkeitstheorie und Verw. Gebiete.* **35**, 103–113.