




Transforméry a iné výpočtové metódy pri spracovaní medicínskych signálov

Diplomová práca

Študent: Bc. Daniela Pillárová

Vedúci práce: doc. RNDr. Ľubomír Antoni, PhD.

Košice, 22.5.2025




Charakteristika problému

Pokračovanie **bakalárskej práce**:

Predikcia prognózy pacientov po zástave srdca pomocou analýzy **EEG záznamov** metódami strojového učenia

- Na EEG zázname je možné skúmať určité **charakteristiky**, ktoré hovoria o možnom budúcom neurologickom **stave pacienta**, napr. burst-suppression



DATASET

Všetci pacienti

ICARE_0284
ICARE_0286
ICARE_0296
ICARE_0299
ICARE_0303
ICARE_0306
ICARE_0311
ICARE_0312
ICARE_0313
ICARE_0316
ICARE_0319
ICARE_0320
ICARE_0326
ICARE_0328
ICARE_0332

⋮


Metadáta o pacientovi

Patient: ICARE_0313
Age: 56
Sex: Male
ROSC: 3
OHCA: False
VFib: False
TTM: 33
Outcome: Good
CPC: 1

ICARE_0313.txt
ICARE_0313_05.he
ICARE_0313_05.mat
ICARE_0313_06.he
ICARE_0313_06.mat
ICARE_0313_07.he
ICARE_0313_07.mat
ICARE_0313_08.he
ICARE_0313_08.mat
ICARE_0313_09.he
ICARE_0313_09.mat
ICARE_0313_10.he
ICARE_0313_10.mat

⋮

Vizualizátor .mat súboru



Samotné
hodnoty
jedného EEG
záznamu

CPC skóre

Cerebral Performance Category (CPC) – **kategória výkonu mozgu:**

1: dobré neurologické funkcie a samostatnosť v každodenných aktivitách

2: stredne závažné neurologické postihnutie, ale nezávislé na činnostiach každodenného života

3: ťažké neurologické postihnutie

4: syndróm nereagujúceho vedomia (vegetatívny stav)

5: smrť

Čomu sa bude táto práca venovať?

Navrhnutie a naučenie modelu správne predikovať neurologický budúci stav pacienta na základe jeho EEG záznamov a zozbieraných CPC výsledkov.

Prehľad súčasného stavu riešenia problému

Výsledky súťaže PhysioNet Challenge 2023:

1. miesto: Algoritmus

“Alrhythm“

- EEG a EKG záznamy
- Predspracovanie dát (filtering, normalizácia)
- CatBoost klasifikátor
- 79% presnosť

2. miesto: tím **ComaToss**

- Menšia podmnižina dát
- Augmentácia
- ConvNeXt model
- 79% presnosť

**Ako tento
problém
zvládnu
transforméry?**



Informér

- Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting, **2021**
- Článok získal ocenenie **Best Paper Award** na celosvetovej AAAI konferencii o umelej inteligencii v 2021
- Ide o predikciu **dlhých časových radov**



Best Papers

Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting

Haoyi Zhou, Shanghang Zhang, Jieqi Peng, Shuai Zhang,
Jianxin Li, Hui Xiong, Wancai Zhang

Exploration-Exploitation in Multi-Agent Learning: Catastrophe Theory Meets Game Theory

Stefanos Leonardos, Georgios Piliouras

Mitigating Political Bias in Language Models through Reinforced Calibration (Best AISI Paper)

Ruibin Liu, Chenyan Jia, Jason W Wei, Guangxuan Xu, Lili Wang, Soroush Vos


Informér

Výhody informéra oproti transformérovi:

- + ProbSparse self-attention mechanizmus, ktorý dosahuje **časovú aj pamäťovú zložitosť $O(n \cdot \log(n))$** .

- + Kaskádovitá redukcia vstupu, ktorá **efektívne zvláda dlhé časové sekvencie**.

- + **Predpoveď dekodera je rýchlejšia**, pretože prebieha v jednej doprednej operácii a nie krok za krokom



Navrhnutie vlastnej implementácie

Princíp pozornosti v Best Paper o informéroch:

Algorithm 1 ProbSparse self-attention

Require: Tensor $\mathbf{Q} \in \mathbb{R}^{m \times d}$, $\mathbf{K} \in \mathbb{R}^{n \times d}$, $\mathbf{V} \in \mathbb{R}^{n \times d}$

1: **print** set hyperparameter c , $u = c \ln m$ and $U = m \ln n$

2: randomly select U dot-product pairs from $\mathbf{K}$ as $\bar{\mathbf{K}}$

3: set the sample score $\bar{\mathbf{S}} = \mathbf{Q}\bar{\mathbf{K}}^\top$

4: compute the measurement $\mathbf{M} = \max(\bar{\mathbf{S}}) - \text{mean}(\bar{\mathbf{S}})$ by row

5: set Top- u queries under $\mathbf{M}$ as $\bar{\mathbf{Q}}$

6: set $\mathbf{S}_1 = \text{softmax}(\bar{\mathbf{Q}}\bar{\mathbf{K}}^\top / \sqrt{d}) \cdot \mathbf{V}$

7: set $\mathbf{S}_0 = \text{mean}(\mathbf{V})$

8: set $\mathbf{S} = \{\mathbf{S}_1, \mathbf{S}_0\}$ by their original rows accordingly

Ensure: self-attention feature map $\mathbf{S}$.

Krok 4:

Max-mean measurement

The max-operator in $\mathbf{M}$ is less sensitive to zero values and is numerical stable.

Krok 8: Vrátime ich v pôvodnom poradí podľa riadkov

Krok 7:

- Pre tie **dotazy**, ktoré **neboli vybrané** (nepatria do Top- u), pozornosť **nepočítame**
- Namiesto toho im priradíme jednoduchý **priemer všetkých hodnôt $\mathbf{V}$**
- Je to rýchly odhad, ktorý **nezaťažuje výpočty**, ale stále dodá nejaký výstup

Návrh: experimentovať s inými mierami v kroku 4 algoritmu

Prehľad splnených úloh

- **Nájdenie relevantných vedeckých prác**
 - napríklad: článok Best Paper o informéroch
 - použitie neurónových sietí pri dlhodobých časových radoch
- **Spracovanie prehľadu dostupnej literatúry**
- **Predspracovanie datasetu**
 - Pôvodný dataset veľkosti **1,5 TB** redukovaný na **130 GB** (na základe konzultácií so spoločnosťou VSL Software)
 - Odstránené časové rady s konštatným priebehom
 - Odstránené časové rady s dlhým výpadkom signálu a iné

Plán práce na najbližšie mesiace

- **Implementácia modelu informérov**
- **Navrhnutie vlastnej implementácie** - skladanie modelov, implementácia vlastných zmien, zakomponovanie metadát o pacientoch, ktoré by vedeli klasifikáciu posilniť
- **Testovanie úspešnosti vybraných modelov**
- **Vyhodnotenie výsledkov**



**Ďakujem za
pozornosť!**

