

Identifikácia barkódov v dátach nanopórového sekvenovania

autor: Bc. Adrián Goga

školiťel': doc. Mgr. Tomáš Vinař, PhD.

konzultant: doc. Mgr. Bronislava Brejová, PhD.

Univerzita Komenského v Bratislave

16. júna 2020

Nanopórové DNA sekvenovanie

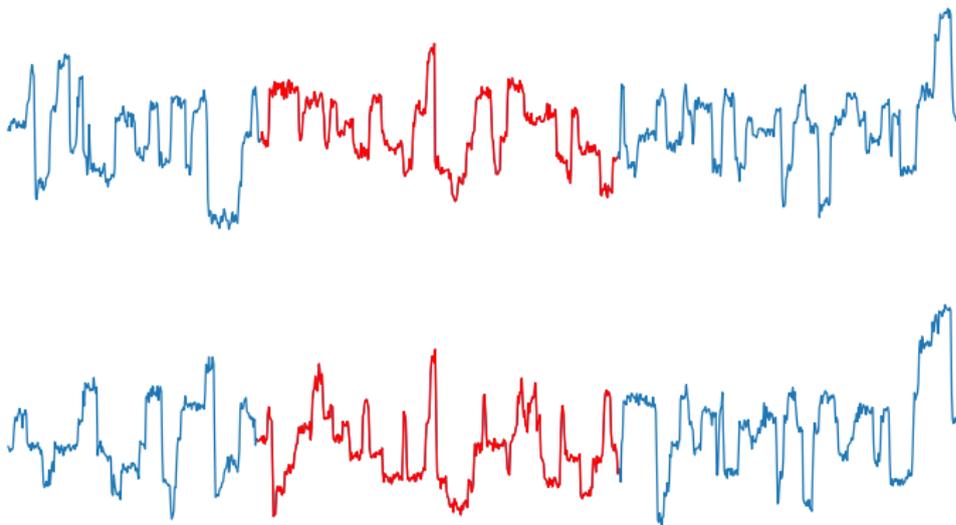
- DNA je nastrihaná na malé kúsky - čítania, ktoré sú po jednom sekvenované
- Čítania prechádzajú cez malý otvor - *nanopór*, na ktorom sa v pravidelných intervaloch meria prúd
- Rýchlosť prechádzania cez nanopór je variabilná
- Každé čítanie je tvorené postupnosťou hodnôt prúdu nameraných v nanopóre - signál
- Osekvenované čítania sa prekladajú do reťazcov nad abecedou $\{A, C, G, T\}$, avšak preklady sú chybové

- Je výhodnejšie sekvenovať viacero DNA vzoriek v jednom behu sekvenátora
- Každé čítanie obsahuje krátku sekvenciu - tzv. **barkód**, ktorý slúži ako jednoznačný identifikátor vzorky
- Problém: chyby v preklade signálu barkódu \implies čítanie nemožno jednoznačne priradiť

- Väčšina existujúcich nástrojov pracuje s preloženými sekvenciami (20 – 25% nepriradených čítaní kvôli chybám v preklade)
- Deepbinner (Wick a spol., 2018) - hlboká konvolučná neurónová sieť klasifikujúca surový signál (iba $\approx 5\%$ čítaní nepriradených, potrebuje veľa tréningových dát)
- Náš cieľ: použiť **učenie bez učiteľa**
- Neuvažujeme znalosť sekvencií barkódov
- Budeme pracovať so surovým signálom pre čo najvyššiu presnosť

Návrh metódy učenia bez učiteľa

- 1 Porovnať dvojicu čítaní na základe podobnosti ich signálov v oblastiach, v ktorých sa nachádzajú barkódy, napr:

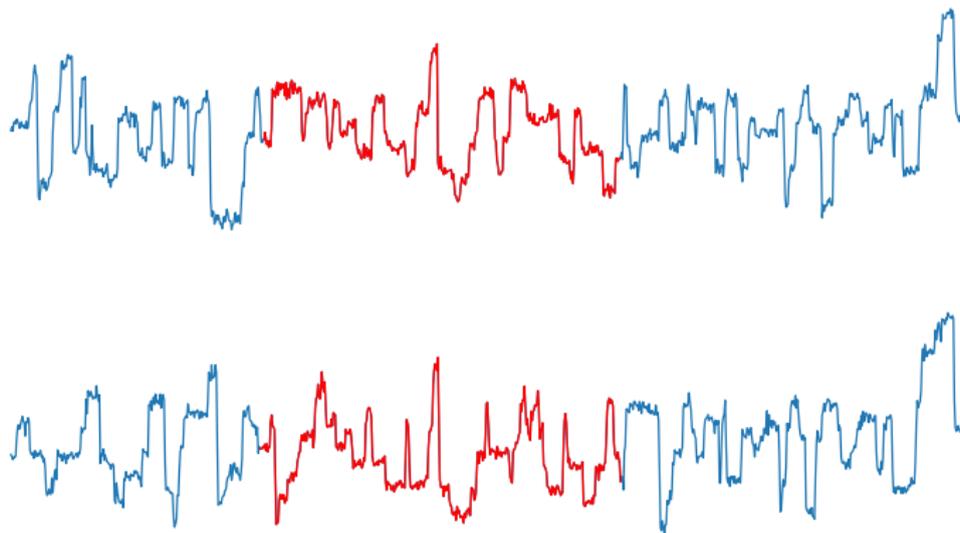


- 2 Pomocou tejto podobnosti nájsť zhľuky čítaní, ktoré zodpovedajú jednotlivým sekvenovaným vzorkám

Meranie podobnosti signálov

Skombinovali sme myšlienky dvoch známych algoritmov:

- Smith-Waterman pre lokálne zarovnávanie reťazcov (Smith a Waterman, 1981)
- Dynamic Time Warping pre globálne zarovnávanie signálov (Sankoff a Kruskal, 1983)



Nový algoritmus sme nazvali **L**ocal **D**ynamic **T**ime **W**arping.

$$\mathbf{LDTW}[i, j] = \max \begin{cases} \mathbf{LDTW}[i, j - 1] + s(x_i, y_j) \\ \mathbf{LDTW}[i - 1, j] + s(x_i, y_j) \\ 0 \end{cases} \quad (1)$$

- Pre dva signály s dĺžkami n, m vieme $LDTW$ podobnosť spočítať v čase $O(nm)$
- Dôležitým komponentom je skórovacia funkcia $s(\cdot, \cdot)$
- Požadujeme: ak X, Y obsahujú rovnaký barkód, tak $s(X, Y) \gg 0$, inak $s(X, Y) \ll 0$

Skórovanie pomerom vierohodností

Nech p_{xy} je pravdepodobnosť, že hodnoty x a y vidíme zarovnané a nech p_x je pravdepodobnosť výskytu hodnoty x .

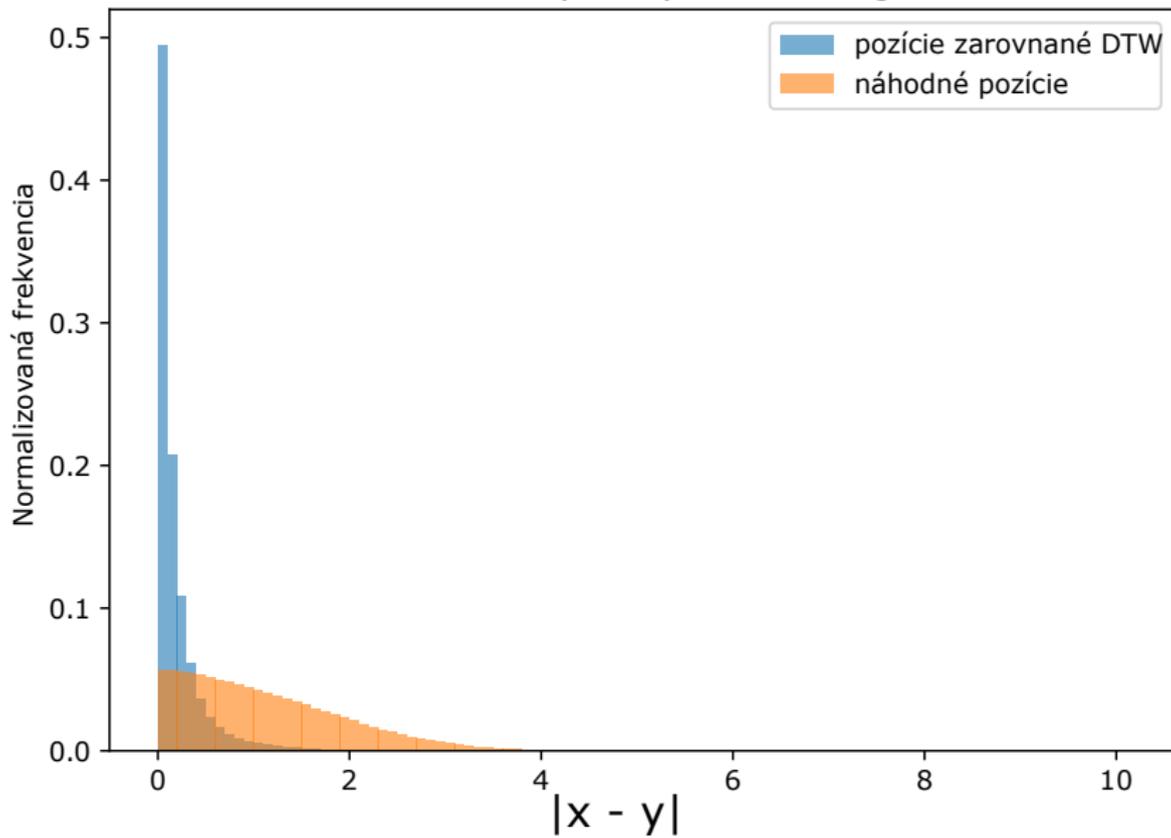
$$s(x, y) = \log \left(\frac{p_{xy}}{p_x p_y} \right) \quad (2)$$

$$\begin{aligned} s(X, Y) &= \sum_{i=1}^n \log \left(\frac{p_{x_i, y_i}}{p_{x_i} p_{y_i}} \right) = \log \left(\prod_{i=1}^n \frac{p_{x_i, y_i}}{p_{x_i} p_{y_i}} \right) = \\ &= \log \left(\frac{\prod_{i=1}^n p_{x_i, y_i}}{\prod_{i=1}^n p_{x_i} \prod_{i=1}^n p_{y_i}} \right) = \log \left(\frac{P(X, Y \mid X \text{ a } Y \text{ spolu súvisia})}{P(X, Y \mid X \text{ a } Y \text{ spolu nesúvisia})} \right) \end{aligned} \quad (3)$$

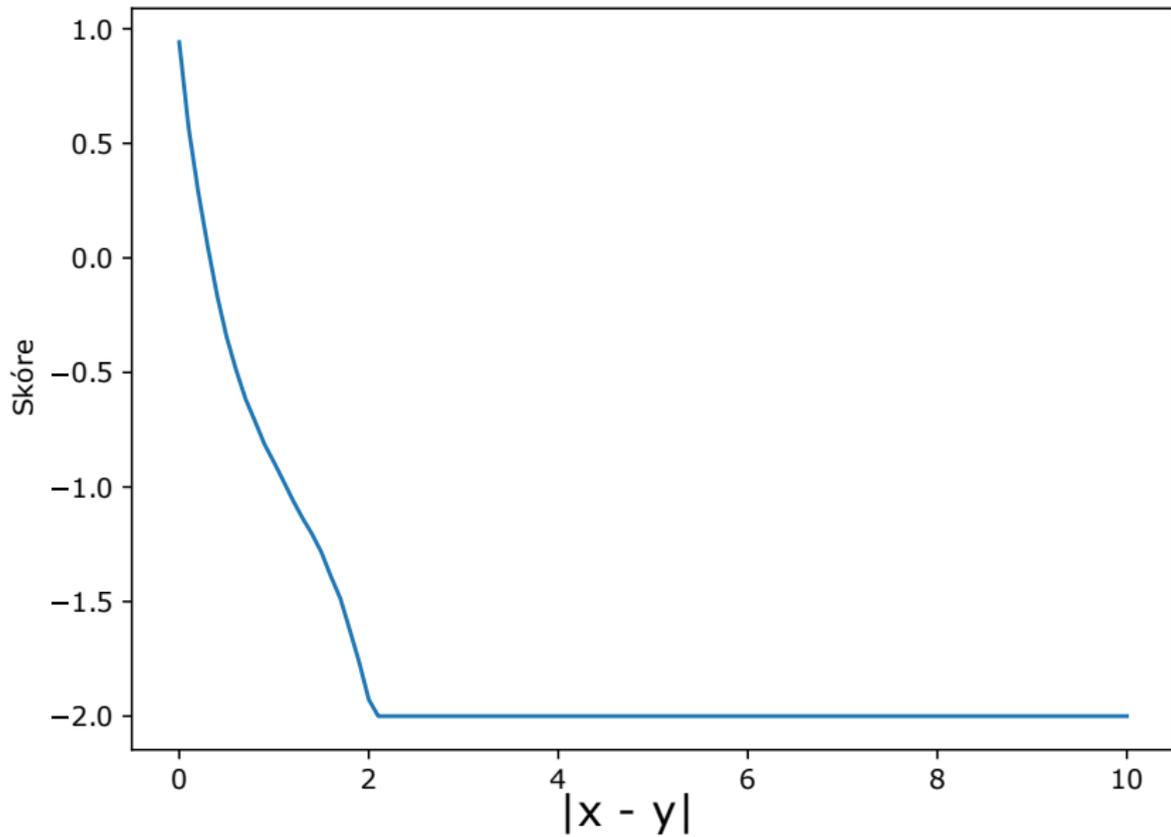
Nech $s(x, y)$ závisí iba od $|x - y|$. Potom $s(x, y)$ odhadneme nasledovne:

$$\begin{aligned} s(x, y) &= \log \left(\frac{P(|x - y| \text{ v správne zarovnaných barkódoch})}{P(|x - y| \text{ v nezávislých signáloch})} \right) \approx \\ &\approx \log \left(\frac{P(|x - y| \text{ v DTW zarovnaniach barkódov})}{P(|x - y| \text{ v nezávislých signáloch})} \right) \quad (4) \end{aligned}$$

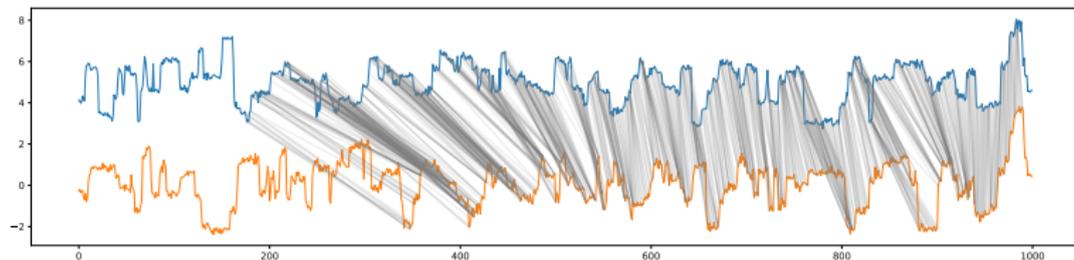
Distribúcia absolútnych chýb bodov v signáloch



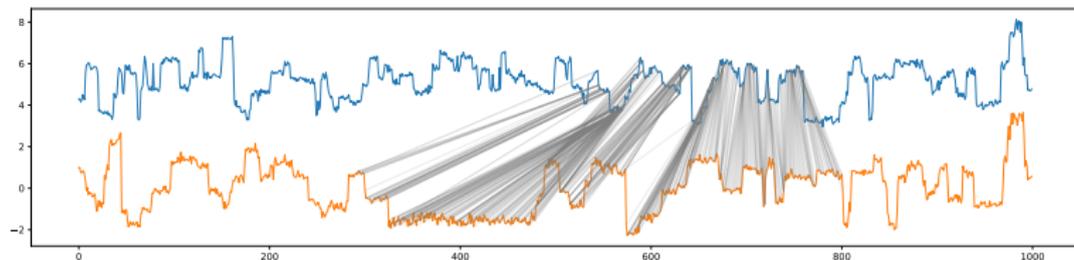
Výsledná skórovacia schéma



LDTW ako miera podobnosti



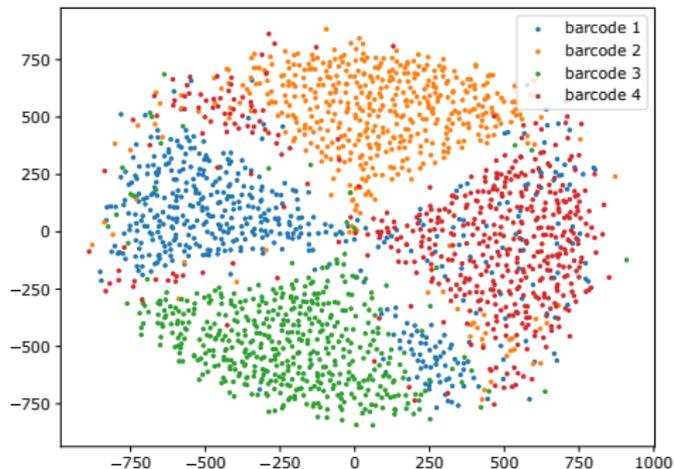
Obr.: Rovnaké barkódy, vysoké skóre zarovnaní.



Obr.: Rôzne barkódy, nízke skóre zarovnaní.

Nasledujúca fáza

- Vieme merať podobnosť čítaní
- Nasledujúca fáza: zhlukovanie čítaní na základe podobnosti signálov

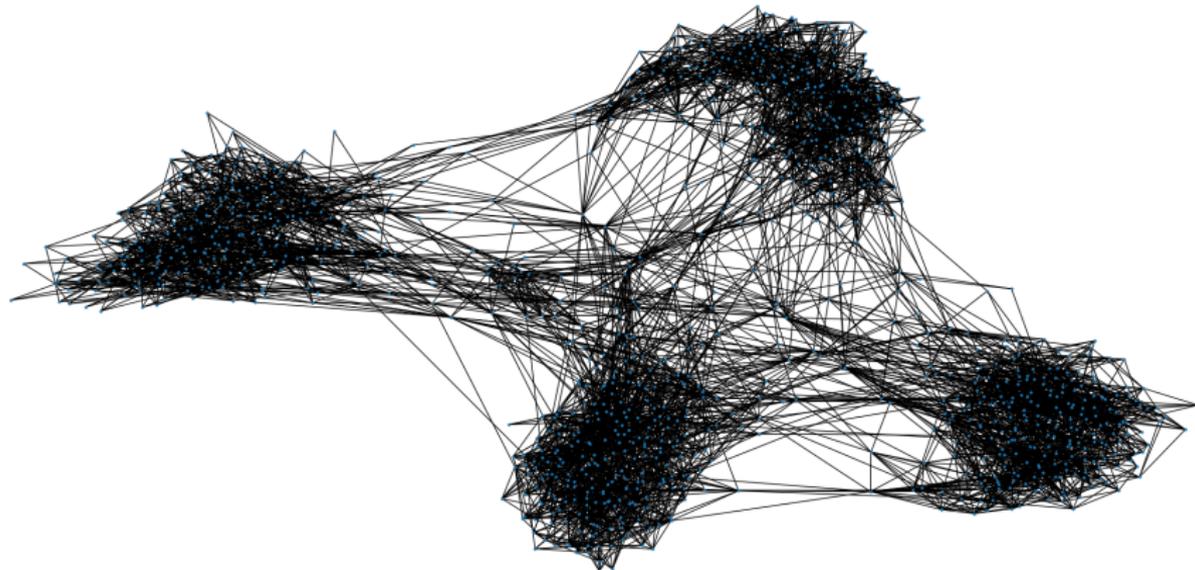


Obr.: Vizualizácia LDTW podobnosti pomocou viacrozmerného škálovania (Kruskal, 1964).

Základná štruktúra algoritmov spektrálneho zhľukovania (von Luxburg, 2007):

- 1 Z matice podobností S si skonštruujeme váhovaný graf G
- 2 Laplacian grafu G : $L = D - S$ ($d_{ii} = \sum_j s_{ij}$ a 0 mimo diag.)
- 3 Vypočítame prvých k vlastných vektorov L a uložíme ich do riadkov matice $U_{k \times n}$
- 4 Použijeme štandardný zhľukovací algoritmus (napr. k -means) na stĺpce matice U

Viacero formulácií, my sme použili variant tzv. *normalizovaného* spektrálneho zhľukovania (Shi a Malik, 2000).



Obr.: Príklad grafu k najbližších susedov ($k = 20$) pre 4 barkódy.

Aplikovať spektrálne zhlukovanie na celú množinu (niekoľkých miliónov) čítaní by bolo pomalé, preto náš algoritmus postupuje nasledovne:

- 1 Výber malej náhodnej vzorky čítaní \mathcal{A}
- 2 Výpočet **LDTW** podobností pre všetky dvojice z \mathcal{A}
- 3 Spektrálne zhlukovanie na \mathcal{A}
- 4 Výber malého počtu reprezentantov z každého zhluku
- 5 Každému ďalšiemu čítaniu je priradená značka na základe podobností k reprezentantom

Testovanie na čítaniach s barkódmi, na ktorých náš model nebol trénovaný.

Experiment	Barkódy	Presnosť(%)	Označkovaných čítaní(%)
1	5, 6, 7	98.77	94.59
2	5, 6, 7, 8	88.69	66.82
3	5, 7, 9, 12	97.41	91.91
4	8, 9	98.95	93.26
5	5, 6, 11, 12	98.60	95.18
6	11, 12	98.50	92.81

Experiment: učenie s učiteľom

- Dovolili sme nášmu modelu pozrieť sa na niekoľko správne označkových čítaní - učenie s učiteľom
- Porovnateľné výsledky s Deepbinnerom
- Rýchlejší a **interpretovateľný** model

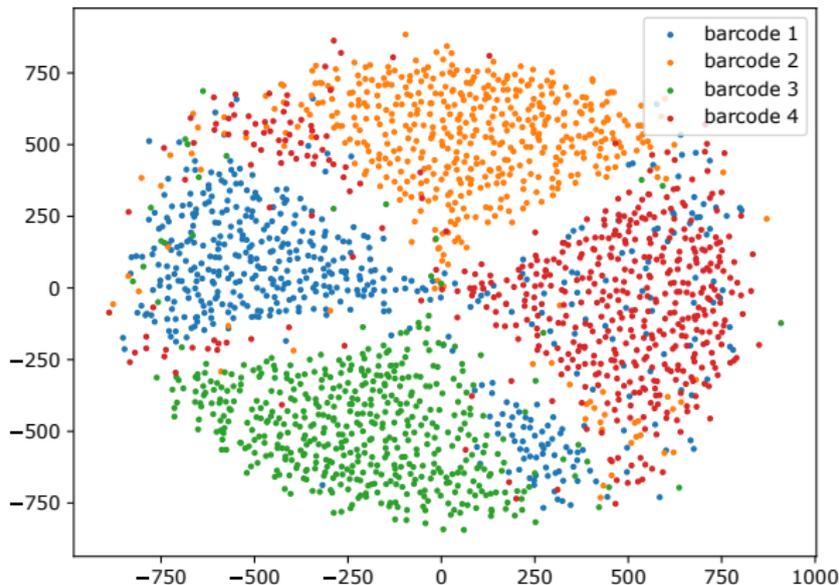
	Presnosť (%)	Označkových (%)
naša metóda	98.39	92.84
Deepbinner (neurónová sieť)	98.41	94.84
Albacore (preložené sekvencie)	97.27	81.10

- Paralelné výpočty na grafickej karte
- Zložitejšia skórovacia funkcia
- Uvažovať históriu signálu
- Zhlukovanie nevyvážených dát (napr. pre spektrálne zhlukovanie Qian a spol., 2013)

Ďakujem všetkým za pozornosť.

Otázka č.1

“Chýba mi uvedenie použitia tejto sady [Native Barcoding Kit] a jej výhod a nevýhod hneď v úvode.” - Ing. Matej Lexa, PhD. (oponent)



Obr.: Vizualizácia LDTW podobnosti pomocou viacrozmerného škálovania.

“Kód v Pythone používa niektoré externé rozširujúce balíčky, ktoré nie sú nikde v texte spomenuté alebo citované. Príkladom môže byť balík HDF5PY...” - Ing. Matej Lexa, PhD. (oponent)

Použité balíčky/knižnice:

- H5PY (<https://github.com/h5py/h5py>)
- scikit-learn (<https://github.com/scikit-learn/scikit-learn>)
- matplotlib (<https://github.com/matplotlib/matplotlib>)
- seaborn (<https://github.com/mwaskom/seaborn>)
- numpy (<https://github.com/numpy/numpy>)