

# Stochastické metody v krystalografii

Damián Kulich

16. března 2020

# Osnova

- 1 Úvod
- 2 Základní definice
- 3 Model hustoty
- 4 Algoritmus
- 5 Závěr


# Cíl práce

- Simulovat možná rozdělení misorientací zrn v polykrystalu.

# Polykrystal I

- Polykrystalický materiál se skládá z velkého množství malých krystalů.
- Těmto malým krystalům říkáme zrna.
- Krystalické mřížky jednotlivých zrn jsou vůči sobě různě natočené.

# Polykrystal II



Obrázek: Struktura polykrystalu

# Modelování polykrystalu I

## Definice (Obecná poloha v $\mathbb{R}^3$ )

Říkáme, že  $n$ -tice bodů v  $\mathbb{R}^3$  je v obecné poloze, pokud žádné tři body neleží v jedné přímce, žádné čtyři v jedné rovině a žádných pět na sféře.


## Definice (Voronioiva mosaika v $\mathbb{R}^3$ )

Nechť  $\{x_1, x_2, \dots, x_n\}$  je  $n$ -tice bodů v obecné poloze v  $\mathbb{R}^3$ . Pak  $C_i = \{x \in \mathbb{R}^3; \forall k \neq i |x - x_i| \leq |x - x_k|\}$  nazveme Voroniovou buňkou a množinu  $V = \{C_1, \dots, C_n\}$  Voroniovou mosaikou v  $\mathbb{R}^3$ . Dále definujeme stěnu mezi buňkami  $C_i, C_j$  jako  $F_{i,j} = C_i \cap C_j$ .

## Modelování polykrystalu II

- Polykrystal reprezentujeme Voronoiovou mosaikou
- Vnitřek zrn je tvořen krystalickou mřížkou s orientací  $M_i$ , zrna tedy reprezentujeme dvojicí  $(C_i, M_i)$ .
- Stěny reprezentují hranice mezi zrnny.
- Pokud  $F_{i,j} \neq \emptyset$  pak říkáme, že buňky  $C_i$  a  $C_j$  spolu sousedí, značíme  $C_i \sim C_j$ .

## Modelování polykrystalu III



Obrázek: Příklad Voronoiovy mosaiky v  $\mathbb{R}^2$



## Popis orientace

- Označme osy systému souřadnic v  $\mathbb{R}^3$   $x, y, z$
- Osy souřadného systému buňky budeme značit  $X, Y, Z$  a považovat je za referenční.

# Matrice orientace I

- Označme  $G_s$  a  $G_c$  matice bází souřadného systému mosaiky a buňky respektive.

$$G_s = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad G_c = (b_1, b_2, b_3)$$

- $b_1, b_2, b_3$  jsou bázové vektory mosaiky vyjádřené vůči bází buňky.

## Matice orientace II

### Definice (Matice orientace)

Matice orientace  $G$  je taková matice, že  $G_c = GG_s$ .

- Matice  $G$  se dá vyjádřit jako

$$\begin{pmatrix} \cos(\alpha_1) & \cos(\beta_1) & \cos(\gamma_1) \\ \cos(\alpha_2) & \cos(\beta_2) & \cos(\gamma_2) \\ \cos(\alpha_3) & \cos(\beta_3) & \cos(\gamma_3) \end{pmatrix},$$

kde  $\alpha_i, \beta_i, \gamma_i$  jsou úhly mezi  $x, y, z$  a  $b_i$ .

# Eulerovy úhly I


## Definice (Eulerovy úhly)

Eulerovými úhly nazveme trojici  $\psi = (\varphi_1, \phi, \varphi_2)$ , kde  $\varphi_1, \varphi_2 \in [0, 2\pi)$  a  $\phi \in [0, \pi)$ . Tyto tři úhly popisují rotace

$$G_{\varphi_1} = \begin{pmatrix} \cos(\varphi_1) & \sin(\varphi_1) & 0 \\ -\sin(\varphi_1) & \cos(\varphi_1) & 0 \\ 0 & 0 & 1 \end{pmatrix}, G_{\varphi_2} = \begin{pmatrix} \cos(\varphi_2) & \sin(\varphi_2) & 0 \\ -\sin(\varphi_2) & \cos(\varphi_2) & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

$$G_{\phi} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos(\phi) & \sin(\phi) \\ 0 & -\sin(\phi) & \cos(\phi) \end{pmatrix}.$$

# Eulerovy úhly II



Obrázek: Eulerovy úhly

## Úhel a osa rotace, misorientace

- Rotaci můžeme popsat pomocí jednotkového vektoru  $\mathbf{n}$  a úhlu  $\omega \in [-\pi, \pi)$ , který popisuje úhel rotace okolo  $\mathbf{n}$ .
- Zavedeme misorientaci  $M_{i,j} = G_i G_j^{-1}$ , kde  $G_i, G_j$  jsou matice orientace buněk  $C_i, C_j$ .
- Misorientaci  $M_{i,j}$  přísluší dvojice  $(\mathbf{n}_{i,j}, \alpha_{i,j})$ ,  $\alpha_{i,j}$  nazveme úhlem misorientace  $C_i, C_j$ .

# Stavový prostor

- Dále uvažujme pevnou Voronoiovu mosaiku  $\{C_1 \dots C_n\}$  a orientace (Eulerovy úhly) buněk náhodné.
- Necht'  $S = \{(\varphi_1, \phi, \varphi_2); \varphi_1, \varphi_2 \in [0, 2\pi), \phi \in [0, \pi)\}$ .
- Necht'  $(\Omega, \mathcal{A}, P)$  je pravděpodobnostní prostor a  $\mathcal{S}$  je sigma-algebra na  $S$ .
- $\mathbf{X} : (\Omega, \mathcal{A}) \rightarrow (S, \mathcal{S})$  je náhodný vektor  $(X_1, \dots, X_n)$  orientací jednotlivých buněk.

# Hustota

- Chceme simulovat cílové rozdělení náhodného vektoru  $\mathbf{X}$  s hustotou  $f(\psi_1, \psi_2 \dots \psi_n) \propto \exp(\theta \varepsilon(\psi_1, \psi_2 \dots \psi_n))$  vzhledem k Lebesguově míře na  $S^n$ .
- $\varepsilon$  je tzv. funkce energie, v našem případě  $\varepsilon(\psi_1, \psi_2 \dots \psi_n) = \sum_{C_i \sim C_j} \sin(\alpha_{i,j})$ .
- $\theta \in \mathbb{R} \setminus \{0\}$  je libovolně volený parametr.



# Markovské řetězce

## Definice (Stacionární rozdělení)

Nechť  $U$  je markovský řetězec. Stacionárním rozdělením  $U$  rozumíme takové rozdělení  $\pi$ , že pokud je  $\pi$  počátečním rozdělením  $U$ , potom marginální rozdělení stavů  $U$  v každém čase je  $\pi$ .

- Za určitých předpokladů je  $\pi$  limitním rozdělením markovského řetězce.

# MCMC

- Algoritmus který budeme používat patří mezi tzv. Markov chain Monte Carlo algoritmy.
- Idea je taková, že navrhne markovský řetězec, který bude mít hledanou hustotu  $f$  jako stacionární rozdělení a zároveň splňuje podmínky pro to, aby bylo stacionární rozdělení jeho limitním.
- Tento řetězec pak simulujeme po dostatečný počet iterací, měli bychom tím vygenerovat přibližně výběr z  $f$ .
- Náš algoritmus se nazývá hybridní algoritmus, jeho základem je Gibbsův výběrový plán, uvnitř jeho kroků se provádí Metropolis-Hastings.

# Náčrt algoritmu I

- V jedné iteraci algoritmu postupně procházíme všechny buňky.
- Pro  $i$ -tou buňku známe plně podmíněné rozdělení  $X_i | X_1 \dots X_{i-1}, X_{i+1} \dots X_n$ .
- Navrhujeme rovnoměrně náhodně novou orientaci buňky  $i$ :  $\psi = (\psi_1, \Psi, \psi_2)$ .
- Novou orientaci přijmeme s pravděpodobností  $\min(H, 1)$ , kde  $H = \exp(\theta \sum_{C_j \sim C_i} (\sin(\alpha_{i,j}) - \sin(\bar{\alpha}_{i,j})))$ .  $\bar{\alpha}_{i,j}$  značí úhel misorientace buňky  $C_j$  s novou orientací  $\psi$  a buňky  $C_i$ .

# Náčrt algoritmu II

## Věta

*Jednotlivé kroky algoritmu utváří markovský řetězec, jehož jednoznačné stacionární rozdělení má hustotu  $f$ . Toto rozdělení je zároveň jeho limitním rozdělením.*

## Vlastní přínos

- Implementace algoritmu
- Porovnávání výsledků pro různé volby  $\theta$ .

Díky za pozornost!