

Monte Carlo Integration: Metropolis Algorithmus

In der letzten Vorlesung haben wir über Monte Carlo-Verfahren zur Integration (höher-dimensionales) Funktionen gesprochen.

Besonders schnell konvergierende Resultate erhalten wir dabei, wenn wir ein sogenanntes "importance sampling" durchführen. Also anstelle gleichverteilter Zufallszahlen $\{x_i\}$ im Integrationsvolumen folgen die Zufallszahlen einer Verteilung $p(x)$, welche möglichst nahe an der zu integrierenden Funktion $f(x)$ liege, dann gilt:

$$\int f(x) dx = \int \frac{f(x)}{p(x)} \cdot p(x) dx \approx \frac{1}{N} \sum_{i=1}^N \frac{f(x_i)}{p(x_i)} \quad \text{für } p\text{-verteilte Zufallszahlen } \{x_i\}$$

mit statistischem Fehler

$$\Delta = \frac{1}{\sqrt{N}} \cdot \sqrt{\text{Var} \frac{f}{p}}.$$

Hente wollen wir der Frage nachgehen, wie man p -verteilte Zufallszahlen für beliebige Verteilungen $p(x)$ erzeugen kann. ($\int dx p(x) = 1$)

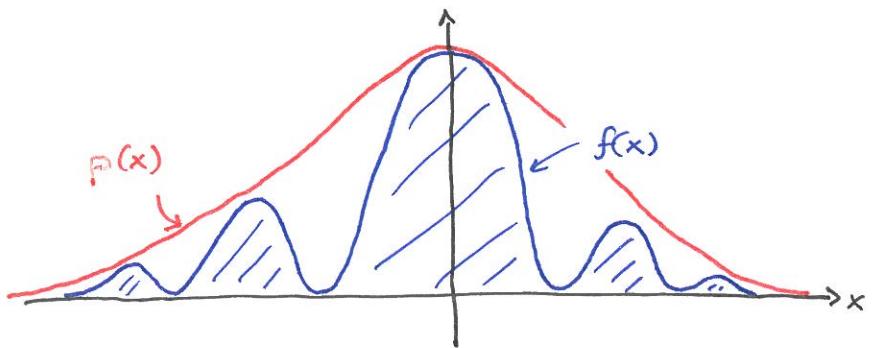
Hierzu werden wir den sogenannten Metropolis-Algorithmus kennenlernen, welches häufig als der mächtigste Algorithmus überhaupt bezeichnet wird.

Entwickelt wurde der Algorithmus vor knapp 60 Jahren, also im Jahre 1953, von Metropolis, Rosenbluth² und Teller² am Los Alamos National Laboratory, wo seinetzt auch die ersten "Super-Computer" in Betrieb genommen wurden, etwa die MANIAC.

-2-

Betrachten wir dazu wieder das Beispiel einer zu integrierenden Funktion in einer Dimension:

$$I = \int_{-\infty}^{\infty} f(x) dx$$



Austelle nun zu versuchen, p-verteilte Zufallszahlen direkt zu generieren, wollen wir nach dem folgenden Schema vorgehen:

- $x_i \in \mathbb{R}$ sei gegeben
- Wähle Zufallszahl Δx gleichverteilt im Intervall $[-h, h]$, wobei h eine sogenannte Schrittweite sei.
Damit

$$\tilde{x}_{i+1} = x_i + \Delta x$$

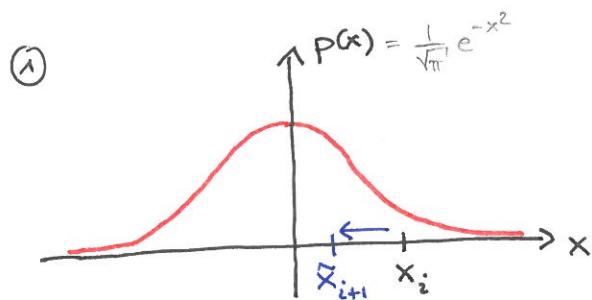
- Berechne $\alpha = \frac{p(\tilde{x}_{i+1})}{p(x_i)}$ wobei $p(x)$ eine gegebene Verteilung sei

- Wähle eine Zufallszahl γ gleichverteilt in $[0, 1)$ und mache folgende Fallunterscheidung

$\gamma \leq \alpha \rightarrow \tilde{x}_{i+1}$ wird akzeptiert, d.h. $x_{i+1} = \tilde{x}_{i+1}$

$\gamma > \alpha \rightarrow \tilde{x}_{i+1}$ wird verworfen, d.h. $x_{i+1} = x_i$

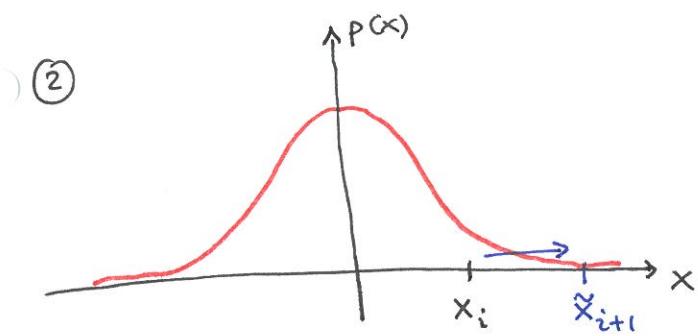
Der Metropolis - Algorithmus erzeugt eine Sequenz von Zahlen $\{x_i\}$, die einem gewichteten Zufallslauf entsprechen. Speziell gilt:



$$\alpha = \frac{p(\tilde{x}_{i+1})}{p(x_i)} > 1$$

d.h. $\gamma < \alpha$ für alle $\gamma \in [0,1]$

→ Änderung wird auf jeden Fall akzeptiert

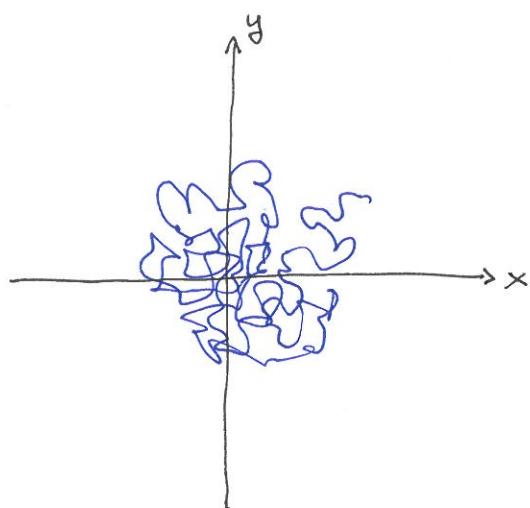


$$0 < \alpha < 1$$

d.h. Änderung wird akzeptiert, falls $\gamma \leq \alpha$, d.h. mit Wahrscheinlichkeit α

Die Sequenz der so erzeugten Zahlen $\{x_i\}$ wird auch als sogenannte Markov-Kette bezeichnet.

Beispiel: Illustration eines Markov-Kette in 2 Dimensionen



$$p(x,y) = \frac{1}{\pi} e^{-(x^2+y^2)}$$

Markov-Ketten

Im obigen Beispiel haben wir einen Algorithmus kennengelernt, der durch einen geschickt gewichteten Zufallslauf eine Sequenz $\{x_i\}$ von p-verteilten Zufallszahlen zu einer sogenannten Markov-Kette erzeugt hat.

Dies wollen wir uns im folgenden noch einmal im Detail anschauen, insbesondere um zu verstehen, welche Bedingungen an den sogenannten Markov-Prozess zur Gewinnung eines solchen Zufallslaufes gestellt werden, damit in der Tat eine bestimmte, beliebig vorgegebene Verteilung "gesampled" wird.

Betrachten wir dazu die folgende Sequenz von Konfigurationen

$$x_0 \rightarrow x_1 \rightarrow x_2 \rightarrow x_3 \rightarrow \dots \rightarrow x_i \rightarrow x_{i+1} \rightarrow \dots$$

Welche in einem sogenannten Markov-Prozess erzeugt werden sollen. Eine Konfiguration x_i mag dabei eine ein- oder zweidimensionale Koordinate wie im obigen Beispiel der Monte Carlo-Integration sein. Es mag sich dabei aber auch um komplexere Objekte wie etwa einer Spin-Konfiguration handeln, wie wir sie in der kommenden Vorlesung in Zusammenhang mit dem klassischen Ising-Modell besprechen werden.

Der Übergang von einer gegebenen Konfiguration x zu einer neuen Konfiguration y erfolgt im Markov-Prozess mit einer Wahrscheinlichkeit W_{xy} . Für alle möglichen Konfigurationen x, y definieren diese Wahrscheinlichkeiten eine Übergangsmatrix, deren Elemente eben diese W_{xy} sind.

Da die Summe aller Wahrscheinlichkeiten, aus einem Zustand x zu einem beliebigen anderen Zustand zu gehen, genau 1 sein muss, gilt für die Spalten der Übergangsmatrix

$$\sum_y W_{xy} = 1$$

Diese Normierung der Spalten hat wichtige Konsequenzen:

Ein Markov-Prozess erhält die gesamten Wahrscheinlichkeiten.

Und zweitens: Der größte Eigenwert der Übergangsmatrix ist 1, und der zugehörige Eigenvektor mit ausschließlich positiven Einträgen ist eine Gleichgewichtsverteilung, welche nach einer großen Zahl von Markov-Schritten erhalten wird.

Die Frage ist nun, wie wir die Übergangsmatrix W wählen müssen, so dass die sich einstellende Gleichgewichtsverteilung der gewünschten Verteilung $p(x)$ entspricht.

Eben solches wird durch die folgenden Bedingungen erfüllt:

1) Normierung:

$$\boxed{\sum_y w_{xy} = 1}$$

2) Ergodizität: Es muss möglich sein, von einer beliebigen Konfiguration x zu einer beliebigen Konfiguration y in einer endlichen Zahl von Markov-Schritten zu gelangen (unabhängig von der Wahrscheinlichkeit dieses Prozesses), d.h. es gibt für alle Konfigurationen x und y eine positive Zahl $n < \infty$ so dass $(w^n)_{xy} \neq 0$:

$$\boxed{\forall x, y \exists n: (w^n)_{xy} \neq 0}$$

3) Gleichgewicht: Die Wahrscheinlichkeitsverteilung $p_x^{(n)}$ ändert sich bei jedem Markov-Schritt genauso:

$$\boxed{\sum_x p_x^{(n)} w_{xy} = p_y^{(n+1)}},$$

aber konvergiert zu einer Gleichgewichtsverteilung

$$\lim_{n \rightarrow \infty} p_x^{(n)} = p_x.$$

Die Gleichgewichtsverteilung p_x ist ein Eigenvektor der Übergangsmatrix mit Eigenwert 1, so dass die Gleichgewichtsbedingung

$$\boxed{\sum_x p_x w_{xy} = p_y}$$

erfüllt ist.

Wir können sofort sehen, daß dafür die sogenannte "detailed balance" Bedingung hinreichend ist

$$\frac{W_{xy}}{W_{yx}} = \frac{p_y}{p_x} \Leftrightarrow p_x W_{xy} = p_y W_{yx}$$

denn Summation über alle Konfigurationen x liefert:

$$\sum_x p_x W_{xy} = \sum_x p_y W_{yx} = p_y \cdot \underbrace{\sum_x W_{yx}}_{=1 \text{ wegen Normierung}} = p_y$$

Eine Möglichkeit, die "detailed balance" Bedingung zu erfüllen, sind die sogenannten Gibbs-Gewichte:

$$W_{xy} = \frac{p_y}{p_x + p_y} \quad W_{yx} = \frac{p_x}{p_x + p_y}$$

$$\rightarrow \frac{W_{xy}}{W_{yx}} = \frac{p_y}{p_x}$$

Eine zweite Möglichkeit, die "detailed balance" Bedingung zu erfüllen, sind die bereits erwähnten Metropolis-Gewichte:

$$W_{xy} = \min\left(1, \frac{p_y}{p_x}\right) \quad W_{yx} = \min\left(1, \frac{p_x}{p_y}\right)$$

$$\rightarrow \frac{W_{xy}}{W_{yx}} = \frac{p_y}{p_x} \quad \text{unabhängig davon ob } p_y > p_x \text{ oder } p_y < p_x.$$