

6. Sovellus simulointiin

Olkoot prosessit  $\{Y_n\}$ ,  $\{X_n\}$  ja funktiot  $\Lambda_n$  ja  $\Lambda$  kuten aiemminkin. Oletetaan tässä kappaletessa, että  $d = 1$ .

Olkoon  $A$  Boreljoukko, jälle

(6.1)  $\lim_{n \rightarrow \infty} \log P(X_n \in A) = -\gamma < 0$ .

Tarkastelun kohteena tulee olemaan todennäköisyys

$\alpha = \alpha_{n_0} = P(X_{n_0} \in A)$ ,

missä  $n_0$  on kiinteä, mutta suuri. Tällöin  $P(X_{n_0} \in A)$  tulee olemaan pieni; se lähestyy nollaa eksponentiaalisesti vauhtia, kun  $n_0 \rightarrow \infty$ .

Sovelluksissa on tavetta löytää tarkka approksimaatio  $\alpha$  lle. Eräs vaihtoehto on simulointi. Tällöin luotetaan tietokoneella riippumattomia 'havaintoja'  $X_{n_0}^{(i)}$  jakaumasta. Olkoot nämä

$X_{n_0}^{(1)}, \dots, X_{n_0}^{(N)}$ .

Esimerkiksi  $\alpha$  otoksesta asettamalla

$\hat{\alpha} = N^{-1} \sum_{i=1}^N \mathbb{1}(X_{n_0}^{(i)} \in A)$ .

Selvästi

$E(\mathbb{1}(X_{n_0}^{(i)} \in A)) = \alpha$ ,  $\text{Var}(\mathbb{1}(X_{n_0}^{(i)} \in A)) = \alpha(1 - \alpha)$ .

Nähdään, että estimaattokin  $\hat{\alpha}$  odotusarvo ja varianssi ovat

$$E(\hat{\alpha}) = \alpha, \quad \text{Var } \hat{\alpha} = \frac{\alpha(1-\alpha)}{N}$$

Otoskoko  $N$  valitaan siten, että suhteellinen häiriö

$$\frac{\sqrt{\text{Var } \hat{\alpha}}}{E(\hat{\alpha})} = \sqrt{\frac{1-\alpha}{\alpha N}} \leq p_0,$$

missä  $p_0$  on kiinnitetty (ja säätää estimaatin suhteellista virhettä). Valittiin esim.  $p_0 = 0.1$ .  
Nähdään, että sopiva otoskoko on

$$(6.3) \quad N = \frac{1-\alpha}{\alpha p_0^2}.$$

Kerta luku on siis vakio  $\cdot e^{\alpha n_0}$ , missä  $-X$  on (6.1):n tarkkuus. Ongelmaksi muodostuu suuri otoskoon tarve, jos  $n_0$  on suuri.

Ongelmaa voidaan lähestyä esimerkiksi kahdenkertainen simuloinnin avulla. Ollaan  $t_0 \in \mathcal{D}(X)$  ja  $\mathbb{P}_{t_0}$   $Y_n$ :n konjugaattijakauma (tai mikä, kts. kohta 3.2).

$$\mathbb{P}_{t_0}(Y_n \in B) = E(e^{-t_0 Y_n + n \Lambda_n(t_0)} \mathbb{1}(Y_n \in B)),$$

jollain

$$(6.2) \quad \mathbb{P}(Y_n \in B) = E_{t_0}(e^{-t_0 Y_n + n \Lambda_n(t_0)} \mathbb{1}(Y_n \in B)), \quad B \in \mathcal{B}.$$

Ajatuksena on luoda riippumattomia havaintoja muuttujasta (käyttien  $Y_n$ :lle jakaumaa  $\mathbb{P}_{t_0}$ )

$$e^{-t_0 Y_n + n \Lambda_n(t_0)} \mathbb{1}(Z_n \in A).$$

Ollaan  $Z_1, \dots, Z_N$  tällaisia. Estimoidaan  $\alpha$ :aa asettamalla

$$\hat{\alpha}(t_0) = N^{-1} \sum_{i=1}^N Z_i.$$

Yhtälön (6.2) nojalla

$$\mathbb{E}_{t_0}(\vec{z}(t_0)) = \alpha \quad \text{ja} \quad \text{Var}_{t_0} \vec{z}(t_0) = \frac{\eta_n(t_0) - \alpha^2}{N},$$

missä

$$\eta_n(t_0) = \mathbb{E}_{t_0} \left( e^{-2t_0 Y_n + 2n \mathcal{L}_n(t_0)} \mathbb{1}(\mathbb{Z}_n \in A) \right).$$

Luonteva konkreetti estimointivähelellä on näyttää väittä, että

$$\frac{\sqrt{\text{Var}_{t_0} \vec{z}(t_0)}}{\mathbb{E}_{t_0}(\vec{z})} = \sqrt{\frac{\eta_n(t_0) - \alpha^2}{\alpha^2 N}} \leq p_0.$$

Tämäntyyppinen otoskoko on

$$N(t_0) = \frac{\eta_n(t_0) - \alpha^2}{\alpha^2 p_0^2}.$$

Tämä voi olla merkittävästi (6.3):ä pienempi, jos  $t_0$  valitaan sopivasti.

Otoskoko riippuu toista vain suuren  $\eta_n(t_0)$  kautta, joten tavallisena on minimoida  $\eta_n(t_0)$ :ää. Sen sijaan  $t_0$  valitaan asymptoottisen keiteen avulla, kun  $n \rightarrow \infty$ .

Koska varianssi on ei-negatiivinen, niin

$$\begin{aligned} \eta_n(t_0) &\geq \mathbb{E}_{t_0} \left( e^{-2t_0 Y_n + 2n \mathcal{L}_n(t_0)} \mathbb{1}(\mathbb{Z}_n \in A) \right)^2 \\ &= \mathbb{P}(\mathbb{Z}_n \in A)^2. \end{aligned}$$

Siksi

$$(6.4) \quad \liminf_{n \rightarrow \infty} \log \eta_n(t_0) \geq -2 \log p_0,$$

ks. (6.1).

Konjugaattimuunnos  $P_{\lambda_0}$  on tehokas, jos

$$\lim_{n \rightarrow \infty} \log \eta_n(\lambda_0) = -2 \text{ fl.}$$

Tarkastellaan tehokkaita konjugaattimuunnoksia seuraavien oletusten:

$$1) \quad \lambda(|x|) < \infty, \quad \forall x, \quad \text{ja} \quad \lambda'(|x|) \exists, \quad \forall x, \quad \text{ja} \quad \lambda(x) = \lim_{n \rightarrow \infty} \lambda_n(x)$$

$$2) \quad \lambda'(|x|) < 0$$

$$3) \quad \Lambda = (a_1, a_2), \quad \text{missä} \quad 0 < a_1 < a_2 \leq \infty,$$

Oletukset tehdään mukavuuksien, lievemmit käyttöä helpottavat.

Lemma 6.1. Oletetaan, että  $\{\mathcal{Z}_n\}$  toteuttaa SPP:n vauhti-invariantilla  $I$ . Silloin

$$(6.5) \quad \liminf_{n \rightarrow \infty} n^{-1} \log m_n(t_0) \geq \Lambda(t_0) = \min_{x \in \mathring{A}} \{t_0 x + I(x)\}$$

ja

$$(6.6) \quad \limsup_{n \rightarrow \infty} n^{-1} \log m_n(t_0) \leq \Lambda(t_0) = \min_{x \in \bar{A}} \{t_0 x + I(x)\}.$$

Todistus. Selvästi

$$\begin{aligned} n^{-1} \log m_n(t_0) &= n^{-1} \log \mathbb{E} \left( e^{-\langle t_0, Y_n \rangle} \mathbb{1}_{\{Y_n \in A\}} \right) \\ &= \Lambda_n(t_0) + n^{-1} \log \mathbb{E} \left( e^{-\langle t_0, Y_n \rangle} \mathbb{1}_{\{Y_n \in A\}} \right). \end{aligned}$$

Väite on todettava suorastaan lauseen 5.2 pätevästä huomannuksesta.  $\square$

Seuraus 6.1. Konjugaattijakauma parametreilla  $t_0$  on tehokas, jos

$$(6.7) \quad \Lambda(t_0) = \min_{x \in \bar{A}} \{t_0 x + I(x)\} \geq 2 \min_{x \in \mathring{A}} I(x).$$

Oletetaan lisäksi, että  $I(\mathring{A}) = I(\bar{A})$ . Jos konjugaattijakauma parametreilla  $t_0$  on tehokas, niin

$$(6.8) \quad \Lambda(t_0) = \min_{x \in \mathring{A}} \{t_0 x + I(x)\} \geq 2 \min_{x \in \bar{A}} I(x).$$

Toodistus. Jos (6.7)  $\downarrow$  oletetaan, niin lemmän 6.1  
nohjalla

$$\limsup_{n \rightarrow \infty} \log \eta_n(t_0) \leq \mathcal{L}(t_0) - \mathcal{L}(t_0) - 2 \inf_{x \in \bar{A}} \{I(x)\} \leq -2I(A),$$

Jos taas  $P_{t_0}$  on tehokas ja  $I(\bar{A}) = I(\hat{A})$ , niin

$$-2I(\bar{A}) = \lim_{n \rightarrow \infty} \log \eta_n(t_0)$$

$$\geq \mathcal{L}(t_0) - \inf_{x \in \bar{A}} \{t_0 x + I(x)\}$$

äläyän (6.5) nohjalla. Tämä on juna (6.8).  $\square$

Olkoon nyt äälypisesti  $I = \mathcal{L}^*$ . Oletetaan, että

$$\mathcal{L}^*(\bar{A}) = \mathcal{L}^*(\hat{A}).$$

Koska  $\mathcal{L}^*(\mathcal{L}'(0)) = 0$ , on  $\mathcal{L}^*$  kasvava alueessa  $x \geq \mathcal{L}'(0)$ ,  
joten

$$\mathcal{L}^*(A) = \mathcal{L}^*(a_1).$$

Seuraavaksi 6.1 soveltamiseksi, on scharaktiivilla milla  
parametrit  $t$  arvot

$$(6.9) \quad -\mathcal{L}(t) + \inf_{x \in \bar{A}} \{tx + \mathcal{L}^*(x)\} \geq 2\mathcal{L}^*(a_1).$$

Olkoon aluksi  $t \geq 0$ . Täällä (6.9):n vasen  
puoli on

$$f(t) = -\mathcal{L}(t) + ta_1 + \mathcal{L}^*(a_1).$$

Scheästä  $f$  on konveksi ja yhtälöllä

$$f'(t) = -\lambda'(t) + a_1 = 0$$

on ratkaisu, jos  $a_1 \in \text{ri } D(\lambda^*)$  (lemma 3.5).  
Oletetaan, että näin on ja olkoon

$$(6.10) \quad \lambda'(t_0) = a_1.$$

Tällöin

$$f(t_0) = -\lambda(t_0) + t_0 a_1 + \lambda^*(a_1) = 2\lambda^*(a_1).$$

Sisä (6.7) totuus ja parametri  $t_0$  antaa tehokkaan simulointipätkän. Jos  $\lambda'(t) \neq a_1$ , ei  $t_0$  toteuta ehtoa (6.7). Tällöin nimittävän  $f$  on joko aidosti kasvava tai aidosti vähenevä  $\pi/s + c$  estä  $t$ , joten

$$f(t) < \sup_{u \in \mathbb{R}} \{ f(u) \} = f(t_0)$$

(lemma 3.11), samoin (6.7) ei totuus, jos  $t_0 < 0$ .

Oletetaan vielä lisäksi, että  $\{Y_n\}$  on säännöllis-  
kukka. Voidaan nähdä, että  $\lambda$  on aidosti kon-  
vekssi, joten yhtälöllä (6.1) on korkeintaan yksi rat-  
kaisu. Olkoon

$$M(t) = \mathbb{E}(e^{tY_n}) = \mathbb{E}(e^{tS})^n$$

Konjugaatti muunnoksen jälkeen

$$\begin{aligned} M_{t_0}(t) &= \mathbb{E}_{t_0}(e^{tY_n}) = \mathbb{E}(e^{(t-t_0)Y_n} e^{t_0 Y_n}) \\ &= \frac{\mathbb{E}(e^{(t-t_0)Y_n})}{\mathbb{E}(e^{t_0 Y_n})} = \left( \frac{\mathbb{E}(e^{(t-t_0)S})}{\mathbb{E}(e^{t_0 S})} \right)^n. \end{aligned}$$

Tämä on satunnaiskulun momentit generoiva funktio, palon konjugaattimomentien jälkeen  $Y_n$  on edelleen satunnaiskulun. Käsityksen mukaan on  $Y_n$  konjugaattijakauma parametrilla  $\theta$ . (päättely perustuu kummitulun tulokseen: jos momentit generoiva funktio on äärellinen jaksen ensimmäisessä potkussa, niin se määrää jakauman yksikähtäisesti;  $M_1$  ja  $M_2$  edellä ovat momentit generoiva funktioita).



Jos  $\{X_n\}$  toteuttaa SPP:n vaihtifunktiolla  $\Lambda^*$ , niin

$$\begin{aligned}\Lambda^*(x) &= \sup \{ \langle t, x \rangle - \Lambda(t); t \in \mathbb{R}^d \} \\ &= \sup \{ f(x) - \Lambda_f; f \in (\mathbb{R}^d)^* \},\end{aligned}$$

missä

$$(7.1) \quad \Lambda_f = \limsup_{n \rightarrow \infty} \log \mathbb{E}(e^{n \langle f, X_n \rangle})$$

$$\text{ja } (\mathbb{R}^d)^* = \{ f: \mathbb{R}^d \rightarrow \mathbb{R}; f \text{ lineaarinen} \}.$$

Tämä tulos yleisty (lähes) kaikille konvekseille vaihtifunktiolle. Jos nimittäin  $\{X_n\}$  toteuttaa SPP:n konvekilla vaihtifunktiolla ja

$$\Lambda(t) = \limsup_{n \rightarrow \infty} \log \mathbb{E}(e^{n \langle t, X_n \rangle}) < \infty, \quad \forall t \in \mathbb{R}^d,$$

niin  $I = \Lambda^*$ . Perusteilyä esitetään harjoituksissa.

Luonnollista on kysyä, onko vaihtifunktiolla yleisemmin jokin saman tyyppinen esitys. Brucin lauseen nojalla näin on. Tarkastellaan tätä seuraavassa.

Lause 7.1. Oletetaan, että  $\{X_n\}$  toteuttaa SPP:n vaihtifunktiolla  $I$ . Silloin

$$I(x) = \sup \{ f(x) - \Lambda_f; f \in \mathcal{C}_b(\mathbb{R}^d) \},$$

missä  $\Lambda_f$  on kuten edellä ja

$$\mathcal{C}_b(\mathbb{R}^d) = \{ f: \mathbb{R}^d \rightarrow \mathbb{R}; f \text{ jatkuva ja rajoitettu} \}.$$

Todistus. Todetaan ensin, että  $\Lambda_f < \infty$  ja (7.1) pätee raja-arvona. Valitaan integroilun käyttöä,  $f \in \mathcal{C}_b(\mathbb{R}^d)$ , ja

$$\Lambda_f = \sup_{x \in \mathbb{R}^d} \{ f(x) - I(x) \}.$$

Harjoituksesta näytetään, että

$$I(x) \geq \sup \{ f(x) - \Lambda_f \mid f \in \mathcal{C}_b(\mathbb{R}^d) \}, \quad \forall x \in \mathbb{R}^d.$$

Kiinteän epäyhtälön todistamiseksi tarkastellaan kiinteää  $x_0 \in \mathbb{R}^d$ . Ollaan  $M > 0$  luvut ja  $\varepsilon > 0$  pieni. Ollaan ensin  $I(x_0) < \infty$ . Määritellään  $\delta > 0$  siten, että

$$\inf \{ I(x) \mid |x - x_0| \leq \delta \} \geq I(x_0) - \varepsilon.$$

Valitaan sopiva  $a > 0$  ja  $f_a$  ehdosta

$$f_a(x) = \max \{ -a|x - x_0|, -M \}.$$

Tällöin  $f_a \in \mathcal{C}_b(\mathbb{R}^d)$ . Lisäksi

$$\sup \{ f_a(x) - I(x) \mid |x - x_0| \leq \delta \} \leq -I(x_0) + \varepsilon$$

ja

$$\sup \{ f_a(x) - I(x) \mid |x - x_0| > \delta \} \leq \max \{ -a\delta, -M \}.$$

kiinnitetään  $a = \frac{M}{\delta}$ , jolloin

$$\Lambda_{f_a} = \sup \{ f_a(x) - I(x) \mid x \in \mathbb{R}^d \}$$

$$\leq \max \{ -I(x_0) + \varepsilon, -M \}$$

$$= -I(x_0) + \varepsilon, \quad \text{kun oletetaan } M \geq I(x_0).$$

Nähdään, että

$$\begin{aligned} I(x_0) &\leq -\lambda_{f_a} + \varepsilon \\ &= f_a(x_0) - \lambda_{f_a} + \varepsilon \\ &\leq \sup \{ f(x_0) - \lambda_{f_a} : f \in \mathcal{E}_b(K^d) \} + \varepsilon. \end{aligned}$$

Olkoon  $\lambda_{f_a}$  lukuksi  $I(x_0) = \infty$  ja  $\delta > 0$  sellainen, että

$$\text{in } f \in \mathcal{I}(x) : |x - x_0| \leq \delta \Rightarrow f > M.$$

olkaan  $\lambda_a$  luvun edellä. Tällöin

$$\lambda_{f_a} \leq \max(-a\delta, -M)$$

ja

$$f_a(x_0) - \lambda_{f_a} \geq M.$$

kun valitaan  $a = \frac{M}{\delta}$ . Nähdään, että

$$\begin{aligned} &\sup \{ f(x_0) - \lambda_{f_a} : f \in \mathcal{E}_b(K^d) \} \\ &= \infty = I(x_0). \quad \square \end{aligned}$$

# Sisällysluettelo

## Johdatus suurten painkeamien teoriaan

1. Johdanto	1.1 - 1.3
2. Suurten painkeamien periaate	2.1 - 2.16
3. Gärther - Ellisin lause	3.1 - 3.16
3.1. Konvektia analyysiä	3.11 - 3.28
3.2. Alareijat	3.25 - 3.42
4. Sovellus vararikkoteoriaan	4.1 - 4.6
5. Suurten painkeamien periaatteen seurauksia	5.1 - 5.1
5.1. Kontaktiperiaate	5.2 - 5.4
5.2. Varadhanin integraalilemma	5.5 - 5.10
6. Sovellus simulointiin	6.1 - 6.8
7. Brycin eriytyminen veeftidun leti cella	7.1 - 7.3

## Läselähtettä

Sovelluspainotteinen loppu

Bucklew, J. (1990) Large deviation techniques in Decision, Simulation, and Estimation. Wiley & Sons.

Kohda 4. Collamore, J. (1996) Hitting probabilities and large deviations. Ann. Probab. 24, 2065-2078

Kohda 6. Dieker, B. and Mandjes, M. (2005) On asymptotically efficient simulation of large deviations probabilities. Adv. Appl. Prob. 37, 539-552.