


# Importance sampling TC


- co když je  $\mathcal{X} = \mathbb{R}^d$  neomezená? Pak neexistuje rovnoměrné rozdělení
- co když umím samplovat body z  $\mathcal{X}$  odpovídající jen skrze nějaké dané rozdělení  $W$  s distrib. funkcí  $W(x)$  a hustotou  $w(x)$ ?

⇒ potřebujeme upravit  $I_{MC}(N)$  pro  $\{x_i\}_{i=1}^N$  odpovídající danému rozdělení  $W$  s distrib. funkcí  $W(x)$  a hustotou  $w(x)$ .

Nebo-li, potřebujeme zvládnout odhadnout  $\int_a^b f(x) dx$  v „obou případech níže“



$x_i \sim$  nerovnoměrné rozdělení



$x_i \sim$  rovnoměrné rozdělení

Řešení: náš odhad  $\int_a^b f(x) dx$  bude vážený průměr - každá funkční hodnota  $f_i \equiv f(x_i)$  bude škálována „pravděpodobností výskytu  $x_i$ “

$w(x) \neq 0$  skoro všude, protože je to hustota definice  $W(x)$

Zapíšeme formálně: 
$$\int_{\mathcal{X}} f(x) dx \stackrel{!}{=} \int_{\mathcal{X}} \frac{f(x)}{w(x)} \cdot w(x) dx = \int_{\mathcal{X}} \frac{f(x)}{w(x)} dW(x)$$

a tedy 
$$\int_{\mathcal{X}} f(x) dx = \mathbb{E}_W \left( \frac{f}{w} \right)$$

střední hodnota funkce  $f/w$  vzhledem k míře  $dW \rightarrow$  při výpočtu této střední hodnoty „už nejsou všechny jevy stejně pravděpodobné“ jako v klasické definici  $\rightarrow$  naopak zohledňují jejich pravděpodobnost, právě skrze pravděpodob. míru  $dW$

$x_i$  má velkou pravděpodobnost v  $W \Rightarrow w(x_i)$  je vysoká  
a tedy hodnoty  $f_i = f(x_i)$  jsou škálovány nepřímou úměrně jejich šanci na samplování.

Pokud máme  $\{x_i\}_1^N$  náhodné veličiny, iid, odpovídající rozdělení  $W$  (hust.  $w(x)$  / distr.  $W(x)$ )

$$I_{MCIS}(N) := \frac{1}{N} \sum_{i=1}^N \frac{f(x_i)}{w(x_i)}$$

Hodnoty  $f_i = f(x_i)$  jsou skalarův „pravděpodob.“  
 že se při samplování z  $W$  objeví  $\Rightarrow$   
 $\Rightarrow$  „vážné“ hodnoty ovlivní odhad více než „běžné“

pak platí:

- $I_{MCIS}(N)$  je náhodná veličina
- $E_W(I_{MCIS}(N)) = \frac{1}{N} \sum_{i=1}^N E_W\left(\frac{f(x_i)}{w(x_i)}\right) = E_W\left(\frac{f}{w}\right) = \int_{\mathcal{X}} f(x) dx$
- $Var_W(I_{MCIS}(N)) = \frac{1}{N^2} \sum_{i=1}^N Var_W\left(\frac{f(x_i)}{w(x_i)}\right) = \frac{1}{N} Var_W\left(\frac{f}{w}\right)$

a tedy za použití Chebysheva lemma dostáváme

$$P_W\left(\left|I_{MCIS}(N) - \int_{\mathcal{X}} f(x) dx\right| < \sqrt{\frac{1}{N}} \cdot \frac{Var_W(f(x)/w(x))}{\sqrt{\epsilon}}\right) \geq 1 - \epsilon$$

Všimněme si, že se nám nutně mění i význam toho odchodu ve smyslu „jak měříme, že je něco nepravděpodobné“.

To by nemuselo být tak překvapivé  $\rightarrow$   $\mathcal{X}$  může být neomezená z my samplujeme v  $I_{MCIS}$  z celé  $\mathcal{X}$ . Tudiž vě to nelze „klasicky, rovnoměrně“ a kdy ani nedává a-priori smysl měřit pravděpodobnost výsledku ve stylu „klasicky, rovnoměrně“, ale naopak použít pravděpodobnost indukovanou tím procesem generování  $\{x_i\}_{i=1}^N$ .

$\rightarrow$  konvergence opět řádu  $(\epsilon \cdot N)^{-1/2}$  s pravděpodobností alespoň  $1 - \epsilon$

$\rightarrow$  k rozmyšlení: lze získat  $I_{MC}$  jako specifický případ  $I_{MCIS}$ ?

# Další adaptace MC metod

## • adaptivní MC/MCIS

Dejme tomu, že chceme celkem použít  $N$  bodů pro aproximaci  $\int_{\mathcal{X}} f(x) dx$ .

Nejdřív nasampluju  $N/2$  bodů z daného rozdělení  $w$  (klidně rovnoměrné) a spočtu si odhad  $I_{MCIS}(N/2) \approx \int_{\mathcal{X}} f(x) dx$ .

Zbývá mi ještě dalších  $N/2$  bodů  $\rightarrow$  nasampluju je tam z oblasti  $\tilde{\mathcal{X}} \subseteq \mathcal{X}$ , kde na základě hodnot  $\{f(x_i)/w(x_i)\}_{i=1}^{N/2}$  je největší rozptyl  $\text{var}_w(f(x_i)/w(x_i))$ .

## • stratifikované MC/MCIS

Dejme tomu, že chceme celkem použít  $N$  bodů pro aproximaci  $\int_{\mathcal{X}} f(x) dx$ .

Rozdělím si  $\mathcal{X} = \mathcal{X}_1 \cup \mathcal{X}_2 \cup \dots \cup \mathcal{X}_m$  a použiju MC/IS s  $N/2m$  body na každou z oblastí  $\mathcal{X}_i \rightarrow$  stále mi zůstává  $N/2$  bodů. Ty využiju k tomu abych „resamploval“  $\mathcal{X}_i$  s nejvyšší hodnotou  $\text{var}_w(f(x_i)/w(x_i))$ .

$\rightarrow$  souhrnná idea: přidat body tam, kde je výsoký rozptyl a tím ho zmenšit  $\rightarrow$  zlepšujeme odhad

## • Quasi Monte-Carlo

Idea je založená na pozorování, že pro klasické algoritmy generující náhodná čísla z rovnoměrného rozdělení pozorujeme jejich „shlukování“  $\rightarrow$  demo v pythonu.

Jak jsme tyto čísla dostali? Klasicky číslici po číslici jako zbytky po dělení. Lze to lépe! Lze generovat „také náhodně vypadající“, ale bez shlukování  $\rightarrow$  tzv. quasi random numbers.

Dobrou volbou lze dosáhnout konvergence  $O\left(\frac{\log^d(N)}{N}\right)$  místo  $O(N^{-1/2})$