

# Metoda Monte Carlo

Jerzy Mycielski

grudzien 2012

- Powiedzmy, że mamy do policzenia następującą całkę:

$$\int_a^b f(x) dx = I$$

- Załóżmy, że funkcja  $f(x)$  jest tak skomplikowana, że nie jesteśmy w stanie policzyć tej całki analitycznie
- Możemy, zastąpić liczenie tej całki liczeniem wartości oczekiwanej.
- Załóżmy, że mamy pewną zmienną losową  $v \in [a, b]$  o znanej funkcji gęstości  $p(\cdot)$  i zdefiniujmy  $\eta = \frac{f(x)}{p(x)}$
- Wtedy:

$$E(\eta) = \int_a^b \left[ \frac{f(x)}{p(x)} \right] p(x) dx = I$$

- Wykorzystując Prawo Wielkich Liczb przy założeniu, że  $\text{Var}\left(\frac{f(x)}{p(x)}\right) < \infty$

$$\hat{T} = \bar{\eta} = N^{-1} \sum_{i=1}^N \frac{f(x_i)}{p(x_i)} \xrightarrow{P} E(\eta) = I$$

# Badanie własności estymatorów

- Załóżmy, że znamy **Proces Generujący Dane** (PGD)
- Załóżmy, że PGD zależy od wektora parametrów  $\theta$
- Chcemy znaleźć formułę dla wartości oczekiwanej estymator  $\hat{\beta}$  w małej próbie
- Oznaczmy

$$E(\hat{\beta}) = \mathbf{G}_1(\theta, T) = \psi_{T1}$$

$$\text{Var}(\hat{\beta}) = E(\hat{\beta} - \psi_{T1})(\hat{\beta} - \psi_{T1}) = \mathbf{G}_2(\theta, T) = \psi_{T2}$$

gdzie  $T$  jest liczbą obserwacji

- Na podstawie Monte Carlo można  $E(\hat{\beta})$ ,  $\text{Var}(\hat{\beta})$  oszacować dla *znanego*  $\theta$ ,  $T$ ,

$$\bar{\psi}_{T1} = \frac{1}{N} \sum_{i=1}^N \hat{\beta}_i$$

$$\bar{\psi}_{T2} = \frac{1}{N} \sum_{i=1}^N E(\hat{\beta}_i - \bar{\psi}_{T1})(\hat{\beta}_i - \bar{\psi}_{T1})$$

- Istnieje szereg generatorów liczb pseudolosowych: najczęściej można z nich uzyskać liczby losowe z rozkładu jednostajnego
- Generator liczb losowych rozpoczyna generować liczby losowego wykorzystując ziarno (*seed*). Ciąg liczb pseudolosowych uzyskanych przy tym samym ziarnie jest zawsze ten sam
- Za pomocą generatora liczb losowych z rozkładu jednostajnego można uzyskać także zmienne z innych rozkładów
- Jeśli zmienna  $\eta$  ma rozkład jednostajny, to zmienna  $\xi = F^{-1}(\varepsilon)$  ma rozkład dany dystrybucją  $F$

- Dla rozkładu jednostajnego na przedziale  $[0, 1]$

$$\Pr(\xi \leq x) = x$$

uzyskujemy przekształcając

$$\Pr(\xi \leq x) = \Pr(F(\xi) \leq F(x)) = \Pr(\varepsilon \leq F(x)) = F(x)$$

ponieważ  $\varepsilon = F(\xi)$ , skoro  $\xi = F^{-1}(\varepsilon)$

- W przypadku rozkładu normalnego można wykorzystać odwrotność rozkładu bądź przybliżenie z centralnego twierdzenia granicznego

$$\xi = \left( \sum_{j=1}^{12} \eta_j - 6 \right)$$

- Główny problem z eksperymentami Monte Carlo: wnioski dotyczą jedynie PGD określonego przez  $\theta$  i  $T$
- Można przeprowadzić wiele eksperymentów, dla różnych  $\theta$  i  $T$  ale w tym przypadku powstaje pytanie jak w syntetyczny sposób podsumować wnioski
- Rozwiązaniem są płaszczyzny odpowiedzi definiowane przez funkcję

$$\bar{\psi}_{Ti} = \mathbf{H}_i(\theta, T) + \mathbf{v}_{Ti}$$

- Funkcje te dopasowujemy do uzyskanych z Monte Carlo oszacowań  $\bar{\psi}_{Ti}$

- Forma funkcyjna  $\mathbf{H}_i(\boldsymbol{\theta}, T)$  powinna być dobrana tak, by dopasowanie było jak najlepsze
- Całkowity błąd  $\mathbf{v}_{Ti}$  płaszczyzny odpowiedzi można zdekomponować na
  - błędem pomiaru:

$$\mathbf{v}_{1Ti} = \psi_{Ti} - \bar{\psi}_{Ti}$$

przy czym  $E(\mathbf{v}_{1Ti}) = 0$

- błąd aproksymacji

$$\mathbf{v}_{2Ti} = \mathbf{G}_i(\boldsymbol{\theta}, T) - \mathbf{H}_i(\boldsymbol{\theta}, T)$$

- Forma  $\mathbf{H}_i(\boldsymbol{\theta}, T)$  powinna być tak dobrana, by wartości asymptotyczne zgadzały się wielkościami uzyskanymi z płaszczyzny odpowiedzi dla  $T \rightarrow \infty$
- Typowa forma funkcyjna płaszczyzny odpowiedzi dla wartości oczekiwanej

$$H_1(\boldsymbol{\theta}, T) - \beta = \gamma_{01}I + \gamma_{11}\frac{1}{T} + \gamma_{21}I\frac{1}{T} + \sum_{j=1}^{k_1} \gamma_{j+2,1}\phi_{j,1}\frac{1}{T}$$

gdzie  $\phi_{j,1}$  są funkcjami  $\theta, \frac{\theta}{T}, \theta^2, \frac{1}{T}, \frac{1}{T^2}$  a  $I = \text{plim } \hat{\beta} - \beta$

- Jeśli  $\gamma_{01} = 0$ , to zarówno  $H_1(\boldsymbol{\theta}, T)$  jak i  $G_1(\boldsymbol{\theta}, T)$  dążą do prawdziwego  $\beta$



# Sposoby zwiększania dokładności Monte Carlo

- Znajdź parametry, które nie wpływają na wielkość statystyki (niezmienniczość)
- Można to sprawdzić licząc wielkość statystyki dla kilku zbiorów parametrów ale *tego samego* zbioru liczb pseudolosowych
- Antytetyczne liczby pseudolosowe:
  - założmy, że mamy dwa estymatory  $\hat{\psi}$ ,  $\tilde{\psi}$  i estymator wymieszany  $\bar{\psi} = \frac{1}{2} (\hat{\psi} + \tilde{\psi})$  taki, że  $E(\bar{\psi}) = \psi$
  - wariancja estymatora  $\bar{\psi}$  jest równa  $\frac{1}{4} [\text{Var}(\hat{\psi}) + \text{Var}(\tilde{\psi}) + 2\text{Cov}(\hat{\psi}, \tilde{\psi})]$
  - jeśli  $\text{Cov}(\hat{\psi}, \tilde{\psi}) < 0$  to wariancja estymatora wymieszanego mniejsza od estymatorów pierwotnych
  - czasami jesteśmy w stanie tak przekształcić zbiór liczb pseudolosowych  $\{\varepsilon_i\}$ , że estymator policzony dla przekształconego zbioru jest ujemnie skorelowany z estymatorem ze zbioru oryginalnego
  - w takim przypadku możliwe będzie uzyskanie dokładniejszych oszacowań
  - najczęściej stosujemy zbiory  $\{\varepsilon_i\}$  i  $\{-\varepsilon_i\}$

- zmienne kontrolne:

- założmy, że znamy takie  $\psi^*$ , dla którego znamy  $E(\psi^*)$
- założmy ponadto, że  $\hat{\psi}$  i  $\psi^*$  są dodatnio skorelowane ( $\psi^*$  zachowuje się podobnie do  $\hat{\psi}$ )
- zdefiniujmy  $\bar{\psi} = \tilde{\psi} - \psi^* - E(\psi^*)$
- wtedy

$$\text{Var}(\bar{\psi}) = \text{Var}(\tilde{\psi}) + \text{Var}(\psi^*) - 2\text{Cov}(\tilde{\psi}, \psi^*)$$

- i  $\text{Var}(\bar{\psi}) < \text{Var}(\tilde{\psi})$  jeśli  $\text{Cov}(\tilde{\psi}, \psi^*) > \frac{1}{2} \text{Var}(\psi^*)$