




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

Obhajoba bakalárskej práce

Študent: Daniela Pillárová


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

Košice, 19.6.2024



Motivácia


- **6 miliónov prípadov** náhlej zástavy srdca každoročne.
- Človek, ktorý je resuscitovaný a **upadne do kómy**, môže mať už **po 12 hodinách** trvalé problémy s myslením, pohybmi a pocitmi.
- Od lekárov sa žiada, aby poskytli **skorú prognózu stavu pacienta**.
- V literatúre sa uvádza, že modely strojového učenia v oblasti zdravotníctva často generujú „**falošne pozitívne**“ **príklady**.



Prúdenie krvi ľudským srdcom [1]

Význam EEG (elektroencefalografia)

- Početné **charakteristiky mozgovej aktivity**, ktoré pomáhajú predpovedať prognózu po zástave srdca, sú napríklad:
 - ✓ *zníženie napätia na EEG zázname (redukovaná voltáž),*
 - ✓ *burst-suppression (striedanie úsekov vysokého a nízkeho napätia)*
 - ✓ *a ďalšie stavy podobné záchvatom.*
- Kvalitatívna interpretácia dlhodobého EEG záznamu je však **pracná, nákladná** a vyžaduje si **kontrolu od neurológov s pokročilým tréningom v neurofyziológii**, ktorí nie sú k dispozícii vo väčšine lekárskech stredísk.




Príklad burst-suppression [2]

Ciele bakalárskej práce

1. Vytvoriť **prehľad existujúcich metód strojového učenia** a popísať ich aplikácie **v oblasti analýzy EEG dát.**
2. **Modifikovať existujúce metódy a navrhnúť nové metódy** strojového učenia na predikciu prognózy komatóznych pacientov po zástave srdca.
3. **Implementovať kombináciu navrhnutých metód** strojového učenia a **porovnať úspešnosť navrhnutého riešenia** s inými dostupnými štúdiami.

Schéma postupu





EEG záznamy

- **Cardiac Arrest REsearch (I-CARE)** zhromaždilo súbor EEG údajov a neurologických výsledkov od pacientov v kóme – dataset sprístupnený pre účastníkov súťaže **PhysioNet Challenge 2023**.
- **Sedem nemocníc** zo Spojených štátov a Európy (2xHolandsko, Belgicko, 3xBoston, New Heaven).
- **607 pacientov**, ktorí boli monitorovaní **19 kanálovým dlhodobým EEG**.
- Od každého pacienta je k dispozícii viacero súborov (v závislosti od počtu monitorovacích hodín).
- V každom súbore je vybraných 5 minút dobrej kvality, napríklad súbor **ICARE_0284_06.mat** obsahuje **päť minút** signálových údajov zo **šiestej hodiny** po zástave srdca od pacienta s označením **0284**.
- Vyhodnotenie výsledkov pacienta na základe **Cerebral Performance Category (CPC)** skóre: **1-2** (dobrý výsledok) a **3-5** (zlý výsledok).


Výber EEG záznamov

- Stratifikovaný výber **150 pacientov** zo 607 I-CARE pacientov.
- Od každého pacienta sme použili **1 EEG záznam v prvej monitorovacej hodine**.
- Výber sa skladá z:
 - **65 pacientov s dobrým výsledkom** (CPC 1: 33x, CPC 2: 32x),
 - **85 pacientov so zlým výsledkom** (CPC 3: 19x, CPC 4: 9x, CPC 5: 57x).



Príprava datasetu z EEG záznamov

- Záznamy (pacientov) sme rozdelili na 2 skupiny vzhľadom na prognózu zotavenia po zástave srdca: **dobrá a zlá**.
- Jeden EEG záznam obsahoval **18 jedno-elektrodových záznamov**.
- Na predikciu sme využili prvých **10 sekúnd** z každého záznamu.
- Pri datasete veľkosti 150 sme mali k dispozícii **2700 záznamov** ($18 * 150$ pacientov), kde jeden záznam bol reprezentovaný **1000 numerickými hodnotami** (vzorkovacia frekvencia dát: 100 Hz za 1 sekundu).
- Do iného poľa sme ukladali informáciu či ide o **zlý (0)** alebo **dobrý (1)** záznam.




Implementácia metód strojového učenia

Rozdelenie dát pomocou

5-foldovej krížovej validácie:

- **klasický náhodný les** (Random Forest),
- **náhodný les s váhami kategórií** (Weighted Random Forest),
- **balansovaný náhodný les** (Balanced Random Forest),
- **AdaBoost klasifikátor**,
- **EasyEnsemble klasifikátor**.



Príklad náhodného lesu

Vyhodnotenie modelov (1)

Klasický náhodný les

- F1 skóre je **79 %** s citlivosťou pre dobré záznamy **68 %** a zlé záznamy **88 %**.
- Najlepší dosiahnutý výsledok v metrike F1 skóre.

Triedy	Presnosť	Citlivosť	F1-skóre	Podpora
Dobrý výstup	0.82	0.68	0.75	1170
Zlý výstup	0.79	0.88	0.83	1530
Celkovo	0.803	0.793	0.795	2700

Vyhodnotenie modelov (2)

Náhodný les s váhami kategórií

- F1 skóre je **77 %** s citlivosťou pre dobré záznamy **72 %** a zlé záznamy **81 %**.

Triedy	Presnosť	Citlivosť	F1-skóre	Podpora
Dobrý výstup	0.74	0.72	0.73	1170
Zlý výstup	0.79	0.81	0.80	1530
Celkovo	0.768	0.771	0.770	2700

Vyhodnotenie modelov (3)

Balansovaný náhodný les

- F1 skóre je **77 %** s citlivosťou pre dobré záznamy **87 %** a zlé záznamy **69 %**.
- Najlepší výsledok pri správnej predikcii dobrých záznamov.

Triedy	Presnosť	Citlivosť	F1-skóre	Podpora
Dobrý výstup	0.68	0.87	0.77	1170
Zlý výstup	0.88	0.69	0.77	1530
Celkovo	0.793	0.768	0.770	2700

Vyhodnotenie modelov (4)

AdaBoost klasifikátor

- F1 skóre je **74 %** s citlivosťou pre dobré záznamy **65 %** a zlé záznamy **83 %**.

Triedy	Presnosť	Citlivosť	F1-skóre	Podpora
Dobrý výstup	0.75	0.65	0.69	1170
Zlý výstup	0.75	0.83	0.79	1530
Celkovo	0.750	0.752	0.747	2700

Vyhodnotenie modelov (5)

EasyEnsemble klasifikátor

- Dataset o veľkosti 100 pacientov.
- F1 skóre je **72 %** s citlivosťou pre dobré záznamy **74 %** a zlé záznamy **71 %**.

Triedy	Presnosť	Citlivosť	F1-skóre	Podpora
Dobrý výstup	0.63	0.74	0.68	720
Zlý výstup	0.80	0.71	0.75	1080
Celkovo	0.732	0.722	0.722	1800

Výsledok štatistických testov

- Štatisticky významné rozdiely medzi modelmi sa potvrdili v spojitosti s **EasyEnsemble** klasifikátorom.
- Skúšali sme aj model podporných vektorov a naivného Bayesovho prístupu - dosahovali slabé výsledky.

P	RF	WRF	BRF	AB	EE	SVC	GB
RF	-	0.1624	0.2182	0.0897	0.0216*	0.0001***	0.0003***
WRF	0.1624	-	0.3989	0.4106	0.0062**	0.0000***	0.0000***
BRF	0.2182	0.3989	-	0.4559	0.0013**	0.0000***	0.0000***
AB	0.0897	0.4106	0.4559	-	0.0142*	0.0000***	0.0000***
EE	0.0216*	0.0062**	0.0013**	0.0142*	-	0.0000***	0.0000***
SVC	0.0001***	0.0000***	0.0000***	0.0000***	0.0000***	-	0.0220*
GB	0.0003***	0.0000***	0.0000***	0.0000***	0.0000***	0.0220*	-

* štatisticky významný rozdiel na úrovni <0.05 , ** na úrovni <0.01, *** na úrovni <0.001

Porovnanie výsledkov

- ADMIRAAL, Marjolein M. et al., 2021. Quantitative analysis of EEG reactivity for neurological prognostication after cardiac arrest.
- ZABIHI, Morteza et al., 2023. HyperEnsemble Learning from Multimodal Biosignals to Robustly Predict Functional Outcome after Cardiac Arrest. PhysioNet Challenge 2023.
- ZHENG, Wei-Long et al., 2022. Predicting Neurological Outcome From Electroencephalogram Dynamics in Comatose Patients After Cardiac Arrest With Deep Learning.

Autor	Dataset	Veľkosť	RD	VA	HM	F1-skóre	CD	CZ
Náš model	I-CARE	150	5-fold CV	CPC	RF	79 %	68 %	88 %
Náš model	I-CARE	150	5-fold CV	CPC	BRF	77 %	87 %	69 %
Náš model	I-CARE	150	5-fold CV	CPC	AB	74 %	65 %	83 %
Admiraal et al.	-	134	5-fold CV	CPC	RF	83 %*	46 %	89 %
Zabihi et al.	I-CARE	607	5-fold CV	CPC	CB	79 %	78 %	79 %
Zheng et al.	I-CARE	1038	5-fold CV	CPC	RNN	88 %*	-	-

* vyhodnotenie modelu na metrike AUC-ROC

Záver a ďalšie možnosti práce

Zistili sme že náhodné lesy, ktoré fungujú na princípe rozhodovacích stromov, dosahujú pre tento typ predikcie veľmi dobré výsledky.

Ďalšie možnosti:

- využitie **neurónových sietí** (konvolučné, rekurentné, ...),
- predikcia stavu pacienta na základe numerických hodnôt z EEG záznamov ako aj ich **vizuálnej reprezentácie**,
- využitie **teplotných máp** pre získanie častí z EEG záznamov, ktoré sa najviac podieľajú na výsledku klasifikácie.

Zdroje

[1] *Infarkt myokardu - srdcový infarkt*. [online]. [cit. 10-03-2024]. Dostupné na: <https://www.zdravie.sk/galeria/68-3/clanok-191/srdce-krv/srdce>

[2] NIEDERMEYER, E. et al., 1999. *The Burst-Suppression Electroencephalogram*. In: *Clinical Electroencephalography*. Vol. 30, no. 3, p. 99-105. DOI:10.1177/155005949903000305

GRAHAM, Robert et al., 2015. Strategies to improve cardiac arrest survival: a time to act. In: National Academies Press (US), p. 456. DOI:10.17226/21723

VAN PUTTEN, Michel JAM et al., 2018. Deep Learning for outcome prediction of postanoxic coma. In: EMBEC & NBC 2017. Singapore: Springer Singapore, p. 506-509. DOI: 10.1007/978-981-10-5122-7_127


ZHENG, Wei-Long et al., 2022. Predicting Neurological Outcome From Electroencephalogram Dynamics in Comatose Patients After Cardiac Arrest With Deep Learning. In: *IEEE Transactions on Biomedical Engineering*. Vol. 69, no. 5, p. 1813-1825. DOI: 10.1109/TBME.2021.3139007

ADMIRAAL, Marjolein M. et al., 2021. Quantitative analysis of EEG reactivity for neurological prognostication after cardiac arrest. In: *Clinical Neurophysiology*. Vol. 132, no. 9, p. 2240–2247. ISSN 1388-2457.

ZABIHI, Morteza et al., 2023. HyperEnsemble Learning from Multimodal Biosignals to Robustly Predict Functional Outcome after Cardiac Arrest. *PhysioNet Challenge 2023*.



**Ďakujem za
pozornosť!**



Otázky

- **Popíšte možné úlohy, ktoré by bolo možné riešiť v tejto oblasti v budúcnosti.**
 - regresia pre 5 CPC kategórií, vizuálna reprezentácia (obrázky EEG záznamov)
- **Aké ďalšie aplikácie strojového učenia v oblasti zdravotníctva môžu mať v súčasnosti potenciál?**
 - rádiológia (napr. analýza röntgenových snímok), genetická analýza, personalizovaná medicína,...
- **Ukážte príklad a štruktúru dátovej sady I-CARE. Popíšte, čo jednotlivé údaje predstavujú a aké hodnoty môžu nadobúdať.** (nasledujúci slajd)
- **Čo si viete predstaviť ako ďalší nadväzujúci výskum v tejto oblasti? Môžete špecifikovať konkrétne aspekty, ktoré by stáli za hlbšie preskúmanie alebo navrhnúť nové smery, ktoré by mohli obohatiť a rozšíriť výsledky tejto bakalárskej práce?**
 - skúmanie epilepsie alebo iných poškodení mozgu

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

⋮

Metadátá 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.heg

ICARE_0313_05.mat

ICARE_0313_06.heg

ICARE_0313_06.mat

ICARE_0313_07.heg

ICARE_0313_07.mat

ICARE_0313_08.heg

ICARE_0313_08.mat

ICARE_0313_09.heg



ICARE_0313_09.mat

ICARE_0313_10.heg

ICARE_0313_10.mat

⋮

Vizualizátor .mat súboru



Samotné
hodnoty
jedného EEG
záznamu