

DEEP CONVOLUTIONAL NEURAL NETWORK MODEL FOR CLASSIFICATION OF ATRIAL FIBRILLATION

Barbora Budíková

Master Degree Programme (2), FEEC BUT

E-mail: xbudik05@vutbr.cz

Supervised by: Jakub Hejč

E-mail: hejc@vutbr.cz

Abstract: Atrial fibrillation is a very common heart pathology, which is usually detected from electrocardiogram (ECG). This article presents recognition of atrial fibrillation in ECG using deep convolutional neural network. Data used for training the network includes physiological ECG, atrial fibrillation and nine other pathologies. The detection is performed by algorithm in Python language and is being assessed by accuracy and F1 measure.

Keywords: ECG, atrial fibrillation, convolutional neural network, detection

1 ÚVOD

Fibrilace síní je arytmie s nejednoznačným původem, která může vést k velmi závažným stavům. Incidence této arytmie byla v roce 2010 odhadnuta na 77,5 na 100 000 mužů a 59,5 na 100 000 žen, se znatelným nárůstem oproti roku 1990. S ohledem na často asymptomatický průběh je incidence pravděpodobně podhodnocena. [1] Na křivce EKG se projevuje abnormálními vlnami způsobenými rychlým a chaotickým pohybem síní za nepravidelné aktivity komor. Léčba fibrilace síní (respektive potlačení syndromů) je zpravidla realizována katéetrovou ablací, farmakologicky či elektrickou kardioverzí, v případě pomalého převodu na komory kardiostimulací. Automatická detekce fibrilace síní umožňuje včasnou diagnostiku a tím brání progresi do závažnějších doprovodných stavů, jako jsou dilatace síně, zhoršená čerpací schopnost, tvorba trombů a následná cévní mozková příhoda. **Chyba! Nenalezen zdroj odkazů., 0, Chyba! Nenalezen zdroj odkazů.**

Detekce síňových fibrilací z EKG je zpravidla založena na nepravidelně pravidelných intervalech RR, méně často na abnormálních (či zcela chybějících) vlnách P. V posledních letech je k detekci stále častěji využíváno neuronových sítí (potažmo hlubokých neuronových sítí), které sice vyžadují k trénování velké množství signálů, ale mají mnoho výhod, mezi něž patří především vysoká přesnost detekce a schopnost extrakce vysoce specifických příznaků. [5], [6], [7]

Článek se zabývá návrhem modelu pro detekci fibrilace síní z EKG pomocí hluboké konvoluční neuronové sítě. K detekci je využito 12svodové EKG. Přesnost navržené a naučené sítě je poté testována pomocí nezávislé množiny dat.

2 METODY

2.1 DATA

K práci byla využita data poskytnutá komerčním partnerem. Jde o ambulatorní záznamy 12svodového EKG o délce 10 s, jejichž vzorkovací frekvence je 500 Hz. Signály byly již částečně předzpracovány vyhlazovacími filtry a korekcí nulové izolinie. Součástí datového souboru je anotace přiřazující každému záznamu minimálně jeden z rytmů či patologií. Data byla nejdříve adekvátně předzpracována, po předzpracování bylo realizováno trénování navrženého modelu, jeho průběžná validace a na závěr testování. K trénování a validaci bylo využito 6 884 záznamů EKG, dalších 910 záznamů bylo využito k testování. Pro účely práce byla anotace záznamů upravena


na tři skupiny – sinusové rytmy (dále SR), fibrilace síní (dále FS) a ostatní arytmie a patologie (dále OA, konkrétně jde o supraventrikulární (194) a ventrikulární (102) tachykardie, AV blokádu (250) a raménkovou blokádu (434), síňové (418) a komorové (413) extrasystoly a nezařazené či zašuměné záznamy (2271)), do nichž byla dále uvážena klasifikace. Počty záznamů v jednotlivých skupinách v učební a testovací množině dat jsou shrnuty v Tabulce 1.

Tabulka 1: Počty záznamů ve skupinách a množinách dat

	SR	FS	OA
Učební množina	5 942	553	389
Testovací množina	690	110	110

2.2 PŘEDZPRACOVÁNÍ

Průběh předzpracování je znázorněn na Obrázku 1. Pro práci je využito všech 12 svodů, jeden trénovací vzor je tedy na počátku předzpracování velikosti 12 x 5 000.



Obrázek 1: Schéma předzpracování dat

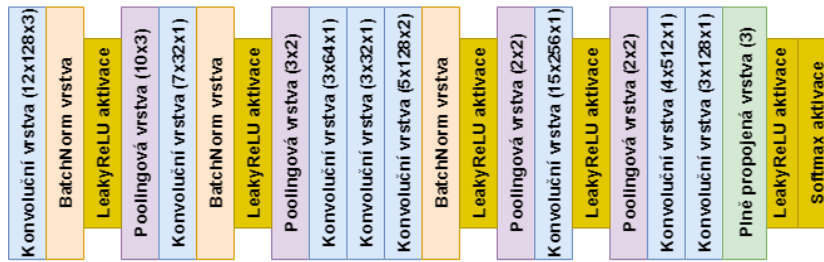
Po načtení dat jsou záznamy podvzorkovány s faktorem 4 pro snížení velikosti dat za maximálního zachování informace. Faktor 4 byl zvolen s ohledem na vzorkovací frekvenci a frekvenční rozsah jednotlivých vln a kmitů EKG. Poté jsou data metodou random sampling rozdělena do trénovací a validační množiny, s ohledem na četnosti zastoupení záznamů v jednotlivých třídách po rozdělení v poměru 7:3. Rozdělení proběhlo tak, aby poměr zastoupení klasifikačních tříd byl v obou množinách stejný. V trénovací množině dat byla provedena augmentace tříd FS a OA, protože zastoupení tří skupin není rovnoměrné. Augmentace byla realizována metodou Random Resampling a to výběrem bez opakování. Počty signálů v jednotlivých skupinách a množinách na konci předzpracování znázorňuje Tabulka 2.

Tabulka 2: Počty signálů v jednotlivých skupinách a množinách na konci předzpracování

	SR	FS	OA
Trénovací množina	4 160	4 548	4 433
Validační množina	1 782	165	116

2.3 KLASIFIKAČNÍ MODEL


Model je založen na konvoluční neuronové síti, část architektury a parametrů je převzata z [5]. Model byl implementován v programovacím jazyce Python (verze 3.7.0), k tvorbě modelu bylo využito knihovny PyTorch (verze 1.3). Architekturu navržené sítě a parametry jednotlivých vrstev znázorňuje Obrázek 2. Parametry modelu byly na počátku nastaveny na základě studia literatury [5], později optimalizovány na základě lepších výsledků prohledáváním stavového prostoru.



Obrázek 2: Architektura navržené sítě (parametry v závorce u konvolučních vrstev značí velikost filtru × počet výstupních kanálů × překryv, u poolingových vrstev velikost filtru × překryv, u plně propojených vrstev počet neuronů)

2.4 PRŮBĚH UČENÍ

Učení proběhlo v 30 epochách, počáteční krok učení byl 0,0005, data byla načítána v dávkách o velikosti 1 000 trénovacích vzorů. Hyperparametry byly zvoleny s ohledem na dosažení nejlepších výsledků v prohledávaném stavovém prostoru. Průběh učení byl hodnocen pomocí přesnosti (Přesnost = Správně klasifikované vzorky/Všechny vzorky) a F1 skóre. Vypočtené metriky v průběhu učení pro trénovací a validační množinu dat jsou znázorněny na Obrázku 3.



Obrázek 3: Přesnost (vlevo) a F1 skóre (vpravo) pro trénovací a validační množinu v průběhu učení sítě

3 VÝSLEDKY

Matice záměn pro trénovací a validační množiny dat v poslední epoše učení znázorňuje Tabulka 3. Přesnost klasifikace na konci učení je pro trénovací množinu 97,3 % a pro validační množinu 87,7 %. F1 skóre pro fibrilaci síní v trénovací množině je 96,9 %, ve validační množině 54,3 %.

Tabulka 3: Matice záměn pro trénovací (vlevo) a validační (vpravo) množiny v poslední epoše učení

		Predikovaná skupina								
		SR	FS	OA	SR	FS	OA	SR	FS	OA
Anotovaná skupina	SR	3 886	218	56	1 611	126	45			
	FS	24	4 156	8	19	117	29			
	OA	22	17	4 394	12	23	81			

Matice záměn pro testovací množinu je v Tabulce 4. Přesnost klasifikace v testovací množině je 79,1 %, F1 skóre pro detekci fibrilace síní je 58,7 %.

Tabulka 4: Matice záměn pro testovací množinu dat

	Predikovaná skupina			
		SR	FS	OA
Anotovaná skupina	SR	632	29	29
	FS	23	66	21
	OA	68	20	22

4 DISKUZE A ZÁVĚR

Cílem práce byl návrh modelu pro klasifikaci detekce fibrilace síní pomocí hluboké konvoluční neuronové sítě. Detekce je v testovací množině dat realizována s přesností 79,1 % a F1 skóre 58,7 %. Přesnost detekce může být snižována několika faktory. Zatímco anotace trénovací a validační množiny dat byly validovány nezávislými odborníky, u anotací testovací množiny k takové validaci nedošlo a je tedy možné, že je anotace zatížena chybami více než validované množiny. Fibrilace síní zároveň mohou být doprovázeny některými dalšími patologiemi, které se na křivce EKG projeví a zkreslí proces učení. I přes tyto faktory dosahuje výsledný model velmi dobrých klasifikačních výsledků. V průběhu učení dochází k nežádoucí oscilaci přesnosti i F1 skóre.

Při srovnání s jinými autory lze pozorovat nižší dosažené přesnosti (83 % vs. 58,7 %), je nicméně třeba uvážit rozdílnosti v cílech, datech a metrice hodnocení přesnosti. [8]

REFERENCE

- [1] CHUGH Sumeet S., Rasmus HAVMOELLER, Kumar NARAYANAN et al. *Worldwide Epidemiology of Atrial Fibrillation*. *Circulation* [online]. 2014, **129**(8), 837–847. Dostupné z: doi:10.1161/CIRCULATIONAHA.113.005119
- [2] HAMPTON, John R. *EKG stručně, jasně, přehledně; Překlad 7. vydání*. 1. české vydání. Praha: Grada Publishing a.s., 2013. ISBN 978-80-247-4246-5.
- [3] BENNETT, David H. *Srdeční arytmie praktické poznámky k interpretaci a léčbě; Překlad 8. vydání*. 1. vydání. Praha: Grada Publishing a.s., 2014. ISBN 978-80-247-5134-4.
- [4] LUKL, Jan, Alan BULAVA, Miroslava BENEŠOVÁ, et al. *Fibrilace síní*. 1. vydání. Praha: Grada Publishing a.s., 2009. ISBN 978-80-247-2768-4.
- [5] KENNEDY, Alan, Dewar D FINLAY, Daniel GULDENRING, et al. *The accuracy of beat-interval based algorithms for detecting atrial fibrillation*. In: 2015 Computing in Cardiology Conference (CinC): 2015 [online]. 2015, s. 893–896. ISSN 2325-8861. Dostupné z: doi:10.1109/CIC.2015.7411055
- [6] RUAN, Xiuhua, Changchun LIU, et al. *Automatic detection of atrial fibrillation using R-R interval signal*. In: 2011 4th International Conference on Biomedical Engineering and Informatics (BMEI): 2011 [online]. 2011, s. 644–647. ISSN 1948-2922. Dostupné z: doi:10.1109/BMEI.2011.6098492
- [7] YILDIRIM, Özal, Paweł PŁAWIAK, Ru-San TAN et al. *Arrhythmia detection using deep convolutional neural network with long duration ECG signals*. *Computers in Biology and Medicine* [online]. 2018, 102, 411–420. ISSN 0010-4825. Dostupné z: doi:10.1016/j.compbio.2018.09.009
- [8] results.csv - *AF Classification from a Short Single Lead ECG Recording - The PhysioNet Computing in Cardiology Challenge 2017* [online]. [vid. 2020-03-14]. Dostupné z: <https://physionet.org/content/challenge-2017/1.0.0/results.csv>