

Přednáška 8 - Quasi MC & náhodná čísla

Opětka: viděli jsme metodu Monte-Carlo pro integraci:

- pro X_1, \dots, X_N iid odpovídající rovnoměrnému rozdělení na Ω máme

$$\frac{\text{vol}(\Omega)}{N} \cdot \sum_{i=1}^N f(X_i) \approx \int_{\Omega} f(x) dx \quad \& \quad \mathbb{P}\left(\left| \frac{\text{vol}(\Omega)}{N} \sum_{i=1}^N f(X_i) - \int_{\Omega} f(x) dx \right| \leq \sqrt{\frac{\text{vol}(\Omega)^2 \cdot \text{var}(f(x))}{\Sigma \cdot N}} \right) > 1 - \Sigma$$

mn > aproximace & odhad chyby jsou nezávislé na dimenzi integrálu (tj. na d , kde $\Omega \in \mathbb{R}^d$)

Otevřené otázky / problémy:

- chyba klesá pouze jako $N^{-1/2}$... N je # sámplovaných bodů ... jak zrychlit?
- jak vlastně generujeme náhodné veličiny & jak to ovlivňuje Monte-Carlo?
- co dělat v případě $\text{vol}(\Omega) = +\infty$?
- co když chcí sámplovat z jiného rozdělení?

Ty otevřené otázky vedou k adaptacím / odvozením MC metod:

- Importance sampling MC
- Quasi-MC
- stratified / adaptive / antithetic MC

Importance sampling

- $w \geq 0$ & $w = 0$ nejvýše pro konečné mnoho bodů
- $\int_{\Omega} w(x) dx = 1$

Krok 1: pro libovolné funkce $f(x)$ a $w(x)$, kde $w(x)$ je pdf platí

$$\int_{\Omega} f(x) dx = \int_{\Omega} \frac{f(x)}{w(x)} \cdot w(x) dx \equiv \int_{\Omega} \frac{f(\tilde{x})}{w(\tilde{x})} dW_{\tilde{x}}$$

W je pravděpodobnostní míra odpovídající $w(x)$ →
→ klasický ztotožňovaná s tzv. cumulative distribution function (cdf)

→ vlastně analogické odvozování na minulé přednášce.

Krok 2: $\int_{\Omega} f(x) dx = \int_{\Omega} \frac{f(x)}{w(x)} dW_x = \mathbb{E}_W \left(\frac{f(X)}{w(X)} \right) \approx \frac{1}{N} \sum_{i=1}^N \frac{f(X_i)}{w(X_i)}$

pro iid náhodné veličiny X_1, \dots, X_N z rozdělení daného cdf $W(X)$.

→ opět postup jako minule:

$X_1, \dots, X_N \sim$ iid náhodné veličiny z rozdělení odpovídajícímu $W(x)$

$$Y_N := \frac{1}{N} \sum_{i=1}^N \frac{f(X_i)}{w(X_i)} \quad \& \quad \text{máme:}$$

$$\bullet \mathbb{E}_W(Y_N) = \frac{1}{N} \sum_{i=1}^N \int_{\mathcal{X}} \frac{f(x)}{w(x)} dW(x) = \int_{\mathcal{X}} f(x) dx$$

$$\bullet \text{var}_W(Y_N) = \frac{\text{var}_W\left(\frac{f(X)}{w(X)}\right)}{N} = \mathbb{E}_W\left(\left(\frac{f(X)}{w(X)}\right)^2\right) - \underbrace{\mathbb{E}_W\left(\frac{f(X)}{w(X)}\right)^2}_{= \mathbb{E}(f(x))^2}$$

Pak nám Chebyshevo lemma dává:

$$\mathbb{P}_W \left(\left| \frac{1}{N} \sum_{i=1}^N \frac{f(X_i)}{w(X_i)} - \int_{\mathcal{X}} f(x) dx \right| < \sqrt{\frac{\text{var}_W\left(\frac{f(X)}{w(X)}\right)}{N}} \right) > 1 - \varepsilon$$

→ přímo a úplně zobecnění MC pro libovolné rozdělení náhodné body.

Potřebujeme:

- umět samplovat body X_i z daného rozdělení
- umět vyhodnocovat pdf daného rozdělení ($= w(X_i)$)

Pozorování:

- vyřešili jsme ty poslední 2 otázky/problémy
- může se stát, že $\text{var}_W\left(\frac{f(X)}{w(X)}\right) \ll \text{var}(f(X)) \rightarrow$
→ záleží na porovnání $\mathbb{E}_W\left(\left(\frac{f(X)}{w(X)}\right)^2\right)$ vs. $\mathbb{E}(f(X)^2)$.

V takovém případě jsme i zlepšili přesnost.

- lze psát $\int_{\mathcal{X}} f(x) dx \approx \sum_{i=1}^N w_i f(x_i)$ kde $w_i = \frac{1}{N \cdot w(x_i)}$

→ zjevně tedy stále nejde o klasickou kvadraturu, ale vidíme, že je to stále lineární kombinace funkčních hodnot v různých bodech & ty koeficienty máme zohledňují jak moc je výskyt daného bodu pravděpodobný →
"je-li x_i 2× více pravděpodobný pak má poloviční váhu" →
→ tudíž název "importance sampling".

Quasi-Monte-Carlo

-> jak v počítači generujeme / simulujeme náhodná čísla?

tzv. pseudo-random generators

- > numpy / scipy / MATLAB / R / ... standard
- > Krok 1 -> vygenerovat sekvenci náhodných čísel v $(0,1)$ (...uniformní)
- Krok 2 -> transf. na normální / exponenciální / ...
- > vygenerovaná čísla nejsou opravdu náhodná, ale zkonstruovaná tak, aby šlo dokázat, že splňují klasické testy náhodnosti

Ale pokud si necháme vygenerovat 10^4 bodů v $(0,1)^2$ tak nedostaneme „rovnoměrné pokrytí“ toho $(0,1)^2$.
(s velkou pravděp.)

Pozorujeme něco jako „lokální clusterování“.

To lze spravit tím, že nepoužijeme „pseudo-random generators“, ale tzv. „quasi-random generators“.

- > ty jsou zkonstruovány tak, aby uniformně pokrývali $(0,1)^d$
- > v principu negenerujeme náhodné body, ale deterministické body
- > výhoda je, že uniformní pokrytí $(0,1)^d$ již potřebujeme daleko méně než „(uniformní pokrytí $(0,1)^d$)“ n) tj. řešíme problém, který jsme měli s „interpolacními kvadraturami“ pro vysoké d .
- > „uniformní“ \approx „maximalizujeme počet bodů pro daný rozptyl“

quasi Monte-Carlo $\equiv X_i$ nejsou generovány za použití pseudo-random generátorů, ale za použití quasi-random generátorů.

• místo chyby $O(N^{-1/2})$ lze dokázat $O(\log^d(N) \cdot N^{-1})$

Stratifikované MC \equiv rozdělíme Ω na podoblasti
a aplikujeme MC nezávisle

Adaptivní MC \equiv uděláme stratifikované MC a na podoblastech
s nejvyšší variancí přidáme další samples
m) řešíme problém pouze tam kde je

Antithetic MC \equiv využijeme symetrii Ω , pokud nějaká je

- když $X \in (0,1)$ pak pro $Y := 1-X$ také $Y \in (0,1)$

- antithetic MC: $\frac{1}{2N} \sum_{i=1}^N f(X_i) + f(Y_i)$

- platí $\cdot \mathbb{E}(\text{antithetic MC}) = \int_0^1 f dx$

- $\text{var}(\text{---}) = \frac{\text{var}(f(X))}{2n} (1+\rho)$

kde ρ je korelace X a Y

\Rightarrow pokud umíme najít

jednoduchou transformaci $X \rightarrow Y$ která bude mít malou
korelaci, pak "zadarmo" získáme "dvojnásobek sample
bodů bez větší variance".

