

Strojno učenje svojstava materijala na podacima različite točnosti

Fran Krčelić

Fizika materijala

Predmet promatranja su atomi i strukture koje formiraju

Problem: energija sustava i sile na atome

Rješenje: ploha potencijalne energije (PSE)

- ❖ Schrödingerova jdb
- ❖ Računalne simulacije
- ❖ Neuralne mreže?

Računalne simulacije

DFT (Density-Functional Theory)

- ❖ Precizni rezultati
- ❖ Velika složenost => mali sustavi

"polja sile" (force fields)

- ❖ Aproksimacija potencijala jednostavnim članovima
- ❖ Manja složenost => manja preciznost

Tipovi strojnog učenja

Nadzirano učenje

- ❖ Predviđeni set podataka
- ❖ "Loss" funkcija

Nenadzirano učenje

- ❖ Ishod nije "a priori" poznat
- ❖ Cilj je pronaći "skrivene" poveznice

Učenje s potkrepljenjem

- ❖ Interakcija s okolinom => povratna informacija
- ❖ Maksimiziranje finalne "nagrade"

Strojno učenje u fizici materijala

Prvi slučaj Smith (1999)

Generalizirali Behler i Parinello (2007) - primjer silicija

Cilje i dalje isti - modelirati PES

Proces sličan pristupu "polja sile", no bez pretpostavki o interakciji

Mreža sama "uči" fiziku sustava – prednost i nedostatak

Koliko podataka je dovoljno?

Precizni računi (DFT)

- ❖ Velika točnost podataka
- ❖ Problem količine

Grublje aproksimacije (force fields)

- ❖ Lakši za generirati
- ❖ Podaci lošije kvalitete

Strojno učenje na podatcima različite
točnosti (multi-fidelity ML)

Setovi podataka za treniranje mreže

5 setova različite veličine i točnosti

- ❖ PBE 52,348
- ❖ HSE 6030
- ❖ GLLB-SC 2290
- ❖ SCAN28 472
- ❖ Eksperiment 2703

Svaki set je podjeljen u omjeru

- ❖ 80% treniranje mreže
- ❖ 10% validacija
- ❖ 10% testiranje

Neuralne mreže

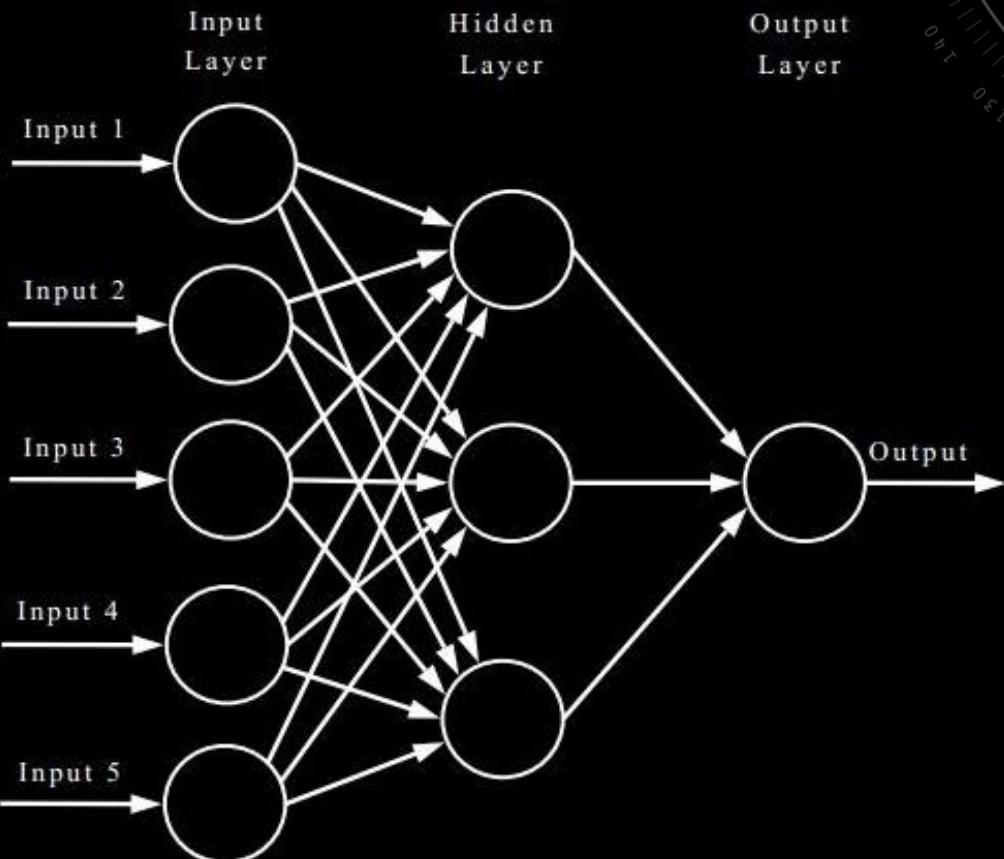
Inspirirane radom mozga – neuroni

Treniranje mreže se odvija
regulacijom "težina" neurona

Igru loss funkcije ima srednja
apsolutna greška (MAE)

Nelinearna aktivacijska funkcija

$$\ln(e^x + 1) - \ln(2)$$



Konstrukcija mreže grafova materijala

Strukturu prikazujemo neusmjerenim grafovima

- ❖ Vrhovi predstavljaju atome
- ❖ Bridovi predstavljaju veze

Elemente prikazujemo vektorima u apstraktnom prostoru

- ❖ Minimalna dimenzija prostora = broj različitih elemenata
- ❖ Dodavanje dimenzija => više parametara mreže
- ❖ Najbolji model pri \mathbb{R}^{16}

Gaussove ekspanzije udaljenosti

m -ti član u razvoju k -te veze

$$e_{k,m} = \exp - \frac{(d_k - \mu_m)^2}{\sigma}, \forall d_k \leq R_c$$

$$\mu_m = \frac{m}{n_{bf} - 1} \mu_{\max}$$

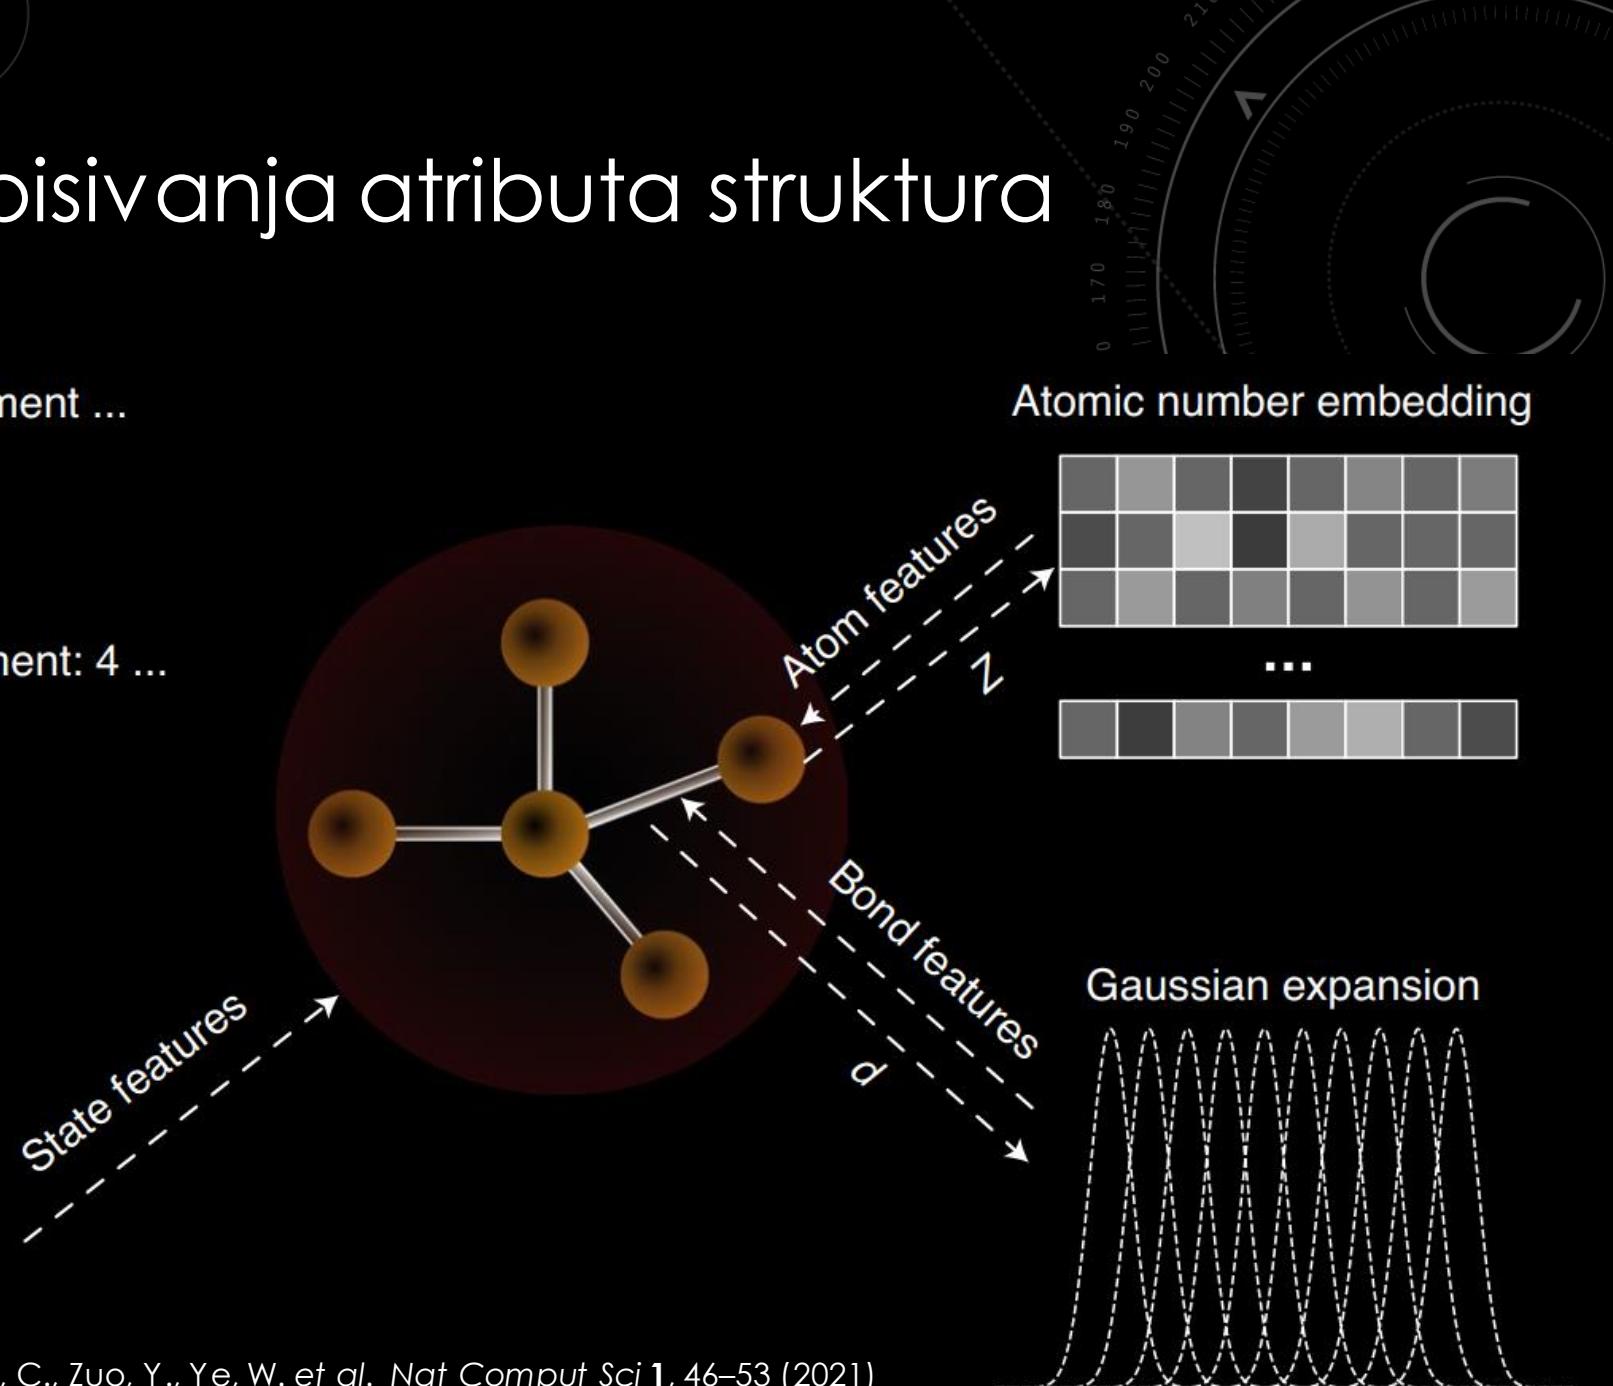
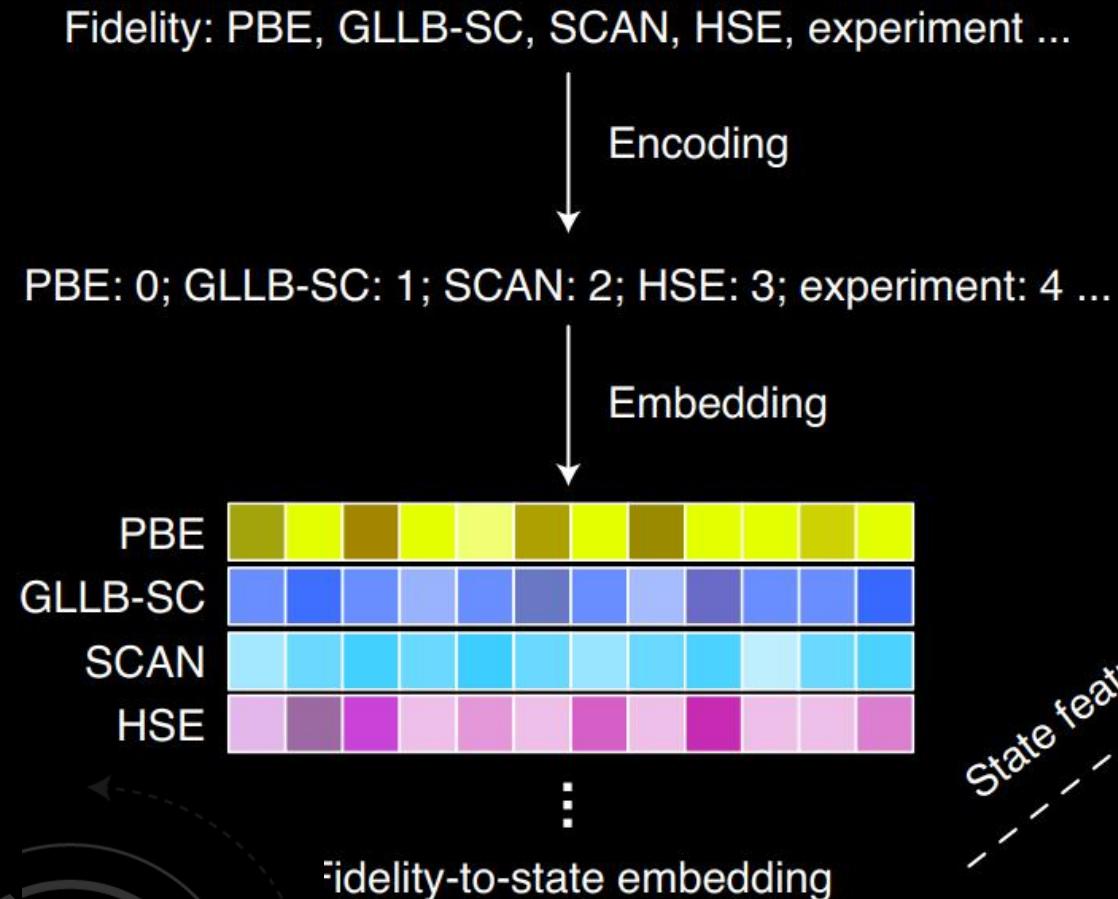
Parametri u modelu

$n_{bf} = 100$ broj članova u razvoju

$R_c = 5\text{\AA}$ "cut-off" radius

$\mu_{\max} = 6\text{\AA}$

Shematski prikaz zapisivanja atributa struktura



Propagiranje atributa (funkcije ažuriranja)

Veze

$$\mathbf{e}'_k = \phi_e (\mathbf{v}_{s_k} \oplus \mathbf{v}_{r_k} \oplus \mathbf{e}_k \oplus \mathbf{u})$$

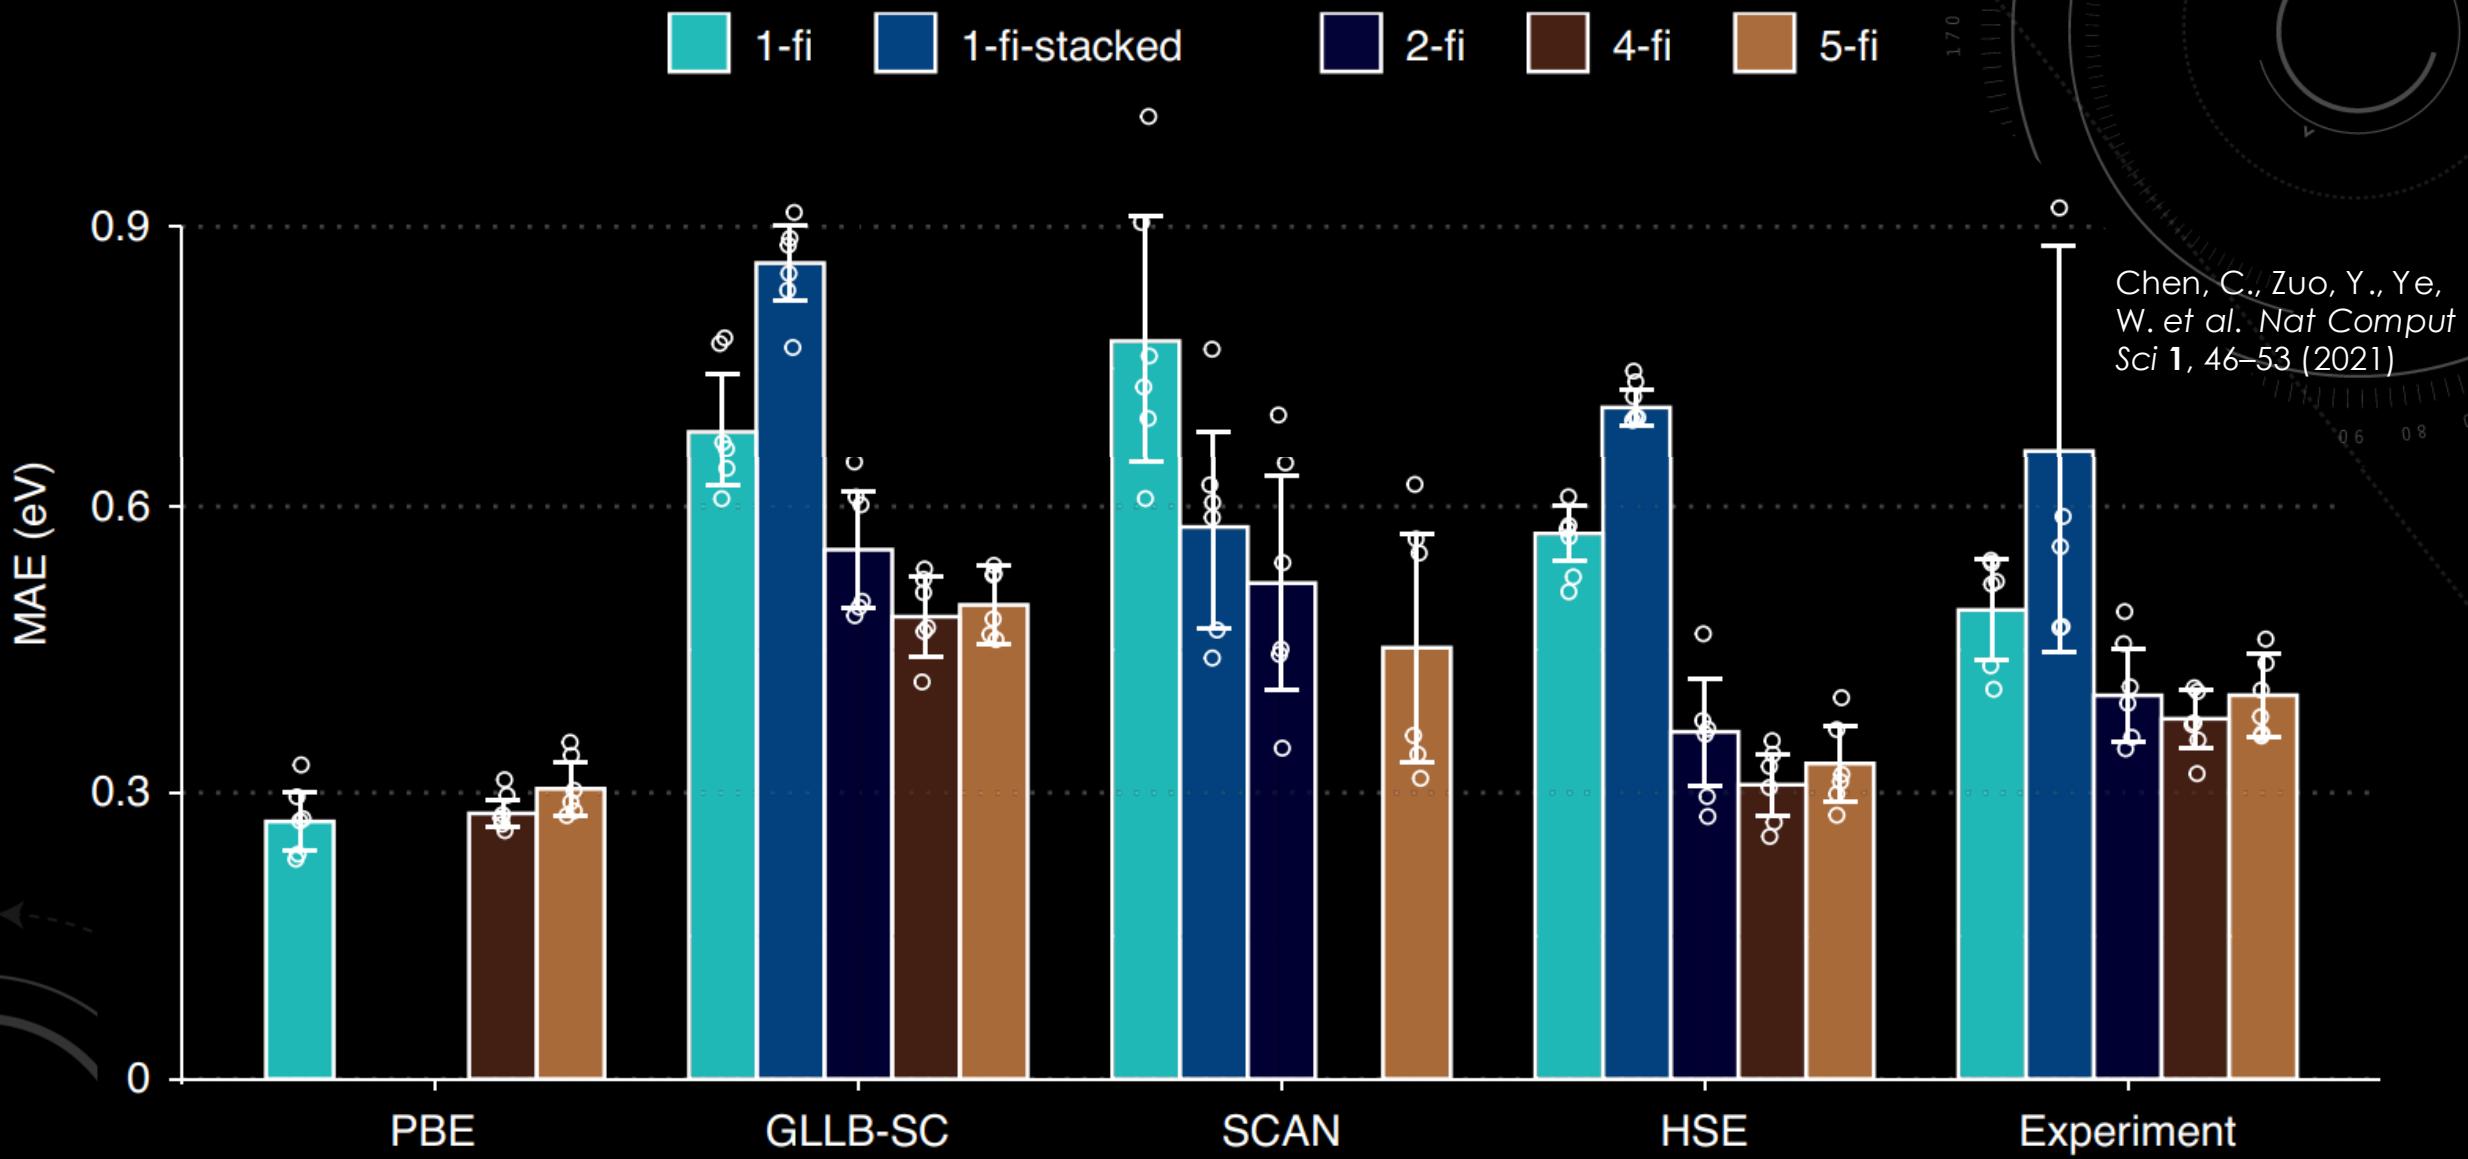
Atomi

$$\mathbf{v}'_i = \phi_\nu (\bar{\mathbf{v}}_i^e \oplus \mathbf{v}_i \oplus \mathbf{u})$$

Stanja

$$\mathbf{v}' = \phi_u (\bar{\mathbf{u}}^e \oplus \bar{\mathbf{u}}^\nu \oplus \mathbf{u})$$

Rezultati



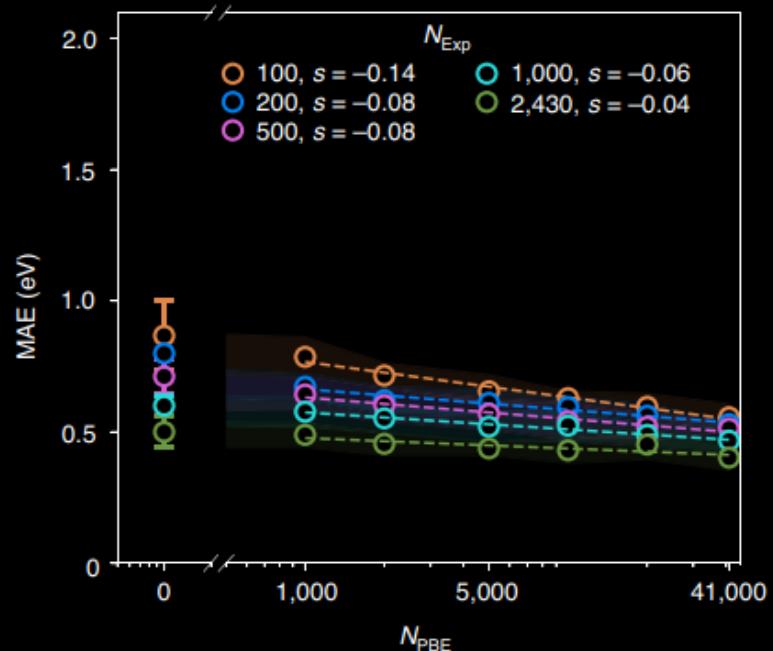
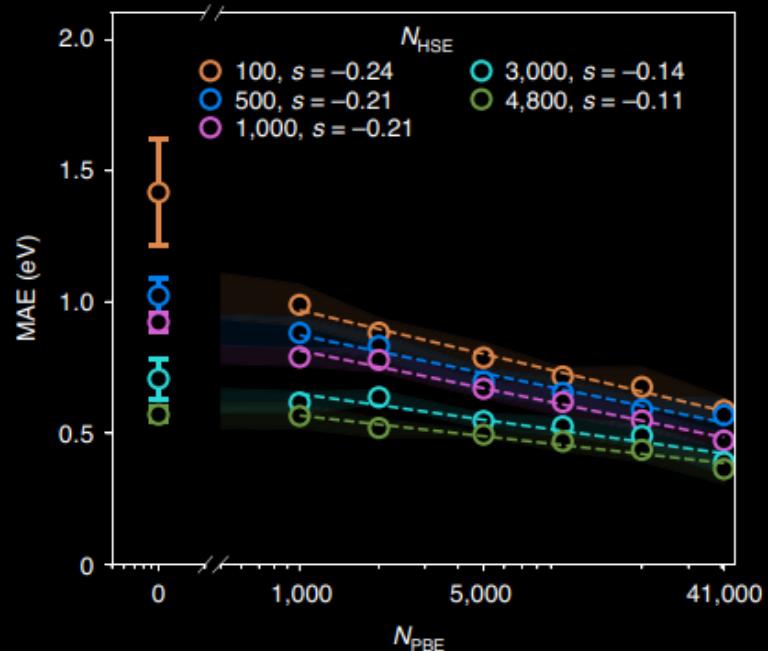
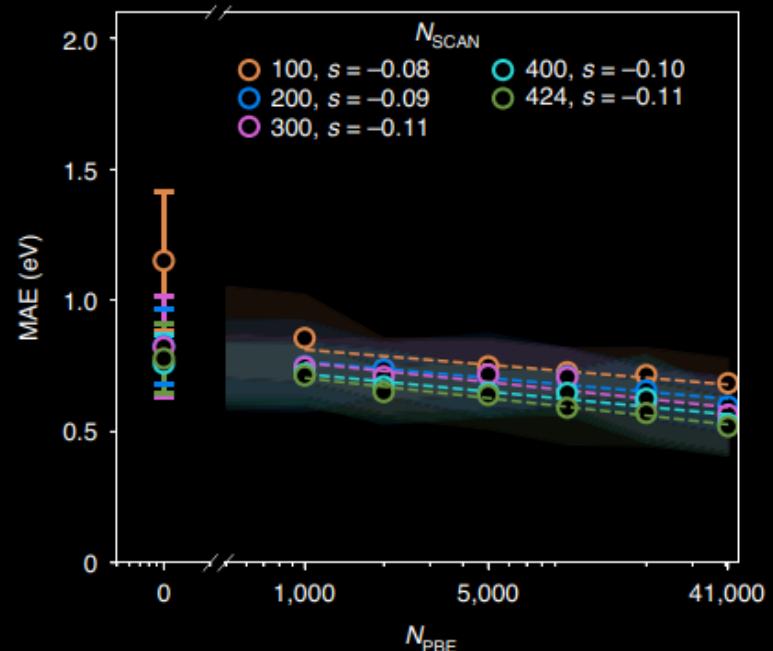
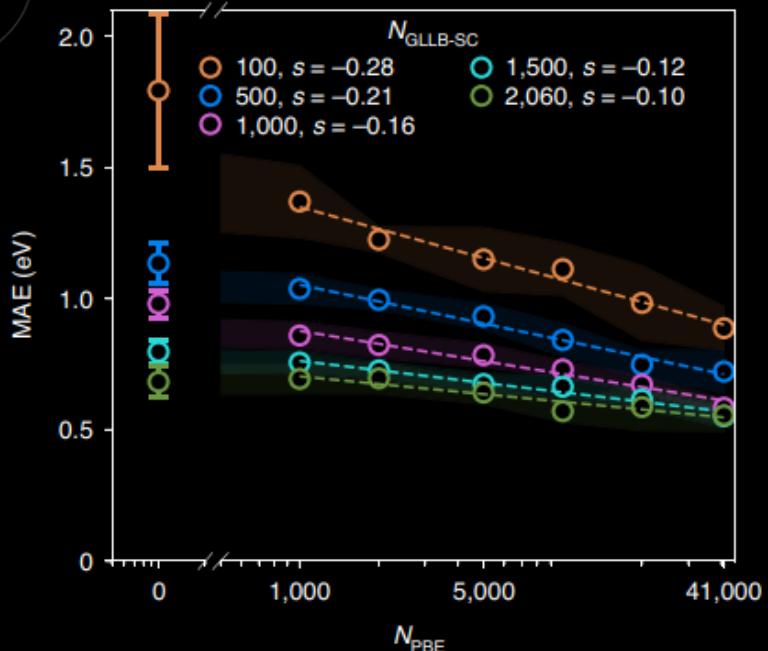
Ovisnost MAE o količini podataka za 2-fi modele

Set podataka više točnosti + PBE

Smanjenje MAE dodavanjem struktura bilo kojeg seta

Parametars predstavlja nagib fitanih pravaca

Chen, C., Zuo, Y., Ye, W. et al. Nat Comput Sci 1, 46–53 (2021)



Zaključak

Veliki sustavi predstavljaju problem za "ab initio" metode, rješenje tražimo koristeći se neuralnim mrežama

Združeno korištenje podataka različite točnosti smanjilo je MAE u rasponu od 22% do 45% u odnosu na korištenje pojedinačnih setova

Korištenjem i samo velikog seta nepreciznijih podataka (PBE) uz bilo koji od setova veće točnosti već vidno smanjuje pogreške modela