

## WSPÓŁCZYNNIKI ZBIEŻNOŚCI ALGORYTMÓW GIBBSA

*Paweł Kopciuszewski*

*Instytut Matematyki i Informatyki, Politechnika Częstochowska*

**Streszczenie.** Praca poświęcona jest badaniu łańcuchów Markowa generowanych różnymi modyfikacjami metody Gibbsa. W szczególności obliczane są współczynniki zbieżności dla trzech najbardziej znanych w literaturze modyfikacji algorytmu Gibbsa dla pewnych szczególnych przestrzeni stanów.

### 1. Modyfikacje metody losowania Gibbsa

Metoda losowania Gibbsa umożliwia generowanie próbki losowej z gęstości  $\pi(x)$  o nośniku  $S \subset R^n$  na podstawie gęstości warunkowych  $\pi(x_i|x_j, j \neq i)$ ,  $i = 1, \dots, n$ , gdzie  $x = (x_1, \dots, x_n) \in S$ . Łańcuch Markowa wygenerowany za pomocą tej metody nazywamy łańcuchem Gibbsa. Aby wygenerować próbkę losową z gęstości  $\pi$ , stosujemy następujący algorytm:

Najpierw wybieramy stan początkowy  $x^{(0)} = (x_1^{(0)}, \dots, x_n^{(0)}) \in S$  w łańcuchu Markowa  $\{X^{(k)}\}$ . W kroku algorytmu  $k = 1, 2, \dots$ , generujemy stan  $x^{(k)} = (x_1^{(k)}, \dots, x_n^{(k)}) \in S$  w następujący sposób:

$$\begin{aligned} x_1^{(k)} & \text{ jest realizacją z } \pi(x_1|x_2^{(k-1)}, \dots, x_n^{(k-1)}) \\ x_2^{(k)} & \text{ jest realizacją z } \pi(x_2|x_1^{(k)}, x_3^{(k-1)}, \dots, x_n^{(k-1)}) \\ & \vdots \\ x_{n-1}^{(k)} & \text{ jest realizacją z } \pi(x_{n-1}|x_1^{(k)}, \dots, x_{n-2}^{(k)}, x_n^{(k-1)}) \\ x_n^{(k)} & \text{ jest realizacją z } \pi(x_n|x_1^{(k)}, \dots, x_{n-1}^{(k)}) \end{aligned} \tag{1}$$

Gęstość prawdopodobieństwa przejścia  $h(x, y)$  ze stanu  $x = (x_1, \dots, x_n) \in S$  do stanu  $y = (y_1, \dots, y_n) \in S$  można wyrazić za pomocą wzoru

$$h(x, y) = \prod_{i=1}^n \pi(y_i|y_1, \dots, y_{i-1}, x_{i+1}, \dots, x_n) \tag{2}$$

Każdy z powyższych  $n!$  wariantów metody Gibbsa nazywany jest algorytmem deterministycznego uaktualniania łańcucha Gibbsa (determining updating Gibbs sampler), w skrócie DUGS.

Przypuśćmy, że  $k$ -ty krok w algorytmie generowania łańcucha Markowa  $\{X^{(k)}\}$  przebiega według następującego schematu: Losujemy najpierw jedną z liczb ze zbioru  $\{1, \dots, n\}$  z prawdopodobieństwem  $p_i$ ,  $i = 1, \dots, n$ . Wylosowaną liczbę oznaczmy przez  $i_0$ . Następnie generujemy wartość  $x_{i_0}^{(k)}$  z gęstości  $\pi(x_{i_0} | x_j^{(k-1)}, j \neq i_0)$ . W  $k$ -tym kroku otrzymamy stan łańcucha  $x^{(k)} = (x_1^{(k-1)}, \dots, x_{i_0}^{(k)}, \dots, x_n^{(k-1)})$ . Gęstość prawdopodobieństwa przejścia ze stanu  $x^{(k-1)}$  do stanu  $x^{(k)}$  jest równa

$$h(x^{(k-1)}, x^{(k)}) = p_{i_0} \pi(x_{i_0}^{(k)} | x_j^{(k-1)}, j \neq i_0) \quad (3)$$

Metodę tę nazywa się algorytmem strategii losowej dla łańcucha Gibbsa (random sweep strategy Gibbs sampler), w skrócie RSGS.

Opiszemy teraz trzecią modyfikację metody losowania Gibbsa.

Niech  $p_{z_1, \dots, z_n}$  będzie prawdopodobieństwem określonym na zbiorze  $\mathcal{Z} = \{(z_1, \dots, z_n) : z_i \in \{1, \dots, n\}, i = 1, \dots, n\}$  wszystkich permutacji zbioru  $\{1, \dots, n\}$ . Wówczas  $k$ -ty krok w algorytmie przebiega według następującego schematu: Ze zbioru  $\mathcal{Z}$  losujemy permutację  $(z_1, \dots, z_n)$  z prawdopodobieństwem  $p_{z_1, \dots, z_n}$ . Wartości  $x_{z_i}^{(k)}$ ,  $i = 1, \dots, n$ , w  $k$ -tym kroku generować będziemy w porządku  $x_{z_1}^{(k)}, \dots, x_{z_n}^{(k)}$ . Gęstość prawdopodobieństwa przejścia ze stanu  $x \in S$  do stanu  $y \in S$  przy ustalonej permutacji  $(z_1, \dots, z_n)$  wynosi

$$h(x, y | (z_1, \dots, z_n)) = \prod_{i=1}^n \pi(y_{z_i} | y_{z_1}, \dots, y_{z_{i-1}}, x_{z_{i+1}}, \dots, x_{z_n}) \quad (4)$$

Gęstość prawdopodobieństwa przejścia ze stanu  $x$  do stanu  $y$  wyraża się wzorem

$$h(x, y) = \sum_{\{(z_1, \dots, z_n) \in \mathcal{Z}\}} p_{z_1, \dots, z_n} \prod_{i=1}^n \pi(y_{z_i} | y_{z_1}, \dots, y_{z_{i-1}}, x_{z_{i+1}}, \dots, x_{z_n}) \quad (5)$$

Jeśli nośnik  $S$  gęstości  $\pi$  jest zbiorem skończonym, to macierz prawdopodobieństw przejścia  $P$  dla łańcucha Markowa wygenerowanego tą metodą może być zapisana w postaci

$$P = \sum_{\{(z_1, \dots, z_n) \in \mathcal{Z}\}} p_{z_1, \dots, z_n} R_{z_1, \dots, z_n} \quad (6)$$

gdzie  $R_{z_1, \dots, z_n}$  jest macierzą prawdopodobieństw przejścia dla łańcucha wygenerowanego metodą DUGS, określoną przez permutację  $(z_1, \dots, z_n)$ .

Metodę opisaną powyżej nazywamy algorytmem losowania permutacji dla łańcucha Gibbsa (random permutation Gibbs sampler), w skrócie RPGS.

## 2. Współczynniki zbieżności

Niech  $S$  będzie zbiorem  $N$ -elementowym. Niech  $\{X^{(k)}\}$  będzie łańcuchem Markowa z przestrzenią stanów  $S$  oraz macierzą prawdopodobieństw przejścia  $H$ .

Zajmiemy się obecnie oceną współczynników zbieżności  $\lambda(H)$  dla łańcuchów Markowa  $\{X^{(k)}\}$ , generowanych za pomocą modyfikacji metody losowania Gibbsa.

**Twierdzenie 1** *Łańcuchy Markowa  $\{X^{(k)}\}$  z niezmienniczym prawdopodobieństwem  $\pi$  oraz skończoną przestrzenią stanów  $S \subset \mathcal{R}^2$ , generowane metodami DUGS, posiadają ten sam współczynnik zbieżności.*

Dowód. Bez straty ogólności możemy założyć, że  $S = \{(u_i, v_j) : i, j = 1, 2, \dots, s\}$ . Liczba wszystkich stanów jest wtedy równa  $N = s^2$ . Aby wygenerować łańcuch Markowa z niezmienniczym prawdopodobieństwem  $\pi$ , można zastosować dwa różne algorytmy DUGS. Dla pierwszego z nich prawdopodobieństwo przejścia  $h(x, y)$  z punktu  $x = (u_i, v_j)$ ,  $i, j = 1, \dots, s$ , do punktu  $y = (u_m, v_l)$ ,  $m, l = 1, \dots, s$ , spełnia warunek

$$h(x, y) = \pi(v_l | u_m) \pi(u_m | v_j) \quad (7)$$

Dla drugiego algorytmu prawdopodobieństwo przejścia spełnia warunek

$$h(x, y) = \pi(u_m | v_l) \pi(v_l | u_i) \quad (8)$$

Niech  $D_1, D_2$  będą macierzami prawdopodobieństw przejścia dla łańcuchów Markowa generowanych odpowiednio pierwszym oraz drugim z algorytmów. Niech  $T_m$ ,  $m = 1, \dots, s$ , będą macierzami o elementach  $t_{i,j}^{(m)}$ , spełniających warunki:

$$t_{i,j}^{(m)} = \pi(y_j | x_m), \quad i, j = 1, \dots, s$$

Niech  $U_m$ ,  $m = 1, \dots, s$ , będą macierzami o elementach  $u_{i,j}^{(m)}$ ,  $i, j = 1, \dots, s$ , spełniających warunki:

$$u_{i,j}^{(m)} = \begin{cases} \pi(x_m|y_i) & \text{dla } j = i \\ 0 & \text{dla } j \neq i \end{cases}$$

Niech macierz  $T$  będzie zdefiniowana następująco:

$$T = \begin{pmatrix} T_1 & 0 & \dots & 0 \\ 0 & T_2 & \dots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \dots & T_s \end{pmatrix} \quad (9)$$

Niech macierz  $U$  będzie zdefiniowana następująco:

$$U = \begin{pmatrix} U_1 & U_2 & \dots & U_s \\ U_1 & U_2 & \dots & U_s \\ \vdots & \vdots & & \vdots \\ U_1 & U_2 & \dots & U_s \end{pmatrix} \quad (10)$$

Wtedy macierze prawdopodobieństw przejścia  $D_1$  oraz  $D_2$  spełniają warunek:

$$\begin{aligned} D_1 &= UT \\ D_2 &= TU \end{aligned} \quad (11)$$

Wartości własne macierzy  $UT$  oraz  $TU$  są identyczne. Zatem współczynniki zbieżności dla tych dwóch algorytmów są sobie równe.

$$\lambda(D_1) = \lambda(D_2) \quad (12)$$

W trzech poniższych przykładach obliczę współczynniki zbieżności dla łańcuchów Markowa, generowanych metodami DUGS, RSGS oraz RPGS, dla szczególnego przypadku przestrzeni stanów  $S = \{(u_i, v_j), i, j = 1, 2\}$ .

Przykład 1 jest ilustracją twierdzenia 1. W przykładzie 2, spośród klasy algorytmów RSGS, wyznaczę jeden algorytm RSGS, dla którego łańcuch Markowa jest najszybciej zbieżny (posiada najmniejszy współczynnik zbieżności). W przykładzie 3 pokażę, że łańcuch Markowa, generowany za pomocą algorytmu RPGS, jest najwolniej zbieżny, gdy permutacje zbioru  $\{1, 2\}$  generuje się z jednakowym prawdopodobieństwem. Przykład ten sugeruje wybór

innego prawdopodobieństwa do generowania permutacji niż prawdopodobieństwo jednostajne.

Niech  $p_1 = \pi(u_1|v_1) > 0$ ,  $p_2 = \pi(u_1|v_2) > 0$ ,  $q_1 = \pi(v_1|u_1) > 0$ ,  $q_2 = \pi(v_1|u_2) > 0$  będą prawdopodobieństwami warunkowymi oraz  $\delta = (p_2 - p_1)(q_2 - q_1)$ .

### Przykład 1

Istnieją dwa algorytmy DUGS, za pomocą których można generować łańcuchy Markowa z przestrzenią stanów  $S$ . Niech  $D_1$  oraz  $D_2$  oznaczają macierze prawdopodobieństw przejścia dla łańcuchów Markowa generowanych za pomocą algorytmów DUGS.

Z twierdzenia 1 wynika, że łańcuchy Markowa generowane za pomocą tych algorytmów posiadają ten sam współczynnik zbieżności. W związku z tym przeanalizujemy zbieżność tylko jednego z tych dwóch algorytmów.

Z równania (2) wynika, że prawdopodobieństwo przejścia z punktu  $x = (u_i, v_j)$ ,  $i, j = 1, 2$ , do punktu  $y = (u_m, v_l)$ ,  $m, l = 1, 2$ , dla pierwszego z algorytmów DUGS spełnia następujący warunek:

$$h(x, y) = \pi(v_l|u_m)\pi(u_m|v_j)$$

Wtedy macierz prawdopodobieństw przejścia  $D_1$  może być zapisana w następującej postaci:

$$D_1 = \begin{pmatrix} p_1q_1 & p_1(1-q_1) & (1-p_1)q_2 & (1-p_1)(1-q_2) \\ p_2q_1 & p_2(1-q_1) & (1-p_2)q_2 & (1-p_2)(1-q_2) \\ p_1q_1 & p_1(1-q_1) & (1-p_1)q_2 & (1-p_1)(1-q_2) \\ p_2q_1 & p_2(1-q_1) & (1-p_2)q_2 & (1-p_2)(1-q_2) \end{pmatrix}$$

Wartości własne macierzy  $D_1$  są równe

$$\lambda_1 = \lambda_2 = 0, \lambda_3 = 1, \lambda_4 = \delta$$

Wynika stąd, że współczynnik zbieżności  $\lambda(D_1) = |\delta|$ .

Zauważmy, że im mniejsze są różnice pomiędzy prawdopodobieństwami  $p_1, p_2$  lub  $q_1, q_2$ , tym mniejszy jest współczynnik zbieżności  $|\delta|$ .

### Przykład 2

W przykładzie tym obliczę współczynniki zbieżności dla łańcuchów Markowa, generowanych za pomocą metod RSGS.

Niech prawdopodobieństwa wylosowania liczb z dwuelementowego zbioru

$\{1, 2\}$  wynoszą  $a_1$  oraz  $a_2 = 1 - a_1$ . Z równania (3) wynika, że macierz prawdopodobieństw przejścia  $R_{(a_1, a_2)}$  spełnia warunek

$$R_{(a_1, a_2)} = \begin{pmatrix} a_1 p_1 + a_2 q_1 & a_2(1 - q_1) & a_1(1 - p_1) & 0 \\ a_2 q_1 & a_2(1 - q_1) + a_1 p_2 & 0 & a_1(1 - p_2) \\ a_1 p_1 & 0 & a_2 q_2 + a_1(1 - p_1) & a_2(1 - q_2) \\ 0 & a_1 p_2 & a_2 q_2 & a_2(1 - q_2) + a_1(1 - p_2) \end{pmatrix}$$

Wartości własne macierzy  $R_{(a_1, a_2)}$  są równe

$$\lambda_1 = 0, \lambda_2 = 1, \lambda_3 = \frac{1 - \sqrt{\Delta}}{2}, \lambda_4 = \frac{1 + \sqrt{\Delta}}{2}$$

gdzie  $\Delta = 1 - 4a_1 a_2(1 - \delta)$ .

Wynika stąd, że współczynniki zbieżności dla łańcuchów Markowa wygenerowanych za pomocą metod RSGS przyjmują wartość

$$\lambda(R_{(a_1, a_2)}) = \left| \frac{1 + \sqrt{\Delta}}{2} \right| \quad (13)$$

Zauważmy, że współczynnik zbieżności  $\lambda(R_{(a_1, a_2)})$  osiąga wartość najmniejszą dla  $a_1 = \frac{1}{2}$  oraz  $a_2 = \frac{1}{2}$ . Niech  $R$  będzie macierzą prawdopodobieństw przejścia,  $R = R_{(\frac{1}{2}, \frac{1}{2})}$ . Wartości własne macierzy  $R$  są równe

$$\lambda_1 = 0, \lambda_2 = 1, \lambda_3 = \frac{1}{2} + \frac{1}{2}\sqrt{\delta}, \lambda_4 = \frac{1}{2} - \frac{1}{2}\sqrt{\delta}$$

Wynika stąd, że współczynnik zbieżności  $\lambda(R)$  wynosi

$$\lambda(R) = \begin{cases} \frac{1}{2} + \frac{1}{2}\sqrt{\delta}, & \delta \geq 0 \\ \frac{1}{2}\sqrt{1 - \delta}, & \delta < 0 \end{cases} \quad (14)$$

### Przykład 3

W przykładzie tym obliczę współczynniki zbieżności dla łańcuchów Markowa generowanych za pomocą metod RPGS. Zbiór  $\mathcal{Z}$  składa się w tym przypadku z dwóch permutacji  $(1, 2)$  oraz  $(2, 1)$ . Niech  $p$  oznacza prawdopodobieństwo wylosowania permutacji  $(1, 2)$  ze zbioru  $\mathcal{Z}$ . Wtedy  $1 - p$  oznacza prawdopodobieństwo wylosowania permutacji  $(2, 1)$ . Niech  $P_p$ ,  $0 < p < 1$ , oznacza macierz prawdopodobieństw przejścia dla łańcucha Markowa generowanego za pomocą metody RPGS. Z równania (6) wynika, że macierz  $P_p$  spełnia następujący warunek:

$$P_p = pD_1 + (1 - p)D_2$$

Wartości własne macierzy  $P_p$  są równe

$$\lambda_1 = 1, \lambda_2 = 0, \lambda_3 = \frac{\delta}{2} + \frac{1}{2}\sqrt{\delta^2 + 4\delta p(1-p)}, \lambda_4 = \frac{\delta}{2} - \frac{1}{2}\sqrt{\delta^2 + 4\delta p(1-p)}$$

Jeśli  $\delta > 0$ , to współczynnik zbieżności  $\lambda(P) = |\lambda_3|$  osiąga wartość najmniejszą dla  $p = 0$  lub  $p = 1$ . Wtedy macierz  $P_p$  równa jest macierzy  $D_1$  lub macierzy  $D_2$ , a przypadek ten rozważany już był w przykładzie 1.

Jeśli  $\delta < 0$ , to współczynnik zbieżności  $\lambda(P) = |\lambda_3|$  osiąga wartość najmniejszą dla

$$p = \frac{1}{2} + \frac{1}{2}\sqrt{1 + \delta} \quad \text{lub} \quad p = \frac{1}{2} - \frac{1}{2}\sqrt{1 + \delta} \quad (15)$$

Niech  $P$  oznacza macierz prawdopodobieństw przejścia dla  $p$  spełniającego warunek (6). Wówczas współczynnik zbieżności

$$\lambda(P) = \frac{|\delta|}{2} \quad (16)$$

W literaturze rozważa się algorytmy RPGS, dla których permutacje ze zbioru  $\mathcal{Z}$  generuje się z jednakowym prawdopodobieństwem [6]. W naszym przykładzie odpowiada to sytuacji, gdy  $p = \frac{1}{2}$ . Okazuje się jednak, że współczynnik zbieżności  $\lambda(P_p)$  osiąga wartość największą dla  $p = \frac{1}{2}$ . Zatem łańcuch Markowa, generowany za pomocą algorytmu RPGS dla  $p = \frac{1}{2}$ , jest najwolniej zbieżny.

Dokonyamy teraz porównania współczynników zbieżności  $\lambda(D_1)$  dla metody DUGS,  $\lambda(R)$  dla metody RSGS oraz  $\lambda(P)$  dla metody RPGS. Z obliczeń wynika, że

$$\lambda(P) < \lambda(D_1) \quad \text{oraz} \quad \lambda(P) < \lambda(R) \quad (17)$$

oraz

$$\lambda(D_1) > \lambda(R) \Leftrightarrow -1 < \delta < \frac{-1 - \sqrt{17}}{8} \quad (18)$$

Współczynnik zbieżności  $\lambda(P)$  jest najmniejszym współczynnikiem z wszystkich analizowanych w powyższych przykładach. Zatem łańcuch Markowa, generowany za pomocą algorytmu RPGS z macierzą prawdopodobieństw przejścia  $P$ , jest najszybciej zbieżny.

## Literatura

- [1] Amit Y., Convergence properties of the Gibbs sampler for perturbations Gaussians, *Ann. Statist.* 1996, 24, 122-140.
- [2] Besag J.E., Spatial interaction and the statistical analysis of lattice systems (with discussion), *J. Roy. Statist. Soc. Ser. B* 1974, 36, 192-236.
- [3] Brémaud P., *Markov Chains*, Springer-Verlag, New York 1999.
- [4] Kopciuszewski P., The class of joint densities uniquely determined by conditionals used in Gibbs sampling, *Demonstratio Math.* 1999, 32, 847-860.
- [5] Kopciuszewski P., Convergence of Hastings-Metropolis algorithm, *Proc. of the Third International Conference on Parallel Processing and Applied Mathematics*, Kazimierz Dolny 1999, 543-549.
- [6] Roberts G.O., Sahu S.K., Updating schemes, correlation structure, blocking and parameterization for the Gibbs sampler, *J. Roy. Statist. Soc. Ser. B* 1997, 59, 291-317.
- [7] Tierney L., Markov chains for exploring posterior distributions, *Ann. Statist.* 1994, 22, 1701-1762.
- [8] Zellner A., Min C.K., Gibbs sampler convergence criteria, *J. Amer. Statist. Assoc.* 1995, 90, 921-927.