

# Nieasympiotyczne oszacowania błędu dla regeneracyjnych algorytmów MCMC<sup>1</sup>

Wojciech Niemirow

Uniwersytet Mikołaja Kopernika, Toruń i Uniwersytet Warszawski

Statystyka Matematyczna  
Wisła, grudzień 2009

---

<sup>1</sup>Współautorzy: Krzysztof Łatuszyński, University of Warwick, U.K. i Błażej Miasojedow, Uniwersytet Warszawski,

# Plan

- 1 Wstęp
  - Obliczanie całek metodą MCMC
  - Oszacowania dokładności
- 2 Regeneracja
  - Mały zbiór
  - Regeneracja
  - Estymator sekwencyjno-regeneracyjny
- 3 Główny wynik
  - Błąd średniokwadratowy
  - Warunek dryfu
  - Jawne oszacowania przy warunku dryfu

# Plan

- 1 Wstęp
  - Obliczanie całek metodą MCMC
  - Oszacowania dokładności
- 2 Regeneracja
  - Mały zbiór
  - Regeneracja
  - Estymator sekwencyjno-regeneracyjny
- 3 Główny wynik
  - Błąd średniokwadratowy
  - Warunek dryfu
  - Jawne oszacowania przy warunku dryfu

# Plan

- 1 Wstęp
  - Obliczanie całek metodą MCMC
  - Oszacowania dokładności
- 2 Regeneracja
  - Mały zbiór
  - Regeneracja
  - Estymator sekwencyjno-regeneracyjny
- 3 Główny wynik
  - Błąd średniokwadratowy
  - Warunek dryfu
  - Jawne oszacowania przy warunku dryfu

## 1 Wstęp

- Obliczanie całek metodą MCMC
- Oszacowania dokładności

## 2 Regeneracja

- Mały zbiór
- Regeneracja
- Estymator sekwencyjno-regeneracyjny

## 3 Główny wynik

- Błąd średniokwadratowy
- Warunek dryfu
- Jawne oszacowania przy warunku dryfu

# Obliczanie całek metodą MCMC

Obliczyć całkę

$$\theta = \int_{\mathcal{X}} f(x)\pi(x)dx,$$

gdzie

- $\mathcal{X}$  – przestrzeń wielowymiarowa,
- $\pi$  gęstość rozkładu prawdopodobieństwa na  $\mathcal{X}$ , zwykle znana tylko z dokładnością do stałej normującej.

Metoda MCMC: generujemy (symulujemy) łańcuch Markowa

$$X_0, X_1, \dots, X_t, \dots \quad \pi_t(A) = \mathbb{P}(X_t \in A) \rightarrow \pi(A), \quad (t \rightarrow \infty).$$

Estymator MCMC:

$$\hat{\theta}_T = \frac{1}{n} \sum_{i=0}^{T-1} f(X_i) \rightarrow \theta \quad (T \rightarrow \infty).$$

# Obliczanie całek metodą MCMC

Obliczyć całkę

$$\theta = \int_{\mathcal{X}} f(x)\pi(x)dx,$$

gdzie

- $\mathcal{X}$  – przestrzeń wielowymiarowa,
- $\pi$  gęstość rozkładu prawdopodobieństwa na  $\mathcal{X}$ , zwykle znana tylko z dokładnością do stałej normującej.

Metoda MCMC: generujemy (symulujemy) **łańcuch Markowa**

$$X_0, X_1, \dots, X_t, \dots \quad \pi_t(A) = \mathbb{P}(X_t \in A) \rightarrow \pi(A), \quad (t \rightarrow \infty).$$

Estymator MCMC:

$$\hat{\theta}_T = \frac{1}{n} \sum_{i=0}^{T-1} f(X_i) \rightarrow \theta \quad (T \rightarrow \infty).$$

# Obliczanie całek metodą MCMC

Obliczyć całkę

$$\theta = \int_{\mathcal{X}} f(x)\pi(x)dx,$$

gdzie

- $\mathcal{X}$  – przestrzeń wielowymiarowa,
- $\pi$  gęstość rozkładu prawdopodobieństwa na  $\mathcal{X}$ , zwykle znana tylko z dokładnością do stałej normującej.

Metoda MCMC: generujemy (symulujemy) **łańcuch Markowa**

$$X_0, X_1, \dots, X_t, \dots \quad \pi_t(\mathbf{A}) = \mathbb{P}(X_t \in \mathbf{A}) \rightarrow \pi(\mathbf{A}), \quad (t \rightarrow \infty).$$

Estymator MCMC:

$$\hat{\theta}_T = \frac{1}{n} \sum_{i=0}^{T-1} f(X_i) \rightarrow \theta \quad (T \rightarrow \infty).$$



# Obliczanie całek metodą MCMC

Obliczyć całkę

$$\theta = \int_{\mathcal{X}} f(x)\pi(x)dx,$$

gdzie

- $\mathcal{X}$  – przestrzeń wielowymiarowa,
- $\pi$  gęstość rozkładu prawdopodobieństwa na  $\mathcal{X}$ , zwykle znana tylko z dokładnością do stałej normującej.


Metoda MCMC: generujemy (symulujemy) **łańcuch Markowa**

$$X_0, X_1, \dots, X_t, \dots \quad \pi_t(\mathbf{A}) = \mathbb{P}(X_t \in \mathbf{A}) \rightarrow \pi(\mathbf{A}), \quad (t \rightarrow \infty).$$


Estymator MCMC:

$$\hat{\theta}_T = \frac{1}{n} \sum_{i=0}^{T-1} f(X_i) \rightarrow \theta \quad (T \rightarrow \infty).$$

## Zbieżność do rozkładu stacjonarnego:



## Zbieżność średnich do estymatora bayesowskiego:



# Oszacowania dokładności

Błąd średniokwadratowy:

$$\text{MSE} = \mathbb{E} (\hat{\theta}_T - \theta)^2 \leq ?$$

Poziom ufności:

$$\mathbb{P}(|\hat{\theta}_T - \theta| > \varepsilon) \leq ?$$

# Oszacowania dokładności

Błąd średniokwadratowy:

$$\text{MSE} = \mathbb{E} (\hat{\theta}_T - \theta)^2 \leq ?$$

Poziom ufności:

$$\mathbb{P}(|\hat{\theta}_T - \theta| > \varepsilon) \leq ?$$

- 1 Wstęp
  - Obliczanie całek metodą MCMC
  - Oszacowania dokładności
- 2 Regeneracja
  - Mały zbiór
  - Regeneracja
  - Estymator sekwencyjno-regeneracyjny
- 3 Główny wynik
  - Błąd średniokwadratowy
  - Warunek dryfu
  - Jawne oszacowania przy warunku dryfu

# Mały zbiór

Łańcuch Markowa  $X_n$  na przestrzeni  $\mathcal{X}$  z jądrem przejścia:

$$P(x, A) = \mathbb{P}(X_n \in A | X_{n-1} = x).$$

## ZAŁOŻENIA

- **Rozkład stacjonarny.** Istnieje rozkład  $\pi$  na  $\mathcal{X}$  taki, że  $\pi P = \pi$  i  $P$  jest  $\pi$ -nieprzywiedlny.
- **Mały zbiór.** Istnieją:  $J \subseteq \mathcal{X}$  z  $\pi(J) > 0$ , miara probabilistyczna  $\nu$  i  $\beta > 0$  takie, że

$$P(x, \cdot) \geq \beta \mathbb{I}(x \in J) \nu(\cdot).$$

# Mały zbiór

Łańcuch Markowa  $X_n$  na przestrzeni  $\mathcal{X}$  z jądrem przejścia:

$$P(x, A) = \mathbb{P}(X_n \in A | X_{n-1} = x).$$

## ZAŁOŻENIA

- **Rozkład stacjonarny.** Istnieje rozkład  $\pi$  na  $\mathcal{X}$  taki, że  $\pi P = \pi$  i  $P$  jest  $\pi$ -nieprzywiedlny.
- **Mały zbiór.** Istnieją:  $J \subseteq \mathcal{X}$  z  $\pi(J) > 0$ , miara probabilistyczna  $\nu$  i  $\beta > 0$  takie, że

$$P(x, \cdot) \geq \beta \mathbb{I}(x \in J) \nu(\cdot).$$



# Regeneracja

„Resztowe” jądro przejścia:

$$Q(x, \cdot) := \frac{P(x, \cdot) - \beta \mathbb{I}(x \in J) \nu(\cdot)}{1 - \beta \mathbb{I}(x \in J)}.$$

- Jeśli  $X_{n-1} \notin J$  to losuj  $X_n \sim P(X_{n-1}, \cdot)$ , **nie ma regeneracji**;
- Jeśli  $X_{n-1} \in J$  to
  - z prawdopodobieństwem  $1 - \beta$  losuj  $X_n \sim Q(X_{n-1}, \cdot)$ , **nie ma regeneracji**;
  - z prawdopodobieństwem  $\beta$  losuj  $X_n \sim \nu(\cdot)$ , **Regeneracja!**

**Remark:** Faktycznie losowanie  $Q(X_{n-1}, \cdot)$  **nie** jest konieczne (Mykland et al. 1995).

# Czasy odnowienia

Momenty regeneracji (odnowienia) dzielą łańcuch na **niezależne** „bloki” losowej długości.

$$\underbrace{X_0, \dots, X_{T_1-1}}_{T_1}, \quad \underbrace{X_{T_1}, \dots, X_{T_2-1}}_{T_2-T_1}, \quad \underbrace{X_{T_2}, \dots, X_{T_3-1}}_{T_3-T_2}, \quad \dots$$

$\uparrow$                      $\uparrow$                      $\uparrow$   
**R**                    **R**                    **R**

Dodatkowo zakładamy, że  $X_0 \sim (\pi(\cdot|J))$ , wtedy 0 jest momentem odnowienia. i wszystkie bloki mają **ten sam rozkład**.

# Estymator sekwencyjno-regeneracyjny

$0 = T_0, T_1, \dots, T_r, \dots$  – losowe momenty regeneracji.

$$R(n) := \min\{r : T_r \geq n\}.$$

Estymator:

$$\hat{\theta}_{T_{R(n)}} = \frac{1}{T_{R(n)}} \sum_{i=0}^{T_{R(n)}-1} f(X_i).$$

$$\begin{array}{cccccc} 0, \dots, T_1 - 1, & T_1, \dots, & T_{R(n)} - 1, \dots, n, \dots, T_{R(n)} - 1, & T_{R(n)}, \dots \\ \uparrow & \uparrow & \uparrow & \uparrow & \uparrow \\ R & R & R & n & R \end{array}$$

- 1 Wstęp
  - Obliczanie całek metodą MCMC
  - Oszacowania dokładności
- 2 Regeneracja
  - Mały zbiór
  - Regeneracja
  - Estymator sekwencyjno-regeneracyjny
- 3 **Główny wynik**
  - Błąd średniokwadratowy
  - Warunek dryfu
  - Jawne oszacowania przy warunku dryfu

# Błąd średniokwadratowy

Całka i jej estymator MCMC:

$$\theta = \pi(f) = \int_{\mathcal{X}} f(x)\pi(x)dx, \quad \hat{\theta}_{T_{R(n)}} = \frac{1}{T_{R(n)}} \sum_{i=0}^{T_{R(n)}-1} f(X_i)$$

## TWIERDZENIE

Zakładamy: **Rozkład stacjonarny i Mały zbiór**. Wtedy

- (i)  $MSE = \mathbb{E}(\hat{\theta}_{T_{R(n)}} - \theta)^2 \leq \frac{\sigma_{as}^2(f)}{n} \left(1 + \frac{n_0}{n}\right)$ ,
- (ii)  $\mathbb{E} T_{R(n)} \leq n + n_0$ ,

gdzie

$$\sigma_{as}^2(f) = \frac{1}{\mathbb{E} T_1} \mathbb{E} \left[ \sum_{i=0}^{T_1-1} (f(X_i) - \theta) \right]^2, \quad n_0 = \frac{\mathbb{E} T_1^2}{\mathbb{E} T_1} - 1.$$

# Błąd średniokwadratowy

Całka i jej estymator MCMC:

$$\theta = \pi(f) = \int_{\mathcal{X}} f(x)\pi(x)dx, \quad \hat{\theta}_{T_{R(n)}} = \frac{1}{T_{R(n)}} \sum_{i=0}^{T_{R(n)}-1} f(X_i)$$

## TWIERDZENIE

Zakładamy: **Rozkład stacjonarny i Mały zbiór**. Wtedy

- (i)  $MSE = \mathbb{E}(\hat{\theta}_{T_{R(n)}} - \theta)^2 \leq \frac{\sigma_{as}^2(f)}{n} \left(1 + \frac{n_0}{n}\right),$
- (ii)  $\mathbb{E} T_{R(n)} \leq n + n_0,$

gdzie

$$\sigma_{as}^2(f) = \frac{1}{\mathbb{E} T_1} \mathbb{E} \left[ \sum_{i=0}^{T_1-1} (f(X_i) - \theta) \right]^2, \quad n_0 = \frac{\mathbb{E} T_1^2}{\mathbb{E} T_1} - 1.$$

# Błąd średniokwadratowy

## Uwaga

- *Nieasymptotyczne oszacowanie z „asymptotycznie poprawnym wyrazem wiodącym”:*

$$MSE = \mathbb{E}(\hat{\theta}_{T_{R(n)}} - \theta)^2 \leq \frac{\sigma_{\text{as}}^2(f)}{n} \left(1 + \frac{n_0}{n}\right),$$

bo

$$\sqrt{n}(\hat{\theta}_{T_{R(n)}} - \theta) \rightarrow \mathcal{N}(0, \sigma_{\text{as}}^2(f)) \quad (n \rightarrow \infty).$$

- *“Niemal deterministyczna” długość symulacji:*

$$\mathbb{E} T_{R(n)} \leq n + n_0.$$

# Błąd średniokwadratowy

## Uwaga

- *Nieasymptotyczne oszacowanie z „asymptotycznie poprawnym wyrazem wiodącym”:*

$$MSE = \mathbb{E}(\hat{\theta}_{T_{R(n)}} - \theta)^2 \leq \frac{\sigma_{\text{as}}^2(f)}{n} \left(1 + \frac{n_0}{n}\right),$$

bo

$$\sqrt{n}(\hat{\theta}_{T_{R(n)}} - \theta) \rightarrow \mathcal{N}(0, \sigma_{\text{as}}^2(f)) \quad (n \rightarrow \infty).$$

- *“Niemal deterministyczna” długość symulacji:*

$$\mathbb{E} T_{R(n)} \leq n + n_0.$$



# Błąd średniokwadratowy

## Uwaga

- *Nieasymptotyczne oszacowanie z „asymptotycznie poprawnym wyrazem wiodącym”:*

$$MSE = \mathbb{E}(\hat{\theta}_{T_{R(n)}} - \theta)^2 \leq \frac{\sigma_{\text{as}}^2(f)}{n} \left(1 + \frac{n_0}{n}\right),$$

bo

$$\sqrt{n}(\hat{\theta}_{T_{R(n)}} - \theta) \rightarrow \mathcal{N}(0, \sigma_{\text{as}}^2(f)) \quad (n \rightarrow \infty).$$

- *“Niemal deterministyczna” długość symulacji:*

$$\mathbb{E} T_{R(n)} \leq n + n_0.$$

# Warunek dryfu do małego zbioru

Dryf do małego zbioru  $J$

## ZAŁOŻENIE

- **Dryf.** Istnieje funkcja  $V : \mathcal{X} \rightarrow [1, \infty[$ , stałe  $\lambda < 1$  i  $K < \infty$  takie, że

$$PV^2(x) := \int_{\mathcal{X}} P(x, dy) V^2(y) \leq \begin{cases} \lambda^2 V^2(x) & \text{dla } x \notin J, \\ K^2 & \text{dla } x \in J. \end{cases}$$

## Uwaga

Notacja  $V^2$ ,  $\lambda^2$ ,  $K^2$  – upraszcza wzory.

# Jawne oszacowania przy warunku dryfu

Oszacowania na stałe  $\sigma_{\text{as}}^2(f)$ ,  $n_0$ .

## TWIERDZENIE

Przy warunku **Dryfu**,

$$\sigma_{\text{as}}^2(f) \leq \|\bar{f}\|_V^2 \frac{K^2(2 + \beta) - 2K(2\lambda + \beta) + 2\lambda^2 + 2\lambda\beta - \lambda^2\beta}{(1 - \lambda)^2\beta},$$

gdzie  $\|\bar{f}\|_V := \sup_x |\bar{f}(x)|/V(x) < \infty$  i  $\bar{f} := f - \theta$ ,

$$n_0 \leq \frac{2}{(1 - \lambda)\beta} \left[ K \frac{1 - \lambda(1 - \beta)}{1 - \lambda} - \beta \left( 1 + \frac{\lambda^2}{1 - \lambda} \right) - \lambda \right].$$

# Problem

Czy można otrzymać **praktycznie użyteczne** i **dające się obliczyć** oszacowania na  $\sigma_{\text{as}}^2(f)$  ?