

Bayesiaans leren

Les 2: Markov Chain Monte Carlo

Joris Bierkens

Vakantiecursus

augustus 2019

Samenvatting en vooruitblik

- Veel statistische problemen kunnen we opvatten in een Bayesiaanse context

$$\pi(\theta) \propto \pi_0(\theta) \prod_{i=1}^n p(y_i | \theta), \quad \theta \in \mathcal{S}.$$

Samenvatting en vooruitblik

- Veel statistische problemen kunnen we opvatten in een Bayesiaanse context

$$\pi(\theta) \propto \pi_0(\theta) \prod_{i=1}^n p(y_i | \theta), \quad \theta \in \mathcal{S}.$$

- Bij predictie hebben we een model $p_{\text{model}}(y | \theta, x)$ en krijgen we de Bayesiaanse predictor

$$p(\widehat{y} | x) = \int_{\mathcal{S}} \pi(\theta) p_{\text{model}}(y | \theta, x) d\theta,$$

Samenvatting en vooruitblik

- Veel statistische problemen kunnen we opvatten in een Bayesiaanse context

$$\pi(\theta) \propto \pi_0(\theta) \prod_{i=1}^n p(y_i | \theta), \quad \theta \in \mathcal{S}.$$

- Bij predictie hebben we een model $p_{\text{model}}(y | \theta, x)$ en krijgen we de Bayesiaanse predictor

$$p(\widehat{y} | x) = \int_{\mathcal{S}} \pi(\theta) p_{\text{model}}(y | \theta, x) d\theta,$$

waarbij

$$\pi(\theta) \propto \pi_0(\theta) \prod_{i=1}^n p_{\text{model}}(y_i | \theta, x_i).$$

Samenvatting en vooruitblik

- Veel statistische problemen kunnen we opvatten in een Bayesiaanse context

$$\pi(\theta) \propto \pi_0(\theta) \prod_{i=1}^n p(y_i | \theta), \quad \theta \in \mathcal{S}.$$

- Bij predictie hebben we een model $p_{\text{model}}(y | \theta, x)$ en krijgen we de Bayesiaanse predictor

$$p(\widehat{y} | x) = \int_{\mathcal{S}} \pi(\theta) p_{\text{model}}(y | \theta, x) d\theta,$$

waarbij

$$\pi(\theta) \propto \pi_0(\theta) \prod_{i=1}^n p_{\text{model}}(y_i | \theta, x_i).$$

- Uitdaging: Hoe kunnen we de integraal over $\pi(\theta)$ berekenen?

Samenvatting en vooruitblik

- Veel statistische problemen kunnen we opvatten in een Bayesiaanse context

$$\pi(\theta) \propto \pi_0(\theta) \prod_{i=1}^n p(y_i | \theta), \quad \theta \in \mathcal{S}.$$

- Bij predictie hebben we een model $p_{\text{model}}(y | \theta, x)$ en krijgen we de Bayesiaanse predictor

$$p(\widehat{y} | x) = \int_{\mathcal{S}} \pi(\theta) p_{\text{model}}(y | \theta, x) d\theta,$$

waarbij

$$\pi(\theta) \propto \pi_0(\theta) \prod_{i=1}^n p_{\text{model}}(y_i | \theta, x_i).$$

- Uitdaging: Hoe kunnen we de integraal over $\pi(\theta)$ berekenen?
- Merk op: we kennen ook de normaliseringsconstante $\pi(\theta)$ niet zonder een integraal uit te rekenen!

Integralen uitrekenen

- We willen een integraal van de vorm $\pi(g) := \int_{\mathcal{S}} g(x)\pi(x) dx$ uitrekenen, waarbij we de normalisatieconstante van π niet kennen.

Integralen uitrekenen


- We willen een integraal van de vorm $\pi(g) := \int_{\mathcal{S}} g(x)\pi(x) dx$ uitrekenen, waarbij we de normalisatieconstante van π niet kennen.
- Mogelijke aanpakken:
 - Numerieke integratie: aantal gridpunten schaalte helaas **exponentieel in dimensie**.

Integralen uitrekenen

- We willen een integraal van de vorm $\pi(g) := \int_S g(x)\pi(x) dx$ uitrekenen, waarbij we de normalisatieconstante van π niet kennen.
- Mogelijke aanpakken:
 - Numerieke integratie: aantal gridpunten schaalst helaas **exponentieel in dimensie**.
 - Monte Carlo: als we X_1, X_2, \dots, X_d **onafhankelijk** kunnen trekken uit de verdeling $\pi(x)$ kunnen we de **wet van de grote aantallen** gebruiken:


$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n g(X_i) = \pi(g).$$

Intermezzo: onafhankelijk trekken uit univariate verdeling




Kansdichtheidsfunctie van de standardnormale verdeling

Intermezzo: onafhankelijk trekken uit univariate verdeling




Cumulative verdelingsfunctie van de standardnormale verdeling


Intermezzo: onafhankelijk trekken uit univariate verdeling




Intermezzo: onafhankelijk trekken uit univariate verdeling




Intermezzo: onafhankelijk trekken uit univariate verdeling




Intermezzo: onafhankelijk trekken uit univariate verdeling



Intermezzo: onafhankelijk trekken uit univariate verdeling



Intermezzo: onafhankelijk trekken uit univariate verdeling



Deze methode heet de **inverse CDF techniek**.

Intermezzo: onafhankelijk trekken met 'rejection sampling'

Gooien van een dobbelsteen is verdeeld volgens uniforme verdeling over $\{1, 2, 3, 4, 5, 6\}$.

Hoe kunnen we nu trekken uit een uniforme verdeling over $\{1, 2, 3, 4, 5\}$?

Intermezzo: onafhankelijk trekken met 'rejection sampling'

Gooien van een dobbelsteen is verdeeld volgens uniforme verdeling over $\{1, 2, 3, 4, 5, 6\}$.

Hoe kunnen we nu trekken uit een uniforme verdeling over $\{1, 2, 3, 4, 5\}$?

- 1 Gooi de dobbelsteen met uitkomst X
- 2 Als $X = 6$, herhaal vanaf stap 1; anders retourneer X .

Intermezzo: onafhankelijk trekken met 'rejection sampling'

Gooien van een dobbelsteen is verdeeld volgens uniforme verdeling over $\{1, 2, 3, 4, 5, 6\}$.

Hoe kunnen we nu trekken uit een uniforme verdeling over $\{1, 2, 3, 4, 5\}$?

- 1 Gooi de dobbelsteen met uitkomst X
- 2 Als $X = 6$, herhaal vanaf stap 1; anders retourneer X .

Rejection sampling

- Doel: trekken van π (niet genormaliseerd).
- Middel: kansverdeling $\tilde{\pi}$ zodat $\pi(x) \leq c\tilde{\pi}(x)$ voor alle x .

Intermezzo: onafhankelijk trekken met 'rejection sampling'

Gooien van een dobbelsteen is verdeeld volgens uniforme verdeling over $\{1, 2, 3, 4, 5, 6\}$.

Hoe kunnen we nu trekken uit een uniforme verdeling over $\{1, 2, 3, 4, 5\}$?

- 1 Gooi de dobbelsteen met uitkomst X
- 2 Als $X = 6$, herhaal vanaf stap 1; anders retourneer X .

Rejection sampling

- Doel: trekken van π (niet genormaliseerd).
 - Middel: kansverdeling $\tilde{\pi}$ zodat $\pi(x) \leq c\tilde{\pi}(x)$ voor alle x .
- 1 Trek X uit $\tilde{\pi}$.
 - 2 Met kans $1 - \pi(X)/c\tilde{\pi}(X)$: herhaal vanaf 1, anders retourneer X .

Intermezzo: onafhankelijk trekken met 'rejection sampling'

Gooien van een dobbelsteen is verdeeld volgens uniforme verdeling over $\{1, 2, 3, 4, 5, 6\}$.

Hoe kunnen we nu trekken uit een uniforme verdeling over $\{1, 2, 3, 4, 5\}$?

- 1 Gooi de dobbelsteen met uitkomst X
- 2 Als $X = 6$, herhaal vanaf stap 1; anders retourneer X .

Rejection sampling

- Doel: trekken van π (niet genormaliseerd).
 - Middel: kansverdeling $\tilde{\pi}$ zodat $\pi(x) \leq c\tilde{\pi}(x)$ voor alle x .
- 1 Trek X uit $\tilde{\pi}$.
 - 2 Met kans $1 - \pi(X)/c\tilde{\pi}(X)$: herhaal vanaf 1, anders retourneer X .

Nadeel: in typische situaties wordt de acceptatiekans exponentieel klein.

Integralen uitrekenen

- We willen een integraal van de vorm $\pi(g) := \int_{\mathcal{S}} g(x)\pi(x) dx$ uitrekenen, waarbij we de normalisatieconstante van π niet kennen.
- Mogelijke aanpakken:
 - Numerieke integratie: aantal gridpunten schaalte helaas **exponentieel in dimensie**.
 - Monte Carlo: als we X_1, X_2, \dots, X_d **onafhankelijk** kunnen trekken uit de verdeling $\pi(x)$ kunnen we de **wet van de grote aantallen** gebruiken:

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n g(X_i) = \pi(g).$$

Integralen uitrekenen

- We willen een integraal van de vorm $\pi(g) := \int_{\mathcal{S}} g(x)\pi(x) dx$ uitrekenen, waarbij we de normalisatieconstante van π niet kennen.
- Mogelijke aanpakken:
 - Numerieke integratie: aantal gridpunten schaalst helaas **exponentieel in dimensie**.
 - Monte Carlo: als we X_1, X_2, \dots, X_d **onafhankelijk** kunnen trekken uit de verdeling $\pi(x)$ kunnen we de **wet van de grote aantallen** gebruiken:


$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n g(X_i) = \pi(g).$$

Onafhankelijk trekken uit een verdeling kan niet zomaar efficiënt gedaan worden.

- Markov Chain Monte Carlo: het woord 'onafhankelijk' hierboven blijkt niet essentieel te zijn. We gaan een **Markov keten** bouwen met de correcte verdeling.


Markov-ketens

Markov-keten



Markov-ketens

Markov-keten



Transitiematrix

$$P = \begin{pmatrix} p^2 & (1-p)^2 & p(1-p) & p(1-p) \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \\ q^2 & q(1-q) & q(1-q) & (1-q)^2 \end{pmatrix}$$

$P(i,j)$ is de kans om van i naar j te springen.

Stationaire verdeling

$$P = \begin{pmatrix} p^2 & (1-p)^2 & p(1-p) & p(1-p) \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \\ q^2 & q(1-q) & q(1-q) & (1-q)^2 \end{pmatrix}$$

Stationaire verdeling

$$P = \begin{pmatrix} p^2 & (1-p)^2 & p(1-p) & p(1-p) \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \\ q^2 & q(1-q) & q(1-q) & (1-q)^2 \end{pmatrix}$$

Stel we beginnen vanuit een kansverdeling π en maken een willekeurige stap volgens P .

Stationaire verdeling

$$P = \begin{pmatrix} p^2 & (1-p)^2 & p(1-p) & p(1-p) \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \\ q^2 & q(1-q) & q(1-q) & (1-q)^2 \end{pmatrix}$$

Stel we beginnen vanuit een kansverdeling π en maken een willekeurige stap volgens P . De kans dat we in toestand j zijn na één stap is $\sum_{i=1}^4 \pi(i)P(i,j)$.

Stationaire verdeling

π is een **stationaire verdeling** voor P als de verdeling na een stap vanuit π weer gelijk is aan π .

Stationaire verdeling

$$P = \begin{pmatrix} p^2 & (1-p)^2 & p(1-p) & p(1-p) \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \\ q^2 & q(1-q) & q(1-q) & (1-q)^2 \end{pmatrix}$$

Stel we beginnen vanuit een kansverdeling π en maken een willekeurige stap volgens P . De kans dat we in toestand j zijn na één stap is $\sum_{i=1}^4 \pi(i)P(i,j)$.

Stationaire verdeling

π is een **stationaire verdeling** voor P als de verdeling na een stap vanuit π weer gelijk is aan π .

$$\sum_i \pi(i)P(i,j) = \pi(j) \quad \text{voor alle } j.$$

Stationaire verdeling

$$P = \begin{pmatrix} p^2 & (1-p)^2 & p(1-p) & p(1-p) \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \\ q^2 & q(1-q) & q(1-q) & (1-q)^2 \end{pmatrix}$$

Stel we beginnen vanuit een kansverdeling π en maken een willekeurige stap volgens P . De kans dat we in toestand j zijn na één stap is $\sum_{i=1}^4 \pi(i)P(i,j)$.

Stationaire verdeling

π is een **stationaire verdeling** voor P als de verdeling na een stap vanuit π weer gelijk is aan π .

$$\sum_i \pi(i)P(i,j) = \pi(j) \quad \text{voor alle } j.$$

Zij X_n de toestand van de Markov keten na n transitities.

Convergentie

Onder milde condities (irreducibiliteit en aperiodiciteit), $X_n \rightarrow \pi$ in verdeling.

Stationaire verdeling

$$P = \begin{pmatrix} p^2 & (1-p)^2 & p(1-p) & p(1-p) \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \\ q^2 & q(1-q) & q(1-q) & (1-q)^2 \end{pmatrix}$$

Stel we beginnen vanuit een kansverdeling π en maken een willekeurige stap volgens P . De kans dat we in toestand j zijn na één stap is $\sum_{i=1}^4 \pi(i)P(i,j)$.

Stationaire verdeling

π is een **stationaire verdeling** voor P als de verdeling na een stap vanuit π weer gelijk is aan π .

$$\sum_i \pi(i)P(i,j) = \pi(j) \quad \text{voor alle } j.$$

Zij X_n de toestand van de Markov keten na n transities.

Convergentie

Onder milde condities (irreducibiliteit en aperiodiciteit), $X_n \rightarrow \pi$ in verdeling. Dus we kunnen (bij benadering) trekken van π !

De uitdaging

- Voor een gegeven Markov transitie matrix P zijn we in staat de stationaire verdeling te berekenen

$$\sum_{i=1} \pi(i)P(i,j) = \pi(j) \quad \text{voor alle } j.$$

- Kunnen we dit ook omdraaien: gegeven een verdeling, wat is de bijbehorende Markov keten?
- Het blijkt dat er **heel** veel manieren zijn om Markov ketens te bouwen.

Markov Chain Monte Carlo algoritmen

Er zijn twee belangrijke generieke algoritmen:

- Metropolis-Hastings
- Gibbs sampling

Metropolis-Hastings

(Metropolis et al, 1953, Hastings et al, 1970)

Metropolis-Hastings algoritme

Vanuit een toestand X_i :

- 1 Stel een nieuwe toestand Y voor volgens 'zomaar' een Markov transitie matrix Q
- 2 Bereken de **acceptatiekans**

$$\alpha(X_i, Y) = \min \left(1, \frac{\pi(Y)Q(Y, X_0)}{\pi(X_i)Q(X_i, Y)} \right).$$

- 3 Definieer

$$X_{i+1} := \begin{cases} Y & \text{(accepteer)} & \text{met kans } \alpha(X_i, Y), \\ X_i & \text{(verwerp)} & \text{met kans } 1 - \alpha(X_i, Y). \end{cases}$$

- Q heet een **proposal** transitie matrix.
- Demo: <https://chi-feng.github.io/mcmc-demo/>

Gibbs sampling

(Glauber, 1963, Geman & Geman, 1984)

- Voor Gibbs sampling is een productstructuur vereist:

$$\mathcal{S} = \mathcal{S}_1 \times \cdots \times \mathcal{S}_n.$$

Gibbs sampling

(Glauber, 1963, Geman & Geman, 1984)

- Voor Gibbs sampling is een productstructuur vereist:
 $\mathcal{S} = \mathcal{S}_1 \times \cdots \times \mathcal{S}_n$.
- Bovendien eisen we dat we kunnen trekken uit de conditionele verdelingen

$$\pi(x^j \mid x^1, \dots, x^{j-1}, x^{j+1}, \dots, x^n).$$

Gibbs sampling

(Glauber, 1963, Geman & Geman, 1984)

- Voor Gibbs sampling is een productstructuur vereist:
 $\mathcal{S} = \mathcal{S}_1 \times \cdots \times \mathcal{S}_n$.
- Bovendien eisen we dat we kunnen trekken uit de conditionele verdelingen

$$\pi(x^j \mid x^1, \dots, x^{j-1}, x^{j+1}, \dots, x^n).$$

- Een iteratie van het Gibbs sampling algoritme vanuit $\mathbf{X}_i = (X_i^1, \dots, X_i^n) \in \mathcal{S}$ is als volgt:

1 Kies willekeurig een component $j \in \{1, \dots, n\}$

2 Definieer

$$X_{i+1}^k = X_i^k \quad \text{voor } k \neq j,$$

en trek

$$X_{i+1}^j \sim \pi(\cdot \mid X_i^1, \dots, X_i^{j-1}, X_i^j, \dots, X_i^n).$$

Samenvatting

We hebben kennisgemaakt met:

- **Bayesiaanse statistiek** als een heel algemeen conceptueel raamwerk voor statistiek
- Een manier om **voorspellingsmethoden** zoals **neurale netwerken** op een Bayesiaanse manier te interpreteren
- Numerieke methoden (**MCMC**) om berekeningen met Bayesiaanse statistiek uit te kunnen voeren.