

Identifikacija faznih prijelaza strojnim učenjem i metodom konfuzije

Ivan Emanuel Pavlov

Mentor: dr.sc. Vinko Zlatić

Zašto strojno učenje?

- Veliki uspjesi strojnog učenja u brojnim područjima uključujući fiziku
- Fazni prijelazi – klasifikacijski problem u strojnom učenju
- Algoritmi direktno iz podataka uče pozadinsku fiziku
- Mogućnost identificiranja nepoznatih faznih prijelaza

2d Ising model

$$H = -J \sum_{\langle i,j \rangle} \sigma_i \sigma_j \quad T_c = 2.269 \frac{J}{k_B}$$

- Ispod T_c -feromagnetska faza, iznad T_c -paramagnetska faza


- $P_\mu = \frac{1}{Z} e^{-\frac{1}{k_B T} E_\mu}$ - vjerojatnost da je sustav u stanju μ

2d XY model

$$H = -J \sum_{\langle i,j \rangle} \vec{s}_i \vec{s}_j = -J \sum_{\langle i,j \rangle} \cos(\theta_i - \theta_j) \quad \frac{T_c}{J} = 0.893 \pm 0.002K$$

- $P_\mu = \frac{1}{Z} e^{-\frac{1}{k_B T} E_\mu}$ - vjerojatnost da je sustav u stanju μ
- Mermin-Wagnerov teorem (za kontinuirane simetrije)
 - Ne postoji uređena faza u 2d no može postojati fazni prijelaz
- Topološki fazni prijelaz
- Spinski vrtlozi umjesto pojedinih spinskih usmjerenja

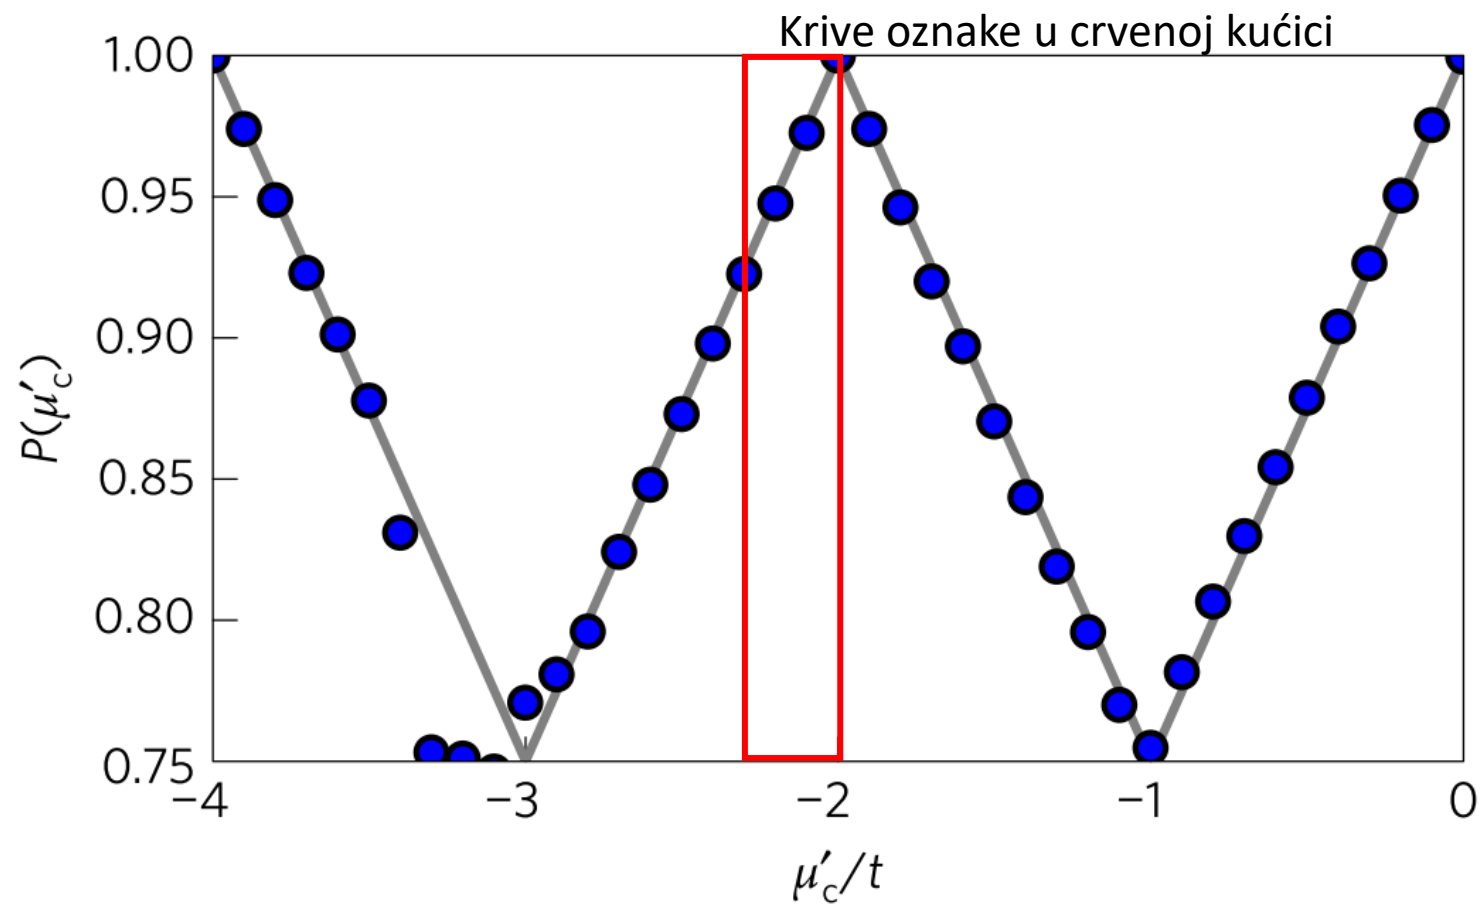
Animacija anihilacije spinskih virova



Metoda konfuzije

- Metoda označavanja skupa podataka
- Način prelaska s nenadziranog na nadzirano učenje
- Algoritam se “zbunjuje” parcijalno krivim označavanjem no uči na temelju većinski dobrih oznaka
- Preciznost algoritma ima W oblik krivulje

Ilustracija:



Monte Carlo metoda - Ising model

- Generiramo inicijalnu konfiguraciju generatorom slučajnih brojeva
- Izabiremo jednu ćeliju i računamo energetske doprinose ćelije sustavu

$$dE(i, j) = -J \cdot S(i, j) \cdot (S(i + 1, j) + S(i - 1, j) + S(i, j + 1) + S(i, j - 1))$$

- Okrećemo spin u toj ćeliji

$$S(i, j) = -S(i, j) \quad \Rightarrow \quad dE'(i, j) = -dE(i, j)$$

$$\Delta E(i, j) = -2 \cdot dE(i, j)$$

- Generiramo slučajni broj p_{random} za koji vrijedi $0 \leq p_{random} \leq 1$


$$\text{Ako } \Delta E(i, j) < 0 \Rightarrow S(i, j) = -S(i, j)$$

$$\text{Ako } \Delta E(i, j) > 0 \Rightarrow \begin{cases} \text{Ako } e^{\frac{-\Delta E}{k_B T}} > p_{random} & \Rightarrow S(i, j) = -S(i, j) \\ \text{Inače} & \Rightarrow S(i, j) = S(i, j) \end{cases}$$

Monte Carlo metoda - XY model


- Analogno Ising modelu
- Razlika:
 - Generiramo slučajni broj (novi kut) te računamo energetske doprinose ćelije s novim usmjerenjem spina
 - Računamo razliku energija sustava prije i poslije promjene orijentacije spina
 - Ostalo je isto kao u Ising modelu
- Konfiguracije spremamo u listu - umjesto kuta spremamo sinus i kosinus kuta svake ćelije

Neuronska mreža




“Loss function” -
unakrsna entropija

$$C(\mathbf{w}) = -(1 - y_i) \log [1 - \sigma(\mathbf{x}_i^T \mathbf{w})] + \text{regularizacija}$$



Sigmoidna aktivacijska
funkcija (logistička)




Parametri modela i neuronske mreže

- Parametri oba modela su radi jednostavnosti postavljeni kao


$$J = 1, k_B = 1$$

- 2000 spinskih konfiguracija za 20 temperatura u slučaju Isingovog modela u rasponu od 0 do $2 \cdot T_c$ (dakle 20 različitih neuronskih mreža)
- 2000 spinskih konfiguracija za 40 temperatura u slučaju XY modela rasponu od 0 do $2K$ (dakle 40 različitih neuronskih mreža)
- Rešetka veličine $L \cdot L$, $L=20$ (to je i broj ulaza neuronske mreže)

Monte Carlo konfiguracije za Isingov model



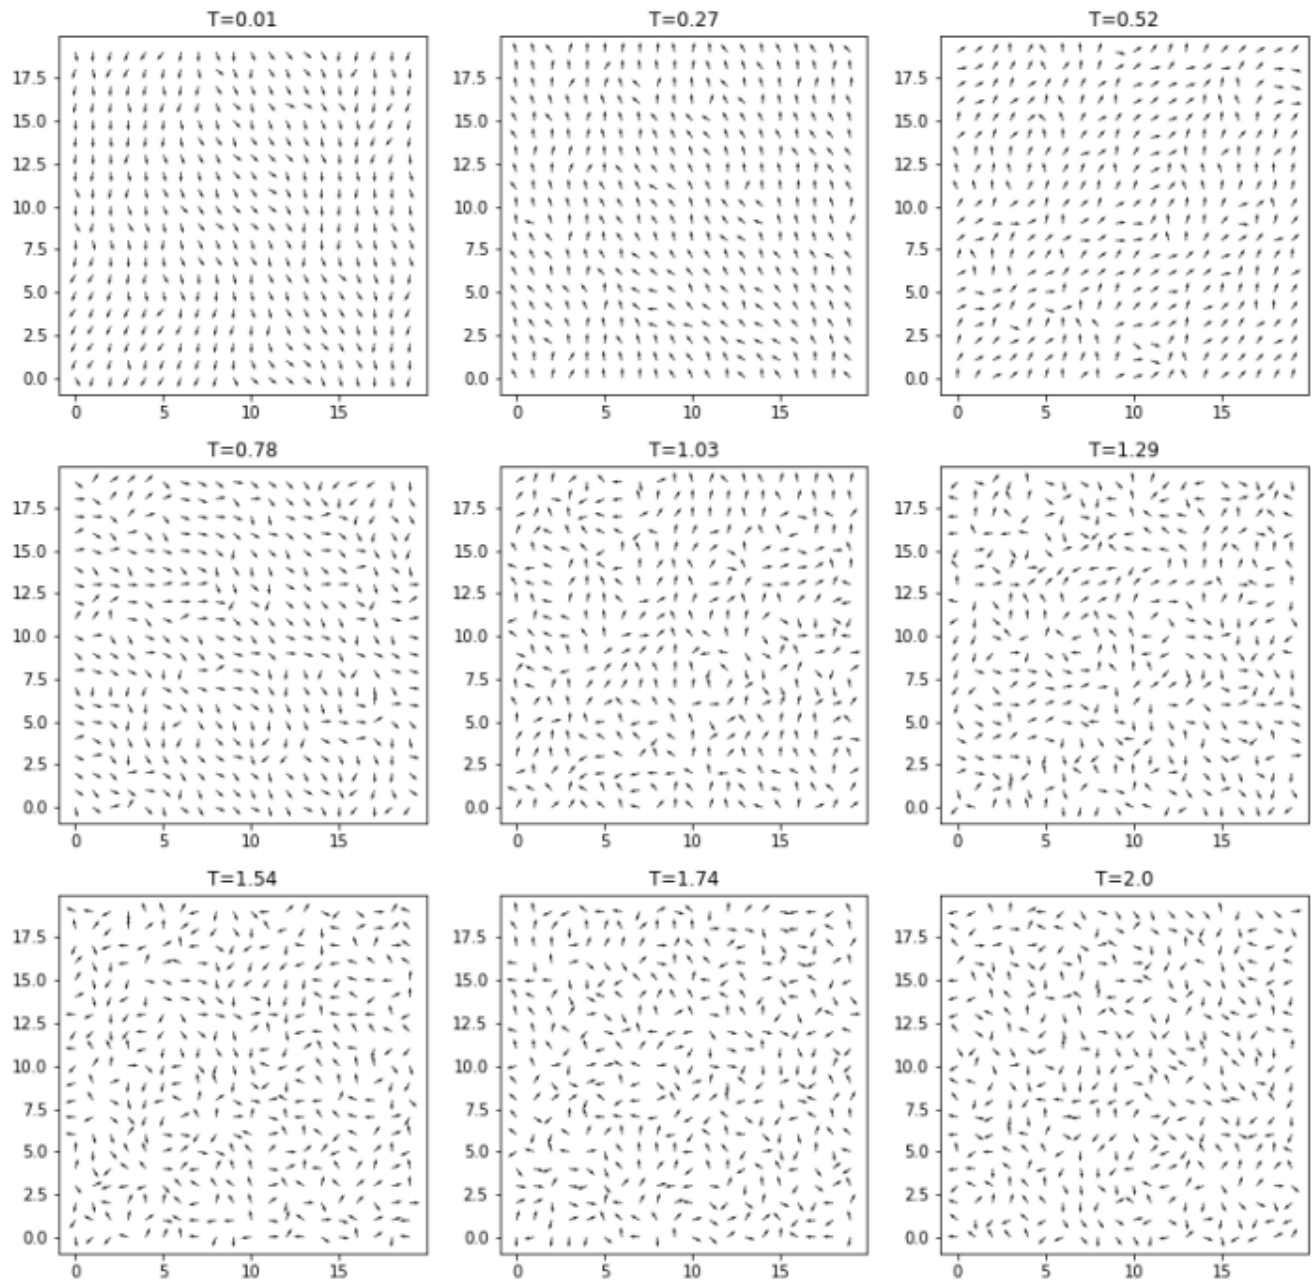
W krivulja preciznosti za Isingov model




Slika 5: Preciznost 20 istreniranih neuronskih mreža za svaki od 20 odabira označavanja skupa podataka

- Vrh krivulje je između vrijednosti na $T=2.15$ i $T=2.38$.

Monte Carlo konfiguracije za XY model



W krivulja preciznosti za XY model



Slika 7: Preciznosti 40 različitih neuronskih mreža za 40 različitih označavanja podataka

- Vrh na $T=1.43\text{K}$. Idealno bi bio na 0.89K

Zaključak

- Metoda konfuzije uspješna na Isingovom modelu
- Metoda konfuzije manje uspješna na XY modelu
- Općenito, metoda se čini perspektivna u slučaju da su ulazi algoritma strojnog učenja dovoljno dobri (kao u Isingovom modelu)
- Inače, potrebno preprocesirati podatke da ulazi budu bolji
- Drugi modeli na koje bi se mogla primjeniti metoda konfuzije s konfiguracijama generiranim Monte Carlo simulacijom : trokutasti Ising, XY model s diskretnim kutovima (modeli sata)

Literatura

- [1] Anders W. Sandvik. Computational Studies of Quantum Spin Systems. AIP Conference Proceedings 1297, 135 (2010)
- [2] Sacha Friedli, Yvan Velenik. Statistical Mechanics of Lattice Systems, (2017)
- [3] Barry M. McCoy and Tai Tsun Wu, The Two- Dimensional Ising Model. Harvard University Press, Cambridge Massachusetts, (1973)
- [4] Evert P. L. van Nieuwenburg, Ye-Hua Liu and Sebastian D. Huber. Learning phase transitions by confusion. Nature physics, (2017).
- [5] Song Sub Lee and Beom Jun Kim. Confusion scheme in machine learning detects double phase transitions and quasi-long-range order. Physical Review E, (2019)

[6] P. Olsson and P. Minnhagen, On the helicity modulus, the critical temperature and Monte Carlo simulations for the two-dimensional XY-model. Phys. Scr. 43, 203 (1992).

[7] Nielsen, Michael A. Neural networks and deep learning. Determination Press, (2015)

[8] Pankaj Mehta, Marin Bukov, Ching-Hao Wang, Alexandre G.R. Day, Clint Richardson, Charles K. Fisher, David J. Schwab. A high-bias, low-variance introduction to Machine Learning for physicists. Physics Reports,(2019)

[9] Aurelien G'eron. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media, (2019)

Hvala na pažnji!