

Apprentissage automatique

Méthodes d'échantillonnage - motivation

ÉCHANTILLONNAGE

Sujets: échantillonnage


- La plupart des algorithmes d'apprentissage vus sont basés sur un modèle probabiliste
 - un modèle probabiliste exprime comment on suppose que nos données ont été générées
- Comment simule-t-on ce processus de génération ?
 - on utilise un algorithme d'**échantillonnage** tel que :

probabilité de générer une donnée $=$ probabilité assignée par le modèle


ÉCHANTILLONNAGE

Sujets: visualisation

- Pourquoi échantillonner ?
 - pour visualiser ce qui a été appris



Ensemble d'entraînement



Mélange de produits
de Bernoulli

Salakhutdinov et Murray, 2008

ÉCHANTILLONNAGE

Sujets: estimation d'espérance, estimation Monte Carlo

- Pourquoi échantillonner ?
 - pour estimer une espérance

$$\mathbb{E}[f] = \int f(\mathbf{z})p(\mathbf{z}) \, d\mathbf{z}$$


ÉCHANTILLONNAGE

Sujets: estimation d'espérance, estimation Monte Carlo

- Pourquoi échantillonner ?

- pour estimer une espérance

$$\mathbb{E}[f] = \int f(\mathbf{z})p(\mathbf{z}) \, d\mathbf{z} \approx \frac{1}{L} \sum_{l=1}^L f(\mathbf{z}^{(l)})$$

$\mathbf{z}^{(l)}$ échantillonnés de $p(\mathbf{z})$ 

- Un tel calcul d'une espérance ainsi est appelé une **estimation Monte Carlo**

ÉCHANTILLONNAGE

Sujets: estimation de la loi prédictive a posteriori

- Pourquoi échantillonner ?
 - pour estimer la loi prédictive a posteriori

$$p(t|\mathbf{t}, \alpha, \beta) = \int p(t|\mathbf{w}, \beta) p(\mathbf{w}|\mathbf{t}, \alpha, \beta) d\mathbf{w}$$

ÉCHANTILLONNAGE


Sujets: estimation de la loi prédictive a posteriori

- Pourquoi échantillonner ?
 - pour estimer la loi prédictive a posteriori

$$p(t|\mathbf{t}, \alpha, \beta) = \int p(t|\mathbf{w}, \beta) p(\mathbf{w}|\mathbf{t}, \alpha, \beta) d\mathbf{w}$$

$$\approx \frac{1}{L} \sum_{l=1}^L p(t|\mathbf{w}^{(l)}, \beta)$$

$\mathbf{w}^{(l)}$ échantillonnés de $p(\mathbf{w}|\mathbf{t}, \alpha, \beta)$



ÉCHANTILLONNAGE

Sujets: estimation de la loi prédictive a posteriori

- Pourquoi échantillonner ?
 - pour approximer l'étape M de l'algorithme EM

$$Q(\boldsymbol{\theta}, \boldsymbol{\theta}^{\text{old}}) = \int p(\mathbf{Z}|\mathbf{X}, \boldsymbol{\theta}^{\text{old}}) \ln p(\mathbf{Z}, \mathbf{X}|\boldsymbol{\theta}) d\mathbf{Z}$$

ÉCHANTILLONNAGE


Sujets: estimation de la loi prédictive a posteriori

- Pourquoi échantillonner ?
 - pour approximer l'étape M de l'algorithme EM

$$Q(\boldsymbol{\theta}, \boldsymbol{\theta}^{\text{old}}) = \int p(\mathbf{Z}|\mathbf{X}, \boldsymbol{\theta}^{\text{old}}) \ln p(\mathbf{Z}, \mathbf{X}|\boldsymbol{\theta}) d\mathbf{Z}$$

$$\simeq \frac{1}{L} \sum_{l=1}^L \ln p(\mathbf{Z}^{(l)}, \mathbf{X}|\boldsymbol{\theta})$$

$\mathbf{Z}^{(l)}$ échantillonnés de $p(\mathbf{Z}|\mathbf{X}, \boldsymbol{\theta}^{\text{old}})$



Apprentissage automatique

Méthodes d'échantillonnage - variable aléatoire discrète scalaire

ÉCHANTILLONNAGE DE BASE

Sujets: méthodes de base

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
 - d'une variable aléatoire **continue** scalaire
 - d'une variable aléatoire **gaussienne vectorielle**
- On va supposer qu'on a accès à un générateur pour une variable aléatoire uniformément distribuée entre 0 et 1
 - les méthodes de base vont utiliser les nombres aléatoires qu'il génère

ÉCHANTILLONNAGE DE BASE

Sujets: méthodes de base

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
 - d'une variable aléatoire **continue** scalaire
 - d'une variable aléatoire **gaussienne vectorielle**
- On va supposer qu'on a accès à un générateur pour une variable aléatoire uniformément distribuée entre 0 et 1
 - les méthodes de base vont utiliser les nombres aléatoires qu'il génère

ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire discrète scalaire

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
- Variable : $Z \in \{1, 2, \dots, M\}$
- Algorithme
 1. séparer l'intervalle $(0, 1)$ en M intervalles, où le i^{e} intervalle est de longueur $p(Z=i)$ et est associé à la valeur i
 2. échantillonner un nombre x uniformément dans $(0, 1)$
 3. retourner l'étiquette de l'intervalle dans lequel x se trouve

ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire discrète scalaire

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire

$$p(Z=1) = 0.4$$

$$p(Z=2) = 0.3$$

$$p(Z=3) = 0.1$$

$$p(Z=4) = 0.2$$



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire discrète scalaire


- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire

$$p(Z=1) = 0.4$$

$$p(Z=2) = 0.3$$

$$p(Z=3) = 0.1$$

$$p(Z=4) = 0.2$$



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire discrète scalaire

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire


$$p(Z=1) = 0.4$$

$$p(Z=2) = 0.3$$

$$p(Z=3) = 0.1$$

$$p(Z=4) = 0.2$$

$$x = 0.7456$$



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire discrète scalaire

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire


$$p(Z=1) = 0.4$$

$$p(Z=2) = 0.3$$

$$p(Z=3) = 0.1$$

$$p(Z=4) = 0.2$$

$$x = 0.7456$$



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire discrète scalaire

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire

$$p(Z=1) = 0.4$$


$$p(Z=2) = 0.3$$

$$p(Z=3) = 0.1$$

$$p(Z=4) = 0.2$$

$$p(0.7 < x < 0.8)$$

$$x = 0.7456$$



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire discrète scalaire

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire

$$p(Z=1) = 0.4$$

$$p(Z=2) = 0.3$$


$$p(Z=3) = 0.1$$

$$p(Z=4) = 0.2$$

retourne 3

$$p(0.7 < x < 0.8)$$

$$x = 0.7456$$



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire discrète scalaire

- Débutons par les méthodes de base pour l'échantillonnage

▸ d'une variable aléatoire **discrète** scalaire

$$p(Z=1) = 0.4$$


$$p(Z=2) = 0.3$$

$$p(Z=3) = 0.1$$

$$p(Z=4) = 0.2$$

$$\overbrace{p(0.7 < x < 0.8)}^{\text{retourne 3}} = \int_{0.7}^{0.8} 1dx = 0.1$$

$$x = 0.7456$$



Apprentissage automatique

Méthodes d'échantillonnage - variable aléatoire continue scalaire

ÉCHANTILLONNAGE DE BASE

Sujets: méthodes de base

RAPPEL

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
 - d'une variable aléatoire **continue** scalaire
 - d'une variable aléatoire **gaussienne vectorielle**
- On va supposer qu'on a accès à un générateur pour une variable aléatoire uniformément distribuée entre 0 et 1
 - les méthodes de base vont utiliser les nombres aléatoires qu'il génère

ÉCHANTILLONNAGE DE BASE

Sujets: méthodes de base

RAPPEL

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
 - d'une variable aléatoire **continue** scalaire
 - d'une variable aléatoire **gaussienne vectorielle**
- On va supposer qu'on a accès à un générateur pour une variable aléatoire uniformément distribuée entre 0 et 1
 - les méthodes de base vont utiliser les nombres aléatoires qu'il génère

ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire continue scalaire

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **continue** scalaire
- Variable : $Z \in I$, fonction de densité $p(z)$
et fonction de répartition $P(z) = \int_{\min(I)}^z p(x)dx$
- Algorithme
 1. échantillonner un nombre x uniformément dans $(0,1)$
 2. retourner $P^{-1}(x)$

ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire continue scalaire

- Débutons par les méthodes de base pour l'échantillonnage


- d'une variable aléatoire **continue** scalaire

- Variable : $Z \in I$, fonction de densité $p(z)$
et fonction de répartition $P(z) = \int_{\min(I)}^z p(x)dx$

- Algorithme

1. échantillonner un nombre x uniformément dans $(0,1)$


2. retourner $P^{-1}(x)$

 fonction réciproque de $P(z)$ (*inverse function*)

ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire continue scalaire


- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **continue** scalaire



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire continue scalaire


- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **continue** scalaire



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire continue scalaire


- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **continue** scalaire



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire continue scalaire


- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **continue** scalaire



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire continue scalaire


- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **continue** scalaire



ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire continue scalaire

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **continue** scalaire




$$p(P^{-1}(X) \leq z) = p(X \leq P(z))$$

ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire continue scalaire

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **continue** scalaire



$$p(P^{-1}(X) \leq z) = p(X \leq P(z)) = P(z)$$

puisque X est
uniforme dans $(0,1)$

Apprentissage automatique

Méthodes d'échantillonnage - vecteur aléatoire gaussien

ÉCHANTILLONNAGE DE BASE

Sujets: méthodes de base

RAPPEL

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
 - d'une variable aléatoire **continue** scalaire
 - d'une variable aléatoire **gaussienne vectorielle**
- On va supposer qu'on a accès à un générateur pour une variable aléatoire uniformément distribuée entre 0 et 1
 - les méthodes de base vont utiliser les nombres aléatoires qu'il génère

ÉCHANTILLONNAGE DE BASE

Sujets: méthodes de base

RAPPEL

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
 - d'une variable aléatoire **continue** scalaire
 - d'une variable aléatoire **gaussienne vectorielle**
- On va supposer qu'on a accès à un générateur pour une variable aléatoire uniformément distribuée entre 0 et 1
 - les méthodes de base vont utiliser les nombres aléatoires qu'il génère

ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire gaussienne vectorielle

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **gaussienne vectorielle**
- Variable : Z gaussienne, fonction de densité $\mathcal{N}(\mathbf{z}|\boldsymbol{\mu}, \boldsymbol{\Sigma})$
- Algorithme
 1. générer vecteur gaussien $\mathbf{x}$ de moyenne 0 et covariance $\mathbf{I}$
 2. calculer $\mathbf{L}$ telle que $\boldsymbol{\Sigma} = \mathbf{L}\mathbf{L}^T$
 3. retourner $\mathbf{L}\mathbf{x} + \boldsymbol{\mu}$

ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire gaussienne vectorielle

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **gaussienne vectorielle**
- Génère de $\mathcal{N}(\mathbf{z}|\boldsymbol{\mu}, \boldsymbol{\Sigma})$ puisque
 - transformation linéaire de variables gaussiennes est aussi gaussienne
 - $\mathbb{E}[\mathbf{L}\mathbf{x} + \boldsymbol{\mu}] = \mathbf{L}\mathbb{E}[\mathbf{x}] + \boldsymbol{\mu} = \boldsymbol{\mu}$
 - $\text{cov}[\mathbf{L}\mathbf{x} + \boldsymbol{\mu}] = \mathbf{L}\text{cov}[\mathbf{x}]\mathbf{L}^T = \mathbf{L}\mathbf{L}^T = \boldsymbol{\Sigma}$

ÉCHANTILLONNAGE DE BASE

Sujets: variable aléatoire gaussienne vectorielle

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **gaussienne vectorielle**
- Comment calculer $\mathbf{L}$?
 - décomposition de Cholesky ($\mathbf{L}$ est alors triangulaire inférieure)
 - à partir de la décomposition en valeurs/vecteurs propres de Σ :

$$\mathbf{L} = \mathbf{U}\mathbf{\Lambda}^{\frac{1}{2}}\mathbf{U}^T$$

Apprentissage automatique

Méthodes d'échantillonnage - méthode de rejet

ÉCHANTILLONNAGE DE BASE

Sujets: méthodes de base

RAPPEL

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
 - d'une variable aléatoire **continue** scalaire
 - d'une variable aléatoire **gaussienne vectorielle**
- On va supposer qu'on a accès à un générateur pour une variable aléatoire uniformément distribuée entre 0 et 1
 - les méthodes de base vont utiliser les nombres aléatoires qu'il génère

ÉCHANTILLONNAGE DE BASE

Sujets: méthodes de base

RAPPEL

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
 - d'une variable aléatoire **continue** scalaire
 - d'une variable aléatoire **vectorielle**
- On va supposer qu'on a accès à un générateur pour une variable aléatoire uniformément distribuée entre 0 et 1
 - les méthodes de base vont utiliser les nombres aléatoires qu'il génère

Quoi faire lorsque ces méthodes
ne sont pas applicables ?

EXEMPLE

Sujets: exemple de cas problématique

- Considérons le cas d'une loi

$$p(z) = \frac{1}{Z_p} \tilde{p}(z)$$

où calculer Z_p est trop lourd, mais pas $\tilde{p}(z)$

- Cas spécifiques :

- loi a posteriori en apprentissage bayésien

$$p(\text{«modèle»} | \text{«données»}) \propto p(\text{«données»} | \text{«modèle»}) p(\text{«modèle»})$$

- probabilités $p(\mathbf{z}|\mathbf{x})$ de modèles plus riche qu'un mélange

MÉTHODE DE REJET


Sujets: méthode de rejet, *proposal distribution*

- Supposons qu'on ait une loi $q(z)$ telle que $kq(z) \geq \tilde{p}(z)$ pour une certaine valeur de k

▸ $q(z)$ est appelée loi instrumentale (***proposal distribution***)

- **Méthode de rejet**

1. échantillonner z_0 de $q(z)$
2. échantillonner u_0 uniformément entre 0 et $kq(z_0)$
3. si $u_0 < \tilde{p}(z)$, alors retourner z_0
4. sinon, revenir à l'étape 1.



MÉTHODE DE REJET

Sujets: méthode de rejet

- La loi $q(z)$ doit être non nulle pour chaque valeur de z telle que $p(z)$ est non nulle
- Si $q(z)$ ne donne pas une borne serrée, cette méthode peut être très inefficace
- Trouver $q(z)$ qui satisfait la condition $kq(z) \geq \tilde{p}(z)$ n'est pas toujours facile
 - il est parfois possible de construire $q(z)$ de façon automatique (voir section 11.1.3)

Apprentissage automatique

Méthodes d'échantillonnage - échantillonnage préférentiel

ÉCHANTILLONNAGE DE BASE

Sujets: méthodes de base

RAPPEL

- Débutons par les méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
 - d'une variable aléatoire **continue** scalaire
 - d'une variable aléatoire **vectorielle**
- On va supposer qu'on a accès à un générateur pour une variable aléatoire uniformément distribuée entre 0 et 1
 - les méthodes de base vont utiliser les nombres aléatoires qu'il génère

Quoi faire lorsque ces méthodes
ne sont pas applicables ?

MÉTHODE DE REJET

Sujets: méthode de rejet, *proposal distribution*


RAPPEL

- Supposons qu'on ait une loi $q(z)$ telle que $kq(z) \geq \tilde{p}(z)$ pour une certaine valeur de k

▸ $q(z)$ est appelée loi instrumentale (***proposal distribution***)

- **Méthode de rejet**

1. échantillonner z_0 de $q(z)$
2. échantillonner u_0 uniformément entre 0 et $kq(z_0)$
3. si $u_0 < \tilde{p}(z)$, alors retourner z_0
4. sinon, revenir à l'étape 1.



ÉCHANTILLONNAGE

Sujets: estimation d'espérance, estimation Monte Carlo

RAPPEL

- Pourquoi échantillonner d'un modèle ?
 - pour estimer une espérance

$$\mathbb{E}[f] = \int f(\mathbf{z})p(\mathbf{z}) \, d\mathbf{z} \approx \frac{1}{L} \sum_{l=1}^L f(\mathbf{z}^{(l)})$$

$\mathbf{z}^{(l)}$ échantillonnés de $p(\mathbf{z})$ 

- Un tel calcul d'une espérance ainsi est appelé une **estimation Monte Carlo**

ÉCHANTILLONNAGE PRÉFÉRENTIEL

Sujets: échantillonnage préférentiel, *importance weights*

- Pourquoi échantillonner d'un modèle ?
 - pour estimer une espérance

$$\begin{aligned}\mathbb{E}[f] &= \int f(\mathbf{z}) p(\mathbf{z}) \, d\mathbf{z} \\ &= \int f(\mathbf{z}) \frac{p(\mathbf{z})}{q(\mathbf{z})} q(\mathbf{z}) \, d\mathbf{z} \\ &\approx \frac{1}{L} \sum_{l=1}^L \frac{p(\mathbf{z}^{(l)})}{q(\mathbf{z}^{(l)})} f(\mathbf{z}^{(l)}).\end{aligned}$$

ÉCHANTILLONNAGE PRÉFÉRENTIEL

Sujets: échantillonnage préférentiel, *importance weights*

- Pourquoi échantillonner d'un modèle ?
 - pour estimer une espérance

$$\begin{aligned}\mathbb{E}[f] &= \int f(\mathbf{z}) p(\mathbf{z}) \, d\mathbf{z} \\ &= \int f(\mathbf{z}) \frac{p(\mathbf{z})}{q(\mathbf{z})} q(\mathbf{z}) \, d\mathbf{z} \\ &\approx \frac{1}{L} \sum_{l=1}^L w_l f(\mathbf{z}^{(l)}).\end{aligned}$$

Importance weights :

$$w_l = p(\mathbf{z}^{(l)}) / q(\mathbf{z}^{(l)})$$

ÉCHANTILLONNAGE PRÉFÉRENTIEL

Sujets: échantillonnage préférentiel, *importance sampling*

- Supposons qu'on ait une loi $q(\mathbf{z})$ (*proposal distribution*)

- **Échantillonnage préférentiel**

1. échantillonner L fois de $q(\mathbf{z})$, pour obtenir $\mathbf{z}^{(1)}, \dots, \mathbf{z}^{(L)}$

2. calculer les L poids $w_1, \dots, w_L$

$$w_l = p(\mathbf{z}^{(l)}) / q(\mathbf{z}^{(l)})$$

3. retourner $\frac{1}{L} \sum_{l=1}^L w_l f(\mathbf{z}^l)$

ÉCHANTILLONNAGE PRÉFÉRENTIEL

Sujets: échantillonnage préférentiel, *importance sampling*

- Comme pour la méthode de rejet, le succès de cette méthode dépend de la proximité entre $q(\mathbf{z})$ et $p(\mathbf{z})$
- Dans le cas où $p(\mathbf{z}) = \frac{1}{Z_p} \tilde{p}(\mathbf{z})$, on peut utiliser les poids suivants :

$$w_l = \frac{L \tilde{p}(\mathbf{z}^{(l)}) / q(\mathbf{z}^{(l)})}{\sum_m \tilde{p}(\mathbf{z}^{(m)}) / q(\mathbf{z}^{(m)})}$$

Apprentissage automatique

Méthodes d'échantillonnage - Metropolis-Hastings

MÉTHODE DE REJET

Sujets: méthode de rejet, *proposal distribution*


RAPPEL

- Supposons qu'on ait une loi $q(z)$ telle que $kq(z) \geq \tilde{p}(z)$ pour une certaine valeur de k

▸ $q(z)$ est appelée loi instrumentale (***proposal distribution***)

- **Méthode de rejet**

1. échantillonner z_0 de $q(z)$
2. échantillonner u_0 uniformément entre 0 et $kq(z_0)$
3. si $u_0 < \tilde{p}(z)$, alors retourner z_0
4. sinon, revenir à l'étape 1.



MÉTHODE DE REJET

Sujets: méthode de rejet, *proposal distribution*

RAPPEL

- Supposons qu'on ait une loi $q(z)$ telle que $kq(z) \geq \tilde{p}(z)$ pour une certaine valeur de k

▸ $q(z)$ est appelée loi

- **Méthode de rejet**


Fonctionne souvent mal en haute dimension, puisque passe son temps à rejeter les propositions z_0

1. échantillonner z_0 d

2. échantillonner u_0 uniformément entre 0 et $kq(z_0)$

3. si $u_0 < \tilde{p}(z)$, alors retourner z_0

4. sinon, revenir à l'étape 1.



MONTE CARLO PAR CHAÎNES DE MARKOV

Sujets: MCMC

- On aimerait que l'algorithme tire profit de ses «bons coups»
 - lorsqu'il trouve un bon échantillon z_0 , on pourrait l'utiliser pour tirer notre prochain échantillon (p. ex. un échantillon «proche»)
- Spécifiquement, on pourrait tirer les $z^{(1)}, \dots, z^{(L)}$ en chaîne
$$z^{(1)} \rightarrow z^{(2)} \rightarrow z^{(3)} \rightarrow \dots \rightarrow z^{(L)}$$
 - la séquence $z^{(1)}, \dots, z^{(L)}$ est donc définie par une chaîne de Markov
- C'est ce qu'on appelle une méthode **Monte Carlo par Chaînes de Markov** (MCMC)

METROPOLIS-HASTINGS

Sujets: Metropolis-Hastings, probabilité d'acceptation

- Supposons qu'on ait une loi $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$  dernier échantillon généré

- **Metropolis-Hastings**

1. échantillonner une proposition $\mathbf{z}^*$ de $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$

2. avec **probabilité d'acceptation**

$$A(\mathbf{z}^*, \mathbf{z}^{(l-1)}) = \min \left(1, \frac{\tilde{p}(\mathbf{z}^*) q(\mathbf{z}^{(l-1)} | \mathbf{z}^*)}{\tilde{p}(\mathbf{z}^{(l-1)}) q(\mathbf{z}^* | \mathbf{z}^{(l-1)})} \right)$$

assigner $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^*$, sinon $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^{(l-1)}$

3. retourner $\mathbf{z}^{(l)}$

METROPOLIS-HASTINGS

Sujets: Metropolis-Hastings, probabilité d'acceptation

- Supposons qu'on ait une loi $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$  dernier échantillon généré

- **Metropolis-Hastings**

1. échantillonner une proposition $\mathbf{z}^*$ de $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$

2. avec **probabilité d'acceptation**

$$A(\mathbf{z}^*, \mathbf{z}^{(l-1)}) = \min \left(1, \frac{\tilde{p}(\mathbf{z}^*)}{\tilde{p}(\mathbf{z}^{(l-1)})} \right)$$

assigner $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^*$, sinon $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^{(l-1)}$

3. retourner $\mathbf{z}^{(l)}$

Se simplifie s'il y a symétrie :
 $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)}) = q(\mathbf{z}^{(l-1)} | \mathbf{z}^{(l)})$

METROPOLIS-HASTINGS


Sujets: Metropolis-Hastings, probabilité d'acceptation

- Le choix de la loi de proposition $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$ est important
 - une condition suffisante pour que l'échantillonnage soit valide est que la probabilité de proposer toute valeur légale de $\mathbf{z}$ soit non nulle sous $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$
- Un choix courant de $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$ est de prendre une gaussienne centrée en $\mathbf{z}^{(l-1)}$
 - une petite covariance impliquera des déplacements lents
 - une grande covariance impliquera des risques de ne pas accepter souvent

METROPOLIS-HASTINGS

Sujets: Metropolis-Hastings

- Exemple :



Apprentissage automatique

Méthodes d'échantillonnage - échantillonnage de Gibbs

MONTE CARLO PAR CHAÎNES DE MARKOV

Sujets: MCMC

RAPPEL

- On aimerait que l'algorithme tire profit de ses «bons coups»
 - lorsqu'il trouve un bon échantillon z_0 , on pourrait l'utiliser pour tirer notre prochain échantillon (p. ex. un échantillon «proche»)
- Spécifiquement, on pourrait tirer les $z^{(1)}, \dots, z^{(L)}$ en chaîne
$$z^{(1)} \rightarrow z^{(2)} \rightarrow z^{(3)} \rightarrow \dots \rightarrow z^{(L)}$$
 - la séquence $z^{(1)}, \dots, z^{(L)}$ est donc définie par une chaîne de Markov
- C'est ce qu'on appelle une méthode **Monte Carlo par Chaînes de Markov** (MCMC)

METROPOLIS-HASTINGS

Sujets: Metropolis-Hastings, probabilité d'acceptation

RAPPEL

- Supposons qu'on ait une loi $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$  dernier échantillon généré

- **Metropolis-Hastings**

1. échantillonner une proposition $\mathbf{z}^*$ de $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$

2. avec **probabilité d'acceptation**

$$A(\mathbf{z}^*, \mathbf{z}^{(l-1)}) = \min \left(1, \frac{\tilde{p}(\mathbf{z}^*) q(\mathbf{z}^{(l-1)} | \mathbf{z}^*)}{\tilde{p}(\mathbf{z}^{(l-1)}) q(\mathbf{z}^* | \mathbf{z}^{(l-1)})} \right)$$

assigner $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^*$, sinon $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^{(l-1)}$

3. retourner $\mathbf{z}^{(l)}$

METROPOLIS-HASTINGS

Sujets: Metropolis-Hastings, probabilité d'acceptation

RAPPEL

- Supposons qu'on ait une loi $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$  dernier échantillon généré

- **Metropolis-Hastings**

1. échantillonner une proposition $\mathbf{z}^*$ de $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$

2. avec **probabilité d'acc**

Peut-on éviter d'avoir à
fournir une loi $q(\mathbf{z}_l | \mathbf{z}_{l-1})$?

$$A(\mathbf{z}^*, \mathbf{z}^{(l-1)}) = \min \left(1, \frac{p(\mathbf{z}^*) q(\mathbf{z}^{(l-1)} | \mathbf{z}^*)}{\tilde{p}(\mathbf{z}^{(l-1)}) q(\mathbf{z}^* | \mathbf{z}^{(l-1)})} \right)$$

assigner $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^*$, sinon $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^{(l-1)}$

3. retourner $\mathbf{z}^{(l)}$

ÉCHANTILLONNAGE DE GIBBS

Sujets: Metropolis-Hastings, probabilité d'acceptation

- **Échantillonnage de Gibbs**

1. assigner $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^{(l-1)}$

2. choisir k aléatoirement parmi $\{1, \dots, D\}$

3. remplacer $z_k^{(l)}$ par un échantillon de $p(z_k^{(l)} | z_1^{(l)}, \dots, z_{k-1}^{(l)}, z_{k+1}^{(l)}, \dots, z_D^{(l)})$

4. retourner $\mathbf{z}^{(l)}$

ÉCHANTILLONNAGE DE GIBBS

Sujets: Metropolis-Hastings, probabilité d'acceptation

- **Échantillonnage de Gibbs**

1. assigner $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^{(l-1)}$

2. choisir k aléatoirement parmi $\{1, \dots, D\}$

3. remplacer $z_k^{(l)}$ par un échantillon de $p(z_k^{(l)} | \underbrace{z_1^{(l)}, \dots, z_{k-1}^{(l)}, z_{k+1}^{(l)}, \dots, z_D^{(l)}}_{\mathbf{z}_{\setminus k}^{(l)} : \text{tout le vecteur } \mathbf{z}^{(l)} \text{ sans la } k^{\text{e}} \text{ composante}})$

4. retourner $\mathbf{z}^{(l)}$

ÉCHANTILLONNAGE DE GIBBS

Sujets: Metropolis-Hastings, probabilité d'acceptation

- Équivaut au Metropolis-Hastings, mais dont la loi instrumentale est telle qu'on accepte toujours

$$\frac{p(\mathbf{z}^*)q(\mathbf{z}^{(l-1)}|\mathbf{z}^*)}{p(\mathbf{z}^{(l-1)})q(\mathbf{z}^*|\mathbf{z}^{(l-1)})} = \frac{p(z_k^*|\mathbf{z}_{\setminus k}^*)p(\mathbf{z}_{\setminus k}^*)p(z_k^{(l-1)}|\mathbf{z}_{\setminus k}^*)}{p(z_k^{(l-1)}|\mathbf{z}_{\setminus k}^{(l-1)})p(\mathbf{z}_{\setminus k}^{(l-1)})p(z_k^*|\mathbf{z}_{\setminus k}^{(l-1)})}$$

ÉCHANTILLONNAGE DE GIBBS

Sujets: Metropolis-Hastings, probabilité d'acceptation

- Équivaut au Metropolis-Hastings, mais dont la loi instrumentale est telle qu'on accepte toujours

$$\frac{p(\mathbf{z}^*)q(\mathbf{z}^{(l-1)}|\mathbf{z}^*)}{p(\mathbf{z}^{(l-1)})q(\mathbf{z}^*|\mathbf{z}^{(l-1)})} = \frac{p(z_k^*|\mathbf{z}_{\setminus k}^*)p(\mathbf{z}_{\setminus k}^*)p(z_k^{(l-1)}|\mathbf{z}_{\setminus k}^*)}{p(z_k^{(l-1)}|\mathbf{z}_{\setminus k}^{(l-1)})p(\mathbf{z}_{\setminus k}^{(l-1)})p(z_k^*|\mathbf{z}_{\setminus k}^{(l-1)})}$$

$$\mathbf{z}_{\setminus k}^{(l-1)} = \mathbf{z}_{\setminus k}^*$$

ÉCHANTILLONNAGE DE GIBBS

Sujets: Metropolis-Hastings, probabilité d'acceptation

- Équivaut au Metropolis-Hastings, mais dont la loi instrumentale est telle qu'on accepte toujours

$$\frac{p(\mathbf{z}^*)q(\mathbf{z}^{(l-1)}|\mathbf{z}^*)}{p(\mathbf{z}^{(l-1)})q(\mathbf{z}^*|\mathbf{z}^{(l-1)})} = \frac{p(z_k^*|\mathbf{z}_{\setminus k}^*)p(\mathbf{z}_{\setminus k}^*)p(z_k^{(l-1)}|\mathbf{z}_{\setminus k}^*)}{p(z_k^{(l-1)}|\mathbf{z}_{\setminus k}^*)p(\mathbf{z}_{\setminus k}^*)p(z_k^*|\mathbf{z}_{\setminus k}^*)}$$

$$\mathbf{z}_{\setminus k}^{(l-1)} = \mathbf{z}_{\setminus k}^*$$

ÉCHANTILLONNAGE DE GIBBS

Sujets: Metropolis-Hastings, probabilité d'acceptation

- Équivaut au Metropolis-Hastings, mais dont la loi instrumentale est telle qu'on accepte toujours


$$\frac{p(\mathbf{z}^*)q(\mathbf{z}^{(l-1)}|\mathbf{z}^*)}{p(\mathbf{z}^{(l-1)})q(\mathbf{z}^*|\mathbf{z}^{(l-1)})} = \frac{p(z_k^*|\mathbf{z}_{\setminus k}^*)p(\mathbf{z}_{\setminus k}^*)p(z_k^{(l-1)}|\mathbf{z}_{\setminus k}^*)}{p(z_k^{(l-1)}|\mathbf{z}_{\setminus k}^*)p(\mathbf{z}_{\setminus k}^*)p(z_k^*|\mathbf{z}_{\setminus k}^*)}$$
$$= 1$$

$$\mathbf{z}_{\setminus k}^{(l-1)} = \mathbf{z}_{\setminus k}^*$$

ÉCHANTILLONNAGE DE GIBBS

Sujets: Metropolis-Hastings, probabilité d'acceptation

- Exemple :



ÉCHANTILLONNAGE DE GIBBS

Sujets: version cyclique

- **Échantillonnage de Gibbs cyclique**

1. assigner $\mathbf{z}^{(l)} \leftarrow \mathbf{z}^{(l-1)}$

2. pour k de 1 à D

– remplacer $z_k^{(l)}$ par un échantillon de $p(z_k^{(l)} | z_1^{(l)}, \dots, z_{k-1}^{(l)}, z_{k+1}^{(l)}, \dots, z_D^{(l)})$

3. retourner $\mathbf{z}^{(l)}$

- Permet de réduire la corrélation entre les $\mathbf{z}^{(l)}$
- L'ordre de remplacement des $z_k^{(l)}$ n'est pas important

Apprentissage automatique

Méthodes d'échantillonnage - résumé

ÉCHANTILLONNAGE

Sujets: estimation d'espérance, estimation Monte Carlo

RAPPEL

- Pourquoi échantillonner d'un modèle ?
 - pour estimer une espérance

$$\mathbb{E}[f] = \int f(\mathbf{z})p(\mathbf{z}) \, d\mathbf{z} \approx \frac{1}{L} \sum_{l=1}^L f(\mathbf{z}^{(l)})$$

$\mathbf{z}^{(l)}$ échantillonnés de $p(\mathbf{z})$ 

- Un tel calcul d'une espérance ainsi est appelé une **estimation Monte Carlo**

ÉCHANTILLONNAGE DE BASE

Sujets: méthodes de base

- Méthodes de base pour l'échantillonnage
 - d'une variable aléatoire **discrète** scalaire
 - d'une variable aléatoire **continue** scalaire
 - d'une variable aléatoire **gaussienne vectorielle**
- Dans ces cas, on est garanti d'obtenir des échantillons de qualité, en un temps bien déterminé

MÉTHODE DE REJET

Sujets: méthode de rejet

- Si les méthodes de base ne sont pas applicables à $p(\mathbf{z})$:

Méthode de rejet :

- doit fournir une loi instrumentale (*proposal distribution*) $q(\mathbf{z})$
- si la loi $q(\mathbf{z})$ n'est pas proche de $p(\mathbf{z})$, on peut attendre longtemps avant d'avoir un échantillon (particulièrement en haute dimension)

ÉCHANTILLONNAGE PRÉFÉRENTIEL

Sujets: échantillonnage préférentiel

- Si les méthodes de base ne sont pas applicables à $p(\mathbf{z})$:

Échantillonnage préférentiel

- doit fournir une loi instrumentale (*proposal distribution*) $q(\mathbf{z})$
- meilleur que la méthode de rejet pour l'estimation Monte Carlo
- permet seulement d'approximer une somme (ne donne pas des échantillons de $p(\mathbf{z})$)
- si la loi $q(\mathbf{z})$ n'est pas proche de $p(\mathbf{z})$, l'approximation peut être très mauvaise (particulièrement en haute dimension)

METROPOLIS-HASTINGS

Sujets: Metropolis-Hastings

- Si les méthodes de base ne sont pas applicables à $p(\mathbf{z})$:

Métropolis-Hastings

- méthode MCMC
- nécessite seulement une loi instrumentale conditionnelle $q(\mathbf{z}^{(l)} | \mathbf{z}^{(l-1)})$
- donne une séquence d'échantillons qui sont corrélés (ne peut pas les traiter comme des échantillons indépendants)

ÉCHANTILLONNAGE DE GIBBS

Sujets: Échantillonnage de Gibbs

- Si les méthodes de base ne sont pas applicables à $p(\mathbf{z})$:

Échantillonnage de Gibbs

- méthode MCMC
- ne nécessite pas de loi instrumentale
- nécessite que les conditionnelles $p(z_k^{(l)} | z_1^{(l)}, \dots, z_{k-1}^{(l)}, z_{k+1}^{(l)}, \dots, z_D^{(l)})$ soient calculables
- donne une séquence d'échantillons qui sont corrélés
(ne peut pas les traiter comme des échantillons indépendants)

METROPOLIS-HASTINGS

Sujets: Metropolis-Hastings

- Toutes les méthodes MCMC génèrent des échantillons corrélés
 - pour réduire la corrélation, on collecte seulement tous les M échantillons (p. ex. $M=100$)
 - on ignore également les premiers échantillons générés (période de *burn-in*)
- Pour en savoir plus sur les propriétés que doivent satisfaire les méthodes MCMC : voir section 11.2.1