



ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE
FAKULTA ELEKTROTECHNICKÁ

Chlum u Třeboně, 13. - 16. 9. 2021

**Workshop lékařské
elektroniky a bioinformatiky
2021**

SBORNÍK

Editoři:

Ing. Jan Havlík, Ph.D.

Ing. Zdeněk Horčík

Katedra teorie obvodů
Fakulta elektrotechnická
České vysoké učení technické v Praze

Technická 2
166 27 Praha 6

Vydalo: České vysoké učení technické v Praze

Zpracovala: Fakulta elektrotechnická

Kontaktní adresa: Jan Havlík, Katedra teorie obvodů, FEL ČVUT v Praze, Technická 2, 166
27 Praha 6

První vydání elektronicky

ISBN 978-80-01-06830-4

Počet stran: 76

ORGANIZAČNÍ VÝBOR

Ing. Jan Havlík, Ph.D.

Ing. Zdeněk Horčík

Bc. Lukáš Daněk

Bc. Filip Šlapal

Konference byla financována z grantu SVK 24/21/F3 uděleného ČVUT v Praze.

PŘEDMLUVA

Vážené kolegyně a kolegové,

držíte v ruce sborník prezentací z devátého ročníku workshopu studentů nastupujících do prvního ročníku studia na Fakultě elektrotechnické ČVUT v Praze, studijního programu Lékařská elektronika a bioinformatika, pořádaného společně pro nastupující bakalářské i magisterské studenty. Příspěvky, které jsou v tomto sborníku prezentovány, představují výsledky bakalářských prací studentů. Jejich prezentace před kolegy studentům magisterského i bakalářského studia umožňují seznámit se navzájem hned zkraje studia s prací svých nových kolegyň a kolegů, přitom studentům bakalářského studia pak především získat prvotní představu o tom, jak by měl po třech letech studia vypadat výsledek jejich práce. Získané poznatky a zkušenosti mohou studenti tvůrčím způsobem využít v dalším studiu. Minulé ročníky konference jasně ukázaly, že takovýto způsob společného sdílení informací hned zkraje studia je pro jeho pokračování velkým přínosem. Studentům napomáhá v rychlejší orientaci ve studovaném oboru, který svojí šíří, rychlým rozvojem a multidisciplinárním pojetím patří k jednému z obtížnějších.

Jan Havlík

Zdeněk Horčík

OBSAH

PŘEDMLUVA	4
OBSAH	5
 <i>PREZENTACE PŘÍSPĚVKŮ NA ZÁKLADĚ BAKALÁŘSKÝCH PRACÍ</i>	
Beckert Adam	
<i>AUTOMATED MUSIC GENERATION</i>	6
Bendová Karolína	
<i>HODNOCENÍ NESTABILITY IRITAČNÍ SÍTĚ POMOCÍ INRAKRANIÁLNÍHO EEG</i>	14
Hladíková Hana	
<i>KLASIFIKACE TREMORU U PACIENTŮ S ROZTROUŠENOU SKLERÓZOU</i>	21
Kanout Fádi	
<i>EFEKTIVNÍ KONEKTIVITA INTRAKRANIÁLNÍHO EEG PŘI ŘEŠENÍ KOGNITIVNÍCH ÚLOH</i>	27
Konicarová Carmen-Anna	
<i>KLASIFIKACE SUBTHALAMICKÉHO JÁDRA Z MIKROELEKTRODOVÝCH ZÁZNAMŮ</i>	33
Macková Kateřina	
<i>HODNOCENÍ HYPOMETABOLISMU V OBRAZECH POZITRONOVÉ EMISNÍ TOMOGRAFIE</i>	40
Mašková Barbora	
<i>GENERACE AUDIO SIGNÁLŮ POMOCÍ MIKROŘADIČE ŘADY STM32</i>	46
Mühlfeitová Lucie	
<i>SUBJEKTIVNÍ TESTOVÁNÍ KVALITY NAHRÁVKY ŘEČI S VODOZNAKEM</i>	53
Růžička Lukáš	
<i>AUTOMATIZOVANÉ ZPRACOVÁNÍ EKG POMOCÍ NEURONOVÝCH SÍTÍ</i>	59

AUTOMATED MUSIC GENERATION

Adam Beckert

FIT ČVUT v Praze, Thákurova 9, Praha 6

Abstrakt

Bakalářská práce se zabývá algoritmickým generováním hudby. Práce shrnuje aktuální řešení automatické kompozice a jejich výsledky. Jsou zde převážně zmíněné rozdíly mezi jednotlivými přístupy a jejich nevýhodami. V další části jsou popsány koncepty z hudební teorie, teorie jazyků a základy pravděpodobnosti a dalších modelů, které jsou dále využity v praktické části.

Praktická část definuje omezení na skladby použité pro generování. Skladby jsou definované ve formátu MIDI. Dále je práce rozdělena do dvou částí: analýzy skladeb a procesu generování. U analýzy je použito znalosti z teorie hudby pro reprezentaci a abstrakci skladeb. Následně s použitím Markovových řetězců je vytvořen model, který slouží ke generování nové skladby.

Testování je následně provedeno se čtyřmi písněmi a vzniklé skladby jsou posouzeny třetí osobou za pomoci předem definovaných charakteristik.

Klíčová slova

hudba; teorie hudby; generování hudby; stavové systémy; Scala; Markovovy řetězce; bezkontextová gramatika

Automated music generation

Bakalářská práce

Adam Beckert
Vedoucí práce: doc. RNDr. Pavel Surynek, Ph.D.

Fakulta informačních technologií
České vysoké učení technické v Praze

29. 08. 2021



1 Cíle práce

2 Návrh řešení

3 Realizace

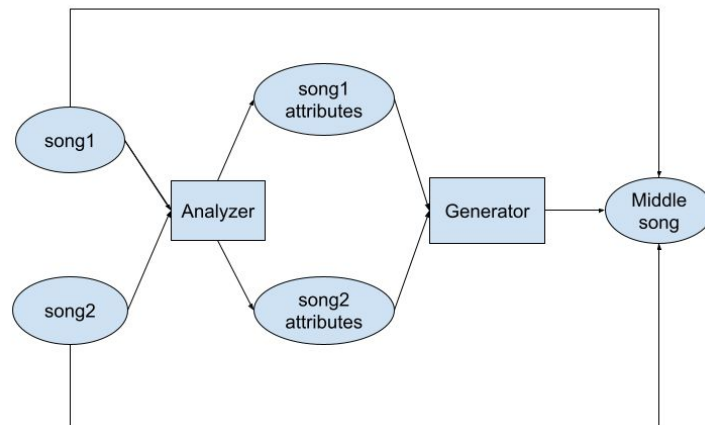
Cíle práce

- Rešerše existujících řešení
- Návrh řešení propojení skladeb
- Implementace generátoru
- Otestování řešení

Zaměření na:

- Znalostní systémy - tonalita
- Markovovy řetězce
- Bezkontextová gramatika

Design implementace



Realizace

- předzpracování
- analýza
- generování
- testování

Předzpracování

- MIDI reprezentace
- simplifikace pro splnění předpokladů
- rozdělení na melodii a doprovod
- extrakce tóniny

Analýza: doprovod

- získání dat z databáze
- dotrénování -> 1st-order Markov Chain
- rytmus je vynechán

Analýza

melodie

- délka a výška tónu
- stochastická bezkontextová gramatika - generická melodie
- zvlášť : vyska: 3rd-order ,rytmus: 1st - Markov chain (po taktech)
- dohromady: 2nd-order Markov chain

Generování

- rozdělení na tři části
- melodie a doprovod řešeny zvlášť

Testování

- Výběr 4 písní: celkem 24 "mezipísní"
- Dva typy testování: blind test, quality test
- Hodnocení - poslouchatelnost, reálnost, zajímavost, podobnost, plynulost
- škála od 1-5

Výsledky

- společné délka + výška lepší výsledky
- dohromady: příjemnější na poslech
- zvlášť: zajímavější a plynulejší přechod

Shrnutí

- propojení dvou písní
- reprezentace skladeb v tóninách
- použití markovových řetězců na doprovod i melodii
- generování generické melodie podle vlastností tonality

Konec

Děkuji za pozornost!

HODNOCENÍ NESTABILITY IRITAČNÍ SÍTĚ POMOCÍ INRAKRANIÁLNÍHO EEG

Karolína Bendová

FEL ČVUT v Praze, Technická 2, Praha 6

Abstrakt

Iritační zóna je síť vzájemně propojených skupin asynchronně generujících interiktální (mezizáchvatovou) epileptiformní aktivitu. Typickou aktivitou pro iritační zónu jsou interiktální epileptiformní výboje (IED). Iritační zóna je rozdělena do podoblastí, tzv. klastrů. Cílem této práce je získat bližší popis iritační zóny analýzou parametrů interiktální epileptiformní aktivity pacientů diagnostikovaných fokální kortikální dysplázií (FCD).

Pro tuto práci byly použity mnohahodinové iEEG záznamy 47 pacientů. Mezi sebou byly porovnávány parametry IED u pacientů rozdělených dle diagnostikovaného podtypu FCD I a FCD II. V rámci sub-regionální organizace iritační zóny byly zvláště analyzovány IED patřící pouze do prvního klastru. Pro tato vybraná IED byla následně zkoumána fluktuace výskytu IED mezi podtypy FCD.

Výsledky ukazují, že frekvence výskytu IED podtypu FCD II je vyšší oproti FCD I ($p < 0,005$). Závislost IED na cirkadiálních rytmech nebyla potvrzena ($p > 0,05$). Vybranými parametry nebyla potvrzena rozdílná fluktuace výskytu IED přiřazených do prvního klastru mezi podtypy FCD I a FCD II ($p > 0,05$).

Bylo potvrzeno, že četnost IED může být v budoucnu využita jako jeden z faktorů stratifikujících podtypy FCD, na rozdíl od dynamiky výskytu IED.

Klíčová slova

fokální kortikální dysplázie; iEEG; iritační zóna; IED; dynamika klastru

Hodnocení nestability iritační sítě pomocí intrakraniálního EEG

bakalářská práce




Karolína Bendová

Vedoucí: Ing. Radek Janča, Ph.D.


7.6.2021

EPILEPSIE

FCD = fokální kortikální dysplázie



ZJEDNODUŠENÉ SCHÉMA EPILEPTICKÝCH ZÓN



Hodnocení nestability iritační sítě pomocí intrakraniálního EEG Karolína Bendová


3

IRITAČNÍ ZÓNA

SUB-REGIONÁLNÍ ORGANIZACE

IED = interiktální epileptiformní výboj

nejvýznamnější zdroj IED
= PRVNÍ KLASTR




Hodnocení nestability iritační sítě pomocí intrakraniálního EEG Karolína Bendová


4

FREKVENCE VÝSKYTU IED

FCD = fokální kortikální dysplázie
IED = interiktální epileptiformní výboj





\sum IED kanálu



délka monitorace

Hodnocení nestability iritační sítě pomocí intrakraniálního EEG 5
Karolína Bendová

DYNAMIKA KLASTRU



$$\Delta_{evt}(n) = t_{evt}(n+1) - t_{evt}(n)$$

Hodnocení nestability iritační sítě pomocí intrakraniálního EEG 6
Karolína Bendová

VÝSLEDKY

frekvence výskytu IED

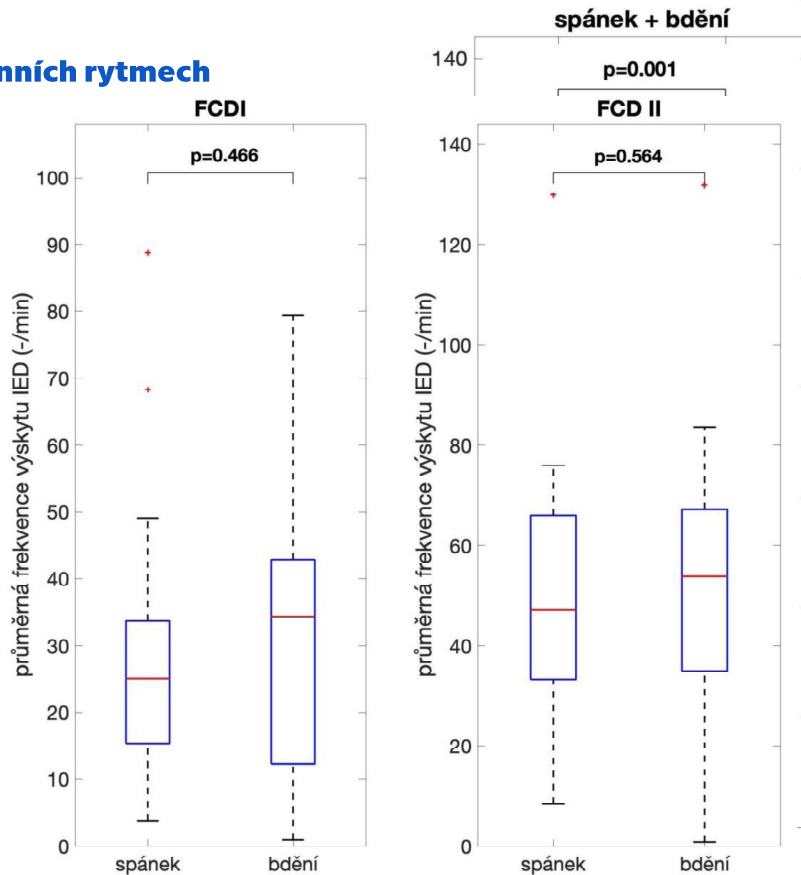


Hypotézy:

- závislost na cirkadiálních rytmech
- FCD I vs. FCD II
- Závislost na cirkadiálních rytmech a podtypu FCD

FCD = fokální kortikální dysplázie


IED = interiktální epileptiformní výboj



7

VÝSLEDKY

frekvence výskytu IED

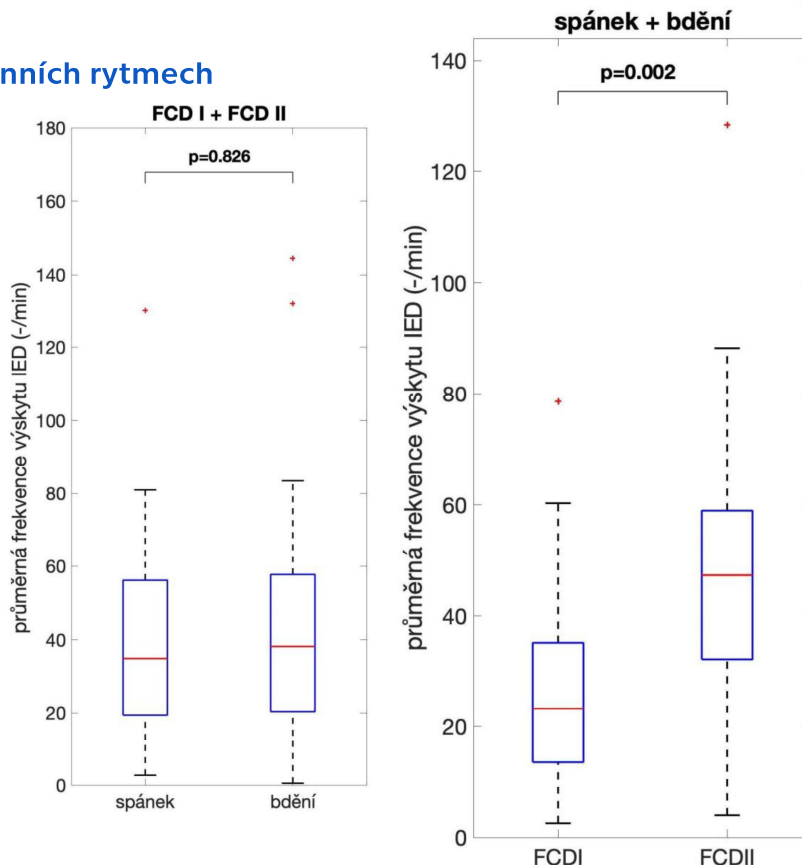


Hypotézy:


- závislost na cirkadiálních rytmech
- FCD I vs. FCD II

FCD = fokální kortikální dysplázie

IED = interiktální epileptiformní výboj



8



Hypotéza:

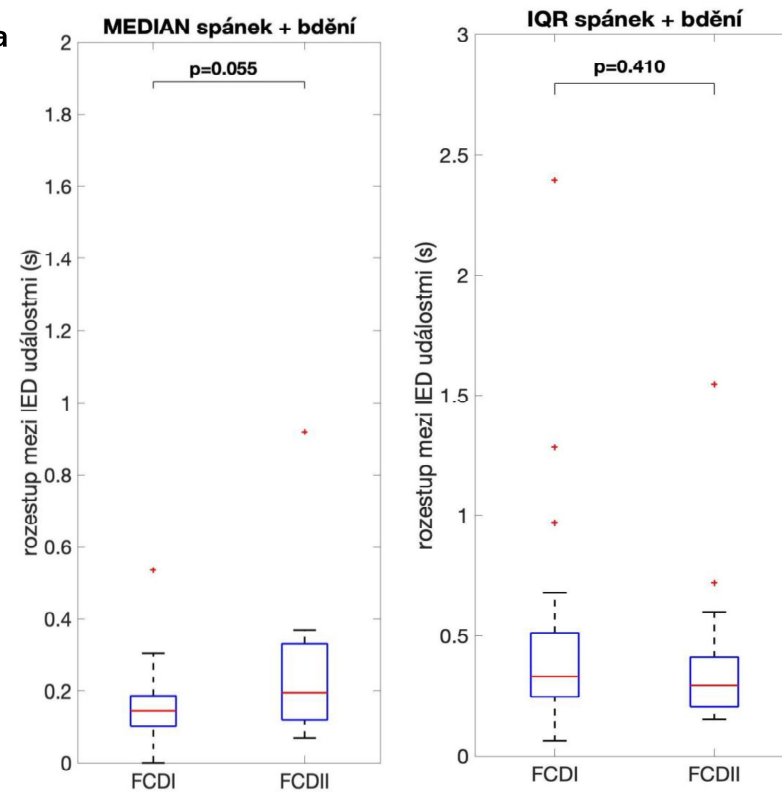
Rozdílná fluktuace mezi FCD I a FCD II v prvním klastru.

Parametry:

IQR
MEDIÁN

FCD = fokální kortikální dysplázie

IED = interiktální epileptiformní výboj



9

SHRNUTÍ

- **Potvrzeno:**
 - FCD II vyšší četnost IED oproti FCD I
- **Zamítnuto:**
 - Závislost četnosti IED na cirkadiánních rytmech
 - Variabilita ve výskytu IED mezi podtypy FCD
- **Využitelnost:**
 - Četnost IED → faktor stratifikující podtyp FCD



ČVUT

ČESKÉ VYSOKÉ
UČENÍ TECHNICKÉ
V PRAZE

DĚKUJI ZA POZORNOST



KLASIFIKACE TREMORU U PACIENTŮ S ROZTROUŠENOU SKLERÓZOU

Hana Hladíková

FEL ČVUT v Praze, Technická 2, Praha 6

Abstrakt

Práce se zabývá klasifikací osob do třídy zdravý/nemocný z pohledu roztroušené sklerózy. Jako parametry klasifikace jsou použity výsledky měření posturálního tremoru akcelerometrem na obou horních končetinách se zavřenými i otevřenými očima. Dále jsou použity výsledky funkčních testů horních končetin – devítikolíkový test a test rotace mince. Pro vlastní klasifikaci byly použity algoritmy K-means a K-NN.

Na vzorku 15 osob s roztroušenou sklerózou a 18 osob z kontrolní skupiny bylo pomocí algoritmu K-means dosaženo klasifikační úspěšnosti 82 % na konkrétní trojici parametrů – devítikolíkový test pro levou i pravou horní končetinu a kumulativní hodnota PSD vyšetření tremoru akcelerometrem ve fixním pásmu 0–4 Hz pro pravou horní končetinu se zavřenými očima. Algoritmus K-NN na tak malém vzorku dat nedosahoval žádných průkazných výsledků.

Klíčová slova

roztroušená skleróza, tremor, K-means, K-NN

Klasifikace tremoru u pacientů s roztroušenou sklerózou

Hana Hladíková

Vedoucí: Ing. Jan Havlík, Ph.D.

2021



1


Cíle práce

- ▶ Navrhnout klasifikátor pro klasifikaci akcelerometrických dat osob do tříd zdravý/nemocný z pohledu roztroušené sklerózy
- ▶ Ověřit použitelnost navržených algoritmů na reálných datech

2

Roztroušená skleróza a tremor

- ▶ Autoimunitní onemocnění CNS
 - ▶ Prevalence v ČR 170-200 pacientů na 100 000 obyvatel
- ▶ Tremor postihuje až 75 % pacientů
- ▶ Včasná diagnóza je klíčová




Zdroj: <https://www.mentem.cz/blog/neuron/>

3

Vstupní data

- ▶ 33 osob - 15 s RS, 18 z kontrolní skupiny
- ▶ Akcelerometrické vyšetření tremoru
 - ▶ Levá/pravá HK, otevřené/zavřené oči
 - ▶ PSD_{max} , PSD_{7Hz} , PSD_{0-4Hz}
- ▶ Klinické funkční testy horních končetin
 - ▶ Devítikolíkový test
 - ▶ Test rotace mince



4

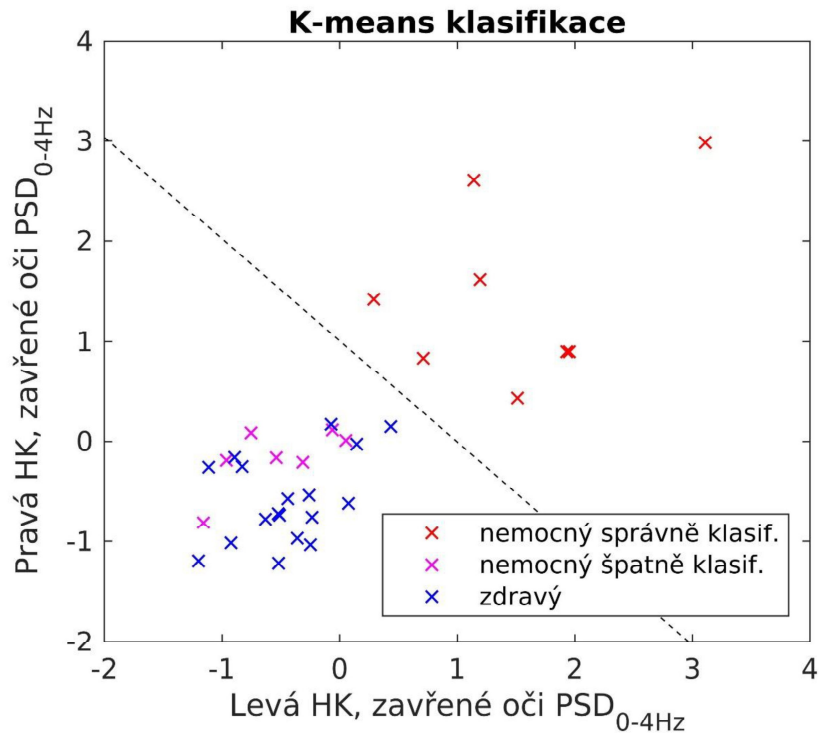
Použité metody

- ▶ Standardizace dat
- ▶ K-means klasifikátor
 - ▶ Bez učitele
 - ▶ Známé číslo K
- ▶ K-NN klasifikátor
 - ▶ S učitelem
 - ▶ Robustní vůči šumu
 - ▶ Náhodný výběr trénovací množiny, leave-one-out
- ▶ Různý způsob výpočtu vzdálenosti

K-means klasifikace

- ▶ Samostatné parametry i jejich kombinace
- ▶ Jednotlivé parametry
 - ▶ V několika případech 76% úspěšnost
- ▶ Nejlepší výsledek - 82 % správně klasifikovaných
 - ▶ Devítikolíkový test levá i pravá HK
 - ▶ PSD_{0-4Hz} pravá HK se zavřenýma očima

K-means klasifikace



7

K-NN klasifikace

- ▶ Různá K
- ▶ Náhodný výběr trénovací množiny
 - ▶ Úspěšnost 20-100 %
- ▶ Leave-one-out klasifikace
 - ▶ Jednotlivé parametry - až 85 %
 - ▶ Kombinace parametrů - až 94 %

8

Diskuse

- ▶ K-means algoritmus
 - ▶ Vybrán jako výsledný klasifikátor
- ▶ K-NN algoritmus
 - ▶ Potřeba více dat
- ▶ Zkoumaná skupina osob
- ▶ Dominantní HK
- ▶ Nejlepší vzdálenost - Čebyševova

Závěrečné zhodnocení

- ▶ Provedená klasifikace
 - ▶ K-means, K-NN
- ▶ Testování různého způsobu výpočtu vzdálenosti
- ▶ K-means výsledný klasifikátor
- ▶ Možné pokračování
 - ▶ Vytvoření větší databáze osob s výsledky vyšetření
 - ▶ Použití jiných klasifikátorů

EFEKTIVNÍ KONEKTIVITA INTRAKRANIÁLNÍHO EEG PŘI ŘEŠENÍ KOGNITIVNÍCH ÚLOH

Fádi Kanout

FEL ČVUT v Praze, Technická 2, Praha 6

Abstrakt

V lidském mozku je stále mnoho neobjasněných procesů, jedním z nich je dynamika pozornosti. Pozornost se dá zhruba rozdělit na externí, se kterou souvisí aktivace neuronové sítě Central Executive network (CEN), a interní, která souvisí s aktivitou Default Mode network (DMN). Dynamika těchto sítí byla zkoumána s pomocí unikátních záznamů intrakraniálního EEG (iEEG), měřeného v hloubce mozku u pacientů s farmakorezistentní epilepsií, kteří dobrovolně podstoupili kognitivní test zaměřený na změny pozornosti z vnitřní na vnější, a naopak. Pro objasnění dynamiky byla vyhodnocována efektivní konektivita mezi CEN a DMN. Pro tento účel byla zvolena metoda direct Directed Transfer function (dDTF). Nejdůležitějším zkoumaným úsekem iEEG signálu přitom byl čas přepnutí na druhý typ pozornosti.

Pro výzkum okolí tohoto časového úseku byl tedy navržen a rozšiřován algoritmus, který rozřadí zaznamenané iEEG signály do zkoumaných sítí, signály filtruje, segmentuje, rozdělí do frekvenčních pásem, a spočítá matice dDTF hodnot a výkonové spektrální hustoty pro jednotlivé pacienty. Tyto výsledky pak byly vyhodnocovány statistickými testy jako je z-test, U-test a korelace efektivní konektivity s energií.

V práci byly nalezeny a popsány signifikantní změny efektivní konektivity a energie mezi DMN a CEN v čase pro přenos v nižších frekvenčních pásmech do 25 Hz. Bylo zjištěno, že u těchto sítí skutečně dochází k měřitelnému rozdílu v toku informace během přepínání vnitřní a vnější pozornosti.

Klíčová slova

Default Mode network, Central Executive network, efektivní konektivita, změna vnější a vnitřní pozornosti, intrakraniální EEG

Efektivní konektivita intrakraniálního EEG při řešení kognitivních úloh

Bakalářská práce:

Fádi Kanout

Vedoucí práce:

Ing. Radek Janča, Ph.D.

Oponent:

Ing. Anna Pidnebesna, Ph.D.

ČVUT FEL



Lékařská elektronika a bioinformatika

07.06.2021




Mozkové funkční sítě


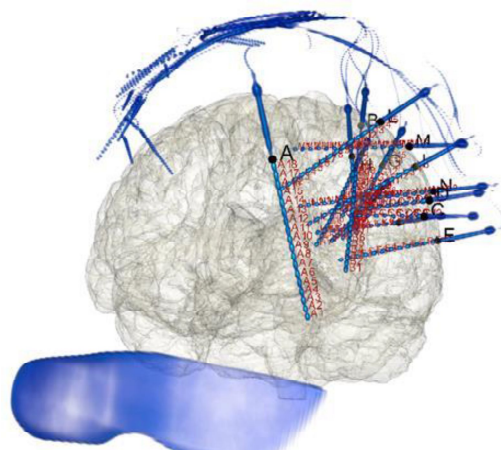
- Řešení úkolu
→ Interní a externí pozornost
- Kde?
 - DMN (Interní pozornost)
 - CEN (Externí pozornost)





Funkční vs. efektivní konektivita



Časové rozlišení
~1 s




Síťový model



Časové rozlišení
~1 ms

3



Testovací protokol



- 6 pacientů
- Průměrně 100 opakování (6 minut)
- iEEG:
 - $F_s=512/2000$ Hz
 - Průměrně 27 kanálů v DMN
 - Průměrně 15 kanálů v CEN

4

direct Directed Transfer Function (dDTF)




Síťový model

- Úloha:
- -3 s : +3 s (od změny úlohy)
- Časová segmentace (0.5 s, 90% překryv)
- *Průměr přes typy úlohy* →
- $dDTF_{E-I}(ch \in I, ch \in E, f, t)$


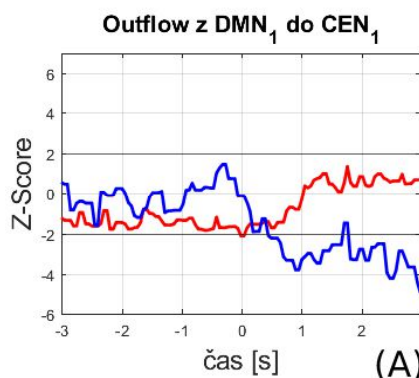
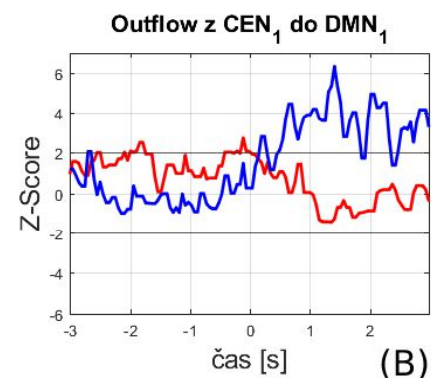


5

Relativní změna konektivity

- Referenční I-úkol
- z-test






2-12 Hz



6

Výsledky

- Komplementární trendy
- Signifikantní změny
 - 2-25 Hz



Energie v DMN

- klesá konektivita DMN → CEN
- roste konektivita CEN → DMN

7

Shrnutí

- Parametrizace iEEG pomocí dDTF
- Stanovení relativní změny E-I, I-E (z-score)
- Výsledky prokázaly:
 - Změna konektivity
 - Přepínání mezi sítěmi (2-25 Hz)
 - Prokázána role CEN, DMN sítí v úlohách I/E
- Další využití:
- Aplikovat metodu na popis dalších sítí (SN aj.)

8

Děkuji za pozornost

KLASIFIKACE SUBTHALAMICKÉHO JÁDRA Z MIKROELEKTRODOVÝCH ZÁZNAMŮ

Carmen-Anna Konicarová

FEL ČVUT v Praze, Technická 2, Praha 6

Abstrakt

Hluboká mozková stimulace je neurochirurgická metoda, spočívající v trvalé elektrické stimulaci vybraných mozkových jader. V případě Parkinsonovy choroby jde nejčastěji o stimulaci subthalamického jádra za účelem zmírnění třesu i dalších příznaků. K umístění této stimulační elektrody je však nutná přesná lokalizace mozkových jader, kterou v praxi nejčastěji provádí zkušený neurolog ruční anotací z elektrofyziologických záznamů během operace. Cílem této práce je implementace a evaluace klasifikátoru pro detekci subthalamického jádra v exploračních trajektoriích hluboké mozkové stimulace u pacientů s Parkinsonovou nemocí, která by značně ulehčila lékařům manuální práci při těchto operacích. Dalším bodem práce je vyhodnocení vlivu šumu na přesnost klasifikace a porovnání přínosu jeho odstranění pomocí manuální metody a dvou automatických metod. Vybrala jsem 9 příznaků na základě předcházející rešerše existujících přístupů k detekci subthalamického jádra. Vyhodnocení příznaků jsem provedla na trénovací množině, obsahující 5834 mikroelektrodových záznamů od 20 pacientů s Parkinsonovou chorobou. Vyhodnocením příznaků na trénovací množině datasetu pomocí ROC křivek jsem zjistila, že nejlepších výsledků dosáhly příznaky energie RMS, její normalizovaná verze NRMS a délka křivky. Nežádoucí šum v mikroelektrodových signálech měl největší vliv na energii RMS, její normalizovanou verzi NRMS a na počet průchodů nulou. Naopak příznaky průměr nelineární energie a délka křivky byly vůči šumu na trénovacím datasetu robustní. Evaluací a porovnáním klasifikátorů na základě hodnot přesnosti, senzitivity a specificity na testovací množině obsahující 2488 mikroelektrodových záznamů od 8 pacientů jsem dospěla k závěru, že klasifikace podle zvoleného prahu dosahuje navzdory své jednoduchosti značně dobrých výsledků. Zpřesnění lze docílit použitím klasifikátoru Support Vector Machine s vyváženým trénovacím datasetem a selekcí příznaků. V konečném důsledku však dojde o zlepšení v rámci pouhých pár jednotek procent. Co ovšem má velký vliv na přesnost klasifikace, je odstranění artefaktů, a to především automatickou autokorelační metodou, kterou bylo docíleno nejlepších výsledků – v případě klasifikace pouhým prahováním NRMS bylo dosaženo 90,47% přesnosti a pomocí SVM klasifikátoru se selekcí příznaků 91,20% přesnosti.

Klíčová slova

mikroelektrodové záznamy; klasifikace; subthalamické jádro; Parkinsonova choroba

Klasifikace subthalamického jádra z mikroelektrodových záznamů

Carmen-Anna Konicarová

Vedoucí práce: Ing. Eduard Bakštein, Ph.D.

Lékařská elektronika a bioinformatika


FEL ČVUT

7.6.2021

Motivace

- Hluboká mozková stimulace
- Parkinsonova choroba
 - Subthalamické jádro (STN)
- Přesná lokalizace mozkových jader
 - Ručně neurologem
- Jak usnadnit lékařům manuální anotaci?
 - Automatická klasifikace mozkových jader

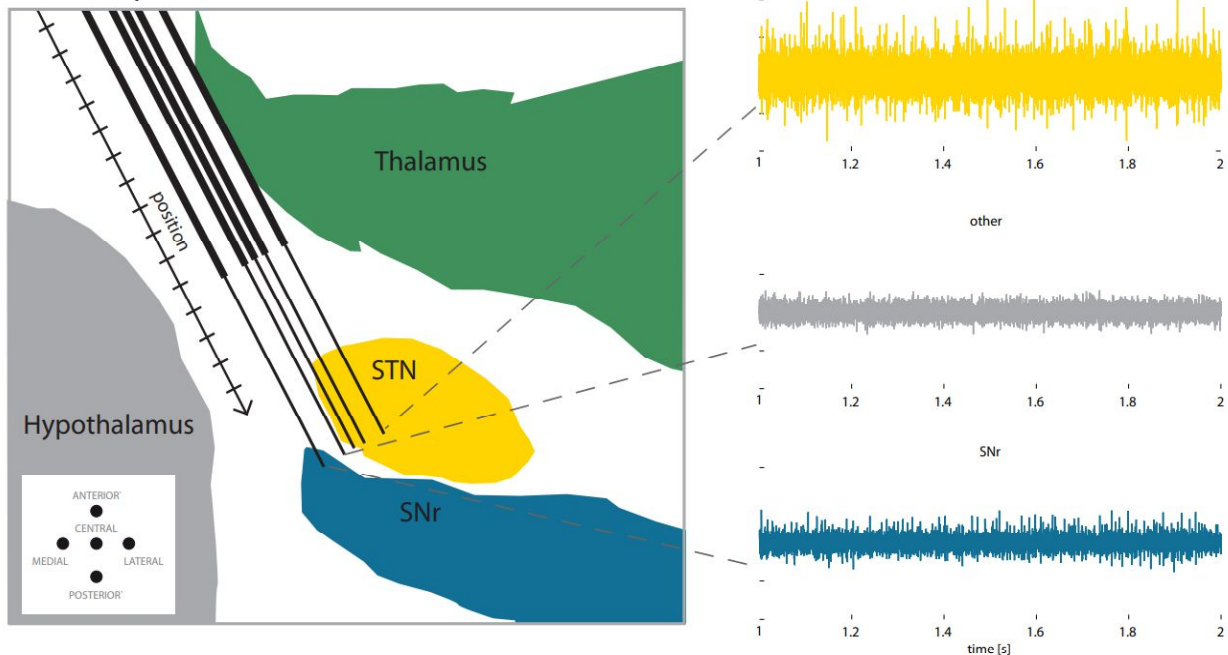
Deep Brain Stimulation (DBS)



<https://www.parkinsonsnew.org.au/3d-software-to-improve-success-of-dbs-surgery/>

Mikroelektrodové záznamy (MER)

→ Z exploračních elektrod



BAKŠTEIN, E., 2016. Deep Brain Recordings in Parkinson's Disease : Processing, Analysis and Fusion with Anatomical Models. Doctoral Thesis. Czech Technical University in Prague. Faculty of Electrical Engineering, Department of Cybernetics.

3

Cíle práce

Pro detekci STN z MER:

- **Nalézt vhodné příznaky**
 - **Vyhodnotit na zadaném datasetu**
 - **Zjistit robustnost vůči artefaktům**
 - **Manuální vs. automatické metody** (Bakštein et al. 2015; 2017)
- **Zvolit vhodný klasifikátor**
 - **Implementovat a evaluovat na zadaném datasetu**


4

Příznaky

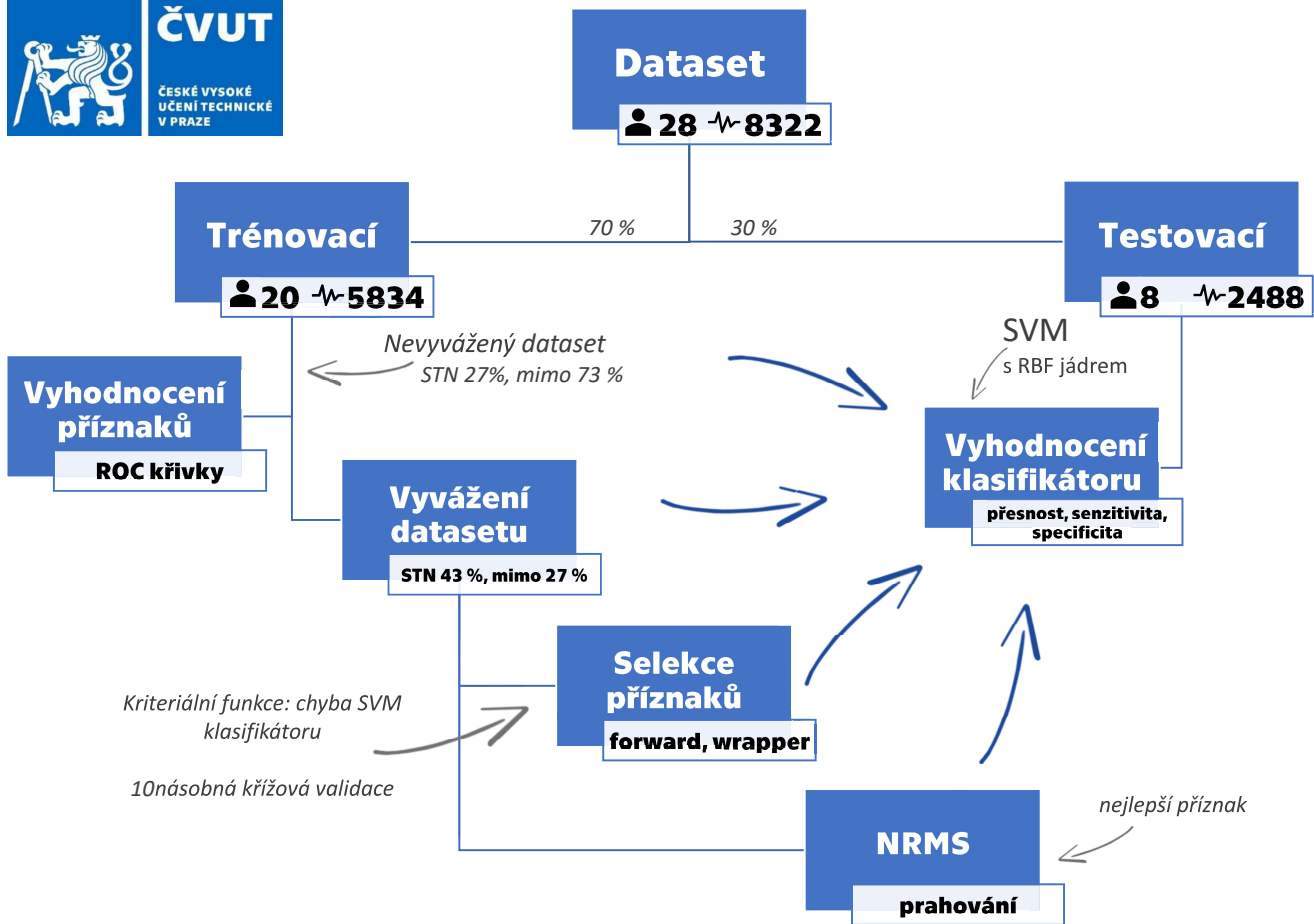
- Na základě rešerše literatury (18 článků)
 - Energie signálu (RMS)
 - Normalizovaná energie signálu (NRMS)
 - Pásma výkonové spektrální hustoty (PSD)
 - alfa: 3-12 Hz (PSD α)
 - beta: 13-30 Hz (PSD β)
 - gama: 31- 100 Hz (PSD γ)
 - Průměr nelineární energie (ANE)
 - Délka křivky (CL)
 - Počet průchodů nulou (ZC)
 - Počet vrcholů (Peaks)

5

Ukázka trajektorie



6



7

SVM klasifikátor

→ Vyvážení datasetu

	trénovací skupina			
	před podvzorkováním		po podvzorkování	
STN	1578	27 %	1578	43 %
mimo STN	4256	73 %	2129	57 %
celkem	5834	100 %	3706	100 %

→ Selektce příznaků

	RMS	NRMS	CL	ZC	PSD α	PSD β	PSD γ	ANE	Peaks
s artefakty	✓	✗	✓	✓	✗	✗	✗	✗	✗
maxDiffPSD	✓	✓	✓	✗	✗	✗	✗	✗	✗
COV	✓	✓	✓	✗	✗	✗	✗	✗	✗
manual	✓	✓	✓	✗	✗	✗	✗	✗	✗

8

Vyhodnocení klasifikátoru

→ Klasifikace podle prahu NRMS vs SVM se selekcí příznaků

	Přesnost na testovací množině	
	NRMS	kombinace příznaků
	podvzorkování ½	podvzorkování ½ + selekce příznaků
s artefakty	0,8505	0,8931
COV	<u>0,9047</u>	<u>0,9120</u>



Pouhé prahování NRMS (zafixovaná hodnota specifity)

→ přesnost: 90,47 %

SVM se selekcí příznaků

→ přesnost: 91,20 %

9

Shrnutí

Automatická detekce STN z MER

- ✓ Problém je řešitelný jednoduchou implementací
 - ✓ Pouhé prahování NRMS
 - ✓ SVM selekce příznaků
- × Kombinace velkého množství příznaků a složité modely nemají příliš smysl ← plyne i z rešerše
- ✓ Co však má vliv na přesnost je odstranění artefaktů

→ v tomto případě automatickou autokorelační metodou (Bakštein et al. 2015; 2017)

10

Děkuji Vám za pozornost



HODNOCENÍ HYPOMETABOLISMU V OBRAZECH POZITRONOVÉ EMISNÍ TOMOGRAFIE

Kateřina Macková

FEL ČVUT v Praze, Technická 2, Praha 6

Abstrakt

Epileptogenní léze způsobená fokální kortikální dysplázií (FCD) se v obrazech pozitronové emisní tomografie fluorodeoxyglukózy (FDG-PET) projevuje jako hypometabolická. Automatická detekce může pomoci odhalení diskretních ložisek a asistovat tak prospektivnímu radiologickému hodnocení při diagnostice a plánování epileptochirurgických výkonů, kde je stále diskutována nutnost zahrnutí hypometabolické léze do resekce k pooperačnímu vymizení záchvatů.

Analyzovány byly obrazy FDG-PET mozku 42 pacientů s FCD (typu 1 a 2), kteří podstoupili chirurgickou léčbu epilepsie ve FN Motol. Rozsah resekce byl ručně zakreslen do snímků magnetické rezonance. Navržena byla metoda detekce hypometabolismu založená na výpočtu indexu asymetrie (AI) kontralaterálních anatomických regionů šedé hmoty. Limitní efektivní rozlišení FDG-PET obrazů bylo zlepšeno korekcí partial volume efektu (PVC). Úspěšnost detekce hypometabolismu byla stanovena ve vztahu k oblasti resekce, dlouhodobému pooperačnímu výsledku a typu FCD.

Vyvinutá metoda prokázala schopnost identifikovat oblasti hypometabolismu s překryvem s epileptogenní tkání na úrovni voxelů. Zahrnutí těchto oblastí do resekce korespondovalo s vymizením záchvatů, zejména pak u pacientů s FCD typu 2. Bylo prokázáno, že PVC má pozitivní vliv na kvalitu FDG-PET snímků pro vizuální hodnocení i na úspěšnost detekce hypometabolismu.

Vyvinutá metoda je nezávislá na použitém PET skeneru a dobře označuje suspektní hypometabolické regiony. Je proto vhodná pro využití v klinické praxi a již je experimentálně testována jako pomocný prospektivní diagnostický nástroj ve FN Motol.

Klíčová slova

Hypometabolismus, partial volume korekce, epilepsie, fokální kortikální dysplázie

Bakalářská práce

Hodnocení hypometabolismu v obrazech pozitronové emisní tomografie

Autor:

Kateřina Macková

Vedoucí práce:

Ing. Radek Janča, Ph.D.

Oponent:

Doc. MUDr. Jakub Otáhal, Ph.D.



FAKULTA
ELEKTROTECHNICKÁ
ČVUT V PRAZE

7. červen 2020

Úvod: Epilepsie na podkladě fokální kortikální dysplázie


2

- Farmakorezistentní fokální epilepsie
- Fokální kortikální dysplázie
- Resekční chirurgická léčba epilepsie ve FN Motol

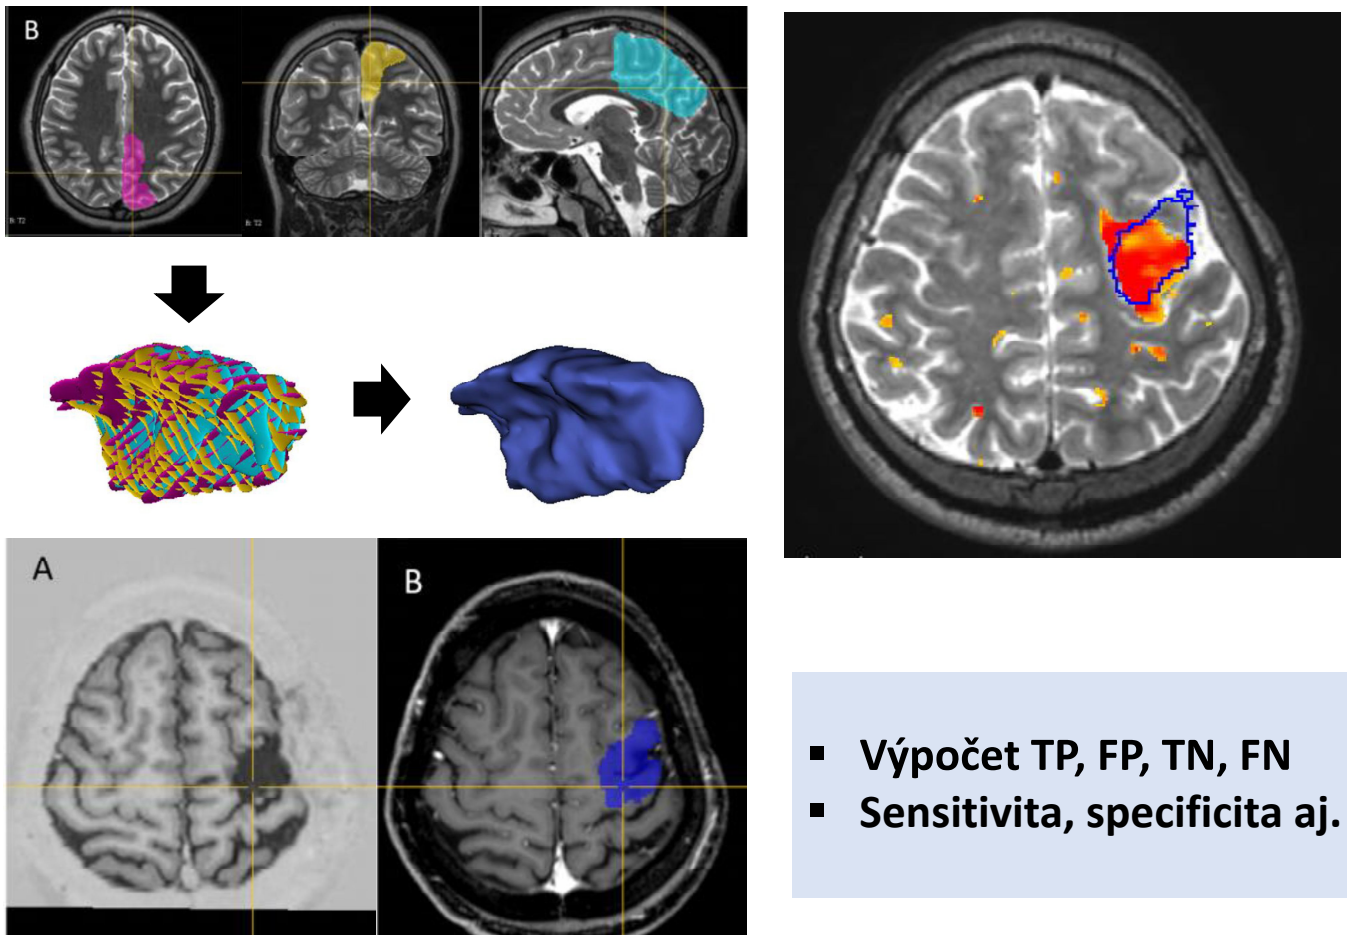
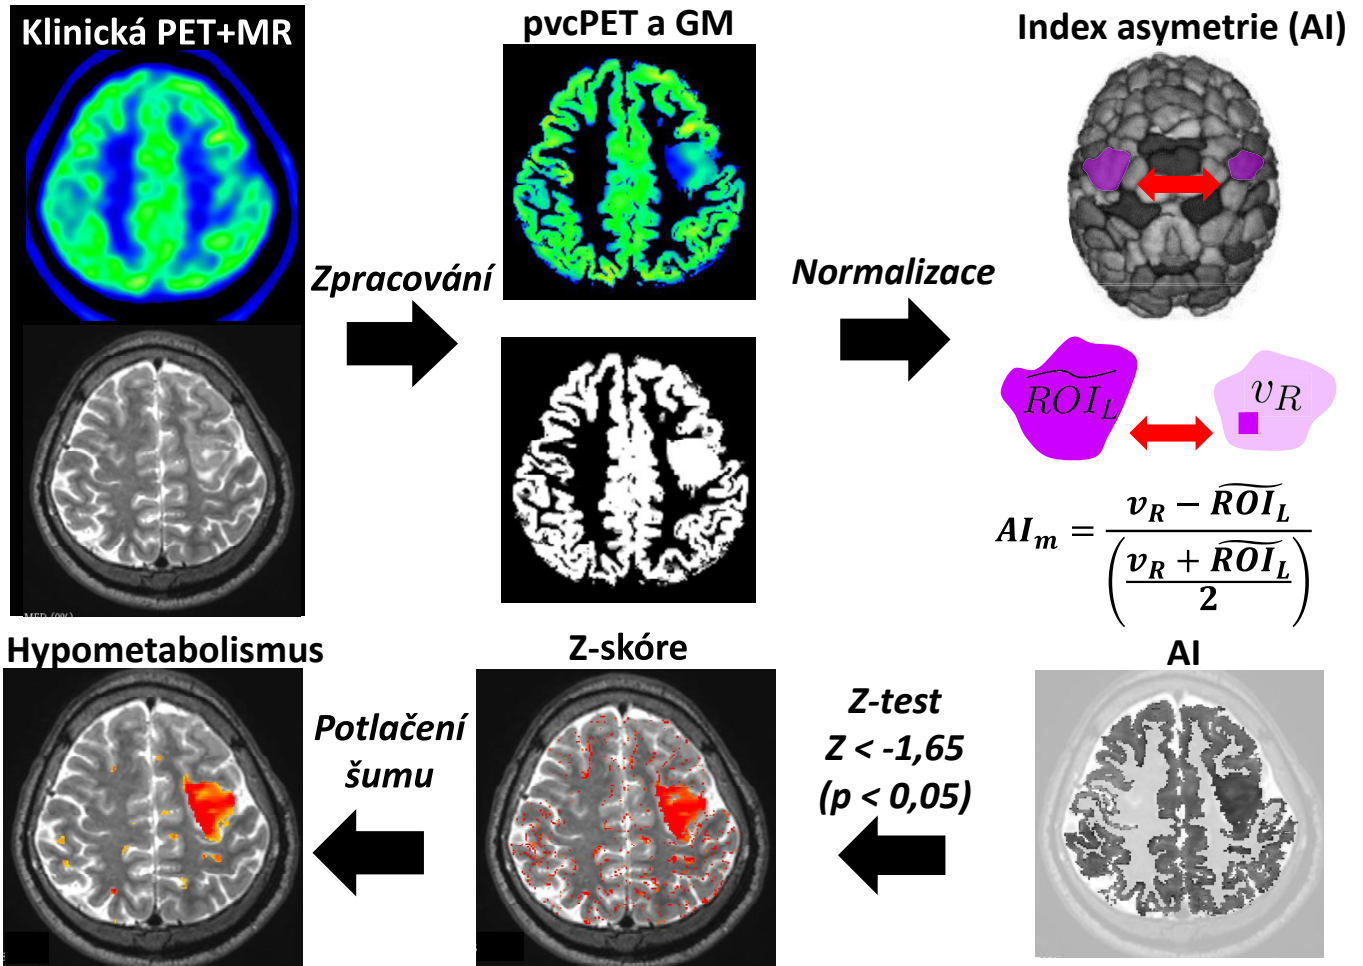
MRI

MRI + FDG-PET (50 %)

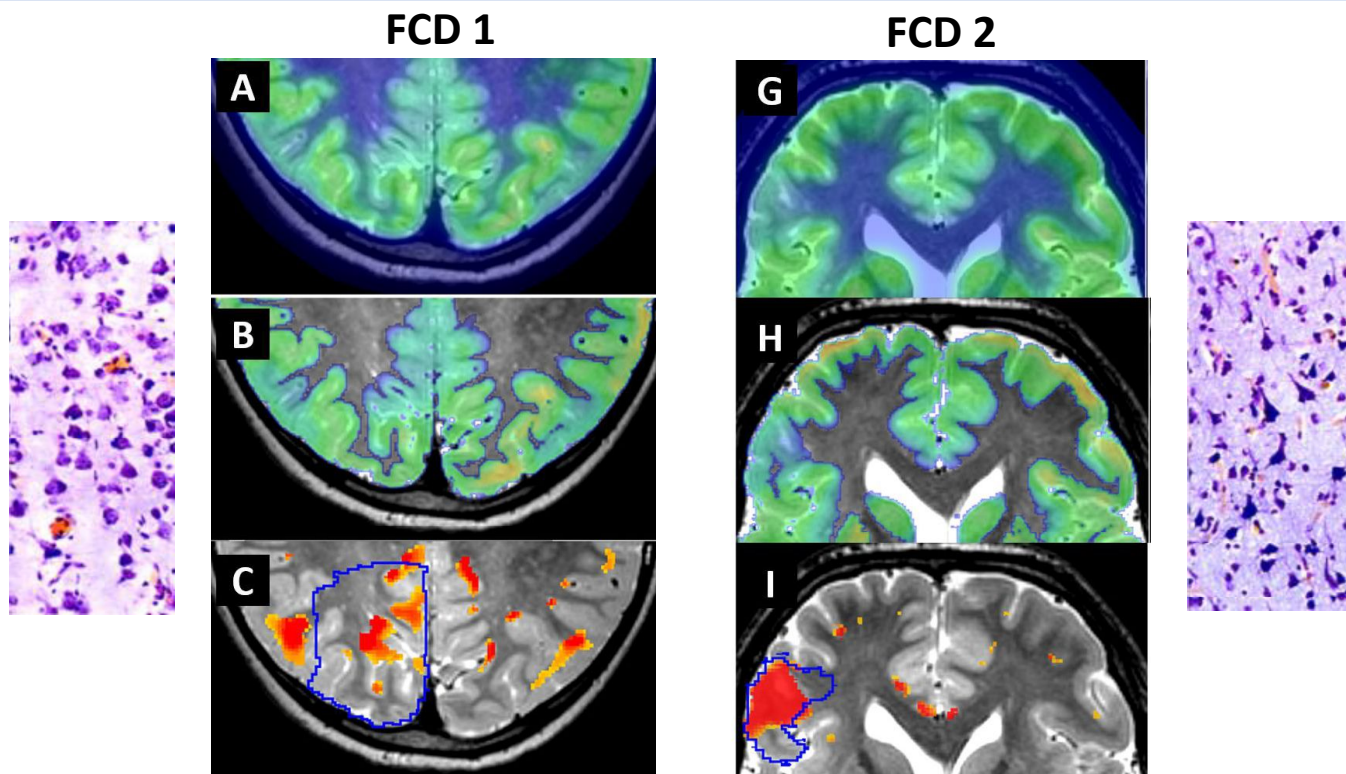
FDG-PET



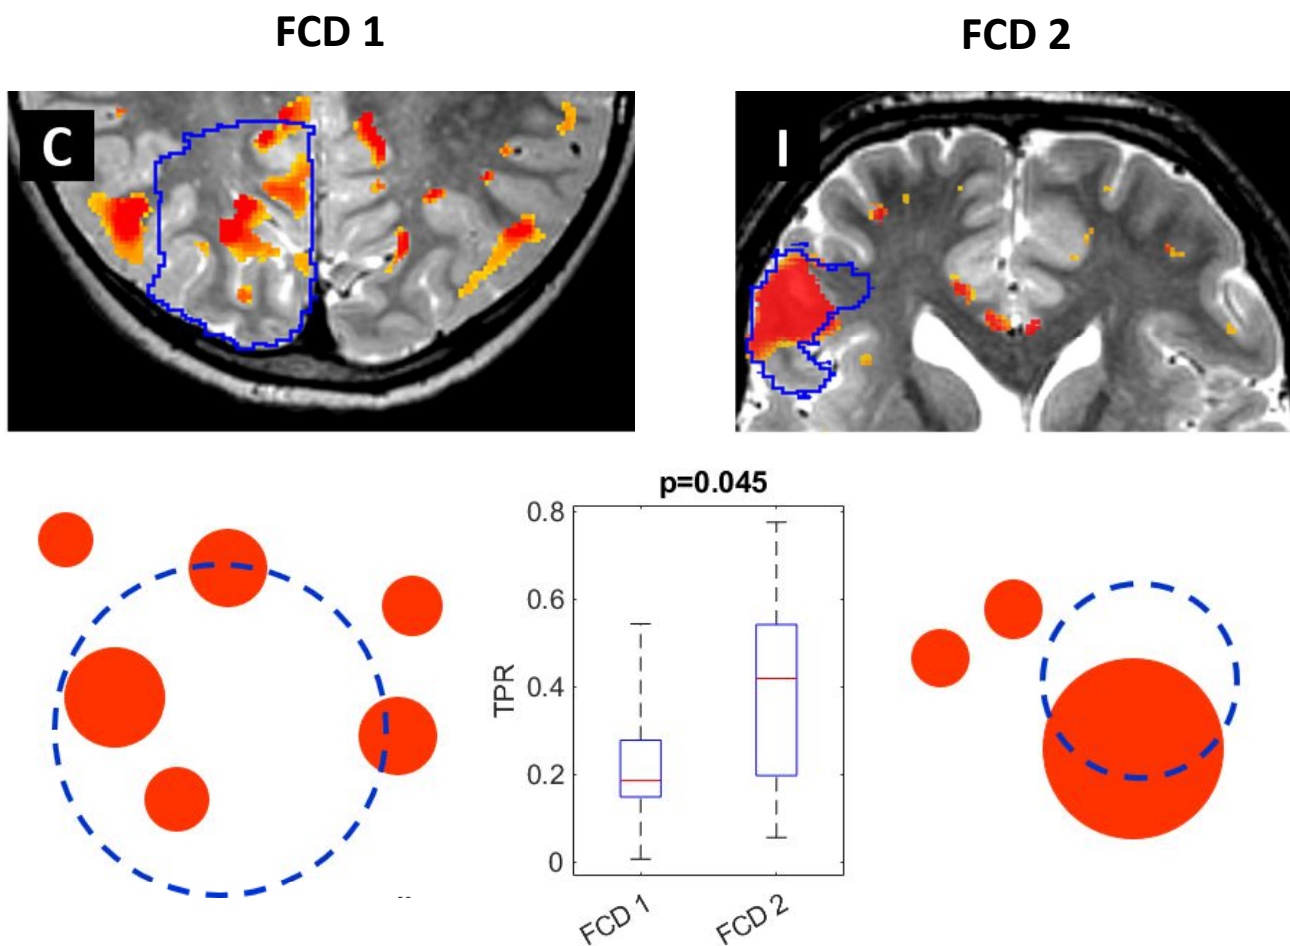
- Automatická lokalizace hypometabolismu v PET




- 42 pacientů s FCD typu 1 a 2
- Stanovení úspěšnosti detekce
- Porovnání FCD 1 vs. 2




Výsledky: Hypometabolismus a typ FCD





FCD 1



FCD 2




Přetrvávající záchvaty



Závěr

- Vyvinula jsem metodu detekce hypometabolismu
- Nezávislá na PET skeneru – index asymetrie
- Validace na mnou zakreslené resekce
- Hypometabolismus lokalizuje FCD 2 lézi



- Již se experimentálně využívá v klinické praxi

Děkuji za pozornost

GENERACE AUDIO SIGNÁLŮ POMOCÍ MIKROŘADIČE ŘADY STM32

Barbora Mašková

FEL ČVUT v Praze, Technická 2, Praha 6

Abstrakt

Tato bakalářská práce se zabývá návrhem a realizací generátorů audiosignálů s využitím bloků PWM a DAC mikrořadiče řady STM32. Při použití bloku PWM je využita vhodná modulace střídání. V případě bloku DAC je využita metoda Přímé digitální syntézy. Dále je zde popsán návrh filtru pro získání požadovaného signálu.

Práce se také zabývá analyzováním možnosti realizace Text-To-Speech generátoru, který by generoval jednoduché signály podobné řečovým, které by byly použitelné jako informační výstup měřicích přístrojů.

Klíčová slova

STM32, STM32F303RE, STM32F042F6P6, audiosignály, Přímá digitální syntéza, PWM, modulace střídání, filtr, dolní propust, generátor, Text To Speech



Generace audio signálů pomocí mikrořadiče řady STM32

Barbora Mašková

Vedoucí: doc. Ing. Jan Fischer, CSc.

1

Rozbor, motivace a cíle práce

Cílem práce je navrhnout generátory audio signálů, které využívají metody DDS a PWM s modulací střídy a analyzovat možnou realizaci metody TTS. Bylo také potřeba navrhnout filtr typu dolní propust pro získání kýženého signálu.

Možnosti generace audio signálů dle vlastností mikrořadiče

- Mikrořadič má D/A převodník - metoda DDS (STM32F303RET6)
- Mikrořadič nemá D/A převodník - potřeba ho nějak nahradit -> PWM s modulací střídy a dolnoproústný filtr (STM32F042F6P6)

Možné využití generátorů audio signálů

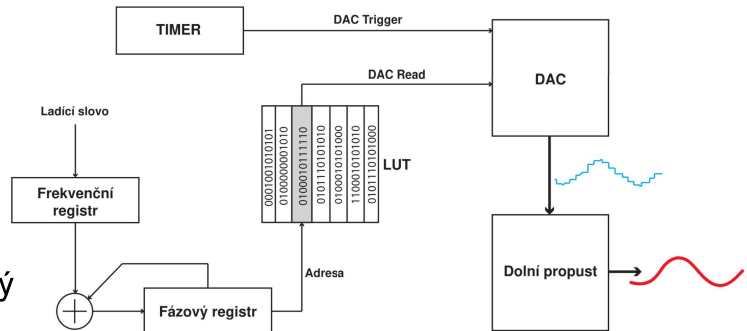
- Ve výuce - analýza funkčnosti obvodu
- Představení elektroniky dětem - potřeba zaujmout -> audio signály
- Indikace v přístrojích - podle často používaných zvuků lze zjistit např. error nebo konec procesu

2

Přímá digitální syntéza DDS

Hlavními bloky metody DDS jsou

- D/A převodník
- Časovač (trigger)
- Look-up tabulka (LUT)
- Dva registry - frekvenční a fázový



Parametry generátoru

- Rozmezí generovaného signálu 10 - 5000 Hz
- Frekvence časovače nastavena na 100 kHz
- Velikost LUT 4096
- Ladící slovo M jako 32 bitový unsigned integer


=> frekvence výstupního signálu $f \approx M \times 2.33 \times 10^{-5}$ Hz

3


Vygenerované signály metodou DDS



f = 415 Hz



f = 2475 Hz




Na obrázku vpravo je ztelně vidět efekt filtru, kdy signál po filtraci je fázově posunutý a amplitudově utlučený

4


Generování signálů s více složkami za pomoci DDS

Spojení n DDS, kde každá generuje hodnotu N_n
 Hodnoty se následně sečtou, zprůměrují
 a takto vzniklá hodnota se posílá do D/A převodníku



Signál se třemi složkami

- Dvě jsou nezávisle nastavitelné
v rozmezí 10 - 5000 Hz
- Jedna je pevně nastavená na 1900 Hz
Frekvence nastavené na 190, 507 a 1900 Hz ----->

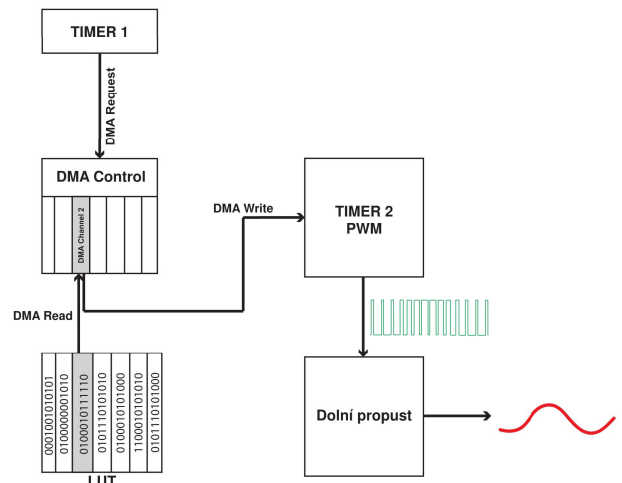


5

PWM s modulací střídá

Hlavními bloky jsou

- DMA blok
- Look-up tabulka (LUT)
- Dva časovače
- Filtr




Nastavené parametry generátoru

- Rozmezí generovaného signálu 150 - 10000 Hz
- Nosná frekvence nastavená na 100 kHz
- Nastavování frekvence pomocí terminálu nebo trimru
- Funkce navíc: sweep, nastavení dvou složek, zvuková indikace


6

Vygenerované signály pomocí PWM s modulací střidy

Nastaveno: $f = 830 \text{ Hz}$
Změřeno: $f = 838 \text{ Hz}$



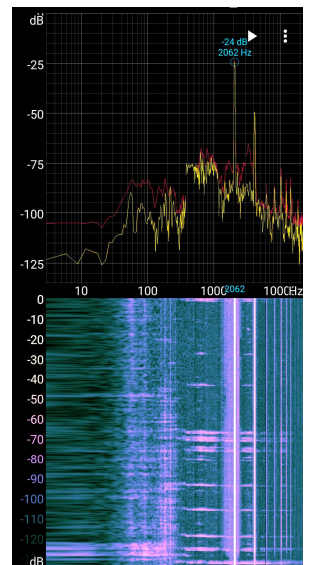

Nastaveno: $f = 2055 \text{ Hz}$
Změřeno: $f = 2062 \text{ Hz}$



7

Experimentální ověření frekvence vygenerovaného signálu

- Do obvodu byl zapojen reproduktor
- Vygenerovaný zvuk byl pak přijímán mikrofonom na mobilním telefonu
- K analýze audio signálu byla využita aplikace Spectroid
 - Sampling rate nastaven na 48 kHz
 - 0 dB je maximální hodnota, kterou mikrofón zvládne změřit -> záporné hodnoty dB






8

Návrh potřebného filtru - dolní propust

Dolní propust 2. řádu s mezní frekvencí 10 kHz (RC článek)

Složena z dostupných rezistorů a kapacitorů






9

Analýza metody Text To Speech (TTS)

Myšlenka využít metodu DDS pro generování audio signálů hlásek

Byly vytvořeny data pro hlásku 'a' a 'b'

Signál se podařilo vygenerovat, avšak velikost vytvořených dat byla až moc velká -> nedostatečná metoda pro generování datasetu



10

Shrnutí

- Vytvořen generátor využívající metodu DDS s možností generace signálu v rozmezí 10 - 5000 Hz.
- Využití metody DDS pro generaci signálu s více nezávisle nastavitelnými složkami
- Vytvoření generátoru s PWM a modulací střídavy - generovaný signál v rozmezí 150 - 10000 Hz
- Navrhnout potřebný filtr typu dolní propust 2. řádu s mezní frekvencí 10 kHz
- Pokus o vytvoření datasetu pro metodu TTS

SUBJEKTIVNÍ TESTOVÁNÍ KVALITY NAHRÁVKY ŘEČI S VODOZNAKEM

Lucie Mühlfeitová

FEL ČVUT v Praze, Technická 2, Praha 6

Abstrakt

Cílem této bakalářské práce je, na základě prostudování současných metod vodoznakování a normy pro subjektivní testování ITU-T P.800, navrhnout a zrealizovat subjektivní test kvality nahrávky řeči s vodoznakem. Cílem bylo najít hraniční hodnotu síly vodoznaku, při které ještě není ovlivněna kvalita nahrávky. Subjektivní test byl proveden metodou ACR. Výsledky byly analyzovány, vyneseny do grafů, byl proveden statistický t-test a výsledky byly srovnány s výsledky obdobného testu provedeného dříve.

Klíčová slova

digitální vodoznak; robustnost; subjektivní testování; Absolute Category Rating; ITU-T P.800

Subjektivní testování kvality nahrávky řeči s vodoznakem

Lucie Mühlfeitová FEL ČVUT
2021



Motivace

- Vodoznakování řeči
 - málo prozkoumaná technologie
- Vliv vodoznaku na kvalitu nahrávek

- Návrh a realizace subjektivního testu
 - Dle normy P.800
- Analýza získaných dat

- Výběr vzorků
 - Různé zastoupení sil vodoznaku
 - Šum na pozadí
- Realizace subjektivního testu
 - Metoda ACR
 - 16 testovacích podmínek

Quality of the speech	Score
Excellent	5
Good	4
Fair	3
Poor	2
Bad	1


Testovací podmínky

Condition	Studio/Acoustic recording	Background noise	Watermark strength
C01	Studio	-	-
C02	Studio	-	10
C03	Acoustic	-	-
C04	Studio	-	30
C05	Studio	Pub noise	-
C06	Studio	Pub noise	10
C07	Studio	-	75
C08	Studio	HMMWV tactical vehicle noise	10
C09	Studio	HMMWV tactical vehicle noise	-
C10	Studio	Pub noise	30
C11	Studio	-	200
C12	Studio	HMMWV tactical vehicle noise	30
C13	Acoustic	Pub noise	30
C14	Studio	-	650
C15	Acoustic	-	500
C16	Acoustic	-	100

Table 4.1: Conditions used in the experiment.


5/10

Výsledky




6/10

Výsledky



7/10

Výsledky



8/10

- Nastudování metod Vodoznakování
- Návrh a realizace subjektivního testu
- Analýza výsledků
 - Určení vlivu vodoznaku na kvalitu nahrávky
- Další postup
 - Objektivní test
 - Subjektivní test s jiným výběrem vzorků
 - Test s paralelní úlohou

Would be results achieved by the DCR method different as those obtained by the ACR method? If so, what would be a main difference?

AUTOMATIZOVANÉ ZPRACOVÁNÍ EKG POMOCÍ NEURONOVÝCH SÍTÍ

Lukáš Růžička

FBMI ČVUT v Kladně, nám. Sítná 3105, 272 01 Kladno

Abstrakt

Cílem práce byl návrh metod strojového učení pro klasifikaci mezi fibrilujícími a nefibrilujícími pacienty na základě parametrických dat extrahovaných z EKG záznamů. Celkem byla získána data od 583 pacientů, přičemž 542 z nich fibrilaci komor neprodělalo a zbylých 42 ji prodělalo. K hodnocení byly navrženy celkem tři modely strojového učení, jeden model na principu metody logistické regrese a dvě neuronové sítě lišící se druhem aktivační funkce. Tyto modely předpokládaly rozdílné rozložení parametrických dat mezi fibrilující a nefibrilující skupinou pacientů. Ze získaných výsledků vyplývá, že neuronové sítě se pro účel klasifikace hodí více nežli model logistické regrese. Je navrženo využití těchto neuronových sítí jako metody, která by mohla sloužit jako dodatečná metoda predikce při použití jiných více přesných metod.

Klíčová slova

neuronové sítě, EKG, klasifikace

Automatizované zpracování EKG pomocí neuronových sítí

Lukáš Růžička

Vedoucí práce: Mgr. Ksenia Sedova, Ph.D.


Úvod

- Ventrikulární fibrilace – často konečným stadiem náhlé srdeční zástavy (NSZ)
- 17 milionů úmrtí v důsledku NSZ
- Vzrůst podílu NSZ v rámci celkové úmrtnosti z důvodu kardiovaskulárního selhání
- Hlavní strategie prevence úmrtnosti – včasná predikce

Přehled současného stavu I

- Současné problémy:
 - Velké množství EKG dat (ročně cca 300 mil. Záznamů)
 - Velký počet pacientů na jednoho lékaře (Indie 10189)
 - Odborníci – subjektivní vyhodnocení
- Strojové učení jako vhodný způsob řešení
 - Rychlé zpracování
 - Objektivní

Přehled současného stavu II



Cíle

1. Navrhnout metodu strojového učení schopnou predikce VF na základně parametrických vstupních dat
2. Statisticky zhodnotit přesnost predikce metody strojového učení

Metody – vstupní dataset

- Chybějící hodnoty parametrů
- Pracoval jsem pouze s pacienty s kompletním záznamem

	Počet pacientů		
	nVF	VF	celkový
Původní dataset	542	41	583
Zpracovaný dataset	385	23	408

Metody - parametry

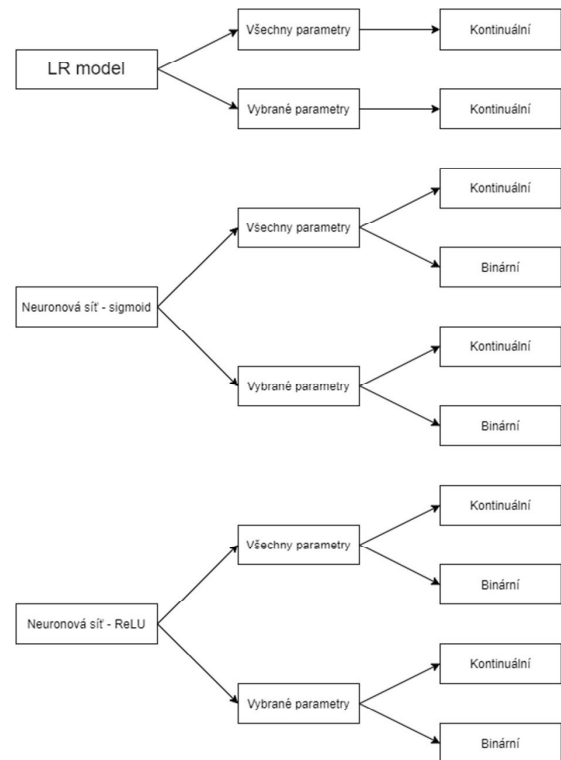
Popis parametru	Zkratka
Maximální amplituda T vlny	Tamp_max
Minimální amplituda T vlny	Tamp_min
Rozdíl maxima a minima T vlny	Tamp_disp
Interval mezi nejdříve detekovaným počátkem a nejpozději detekovaným koncem T vlny přes všech 12 svodů	G_TpkTend
Obsah pod křivkou ST segmentu	summaST
Maximální amplituda ST segmentu	max_ST
Průměrná hodnota ST segmentu	OverallQRS
Srdeční frekvence	HR
Obsah po křivkou T vlny pro Wilsonovy svody	Tarea_V1-V6
Obsah po křivkou T vlny pro Einthovenovy svody	Tarea_I-III
Obsah po křivkou T vlny pro všechny Goldbergovy svody	Tarea_aVL, aVR, aVF

Metody – zpracování datasetu

- Nejdříve použit Kolmogorov-Smirnov test normality
-> ani u jednoho parametru nebylo prokázáno normální rozdělení
- Použit Mann-Whitney U test pro odlišné rozdělení
 - Hladina významnosti $\alpha = 5 \%$
 - Rozdělení do dvou setů dle hodnoty p
- ROC analýza – určení „cutoff“ hodnot pro vytvoření binárních setů

Metody – navržené modely

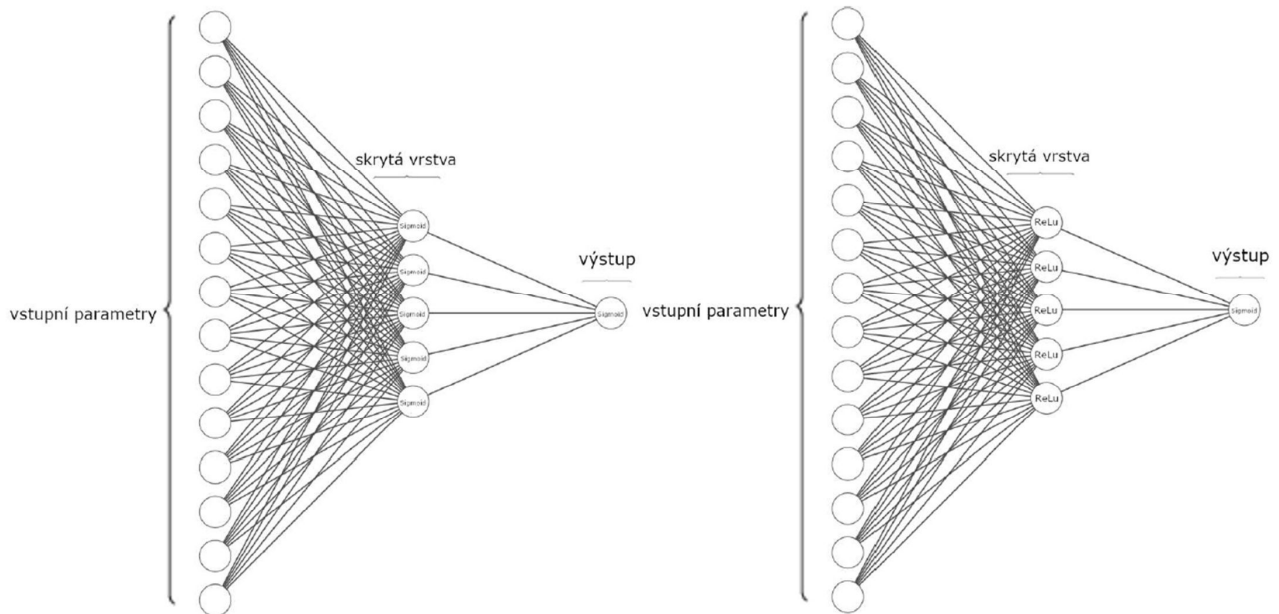
- Celkem navrženy 3 modely
- Datasets:
 - Všechny parametry
 - Vybrané parametry
- Použité typy parametrických hodnot:
 - Binární
 - Kontinuální
 - Pro LR pouze kontinuální



Metody – parametry modelů strojového učení

- Chybová funkce: MSE (Mean squared error)
- Neuronové sítě:
 - Optimalizační algoritmus: gradient descent
 - Rychlost učení = 0,001
 - Implementace tzv. Earlystopperu
 - Minimální změna = 0,001
 - Tolerance 10 iterací

Metody – architektura neuronových sítí



Metody – hodnocení přesnosti

- Výstupem modelů je pravděpodobnost, že pacient patří do třídy fibrilujících
- Výpočty provedeny pro prahové hodnoty $\langle 0,05; 0,95 \rangle$ s krokem 0,05
- 100 iterací
- Výstup: „Confusion“ matice
 - Přesnost
 - Sensitivita, specificita
- Součin sensitivity a specificity

Výsledky – Mann–Whitney U test

Parametr	nVF skupina n = 385		VF skupina n = 23		p hodnota	Výsledek H_0
	Medián	IQR	Medián	IQR		
<u>Tamp_max</u> (mV)	523.1	[374.4;728.6]	716.8	[532.8, 1070.0]	<0.001	zamitnuta
<u>Tamp_min</u> (mV)	-236.1	[-328.2;-156.1]	-381.6	[-568.2, -276.6]	<0.001	zamitnuta
<u>Tamp_disp</u> (mV)	777.4	[586.3;1060.7]	1144.6	[868.4, 1626.4]	<0.001	zamitnuta
<u>G_TpkTend</u> (ms)	128.0	[113.0;148.0]	140.0	[125.0, 150.0]	0.014	zamitnuta
<u>summaST</u> (mV)	1506.5	[970.5;2158.5]	2538.0	[1800.0, 3699.0]	<0.001	zamitnuta
<u>max_ST</u> (mV)	290.5	[179.0;452.2]	483.5	[300.0, 695.0]	<0.001	zamitnuta
<u>OverallQRS</u> (ms)	98.0	[88.0;108.0]	104.0	[94.0, 124.0]	0.019	zamitnuta
<u>HR</u> (bpm)	75.0	[65.0;90.0]	78.0	[63.8, 86.8]	0.958	platí
<u>Tarea_V1</u> (ms·V)	606.0	[-202.5;1428.5]	-212.5	[-1143.5, 1252.5]	0.076	platí
<u>Tarea_V2</u> (ms·V)	2054.5	[122.2;4197.2]	492.0	[-2086.8, 2749.8]	0.045	zamitnuta
<u>Tarea_V3</u> (ms·V)	2017.5	[494.2;4304.0]	2579.0	[213.8, 6096.2]	0.659	platí
<u>Tarea_V4</u> (ms·V)	1553.5	[134.5;3225.8]	2137.0	[495.5, 5628.0]	0.164	platí
<u>Tarea_V5</u> (ms·V)	1093.5	[-58.8;2191.8]	1630.0	[958.8, 3803.8]	0.028	zamitnuta
<u>Tarea_V6</u> (ms·V)	710.5	[-82.0;1561.2]	1261.0	[657.0, 2832.2]	0.012	zamitnuta
<u>Tarea_I</u> (ms·V)	157.5	[-568.8;1006.2]	-284.5	[-1176.5, 809.2]	0.171	platí
<u>Tarea_II</u> (ms·V)	1269.5	[437.2;2473.2]	3130.0	[1701.5, 4454.0]	<0.001	zamitnuta
<u>Tarea_III</u> (ms·V)	1004.0	[-96.8;2373.2]	3629.5	[1197.0, 5798.2]	<0.001	zamitnuta
<u>Tarea_aVL</u> (ms·V)	-853.0	[-1548.0;272.0]	-1495.5	[-2248.2, -821.5]	0.001	zamitnuta
<u>Tarea_aVR</u> (ms·V)	-464.5	[-1457.0;436.8]	-2543.0	[-3498.5, -160.5]	0.001	zamitnuta
<u>Tarea_aVF</u> (ms·V)	1030.5	[208.2;2525.0]	3497.0	[1650.2, 4726.5]	<0.001	zamitnuta

Výsledky – parametrické sety

Set parametrů 1 - (H_0 neplatí)	Set parametrů 2 - (H_0 neplatí, $p \leq 0.001$)
<u>Tamp_max</u>	<u>Tamp_max</u>
<u>Tamp_min</u>	<u>Tamp_min</u>
<u>Tamp_disp</u>	<u>Tamp_disp</u>
<u>G_TpkTend</u>	<u>summaST</u>
<u>summaST</u>	<u>max_ST</u>
<u>max_ST</u>	<u>Tarea_II</u>
<u>OverallQRS</u>	<u>Tarea_III</u>
<u>Tarea_V2</u>	<u>Tarea_aVL</u>
<u>Tarea_V5</u>	<u>Tarea_aVR</u>
<u>Tarea_V6</u>	<u>Tarea_aVF</u>
<u>Tarea_II</u>	
<u>Tarea_III</u>	
<u>Tarea_aVL</u>	
<u>Tarea_aVR</u>	
<u>Tarea_aVF</u>	

Výsledky – příklad tabulky

Typ aktivační funkce:		Sigmoid							
Použitá data:		Set parametrů 2, binární							
Threshold (%)	Confusion matice (-)	Přesnost (%)	Sensitivita (%)	Specifická (%)	Preciznost (%)				
5	<table border="1"><tr><td>70</td><td>558</td></tr><tr><td>3</td><td>469</td></tr></table>	70	558	3	469	49	99	11	46
70	558								
3	469								
10	<table border="1"><tr><td>185</td><td>448</td></tr><tr><td>40</td><td>427</td></tr></table>	185	448	40	427	56	91	29	49
185	448								
40	427								
15	<table border="1"><tr><td>287</td><td>359</td></tr><tr><td>54</td><td>400</td></tr></table>	287	359	54	400	62	88	44	53
287	359								
54	400								
20	<table border="1"><tr><td>306</td><td>299</td></tr><tr><td>101</td><td>394</td></tr></table>	306	299	101	394	64	80	51	57
306	299								
101	394								
25	<table border="1"><tr><td>329</td><td>284</td></tr><tr><td>110</td><td>377</td></tr></table>	329	284	110	377	64	77	54	57
329	284								
110	377								
30	<table border="1"><tr><td>359</td><td>272</td></tr><tr><td>118</td><td>351</td></tr></table>	359	272	118	351	65	75	57	56
359	272								
118	351								
35	<table border="1"><tr><td>387</td><td>214</td></tr><tr><td>140</td><td>359</td></tr></table>	387	214	140	359	68	72	64	63
387	214								
140	359								
40	<table border="1"><tr><td>424</td><td>219</td></tr><tr><td>133</td><td>324</td></tr></table>	424	219	133	324	68	71	66	60
424	219								
133	324								
45	<table border="1"><tr><td>448</td><td>160</td></tr><tr><td>160</td><td>332</td></tr></table>	448	160	160	332	71	67	74	67
448	160								
160	332								
50	<table border="1"><tr><td>456</td><td>148</td></tr><tr><td>176</td><td>318</td></tr></table>	456	148	176	318	70	64	75	68
456	148								
176	318								
55	<table border="1"><tr><td>493</td><td>126</td></tr><tr><td>192</td><td>289</td></tr></table>	493	126	192	289	71	60	80	70
493	126								
192	289								
60	<table border="1"><tr><td>506</td><td>130</td></tr><tr><td>186</td><td>278</td></tr></table>	506	130	186	278	71	60	80	68
506	130								
186	278								
65	<table border="1"><tr><td>508</td><td>100</td></tr><tr><td>203</td><td>289</td></tr></table>	508	100	203	289	72	59	84	74
508	100								
203	289								
70	<table border="1"><tr><td>544</td><td>90</td></tr><tr><td>227</td><td>239</td></tr></table>	544	90	227	239	71	51	86	73
544	90								
227	239								
75	<table border="1"><tr><td>562</td><td>82</td></tr><tr><td>212</td><td>244</td></tr></table>	562	82	212	244	73	54	87	75
562	82								
212	244								
80	<table border="1"><tr><td>570</td><td>44</td></tr><tr><td>298</td><td>188</td></tr></table>	570	44	298	188	69	39	93	81
570	44								
298	188								
85	<table border="1"><tr><td>564</td><td>38</td></tr><tr><td>377</td><td>121</td></tr></table>	564	38	377	121	62	24	94	76
564	38								
377	121								
90	<table border="1"><tr><td>589</td><td>18</td></tr><tr><td>459</td><td>34</td></tr></table>	589	18	459	34	57	7	97	65
589	18								
459	34								
95	<table border="1"><tr><td>613</td><td>0</td></tr><tr><td>485</td><td>2</td></tr></table>	613	0	485	2	56	0	100	100
613	0								
485	2								

Typ aktivační funkce:		Sigmoid							
Použitá data:		Set parametrů 2, binární							
Threshold (%)	Confusion matice (-)	Přesnost (%)	Sensitivita (%)	Specifická (%)	Preciznost (%)				
5	<table border="1"><tr><td>70</td><td>558</td></tr><tr><td>3</td><td>469</td></tr></table>	70	558	3	469	49	99	11	46
70	558								
3	469								
10	<table border="1"><tr><td>185</td><td>448</td></tr><tr><td>40</td><td>427</td></tr></table>	185	448	40	427	56	91	29	49
185	448								
40	427								
15	<table border="1"><tr><td>287</td><td>359</td></tr><tr><td>54</td><td>400</td></tr></table>	287	359	54	400	62	88	44	53
287	359								
54	400								
20	<table border="1"><tr><td>306</td><td>299</td></tr><tr><td>101</td><td>394</td></tr></table>	306	299	101	394	64	80	51	57
306	299								
101	394								
25	<table border="1"><tr><td>329</td><td>284</td></tr><tr><td>110</td><td>377</td></tr></table>	329	284	110	377	64	77	54	57
329	284								
110	377								
30	<table border="1"><tr><td>359</td><td>272</td></tr><tr><td>118</td><td>351</td></tr></table>	359	272	118	351	65	75	57	56
359	272								
118	351								

Výsledky – maximální hodnoty součinů sensitivity a specifity

Typ ML modelu	Použitá data	Threshold (%)	Součin (-)	Sensitivita (%)	Specifická (%)
Logistická regrese	Set 1, kontinuální	55	0,13	38	34
Logistická regrese	Set 2, kontinuální	65	0,15	30	48
Neuronová síť – Sigmoid	Set 1, kontinuální	40	0,43	64	66
Neuronová síť – Sigmoid	Set 1, binární	35	0,51	79	65
Neuronová síť – Sigmoid	Set 2, kontinuální	45	0,46	62	73
Neuronová síť – Sigmoid	Set 2, binární	45	0,50	67	74
Neuronová síť – ReLU	Set 1, kontinuální	35	0,45	64	71
Neuronová síť – ReLU	Set 1, binární	65	0,52	65	81
Neuronová síť – ReLU	Set 2, kontinuální	45	0,43	60	72
Neuronová síť – ReLU	Set 2, binární	30	0,48	74	64

Shrnutí výsledků

- Model logistické regrese není vhodný
- Při implementaci neuronových sítí se jako vhodnější jeví binární parametrický set
- Dosažení až 79% sensitivity a 81% specificity

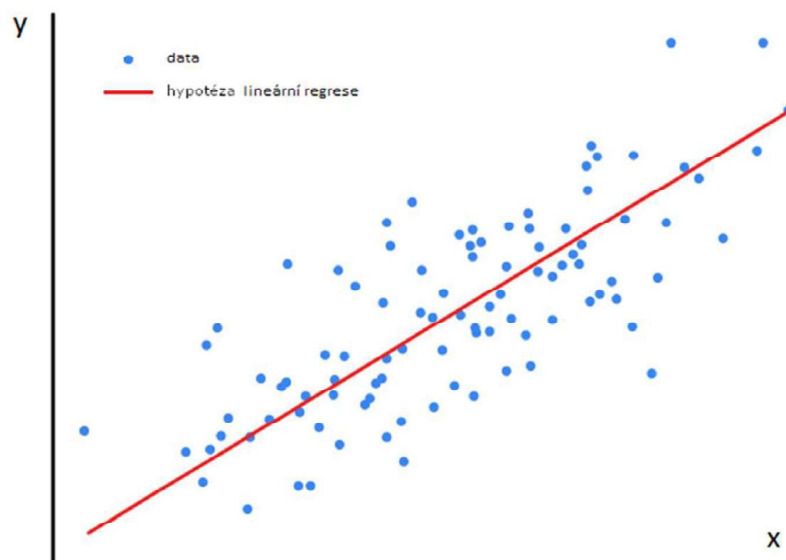
- Lze polemizovat o možnosti využití jako podpůrné diagnostické metody

Logistická regrese I

- Typ modelu strojového učení
- Klasifikační model
- Vychází z modelu lineární regrese
- Upraven pro binární klasifikační problémy

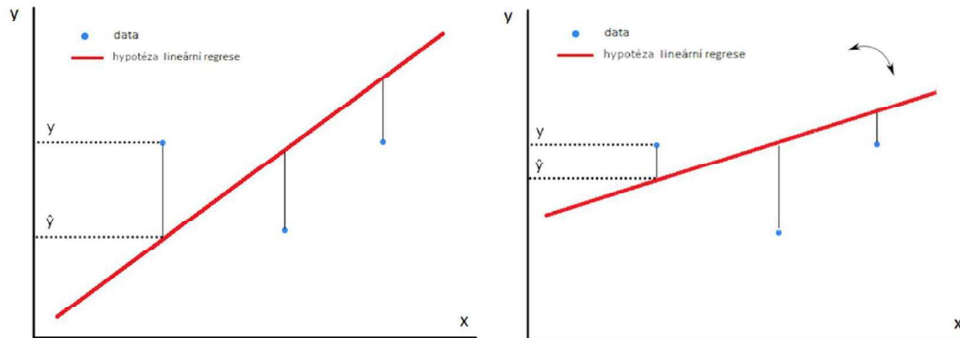
Logistická regrese II

Model lineární regrese



Logistická regrese III


Proces optimalizace lineární regrese



-> cílem je minimalizace „chybové funkce“

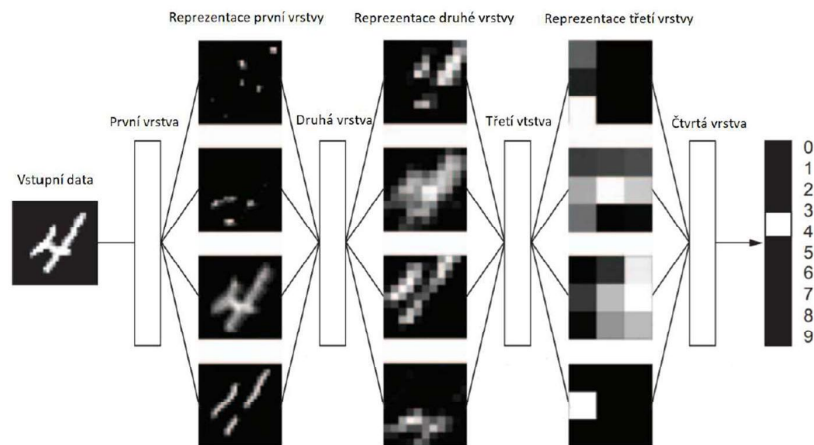
$$MSE = \frac{1}{N} \sum_{i=1}^N (\hat{y} - y)^2$$

Logistická regrese IV



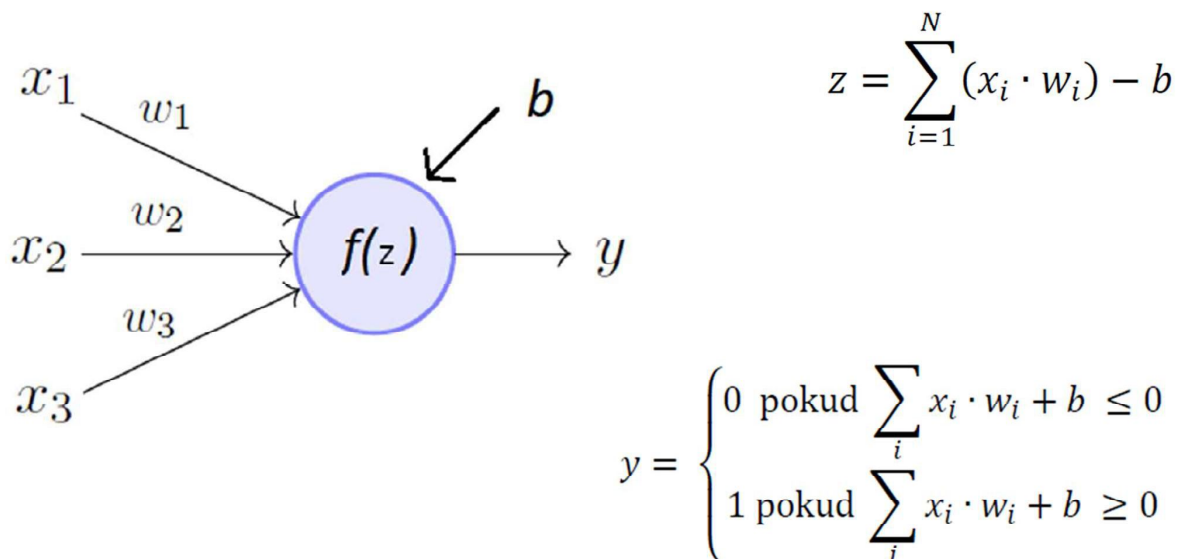
Neuronová síť I

- Inspirována biologickou neuronovou tkání
- Schopnost najít samostatně opakující se vzory či trendy, nemusí se nutně shodovat s teoretickými pravidly






Neuronová síť II

- Základní stavební jednotka – perceptron



Neuronová síť III

- Pro efektivní proces učení potřeba malé změny na výstupu -> aktivační funkce



Neuronová síť IV


- Proces optimalizace: úprava hodnot váhových koeficientů w a hodnot bias b
 - Cíl: minimalizace chybové funkce – použita MSE

$$MSE = \frac{1}{N} \sum_{i=1}^N (\hat{y} - y)^2$$


- Použita metoda „gradient descent“ (gradientový sestup)
 - Princip: výpočet parciálních derivací chybové funkce vzhledem k jednotlivým koeficientům w a b
 - Posun směrem k menší hodnotě
 - Cíl: dostat se do globálního/lokálního minima chybové funkce

Gradient descent


Princip metody gradient descent



Rychlost učení




Příliš vysoká hodnota rychlosti učení




Příliš nízká hodnota rychlosti učení

ROC analýza I

- Model bez schopnosti predikce **červeně**
- Ideální model **modře**
- Zvolení mezní hodnoty
-> binární dataset



ROC analýza II



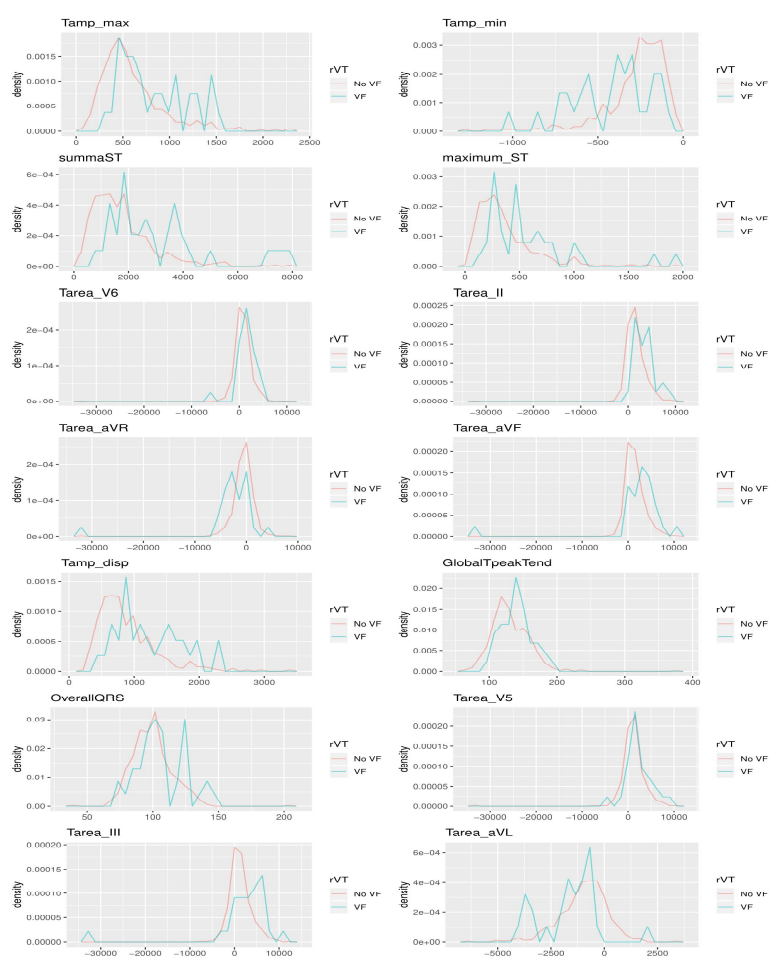
Skutečné hodnoty

		Nefibrilující(0)	Fibrilující(1)
Predikované hodnoty	Nefibrilující(0)	TN	FP
	Fibrilující(1)	FN	TP

$$\text{Přesnost} = \frac{TN + TP}{TN + TP + FN + FP}$$

$$\text{Senzitivita} = \frac{TP}{TP + FN}$$

$$\text{Specifická} = \frac{TN}{TN + FP}$$



WORKSHOP LÉKAŘSKÉ ELEKTRONIKY A BIOINFORMATIKY 2021

© České vysoké učení technické v Praze
ISBN 978-80-01-06830-4