



ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ
V PRAZE

Fakulta biomedicínského inženýrství

Katedra biomedicínské techniky

**Využití analýzy hlavních komponent pro
automatickou detekci EEG tranzientů**

**Principal component analysis for
automatic detection of the EEG transients**

Bakalářská práce

Vedoucí: doc. Ing. Vladimír Krajča, CSc.

Student: Martin Jílek

Kladno, květen 2016

Katedra biomedicínské techniky

Akademický rok: 2015/2016

Z a d á n í b a k a l á ř s k é p r á c e

Student: **Martin Jílek**
Obor: Biomedicínský technik
Téma: **Využití analýzy hlavních komponent pro automatickou detekci EEG transientů**
Téma anglicky: Principal component analysis for automatic detection of the EEG transients

Z á s a d y p r o v y p r a c o v á n í :

Vytvořte syntetický signál s hroty a umělými artefakty (špička, obdélník, sinusovka 15 Hz). Zpracujte takto vytvořený signál pomocí analýzy hlavních komponent (PCA). Odečtěte originální a filtrovaný syntetický signál. Výsledek usměrňte a porovnejte s mezí pro detekci. Označte epileptické hroty přímo v signálu. Totéž ověřte pro reálný EEG signál s transienty. Součástí práce je i vytvoření podrobné uživatelské dokumentace k vytvořenému programu.

Seznam odborné literatury:

- [1] Krajča V., Mohylová J., Číslicové zpracování neurofyziologických signálů, ed. Fakulta biomedicínského inženýrství, ČVUT Praha, 2011, ISBN 978-80-01-04721-7
- [2] Krajča V., Počítačová elektroencefalografie. Habilitační práce, VŠB-TU Ostrava, 1999
- [3] Krajča V., Petránek S., Hořejší J., Procházková V., Application of neural networks based principal component analysis for epileptic spike detection, Technical Colloquium ,Ilmenau, Germany, 1997
- [4] Murtagh Fionn, Multivariate Data Analysis with Fortran, C and Java Code, 2000
- [5] Haykin S., Neural Networks, Macmillan, 1994, ISBN ISBN 0-02-352761-7

zadání platné do: 30.09.2017

Vedoucí: doc. Ing. Vladimír Krajča, CSc.

Konzultant: prim. MUDr. Ing. Svojmil Petránek, CSc., MBA

.....
vedoucí katedry / pracoviště

.....
děkan

V Kladně dne 22.02.2016

Abstrakt

Vizuální interpretace stochastického EEG signálu postavená na zkušenostech a intuici experta je časově náročná a subjektivní, je tedy přirozené, že se jedná o typickou oblast aplikace pokročilých číslicových metod zpracování signálu a strojového učení. Cílem této práce je návrh, implementace a pilotní zkouška nového typu uživatelsky přístupného a efektivního automatického detektoru epileptických hrotů postaveného na jednokanálové filtraci pomocí analýzy hlavních komponent. Výsledkem je návrh a funkční řešení s následným kvalitativním i semikvantitativním otestováním na syntetických i reálných datech. Konečné řešení bylo zapouzdřeno do samostatného modulu a zároveň integrováno do prohlížeče signálu vytvořeného během předcházející práce a připraveno pro srovnání s jinými typy detektorů.

Klíčová slova: EEG, analýza hlavních komponent, detektor tranzientů, epileptický hrot, epilepsie, neuronová síť, GHA, SVD

Abstract

Due to the stochastic nature of EEG signal, its time-consuming interpretation is a matter of experience and intuition. In biomedical engineering, it is a traditional field of application of advanced signal processing techniques and artificial intelligence, both of them help expert to extract hidden information and make him more efficient. This work is devoted to design and implementation of a novel automatic, user-friendly and efficient detector of epileptic spikes based on a single-channel principal component analysis. The final solution was successfully encapsulated into a standalone module and integrated into our EEG browser created in previous work in a form suitable for further comparison with other detectors.

Keywords: EEG, principal component analysis, transient detector, epileptic spike, epilepsy, artificial neural network, GHA, SVD

Poděkování

Rád bych touto cestou vyjádřil poděkování panu doc. Ing. Vladimíru Krajčovi, CSc. za ochotu, trpělivost a vedení, dále bych chtěl poděkovat také Ing. Haně Schaabové a Ing. Václavě Sedlmajerové za konstruktivní připomínky a náměty během práce.

A handwritten signature in blue ink, appearing to read 'Jilek', is positioned above a horizontal dotted line.

Podpis

Prohlášení

Prohlašuji, že jsem bakalářskou práci s názvem Využití analýzy hlavních komponent pro automatickou detekci EEG tranzientů vypracoval samostatně a použil k tomu úplný výčet citací použitých pramenů, které uvádím v seznamu přiloženém k bakalářské práci.

Nemám závažný důvod proti užití tohoto školního díla ve smyslu §60 Zákona č.121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon).

V Praze dne 10.5.2016



.....

Podpis

Obsah

Úvod	1
1 Geneze a charakteristiky signálu	4
1.1 Geneze elektroencefalografického signálu	4
1.2 Snímání signálu	6
1.2.1 Zesilovač signálu	6
1.2.2 Snímací elektrody	6
1.2.3 Systém 10-20 a montáže	7
1.3 Typické charakteristiky signálu	9
1.3.1 Frekvenční pásma	10
1.3.2 EEG grafoelementy	11
2 Metody	14
2.1 Současný přístup k detekci grafoelementů	14
2.2 Analýza hlavních komponent	18
2.2.1 Singulární rozklad	20
2.2.2 Neuronové sítě	21
2.3 Návrh metodického řešení detektoru	26
2.3.1 Aplikace PCA pro filtraci jednorozměrného signálu	26
2.3.2 Koncept vytvoření vícerozměrného signálu	27
2.3.3 Výpočet hlavních komponent	28
2.3.4 Redukce dat a rekonstrukce	29
2.3.5 Usměrnění a stanovení pozic hrotů	31

2.4	Implementace detektoru	33
2.4.1	Výpočet PCA pomocí singulárního rozkladu	33
2.4.2	Výpočet PCA pomocí algoritmu GHA	33
2.5	Zakomponování do dosavadního systému	35
2.5.1	Konečný stav systému	35
2.5.2	Modul detektoru	36
2.6	Metodika testování	38
2.6.1	Syntetické signály	38
2.6.2	Reálné signály	43
2.6.3	Semikvantitativní testování detektoru	44
3	Výsledky	48
3.1	Zobrazení výsledků detekce	48
3.1.1	Uživatelské rozhraní detektoru	50
3.2	Generátor syntetického signálu	51
3.3	Ukázky výsledků detekce	52
3.3.1	Syntetické signály	52
3.3.2	Reálné signály	56
3.4	Ověření činnosti detektoru	61
3.4.1	Optimální nastavení parametrů	61
	Diskuze	68
	Závěr	71

Seznam obrázků

1.1	Neuron	5
1.2	Příložná část pacienta při EEG vyšetření	7
1.3	Základní montáže	8
1.4	Frekvenční pásma	11
1.5	Ukázky artefaktů	12
1.6	Ukázky ostrých transientů	13
2.1	Schéma třístupňového detektoru	15
2.2	Matematický model neuronu	22
2.3	Hebbovská neuronová síť	22
2.4	Celkové schéma PCA detektoru	26
2.5	Schéma první části PCA detektoru	27
2.6	Schéma druhé části PCA detektoru	29
2.7	Vývojový diagram algoritmu GHA	34
2.8	Blokové schéma prohlížeče	35
2.9	Schéma začlenění detektoru do prohlížeče	37
2.10	Signál napodobující hroty	39
2.11	Signál Sin+Tri+Rec	40
2.12	Signál Mukhopadhyay	40
2.13	Fragmenty signálu AR Complex	42
2.14	Signál AR Complex	43
2.15	Schéma závěrečného vyhodnocení	47
3.1	GUI prohlížeče	49

3.2	Temporální profil	49
3.3	GUI detektoru	50
3.4	GUI generátoru	51
3.5	Výsledky detekce (Sin+Tri+Rec)	53
3.6	Výsledky detekce (Mukhopadhyay)	54
3.7	Výsledky detekce (AR Complex)	55
3.8	Výsledky detekce (epileptické hroty)	57
3.9	Výsledky detekce (EMG artefakt)	58
3.10	Výsledky detekce (artefakt způsobený pohyby očí)	59
3.11	Výsledky detekce (amplitudový artefakt)	60
3.12	Konvergence neuronové sítě	62
3.13	Hlavní komponenty	63
3.14	Ukázka scree plotu	64
3.15	ROC křivky detektoru	65
3.16	Závislost AUC na šířce okna	66
3.17	Vliv prahu na detekci	67

Seznam zkratek

AR	AutoRegressive
AUC	Area Under Curve
BCI	Brain-Computer Interface
EEG	ElektroEncefaloGram
EKG	ElektroKardioGram
EMG	ElektroMyoGram
FN	False Negative
FP	False Positive
FPRt	False Positive Rate (in time)
GHA	Generalized Hebbian Algorithm
GUI	Graphical User Interface
PCA	Principal Component Analysis
ROC	Receiver Operating Characteristics
SVD	Singular Value Decomposition
TN	True Negative
TP	True Positive

Úvod

Motivace

Elektroencefalografie je neinvazivní, jednoduše proveditelné elektrofyziologické vyšetření, jehož výstupem je záznam elektrické aktivity mozku ze skalpu hlavy. Přes jednoduchoost snímání je následné vyhodnocení náročné, jelikož elektroencefalograf zaznamenává sumační aktivitu většího množství neuronů a kvůli složitosti chování a počtu nervových buněk v dané oblasti má výstupní signál stochastický a nestacionární charakter. Velké množství v něm obsažené informace je obtížné přesně definovat tak, jak lze například popsat tvar EKG křivky.

Z těchto důvodů je zde velký prostor pro aplikaci výpočetní techniky, ať v podobě sofistikovaných systémů strojového učení schopných extrahovat skrytou, člověkem obtížně zachytitelnou informaci, tak v podobě jednodušších nástrojů, které zvýší pohodlí, produktivitu a výkonnost lékařů. Do takové kategorie patří i detektory tranzientů, jejichž primárním úkolem je upozornit lékaře na z diagnostického hlediska podstatné části signálu. To má velký význam zejména u dlouhých, několikahodinových záznamů, které by po zapsání na papír měly délku až stovek metrů.

Tato práce se zabývá návrhem nového typu detektoru ostrých tranzientů, konkrétně epileptických hrotů, postaveném na analýze hlavních komponent s návazností na předchozí práci pana doc. Ing. Vladimíra Krajčí, CSc. [1] se snahou toto téma oživit a udělat pilotní studii možností detekčního algoritmu. Implementované rutiny a výsledky budou dále využívány v rámci EEG týmu na Fakultě biomedicínského inženýrství ČVUT v Praze.

Cíle

- Vytvořte generátor syntetického signálu, který se bude skládat ze sinusoidy (15 Hz), špiček a obdélníků.
- Navrhněte a implementujte PCA detektor epileptických hrotů, vytvořte uživatelskou dokumentaci.
- Označte detekované grafoelementy v syntetickém i reálném signálu.

Popis kapitol

Geneze a charakteristiky signálu

V první kapitole se nachází obecný úvod do elektroencefalografie. Pozornost je věnována původu signálu, jeho snímání a typickým charakteristikám.

Metody

Druhá kapitola se již přímo dotýká detekce grafoelementů. Rozebírá současný stav problematiky s následným návrhem vlastního řešení. Ten je následně rozveden do podoby implementace v MATLABu s popisem začlenění detektoru do vytvořeného prohlížeče EEG signálu. Poslední část kapitoly se věnuje metodice testování detektoru na reálných i syntetických signálech.

Výsledky

Třetí kapitola se zabývá prezentací stěžejních výsledků získaných na základě postupů popsanych v předchozí části. Na začátku se nachází ukázka implementovaného detektoru s uživatelským rozhraním a označenými hroty a zároveň uživatelské rozhraní generátoru syntetického signálu. Ve druhé části jsou prezentovány výsledky detekce na úsecích umělých i reálných signálů. Poslední sekce se zabývá semikvantitativním testováním detektoru a jedná se již o práci nad rámec zadání.

Diskuze a závěr

V diskuzi jsou okomentovány získané výsledky spolu s popisem komplikací, které

musely být řešeny. V závěru se nachází shrnutí výsledků a popis míry splnění zadaných cílů práce.

Geneze a charakteristiky signálu


Elektroencefalografie je neinvazivní diagnostická metoda využívaná především v neurologii a psychiatrii. Podstata vyšetření spočívá ve snímání rozložení elektrických potenciálů na povrchu hlavy v průběhu času. Metoda patří mezi vyšetření s nízkým prostorovým rozlišením, jelikož snímá změny elektrického potenciálu na povrchu skalpu způsobené součtem výbojů většího množství nervových buněk [2]. Naopak její výhodou je vysoké časové rozlišení, jelikož elektrická aktivita mozku odráží jeho stav prakticky okamžitě.

1.1 Geneze elektroencefalografického signálu

Elektroencefalografický signál je generován neurony v mozku. Tyto specializované vzrušivé buňky s vysokou konektivitou jsou základní stavební jednotkou nervové soustavy jakožto biologického systému pro zpracování informace. Mechanismus jejich funkce spočívá ve schopnosti reagovat na elementární externí podnět generováním elektrických impulzů (akčních potenciálů) pomocí regulace propustnosti iontových kanálů na svých cytoplazmatických membránách, která v kombinaci s aktivním transportem iontovými pumpami umožňuje buňce řídit její membránový potenciál.

Každá nervová buňka se skládá z těla, dendritů a axonu (obr. 1.1). Dendritů může mít neuron libovolné množství, ale nikdy nemá více než jeden axon (někdy též zvaný neurit). Dendrity slouží k aferentnímu vedení signálu, axon slouží k vedení eferentnímu, je tedy výstupem buňky. Dendrity umožňují přijímat akční potenciály přicházející od okolních nervových buněk, s jejichž axony jsou spojeny v místech zvaných synapse, které mohou být buď chemické, nebo elektrické. V chemických sy-

napsích dochází ke konverzi příchozího elektrického akčního potenciálu na chemický signál uvolněním vezikul s neurotransmitery do synaptické štěrbiny.



Obrázek 1.1: Stavba neuronu (Wikimedia Commons, upraveno.)

Molekuly neurotransmiteru dopadající na receptory na druhé straně synapse vyvolají elektrickou odezvu postsynaptické buňky, tzv. postsynaptický potenciál. Díky tomu je u chemické synapse možné, aby elektrická aktivita vyvolaná na postsynaptické membráně byla jiného charakteru než na membráně presynaptické. Některé synapse například mohou na svůj postsynaptický neuron působit inhibičně, jiné excitačně.

Excitační potenciály zvyšují membránový potenciál neuronu, zatímco inhibiční jej snižují. Pokud v daném okamžiku součet všech potenciálů vyvolaných v dendritech buňky zvýší její membránový potenciál z klidových -70 mV na -55 mV, v oblasti těla buňky v tzv. trigger zóně se vygeneruje akční potenciál, který se šíří po axonu k dalším neuronům nebo efektorům, jako jsou např. svalové buňky. [2] Tento potenciál má maximální amplitudu zhruba 30 mV a trvání řádově jednotek milisekund. Po vyslání impulzu se neuron na dobu přibližně 2 ms dostává do refrakterní fáze, kdy není schopen generovat další akční potenciál. [2]

Kromě toho existují i synapse elektrické, u nichž ke konverzi nedochází.

Celkový počet neuronů v centrální nervové soustavě dítěte po narození se pohybuje okolo 100 miliard, přičemž buňky jsou mezi sebou masivně propojeny — dospělý člověk má dohromady okolo 5×10^{14} synapsí [2]. Jejich sumární elektrická aktivita je dostatečná na to, aby byla zaznamatelná i po průchodu lebkou, byť velmi zeslabená.

1.2 Snímání signálu

EEG signál spadá se svou amplitudou (zhruba 10-100 μV [2]) mezi jedny z nejslabších biosignálů. Kvůli nízké amplitudě je nutné signál velmi zesílit, díky tomu je také snadno zarušitelný šumem i artefakty.

1.2.1 Zesilovač signálu

Zesilovače EEG signálu patří mezi zesilovače biologických signálů, na které jsou kladeny vysoké technické nároky. Jelikož signál má extrémně nízkou amplitudu, je nutné ho zesílit řádově 10^5 krát. Zesilovač zároveň musí mít vysokou vstupní impedanci (více než $10^8 \text{ M}\Omega$) a vysoký činitel potlačení souhlasného rušení (více než 10^7). [3]

V minulosti se využívaly analogové přístroje, které výsledné grafy zapisovaly na papír. Nevýhodou tohoto řešení je nemožnost měnit nastavení filtrů a montáží po nasnímání, kromě toho je problém s enormním množstvím záznamu, který je nutné vyhodnotit a skladovat. Pokud by rychlost posuvu papíru byla např. $3 \text{ cm}\cdot\text{s}^{-1}$, dvacetiminutový záznam by byl zapsán na papír o délce 36 m. Pokud by takto měl být pacient sledován po dobu osmi hodin ve spánkové laboratoři, papír by měl celkovou délku 864 m.

Tyto nevýhody odstranil digitální záznam signálu spolu s počítačovým zpracováním. Moderní elektroencefalograf se skládá z analogové části, která obsahuje zesilovače, filtry a ochranné obvody, výstupní signál je následně konvertován do digitální podoby a ukládán do počítače.

1.2.2 Snímací elektrody

Při záznamu EEG je možné využít široké spektrum elektrod, jak těch určených pro opakované užití, tak jednorázových. Je možné se setkat jak s jehlovými podkožními, tak povrchovými elektrodami. V klinické praxi se běžně využívají například argentchloridové nebo zlaté povrchové elektrody, které jsou připojeny k čepici na přesně vyznačená místa, což umožňuje relativně jednoduché polohování ze strany laboranta.

Před nasazením čepice někdy bývá prováděna abraze kůže, poté se čepice odpo- vídající rozměrům pacienta připevňuje na hlavu a pod elektrody se umístí elektroodivný gel, který zajistí optimální kontakt mezi elektrodou a pokožkou. Nicméně díky časově proměnným vlastnostem vlhkého rozhraní mezi pokožkou a elektrodou, jednak způsobenými vysycháním gelu a také potem, se takové zapojení příliš nehodí pro velmi dlouhé záznamy.[6]



(a) EEG čepice pro 256 kanálový záznam. Převzato z [4], upraveno.



(b) Pozlacené povrchové elektrody. Pře- vzato z [5], upraveno.

Obrázek 1.2: Příložná část pacienta při EEG vyšetření

Problém s vysycháním gelu řeší například suché aktivní elektrody, které se s výho- dou dají využít i pro dlouhé záznamy a aplikace typu BCI (brain-computer interface), kdy se vyžaduje spolehlivé spojení elektrody se skalpem i v neideálních podmínkách se zvýšeným rušením. Každá taková elektroda má svůj zesilovač, který provádí im- pedanční přizpůsobení v těsné blízkosti místa snímání.

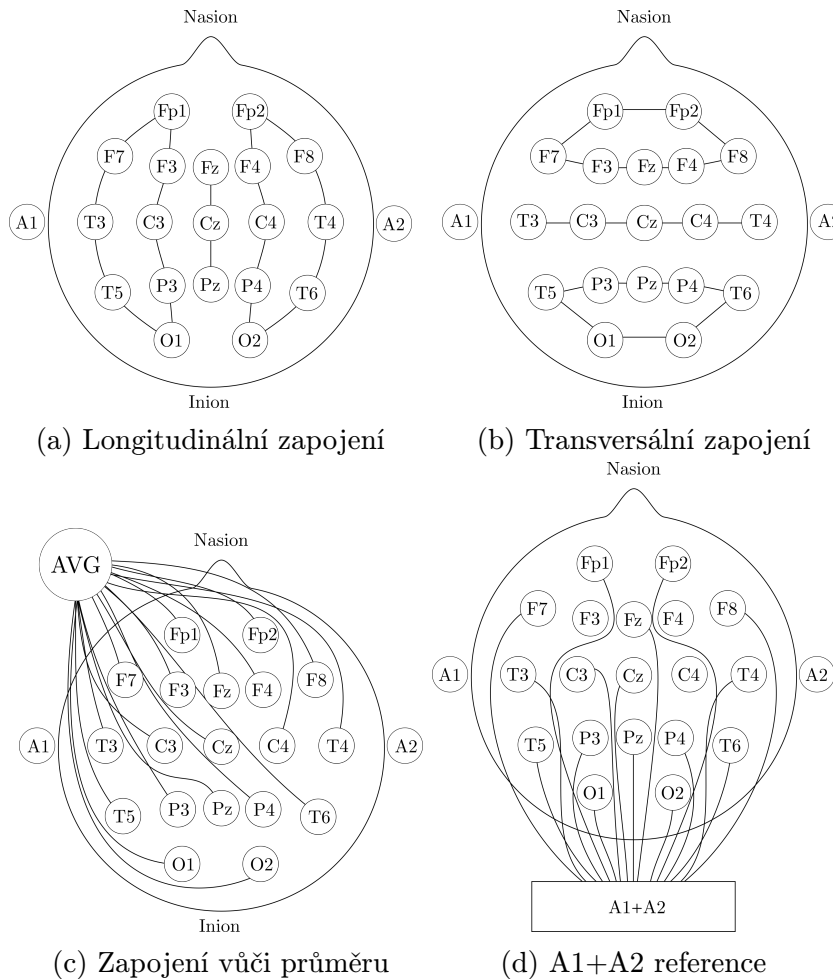
1.2.3 Systém 10-20 a montáže

V klinické praxi se často využívá standardizovaný systém 10-20 s 21 elektrodami, který definuje přesné umístění elektrod na skalpu, aby bylo možné srovnávat záznamy napříč vyšetřeními a pacienty. Název systému vypovídá o vzdálenostech elektrod, které jsou od sebe vzdáleny o 10 % nebo 20 % délky na povrchu skalpu.

Elektrody jsou na obou stranách skalpu zapojeny symetricky a jsou jim přiděleny alfanumerické kódy skládající se z písmene (případně dvou) a čísla, přičemž na levé

straně jsou čísla lichá a na pravé sudá. Písmena jsou volena podle anatomického umístění elektrod na lebce, standardně se rozlišují elektrody frontální (a frontopolární), centrální, temporální, parietální a okcipitální, kromě toho se pracuje s referenčními elektrodami na uších.

Jelikož v elektroencefalografii jsou snímána elektrická napětí, je nutné potenciály na zkoumaných elektrodách vztáhnout k určité referenci. To, jak bude zvolena, popisuje konkrétní montáž. Jedná se o poměrně kritický bod při hodnocení EEG záznamu, jelikož různé volby mohou mít výrazný vliv na čitelnost záznamu. Mezi hlavní kategorie zapojení patří unipolární, bipolární zapojení a zapojení vzhledem ke společné průměrné referenci, jejichž příklady jsou uvedeny na obr. 1.3.



Obrázek 1.3: Základní montáže demonstrovány na zapojení 10-20. Vzájemné referencování elektrod v kruzích představuje jejich propojení. AVG značí průměrný potenciál všech elektrod, A1+A2 je součet (resp. aritmetický průměr) potenciálů aurikulárních elektrod. Vytvořeno na základě [10].

První dva případy (1.3a, 1.3b) jsou zapojení bipolární, ve kterých je každá snímaná elektroda vztažena k některé z elektrod ve svém okolí. U prvního, longitudinálního zapojení, jsou vůči sobě vztaženy elektrody v longitudinální rovině, u zapojení transversálního v rovině transversální. Tato zapojení jsou vhodná pro identifikaci lokálních jevů se střední a vysokou amplitudou. [7]

Zapojení na obr. 1.3d je zapojení vůči společné svorce, v tomto případě průměru potenciálů ušních referenčních elektrod A1 a A2. Elektrody systému 10-20 je možné všechny vztáhnout vůči jedné referenční elektrodě, v klinické praxi se jedná například o elektrodu Cz. Tyto montáže nejsou tak vhodné pro identifikaci silně lokálních jevů, naopak se u nich projeví rozsáhlejší aktivita. Zároveň jsou náchylné na kontaminaci signálu z referenční elektrody. [7]

Zapojení na obr. 1.3c vztahuje potenciál každé elektrody k průměrnému potenciálu v příslušném čase na všech elektrodách. Toto zapojení má výhodu ve schopnosti vyrušit potenciály společné všem elektrodám. Dále srovnává drift izolinie, pokud je ve všech kanálech přibližně stejný. Pokud se však na některé ze zapojených elektrod vyskytne potenciál výrazněji vyšší než na ostatních, může dojít ke kontaminaci signálu. Tato nevýhoda se dá odstranit vážením příspěvků jednotlivých elektrod v závislosti na vzdálenosti v zapojení. [7]

1.3 Typické charakteristiky signálu

EEG signál patří mezi stochastické kvazistacionární signály, což znamená, že ho lze rozdělit do částí, které jsou (téměř) stacionární, tedy mají na čase nezávislé statistické momenty. Amplituda signálu se obvykle pohybuje v řádu desítek až sta mikrovoltů a obsahuje využitelné frekvence zhruba do 100 Hz. [2]

Omezený frekvenční rozsah a útlum amplitudy je způsoben především průchodem signálu skrz lebku a kůži, přičemž celá tato soustava má charakter dolní propusti. Díky tomu je možné zaznamenat jen výboje větších skupin neuronů, například oproti elektrokortikografii, u níž se pracuje s frekvenčním rozsahem řádově kHz a je možné pozorovat aktivitu jednotlivých buněk.

1.3.1 Frekvenční pásma

K popisu signálu se v klinické praxi často využívá aktivita ve čtyřech frekvenčních pásmech - delta, theta, alfa a beta. Kromě toho je možné setkat se i s pásmem gama. Pásmo alfa a beta bylo nalezeno Hansem Bergerem v roce 1929, delta rytmus byl objeven Walterem v roce 1936, dva roky poté Jasper a Andrews našli vysokofrekvenční gama vlny, theta vlny byly nalezeny v roce 1944 Wolterem a Doveyem. [2] Ukázky frekvenčních pásem zachycuje obr. 1.4.

Nejjednodušší přístup pro určení patřičného pásma je "počítání vln", kdy lékař spočítá přibližný počet period signálu za vteřinu záznamu. Pokročilejší obvyklou metodou je spektrální analýza, například pomocí Fourierovy transformace, která je umožněna počítačovým zpracováním signálu.

Tyto typy aktivity jsou jedním ze základních nástrojů při hodnocení záznamů, neboť jejich variabilita odráží psychický stav člověka, věk, umožňují rozlišit mezi různými stavy vědomí a odhalit patologické změny. [2]

Delta:

Delta vlny jsou charakteristické frekvenčním rozpětím 0,5-4 Hz. Obvyklé jsou v hlubokém spánku a probouzení.

Theta:

Theta vlny mají frekvence od 4 do 7,5 Hz. Jsou obvyklé v dětském věku, pokud se ve větší míře vykytují u probouzejících se dospělých, jedná se o patologii. Jsou také spojovány s meditačními stavy.

Alfa:

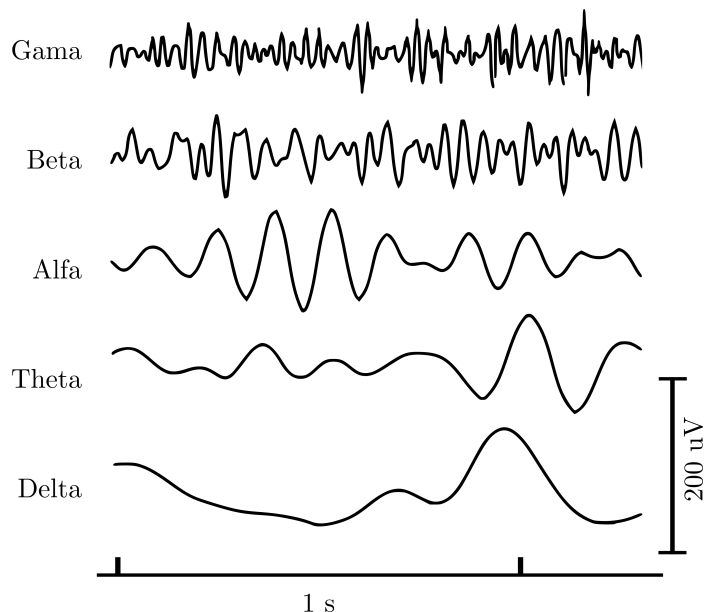
Alfa vlny o frekvencích 8-13Hz byly prvním objeveným EEG rytmem. Mají vzhled sinusoid, občas mohou mít i vzhled ostřejších vln. Jsou spojeny s bdělostí bez usilovné koncentrace, tlumí se při zavřených očích.

Beta:

Beta vlny mají frekvenci 14-26 Hz a jsou spojeny s mentální činností, zvýšený výskyt větších frekvencí může být způsoben stresem nebo panikou.

Gama:

Amplituda gama vln je oproti předchozím nízká, což je způsobeno útlumem vyšších frekvencí (30-45 Hz), ze kterých se tento rytmus skládá.



Obrázek 1.4: Ukázka tvarů signálů v základních frekvenčních pásmech v EEG signálu s orientačními měřítky. Převzato z [2], upraveno.

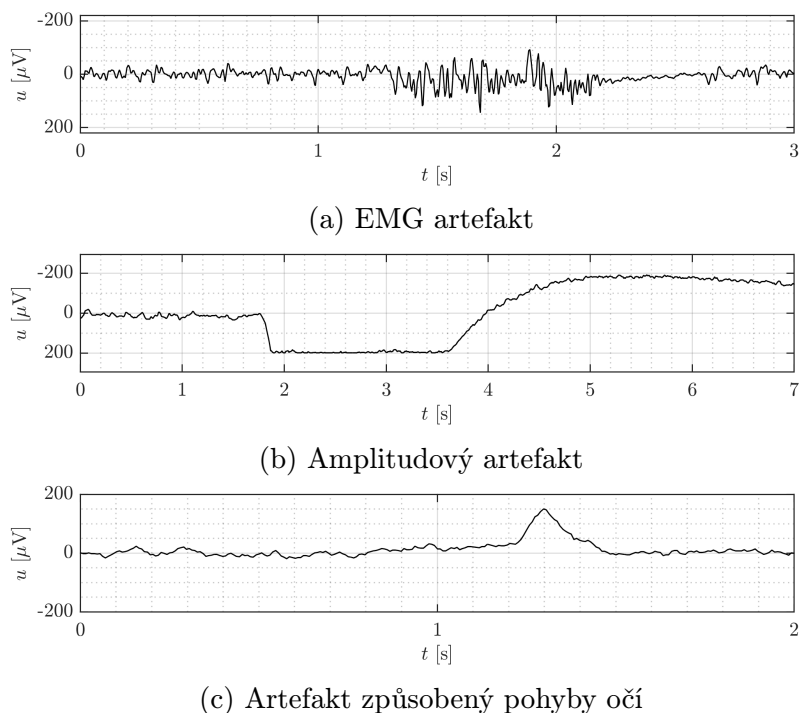
Kromě těchto základních pásem jsou rozlišovány i specifitější rytmy, které se ale v praxi využívají méně a jejich hodnocení často vyžaduje aplikaci pokročilých metod zpracování signálu. Jedná se například o ϕ -rytmus, který je složen z frekvencí menších než 4 Hz a objevuje se během dvou vteřin po zavření očí, τ -rytmus reprezentující alfa aktivitu v temporální oblasti, spánková vřeténka, χ -rytmus o frekvencích 11-17 Hz a podobně. [2]

1.3.2 EEG grafoelementy

Výše popsaná pásma představují déletrvající rytmickou aktivitu. Kromě toho se v záznamech setkáváme i s nestacionárními transienty — krátkodobými přechodovými jevy, které buď mají diagnostickou hodnotu, nebo vznikají jako důsledek nežádoucích rušení na pacientovi či mimo něj jako biologické či technické artefakty.

Mezi artefakty patří například artefakt způsobený mrknutím, EMG, EKG artefakty a amplitudové artefakty způsobené pohybem elektrod. [10] Typickým technic-

kým artefaktem je síťový brum, který se projevuje jako 50 Hz sinusoida superponovaná na signálu.



Obrázek 1.5: Ukázky obvyklých artefaktů v EEG záznamu

Kromě artefaktů můžeme v záznamu pozorovat další tranzienty, jako například vřetena, K-komplexy objevující se během NREM II spánku, pozitivní 14-Hz nebo 16-Hz hroty či vertexové ostré vlny. Kompletní popis dělení grafoelementů přesahuje rozsah této práce a je možné ho nalézt například v [8]. Jejich automatické rozlišení bývá výsadou složitějších, často od experta učících se systémů. Cílem navrženého detektoru je pouze upozornit lékaře na neobvyklé ostré grafoelementy, které jsou potenciálně patologické a epileptiformní, tudíž pro naše potřeby postačí následující dělení dle [11] nebo [12]:

Epileptický hrot:

Definován jako tranzient výrazně odlišitelný od aktivity na pozadí, trvá 20-70 ms. Epileptické hroty patří mezi základní grafoelementy, které jsou, spolu s vlnami, součástí složitějších celků.

Ostrá vlna:

Ostrá vlna je hladší než epileptický hrot, trvá 70-200 ms. Z diagnostického

hlediska má stejnou vypovídací hodnotu jako epileptický hrot, oba tranzienty jsou typické pro epilepsii. [12]

Pomalé komplexy hrot-vlna:

Jedná se o řadu komplexů hrot-vlna s frekvencí menší než 2.5 Hz.


3-Hz komplexy hrot-vlna:

Jedná se o obdobu předchozího případu, ale s rozdílnou frekvencí. Jsou charakteristické pro absenci-záchvat, kdy dochází ke krátkodobé ztrátě vědomí se zachováním svalového tonu.


Ostatní komplexy hrot-vlna:

Do této kategorie spadají další grafoelementy podobného tvaru, které nesplňují předchozí definice.

Na následujícím obrázku jsou ukázky grafoelementů, které jsou v použitých záznamech velmi časté:



(a) Epileptický hrot



(b) Komplexy hrot-vlna s frekvencí zhruba 3 Hz

Obrázek 1.6: Ukázky potenciálně epileptiformní aktivity. Jedná se o typické příklady grafoelementů, jejichž ostrou část má navrhovaný systém detekovat.

Metody

V této kapitole je popsán postup řešení zadání na základě průzkumu dostupné literatury, který je shrnut v první části. Rozebrán je současný stav detekce tranzientů v elektroencefalografii s následným úvodem do analýzy hlavních komponent. Na základě získaných poznatků byl vytvořen návrh řešení. Po něm následující dvě části této kapitoly se věnují implementaci a metodice testování.

2.1 Současný přístup k detekci grafoelementů

Detekce grafoelementů v EEG je velmi obsáhlá problematika, což je dáno zejména stochastickou povahou signálu a jeho interpersonální variabilitou. Mnohé typy grafoelementů je obtížné přesně morfologicky definovat a jejich rozpoznání vyžaduje od lékaře jistou míru zkušeností.

Problémem při práci s EEG signálem je neexistence snadno dostupných a univerzálně platných "zlatých standardů". Práce lékaře v tomto oboru je do velké míry otázkou zkušenosti a intuice, i mezi hodnotícími experty jsou tedy rozdíly. Příkladem je článek [13], v němž se autoři zabývali hodnocením spolehlivosti celkem pěti neurologů při označování epileptických hrotů, přičemž průměrná korelace mezi nimi byla stanovena na 0,68. Nejvíce se lékaři lišili v označení malých sporných grafoelementů.


Kromě toho je ve článku naznačena i časová náročnost. Úkolem lékařů bylo v každém ze 40 záznamů označit prvních 50 hrotů a u každého zaznamenat několik charakteristik. Každý lékař ze skupiny tímto strávil 40-80 h.

Od počátku vývoje automatických detektorů napomáhajících při diagnóze epilepsie se vývoj ubírá dvěma hlavními směry:[14]

- detekce a analýza interiktálních hrotů [16]

- analýza epileptických záchvatů

Jednodušší detektory grafoelementů se obecně skládají ze tří částí částí. V první fázi, po předzpracování (např. redukce šumu, přepočítání montáže) je signál upraven tak, aby došlo ke zvýraznění požadovaných grafoelementů, dále je tento signál usměrněn a nakonec porovnán s prahovou hodnotou, přičemž za pozitivní detekci je považováno její přesáhnutí, jak je ukázáno na schématu 2.1. [17]



Obrázek 2.1: Obecné schéma třístupňového detektoru. Blok předzpracování může obsahovat například filtry pro snížení množství šumu, lze za něj pokládat například i přepočet montáží. Primárním úkolem bloku vytvářejícího detekční signál je zvýraznění detekovaných tranzientů a potlačení ostatní aktivity tak, aby po porovnání výstupního signálu s mezí bylo možné spolehlivě označit epileptické hroty. Vytvořeno na základě [14].

Takto popsaný systém lze považovat za binární klasifikátor. Složitější detekční a klasifikační systémy mohou zařazovat do procesu ještě další bloky jako je segmentace a extrakce vícerozměrných příznaků. Pomocí segmentace je signál rozdělen na části, které splňují určitá kritéria (např. stacionaritu) a z nich jsou poté vypočteny příznaky.

Na extrakci příznaků lze nahlížet jako na redukci dimenze dat ze signálového prostoru (např. kde amplituda n -tého vzorku signálu je n -tá dimenze) do příznakového prostoru. [14]

Volba vhodných příznaků se velmi liší podle zvoleného přístupu klasifikace. Mezi ně dle [14] patří například:

- metody postavené na neuronových sítích
- shluková analýza
- pravidlové systémy
- metody využívající šablony

- parametrické metody
- mimetické metody

Příkladem takového komplexního systému pro automatické zpracování signálu je Wave-Finder [15].

Výše uvedený výčet principů detekce grafoelementů v EEG není jediný možný, jelikož se jedná o velmi rozsáhlou a dynamicky se vyvíjející problematiku. Při průzkumu literatury byla věnována pozornost především detektorům, které odpovídají výše uvedenému třístupňovému konceptu (obr. 2.1), tzn. neaplikují složité klasifikátory, pravidlové systémy, nepotřebují rozsáhlé soubory trénovacích dat a mívají menší množství nastavitelných parametrů. Jejich výhodou je obvykle kromě rychlosti i větší předvídatelnost.

Řadí se sem například detektory využívající parametrické metody. Tyto systémy jsou postaveny na předpokladu, že EEG aktivita na pozadí je stacionární, zatímco epileptické hroty a jiné transienty v signálu jsou nestacionární. Příkladem je detektor [18], jehož jádrem je autoregresní model signálu s časově proměnnými koeficienty, pro jejich odhad je využita Kalmanova filtrace. Jeho výstup je naprahován, čímž je rozhodnuto o přítomnosti případného grafoelementu.

Toho je využito i ve [20], kde James a kolektiv předpokládají, že signál se skládá z pozadí (které je stacionární) a dále z nestacionárních transientů. V práci [20] je pomocí adaptivního filtru na základě více kanálů odhadován signál na pozadí a odečítán od signálu reálného.

Na obdobném principu pracuje detektor [19], kde jsou epileptické hroty detekovány pomocí kombinace vlnkové transformace a časově proměnného autoregresního modelu.

Dalším využívaným přístupem je nelineární Teager-Kaiserův energetický operátor, jehož princip i s odvozením je popsán ve člancích [22] a [23]. Na základě fyzikální analogie zde je poukázáno na fakt, že energie harmonického oscilátoru závisí kvadraticky jednak na amplitudě a jednak na frekvenci oscilací. Jeho využití pro detekci epileptických hrotů zkoumá například [21] nebo [24].

Jedním z matematicky jednodušších a výpočetně méně náročných přístupů je využití informace o tvaru epileptických hrotů. Mezi takové metody patří například detektor [26], který vychází z časové definice epileptického hrotu a předpokládá, že se jedná o signál tvaru vyhlazeného trojúhelníku s náběžnou a sestupnou hranou o určitém sklonu a trvání. Nejprve je vypočten sklon náběžné hrany a , pokud má tato hrana dostatečné trvání, je určena ostrost samotného hrotu. Autoři schválně nevyužívají druhou derivaci kvůli její náchylnosti na vysokofrekvenční šum. Místo toho jako míru ostrosti měří časový interval, v jakém dochází ke změně mezi určitou kladnou a zápornou hodnotou první derivace. Pokud je i tato podmínka splněna, je vypočtena i první derivace sestupné hrany a doba trvání porovnána se stejným prahem jako při testování hrany náběžné. Jestliže jsou splněny všechny podmínky, grafoelement je klasifikován jako epileptický hrot. Problémem je dle autorů vysoké množství falešně pozitivních detekcí v případě výskytu svalových artefaktů a komplexů hrot-vlna, je doporučena kombinace s dalším detektorem.

Ještě výpočetně efektivnější metoda - aritmetický detektor - je navržena v [25]. Prvním blokem detektoru je diferenční filtr, který zvýrazní vysokofrekvenční aktivitu. Výstup je usměrněn umocněním (respektive vynásobením vzorkem signálu o určitém zpoždění) a následně porovnán s nastaveným prahem. Pokud je výstup větší než nastavený práh po dostatečně dlouhou dobu, je detekován hrot.

Detektor, který je citlivý na rychlé změny v signálu, jako např. EMG artefakty, může být postaven na mediánové filtraci. Mediánový filtr se aplikuje na celý signál a jeho výstup se odečte od původního záznamu. Výstupem bude křivka, která bude mít po usměrnění lokální maxima v bodech, kde se v původním signálu vyskytuje rychlá aktivita, jako jsou epileptické hroty a EMG artefakty. Na závěr opět dochází k porovnání s mezí. Nevýhodou takového detektoru je výpočetně náročné zjišťování mediánu. [10]

Robustnější detektor je možné vytvořit zkombinováním různých technik, které navzájem kompenzují své nevýhody. Příkladem je kombinovaný mediánový a aritmetický detektor [10], který za hrot označí pouze takové části signálu, na kterých se shodují výstupy obou systémů.

Ve článku [27] je pro detekci epileptických hrotů využita operace známá spíše ze zpracování obrazových dat - morfologická filtrace. Autoři využívají kombinace operací otevření a uzavření k získání detekčního signálu s potlačenou nehrotovou EEG aktivitou. Takový signál poté prochází prahováním. Výhodou je, že jako hodnotu prahu zde je možné nastavit očekávanou minimální amplitudu hrotu v mikrovoltech.

Mezi hojně využívané metody patří detekce založená na časově-frekvenčním popisu signálu. Jedním z hlavních zástupců je zde vlnková transformace, aplikovaná například v [31]. Ve článku byl signál rozložen do několika pásem a po nalezení optimálního frekvenčního rozmezí pro detekci hrotů naprahován. Pro prahování bylo využito konstantou vynásobeného rozptylu výstupu vlnkové transformace.

Pro vlnkovou transformaci je kritický správný výběr mateřské vlnky, podobný přístup jako v předchozím případě využili autoři [28] s tím, že pro optimalizaci jejich parametrů využívají genetický algoritmus. Vlnková transformace je též používána v kombinaci s neuronovými sítěmi, kde slouží jako předstupeň pro redukci množství vstupních příznaků, jako například v [29].

Mnohem sofistikovanější detektory jsou založeny na expertních systémech, které pracují s pravidly vytvořenými expertem nebo se složitějšími naučenými klasifikátory. Příkladem pravidlového systému je [30]. I tento přístup vyžaduje předzpracování a extrakci příznaků.

Příkladem učícího se systému, který může vyžadovat a priori informaci od experta v podobě množiny trénovacích dat, jsou neuronové sítě jako vícevrstvý perceptron, ať již v podobě sítě pracující s originálním, nepředzpracovaným signálem [32], tak v podobě sítě, jejímž vstupem jsou příznaky vypočtené z částí signálu [33].

2.2 Analýza hlavních komponent

Analýza hlavních komponent je metoda, která je využívána zejména pro redukci dat [34]. Její princip spočívá v nalezení takové ortogonální transformace, která převede původní data do nového souřadného systému takového, že první osa směřuje ve směru nejvyšší variance a další osy v dalších směrech nejvyšších variancí takových, aby byla zachována ortogonalita.

Pro redukci dimenze se využívá předpokladu, že směry nízké variance mají malou informativní hodnotu. Například u trojrozměrného shluku dat by po provedení PCA výrazně menší variance v jednom směru znamenala, že všechna data leží víceméně v rovině.

V následujícím textu jsme vycházeli z [35], kde jsou tvrzení i dokázána. Matematicky z pohledu statistiky jsou hlavní komponenty specifickými lineárními kombinacemi Y_1, Y_2, \dots, Y_p náhodných proměnných X_1, X_2, \dots, X_p z náhodného vektoru \mathbf{X} :

$$\begin{aligned} Y_1 &= \mathbf{a}_1^\top \mathbf{X} = a_{11}X_1 + a_{12}X_2 + \dots + a_{1p}X_p \\ Y_2 &= \mathbf{a}_2^\top \mathbf{X} = a_{21}X_1 + a_{22}X_2 + \dots + a_{2p}X_p \\ &\vdots \\ Y_p &= \mathbf{a}_p^\top \mathbf{X} = a_{p1}X_1 + a_{p2}X_2 + \dots + a_{pp}X_p \end{aligned} \tag{2.1}$$

Cílem analýzy hlavních komponent je maximalizace rozptylu jednotlivých hlavních komponent a zároveň zajištění jejich vzájemné dekorelace. Pro rozptyl a kovarianci v našem případě platí:

$$\text{Var}(Y_i) = \mathbf{a}_i^\top \Sigma \mathbf{a}_i \tag{2.2}$$

$$\text{Cov}(Y_i, Y_k) = \mathbf{a}_i^\top \Sigma \mathbf{a}_k \tag{2.3}$$

Příčemž Σ je kovarianční matice náhodného vektoru \mathbf{X} a indexy i a k jsou v rozsahu od 1 do p , p je počet hlavních komponent.

Pro výpočet první hlavní komponenty se snažíme maximalizovat vztah 2.2 s tím, že budeme požadovat, aby vektor \mathbf{a} byl jednotkový. Bez toho by pro maximalizaci stačilo zvyšovat jeho délku, což není žádoucí — je nutné měnit i směr.

Další hlavní komponenty vypočteme podobným způsobem s tím, že aplikujeme i vztah 2.3, a to tak, abychom dosáhli nezávislosti počítané hlavní komponenty na všech ostatních — tedy všechny kovariance mezi komponentami se musí rovnat nule.

Lze ukázat, že uvedené podmínky pro vztahy 2.2 a 2.3 splňují vlastní vektory kovarianční matice Σ . Pokud odpovídající si dvojice vlastních čísel a vektorů označíme $(\lambda_1, \mathbf{e}_1), (\lambda_2, \mathbf{e}_2), \dots, (\lambda_p, \mathbf{e}_p)$ a $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$, pro i -tou hlavní komponentu

platí:

$$Y_i = \mathbf{e}_i^\top \mathbf{X} = e_{i1}X_1 + e_{i2}X_2 + \cdots + e_{ip}X_p \quad (2.4)$$

A zároveň:

$$\begin{aligned} \text{Var}(Y_i) &= \mathbf{e}_i^\top \boldsymbol{\Sigma} \mathbf{e}_i & i = 1, 2, \dots, p \\ \text{Cov}(Y_i, Y_k) &= \mathbf{e}_i^\top \boldsymbol{\Sigma} \mathbf{e}_k & i \neq k \end{aligned} \quad (2.5)$$

Pro vlastní hodnoty kovarianční matice dále platí:

$$\sum_{i=1}^p \text{Var}(X_i) = \lambda_1 + \lambda_2 + \cdots + \lambda_p = \sum_{i=1}^p \text{Var}(Y_i) \quad (2.6)$$

Pokud chceme určit míru, jakou k -tá hlavní komponenta přispívá k celkové varianci souboru, využíváme poměru:

$$v_{explained} = \frac{\lambda_k}{\lambda_1 + \lambda_2 + \cdots + \lambda_p} \quad k = 1, 2, \dots, p \quad (2.7)$$

2.2.1 Singulární rozklad

Pro výpočet hlavních komponent je možné využít singulární rozklad. Jedná se o metodu, pomocí které můžeme rozložit každou matici \mathbf{A} o velikosti $m \times n$ do podoby:

$$\mathbf{A} = \mathbf{U}\boldsymbol{\Sigma}\mathbf{V}^\top \quad (2.8)$$

Kde \mathbf{U} a \mathbf{V}^\top jsou ortonormální matice o rozměrech $m \times m$ a $n \times n$, matice $\boldsymbol{\Sigma}$ je diagonální matice singulárních hodnot o rozměrech $m \times n$.

Pokud rovnici 2.8 zprava vynásobíme \mathbf{A}^\top , získáme:

$$\mathbf{A}\mathbf{A}^\top = \mathbf{U}\boldsymbol{\Sigma}\mathbf{V}^\top\mathbf{A}^\top = \mathbf{U}\boldsymbol{\Sigma}\mathbf{V}^\top\mathbf{V}\boldsymbol{\Sigma}^\top\mathbf{U}^\top = \mathbf{U}\boldsymbol{\Sigma}\boldsymbol{\Sigma}^\top\mathbf{U}^\top \quad (2.9)$$

Matice \mathbf{U} je poté matice se sloupci vyplněnými vlastními vektory $\mathbf{A}\mathbf{A}^\top$ a $\boldsymbol{\Sigma}\boldsymbol{\Sigma}^\top$ o rozměrech $m \times m$ je diagonální matice singulárních hodnot - druhých mocnin vlastních čísel $\mathbf{A}\mathbf{A}^\top$. Podrobnější matematický popis, ze kterého jsme vycházeli, je možné nalézt v [36].

Pokud bude matice \mathbf{X} v řádcích obsahovat hodnoty jednotlivých proměnných a bude vycentrována, tj. od každého řádku bude odečtena jeho střední hodnota, kovarianční matici můžeme zapsat jako:

$$\mathbf{C} = \frac{1}{n-1} \mathbf{X}\mathbf{X}^\top \quad (2.10)$$

Kde n je počet řádků nebo sloupců matice \mathbf{C} . Dosazením $\mathbf{X}\mathbf{X}^\top$ do vztahu 2.9 je poté možné provést rozklad na vlastní vektory a čísla. [37]

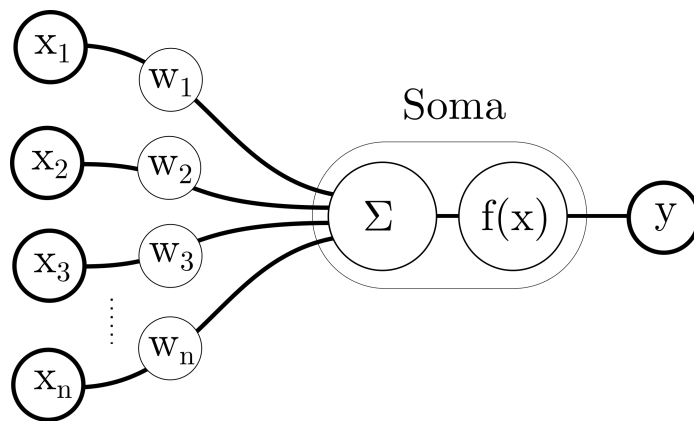
2.2.2 Neuronové sítě

Jeden z dalších možných přístupů k výpočtu hlavních komponent využívá samoorganizující se neuronové sítě adaptující se na principu Hebbova učení. Algoritmus je inspirován biologickými modely učení a asociace. Jeho autorem je psycholog Donald O. Hebb, který na přelomu poloviny 20. století vytvořil hypotézu učení a vzniku podmíněných reflexů u biologických neuronových sítí, popsanou v [38]. Volným překladem z původního textu lze myšlenku shrnout jako:

”Pokud axon buňky A opakovaně nebo vytrvale přispívá k excitaci buňky B, jakýsi růstový proces nebo metabolická změna způsobí zesílení vlivu buňky A na buňku B.”

Základem mnoha neuronových sítí v oblasti strojového učení je jednoduchý matematický model neuronu, který se skládá ze vstupů x_i , synaptických vah w_i , těla buňky a výstupního axonu. Po vložení vstupního vektoru je každý i -tý vstup vynásoben synaptickou vahou w_i . Synaptická váha představuje charakter synapse, tedy zda bude daný vstup na neuron působit excitačně či inhibičně a do jaké míry.


Vstupní signál dále vchází do těla neuronu (tzv. soma), které v prvním kroku působí jako sumátor. K váženému součtu vstupů se v některých případech přičítá ještě tzv. bias, který je ekvivalentní konstantnímu vstupu, opět váženého svou vahou. Výsledek se využije pro výpočet výstupu y pomocí funkce $f(x)$.



Obrázek 2.2: Jednoduchý matematický model neuronu. Vytvořeno na základě [41].

U biologických neuronů je výstupem y sekvence akčních potenciálů s různými časovými rozestupy. U našeho modelu je výstupem jedna hodnota, kterou lze intuitivně uchopit jako frekvenci vysílaných akčních potenciálů. Jako funkce $f(x)$ se využívá například jednotkový skok nebo sigmoida, nicméně v našem případě se bude jednat pouze o lineární funkci se směrnicí rovnou jedné.

Neurony, jako je příklad ilustrovaný na obr. 2.2, jsou skládány do sítí, díky čemuž mohou řešit komplexnější úlohy. Tyto sítě lze reprezentovat jako orientované grafy a dělí se do různých skupin např. podle počtu vrstev, neuronů nebo cykličnosti. V našem případě si vystačíme s acyklickou dopřednou sítí, která má jen jednu vrstvu neuronů. U takové struktury bylo totiž popsáno zvláštní chování — za specifických podmínek je schopna efektivně provést aproximaci hlavních komponent v předložených vícerozměrných datech. Tuto konstrukci nazveme Hebbovskou neuronovou sítí.



Obrázek 2.3: Hebbovská dopředná (feedforward) neuronová síť. Váhy nejsou pro přehlednost zobrazeny, neurony jsou označeny jako N_i . Vytvořeno na základě [41].

Pro její popis a odvození adaptačních algoritmů zavedeme matici vah \mathbf{W} :

$$\mathbf{W} = \begin{bmatrix} w_{11} & w_{21} & \dots & w_{m1} \\ w_{12} & w_{22} & \dots & w_{m2} \\ \vdots & \vdots & \vdots & \vdots \\ w_{1n} & w_{2n} & \dots & w_{mn} \end{bmatrix} \quad (2.11)$$

Kde prvek w_{ji} je synaptickou vahou na i -tém vstupu j -tého neuronu. Pro zjednodušení nejprve budeme uvažovat pouze jeden neuron. Vstupy do neuronové sítě bude obsahovat vektor $\mathbf{x}^\top = [x_1 \ x_2 \ \dots \ x_n]$. Pro vektor hodnot \mathbf{y} na výstupu sítě platí:

$$\mathbf{y} = \mathbf{x}^\top \mathbf{W} \quad (2.12)$$

Tedy výstup každého neuronu je lineární kombinací jeho vážených vstupů. Dále zavedeme pravidlo pro přepočítání vah při adaptaci neuronu:

$$\Delta w_{ji} = \eta x_i(t) y_j(t) \quad (2.13)$$

Kde x_i označuje hodnotu na i -tém vstupu. A váhy v čase $t + 1$ budou:

$$w_{ji}(t + 1) = w_{ji}(t) + \Delta w_{ji} \quad (2.14)$$

Pokud bude na vstup i výstup neuronu v čase t při adaptaci podle rovnice 2.13 předložena velká hodnota, dojde k zesílení váhy, jelikož i hodnota Δw_{ji} bude vysoká. To je velmi jednoduchý matematický zápis výše zmíněného Hebbova učení. Jeho problémem je především stabilita — hodnota vah bude při adaptaci růst bez omezení, což je z biologického hlediska nereálné a z hlediska výpočtů nepraktické.

Tímto problémem se zabýval finský vědec Erkki Oja, který odvodil jednoduchou aproximovanou rovnicí, která zavádí normalizaci. Ve svém článku [39] vychází z toho, že vektor synaptických vah j -tého neuronu může být normalizován vztahem:

$$w_{ji}(t+1) = \frac{w_{ji}(t) + \eta x_i(t)y_j(t)}{\sqrt{\sum_{j=1}^n [w_j(t) + \eta x_i(t)y_j(t)]^2}} \quad (2.15)$$

Přičemž η je kladná konstanta, která určuje rychlost adaptace. Ve článku [39] je uvedený vztah rozvinut do mocninné řady a je ukázáno, že pokud bude parametr η dostatečně malý, lze její vyšší členy zanedbat a pro adaptaci vah využít vztah:

$$w_{ji}(t+1) = w_{ji}(t) + \eta y_j(t) [x_i(t) - y_j(t)w_{ji}(t)] \quad (2.16)$$

To je tzv. Ojův algoritmus. Je nutno podotknout, že platí jen pro jeden neuron, tedy $j = 1$. Ve článku je zároveň poukázáno na to, že rozptyl výstupu s pravděpodobností rovnou jedné konverguje k nejvyšší vlastní hodnotě korelační matice vektoru vstupů, a na to, že vektor vah neuronu konverguje k jí odpovídajícímu vlastnímu vektoru.

Nevýhodou tohoto algoritmu je, že ze vstupních dat vyextrahuje pouze první hlavní komponentu. Vylepšením je zobecněný hebbovský algoritmus (generalized hebbian algorithm, GHA), který umožňuje ze vstupních dat extrahovat prvních n hlavních komponent. [40]

V tomto algoritmu jsou váhy aktualizovány podle rovnice:

$$w_{ji}(t+1) = w_{ji}(t) + \eta \left[y_j(t)x_i(t) - y_j(t) \sum_{k=1}^j w_{ki}(t)y_k(t) \right] \quad (2.17)$$

Základem je stále jednoduchý Ojův neuron z předchozího případu. Jeho výstupem po zkonvergování je první hlavní komponenta. Vstup druhého neuronu je původní signál, od kterého je odečten výstup prvního neuronu po zpětném promítnutí do prostoru vstupů. Ze druhého neuronu bude tedy vystupovat první hlavní komponenta původního signálu, od kterého byla předtím odečtena první hlavní komponenta, z globálního pohledu se tedy bude jednat o druhou hlavní komponentu, přičemž tento vzor se opakuje s každým dalším přítomným neuronem.

Při adaptaci má tedy každý j -tý neuron na svém i -tém vstupu hodnotu:

$$x'_i(t) = x_i(t) - \sum_{k=1}^{j-1} w_{ki}(t)y_k(t) \quad (2.18)$$

Pokud nahradíme v rovnici 2.16 vstup x_i výrazem 2.18, dojdeme opět k rovnici 2.17.

Pro konstantu rychlosti učení η by ideálně mělo platit: [41]

$$\eta(t) \rightarrow 0 \text{ když } t \rightarrow \infty \quad \text{a zároveň} \quad \sum_{t=0}^{\infty} \eta(t) = \infty \quad (2.19)$$

Nicméně v praxi se hodnota η volí jako malá konstanta, synaptické váhy poté k vlastním vektorům zaručeně konvergují se střední kvadratickou chybou v řádu hodnoty η [41].


2.3 Návrh metodického řešení detektoru

Tato kapitola obsahuje konceptuální návrh řešení úlohy s popisem jednotlivých funkčních bloků detektoru bez ohledu na implementaci. Na začátku je uvedeno celkové blokové schéma detektoru a následně jsou rozvedeny jeho jednotlivé části.

2.3.1 Aplikace PCA pro filtraci jednorozměrného signálu

V elektroencefalografii se PCA často využívá k redukci dimenze příznakového prostoru před vstupem příznaků do klasifikátoru. Kromě toho je možné využít PCA k filtraci signálu. Ve vícekanálovém EEG může být každý kanál uchopen jako jedna proměnná, po provedení PCA mohou být vybrány a odstraněny komponenty, které obsahují především šum a nežádoucí složky signálu a poté provedena zpětná projekce.

Další možností je provedení PCA pouze na jednorozměrných datech, čímž se zabývá i tato práce. Jedná se o princip, který není v literatuře příliš zmiňován, jediná nalezená studie je [1], v níž autoři došli k závěru, že metoda je velmi slibná, nicméně otázkou zůstává optimální počet vstupů a využitá hlavní komponenta. Kromě toho v práci není řešena problematika nastavení mezní hodnoty pro prahování a jsou využívány jen neuronové sítě. Tento článek bude v práci využit jako výchozí metodika s tím, že detektor bude implementován v původní zamýšlené formě a následně bude systematicky testován se snahou o jeho optimalizaci. Na základě obecného schématu detektorů epileptických hrotů 2.1 bylo zvoleno uspořádání ilustrované diagramem 2.4.



Obrázek 2.4: Principiální uspořádání navrhovaného detektoru

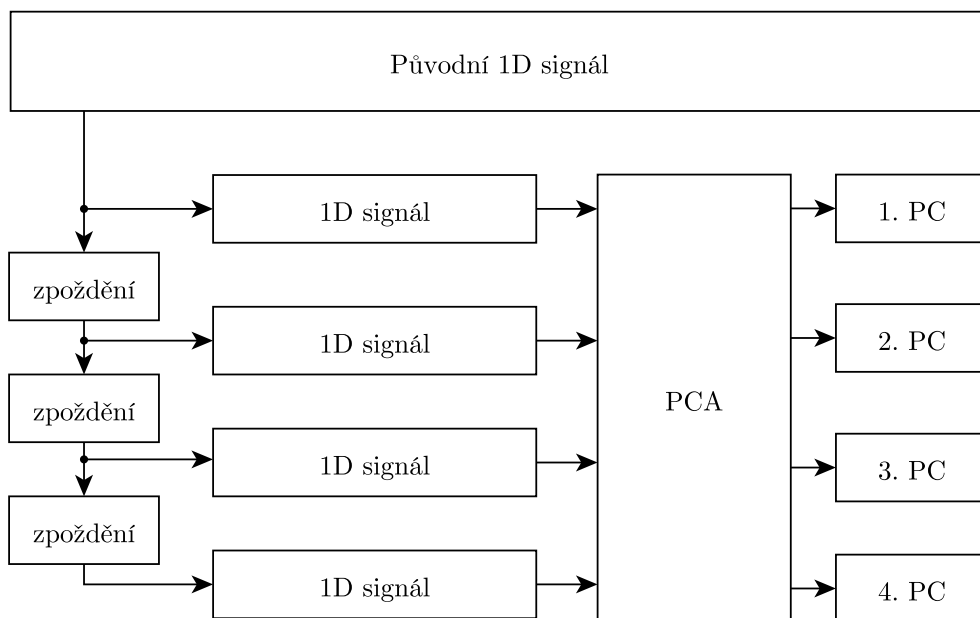
Vstupem do detektoru je originální signál zapojený v referenci vůči průměrnému potenciálu všech elektrod (AVG montáž). Dle článku [1] by nemělo být nutné signál více předzpracovávat.

V další části je jeden kanál rozložen do vícerozměrného prostoru a jsou z něj vypočteny hlavní komponenty. Z nich jsou vybrány ty, které nesou nejvýznamnější informace o pozicích epileptických hrotů a signál je zpětně zrekonstruován jen z nich.

Nakonec je signál usměrněn a porovnán s detekční mezí, výsledkem jsou pozice žádaných grafoelementů. V následující části práce bude schéma podrobněji rozvedeno.

2.3.2 Koncept vytvoření vícerozměrného signálu

Před vstupem do samotného algoritmu, který zajišťuje výpočet hlavních komponent, je nutné signál předzpracovat převedením do vyšší dimenze. To je naznačeno na schématu 2.5.



Obrázek 2.5: Schéma první části adaptivního PCA detektoru

Mějme jednorozměrný signál s celkem N vzorky ve vektoru \mathbf{X} :

$$\mathbf{X}^T = \begin{bmatrix} x(1) & x(2) & \dots & x(N) \end{bmatrix}$$

Tento původní signál postupně vstupuje do zpožďovacích členů. V každém čase je výstup každého zpožďovacího členu přikopírován do příslušného výstupního vektoru \mathbf{Y}_i . Vektor \mathbf{Y}_i je tedy stejný jako vektor \mathbf{X} , jen je o $i - 1$ kroků zpožděný. Např.

podle schématu 2.5 tedy i nabývá hodnot od 1 do 4. Díky tomuto přístupu můžeme k analýze hlavních komponent přistupovat maticově, pokud zavedeme matici \mathbf{V} :

$$\mathbf{V} = \begin{bmatrix} \mathbf{Y}_1 & \mathbf{Y}_2 & \dots & \mathbf{Y}_p \end{bmatrix} = \begin{bmatrix} x(1) & x(2) & \dots & x(p) \\ x(2) & x(3) & \dots & x(p+1) \\ \vdots & \vdots & \vdots & \vdots \\ x(N-p+1) & x(N-p+2) & \dots & x(N) \end{bmatrix} \quad (2.20)$$

Kde p je dimenze, do které chceme vstupní signál převést, a N je počet vzorků původního signálu.

Matice \mathbf{V} je poté vstupem do algoritmu, který z ní vypočítá hlavní komponenty.

2.3.3 Výpočet hlavních komponent

V práci je věnována pozornost dvěma přístupům - maticovému výpočtu PCA a také Hebbovskému učení, které je využito i v [1]. Maticový výpočet je proveden singulárním rozkladem a s výhodou u něj využijeme předchozího převedení signálu do matice. Jelikož detektor má pracovat rychle a s minimálními hardwarovými nároky, předpokládáme, že se nebude jednat o optimální metodu.

Zobecněný hebbovský algoritmus

Jak již bylo řečeno výše, algoritmus GHA je iterativní adaptivní metoda pro aproximaci hlavních komponent vstupních dat. Jeho výhodou by měla být vyšší rychlost v případě práce s mnohazměrnými daty, pokud se spokojíme jen s několika hlavními komponentami. Algoritmus je možné využít i v reálném čase a jelikož pro činnost nepotřebuje v jednom okamžiku všechna data, je efektivní i z paměťového hlediska.

Jelikož algoritmus GHA vyžaduje nastavení rychlosti adaptace, před vstupem do neuronové sítě jsou všechna data ve zpracovávaném signálu vydělena maximální hodnotou v něm nalezenou. Je tomu tak z důvodu snahy o univerzálnost parametru. Po zpětném promítnutí výstupů je amplituda dat vrácena na prvotní úroveň vynáso-

bením původní maximální hodnotou. Bez takového řešení by se neuronová síť mohla adaptovat u různých signálů s rozdílnou rychlostí a v nepříznivém případě by mohlo dojít až k nestabilnímu chování.

Singulární rozklad

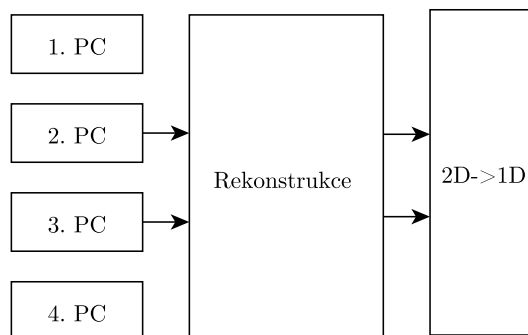
Singulární rozklad je obvyklý přístup k off-line výpočtu hlavních komponent. Jedná se o prostředek lineární algebry, pro který je nutné mít všechna data, se kterými výpočet provádíme, v jedné matici. Oproti výpočtu pomocí neuronových sítí jsou výstupem vždy všechny hlavní komponenty.

Z důvodu efektivity nebyl algoritmus v rámci práce implementován ručně, ale byla využita vestavěná funkce Matlabu `pca()`, která jako vstupní argument potřebuje matici dat \mathbf{V} a na výstup vrací jednak projekční matici (složenou z vlastních vektorů kovarianční matice), kterou je možné provést transformaci z původního prostoru do prostoru hlavních komponent, a jednak samotná transformovaná data.

Tato metoda byla zvolena z toho důvodu, že se jedná o standardní přístup k analýze hlavních komponent, měla by tedy poskytnout zajímavé srovnání s GHA.

2.3.4 Redukce dat a rekonstrukce

Po provedení PCA je nutné provést vhodnou úpravu dat v prostoru hlavních komponent, takovou, která umožní efektivní detekování požadovaných grafoelementů. Z hlavních komponent vybereme takové, jejichž průběh co nejjednoznačněji popisuje jejich pozice. Ostatní vynulujeme a signál zrekonstruujeme zpět.



Obrázek 2.6: Schéma druhé části adaptivního PCA detektoru

Například v ukázce na 2.6 je k detekci využita 2. a 3. hlavní komponenta. Pokud máme matici hlavních komponent \mathbf{P} , kde každé komponentě odpovídá jeden sloupec, a matici vlastních vektorů kovarianční matice (které jsou uspořádány do sloupců) \mathbf{W} , rekonstrukci provedeme pomocí rovnice:

$$\mathbf{X}' = \mathbf{P}\mathbf{W}^\top \quad (2.21)$$

Přičemž komponenty v matici \mathbf{P} , které nechceme využít, vynulujeme. Matice \mathbf{X}' obsahuje vícerozměrná data, my se potřebujeme vrátit zpět k jednorozměrnému signálu. Když matici \mathbf{X}' rozepíšeme, zjistíme, že má tvar:

$$\mathbf{X}' = \begin{bmatrix} x'_1(1) & x'_2(1) & \dots & x'_p(1) \\ x'_1(2) & x'_2(2) & \dots & x'_p(2) \\ \vdots & \vdots & \vdots & \vdots \\ x'_1(N-p+1) & x'_2(N-p+1) & \dots & x'_p(N-p+1) \end{bmatrix}$$

První sloupec matice \mathbf{X}' vznikl z prvního sloupce matice \mathbf{V} , druhý sloupec vznikl ze druhého sloupce matice \mathbf{V} atd. V našem pojetí jsou všechny sloupce matice \mathbf{V} kromě prvního pomocné a nemají pro nás přímý fyzikální význam. První sloupec obsahoval výchozí skutečný signál, po provedení PCA s vynecháním nepotřebné hlavní komponenty bude obsahovat signál vyfiltrovaný.

Zrekonstruovaný jednorozměrný vektor v původním signálovém prostoru získáme jako soubor všech hodnot v prvním sloupci matice \mathbf{X}' , tedy:

$$\mathbf{R}^\top = \begin{bmatrix} x'_1(1) & x'_1(2) & \dots & x'_1(N-p+1) \end{bmatrix}$$

Důležitou částí detekce je výběr správně hlavní komponenty, z níž bude vytvořen detekční signál. Nabízí se několik možností, které shrnuje tabulka 2.1.

Tabulka 2.1: Navržené možnosti vytvoření detekčního signálu

Název	Princip vytvoření detekčního signálu
Subtrakce PC 1	Výpočet první hlavní komponenty, odečtení od původního signálu
PC n	Výpočet n -té hlavní komponenty a její přímé využití
PC auto	Automatické určení hlavní komponenty na základě vysvětlené variance dle vztahu 2.7

Metody *Subtrakce PC 1* a *PC n* byly převzaty ze článku [1], metoda *PC auto* vznikla jako snaha o zevšeobecnění metody *PC n* a o zmenšení vlivu šířky okna na výsledky detekce.

Metoda *Subtrakce PC1* by teoreticky měla mít výhodu v relativně velké nezávislosti na velikosti vstupního okna, jelikož první hlavní komponenta v signálu vždy s poměrně velkým odstupem vysvětluje největší množství variance. Dalším předpokladem je, že metoda *PC n* bude při správné volbě n vykazovat nejlepší výsledky, nicméně toto nastavení nebude přenositelné na jiné záznamy, které mají odlišnou vzorkovací frekvenci, jelikož detekovaný grafoelement zde bude mít jiný počet vzorků. Metoda *PC auto* se snaží o zevšeobecnění metody *PC n*, jelikož využitá hlavní komponenta se vybírá na základě podílu variance, kterou vysvětluje. Výpočet je proveden dle vztahu 2.7.

Dále je tato problematika i s ukázkami signálů rozebrána v kapitole 3.

2.3.5 Usměrnění a stanovení pozic hrotů

Dalším krokem v navrženém detektoru je usměrnění, protože některé části detekčního signálu ve vektoru \mathbf{R} budou záporné. Rozhodli jsme se k využití jednoduché kvadratické funkce 2.22, která kromě usměrnění zajistí i zvýšení kontrastu mezi detekovanými grafoelementy a složkami signálu s nižší amplitudou.

$$y(t) = x'^2(t) \quad (2.22)$$

Takto vytvořený detekční signál je vstupem do systému, který již přímo rozhoduje o pozicích detekovaných grafoelementů. Jelikož máme k dispozici informaci o trvání

epileptického hrotu [11], byla s výhodou využita. V první části jsou v usměrněném signálu nalezena lokální maxima, u nichž jsou následně určeny šířky. Kandidáty na hrot jsou poté extrémy, které mají šířku mezi 5 ms a 70 ms. Dolní hranice byla oproti definici snížena, protože po filtraci se šířka hrotů může změnit.

Jelikož je signál usměrněný, v některých případech se může stát, že na místě jednoho hrotu bude více lokálních maxim, kromě toho bývají hroty často následované vlnou, která má dle definice trvání 70-200 ms [11]. Z tohoto důvodu je přidáno omezení minimálního rozestupu detekovaných hrotů 200 ms.

Poslední částí je prahování potenciálních pozic hrotů. To probíhá porovnáním usměrněného detekčního signálu s hodnotou u_{thr} získanou podle rovnice 2.23.

$$u_{thr} = c \cdot \frac{1}{N} \sum_{t=1}^N y(t) \quad (2.23)$$

Kde N je počet vzorků usměrněného detekčního signálu $y(t)$ a c je uživatelsky volitelná konstanta, která je v této práci v kontextu s nastavením detektoru nazývána prahem. Jedná se o velmi podobnou rovnici jako ve článku řešícím aritmetický detektor [42], její výhodou je jednoduchost a námi empiricky ověřená robustnost.

2.4 Implementace detektoru

Na nejnižší úrovni implementace bylo k detektoru přistupováno čistě funkcionálně. Nejdříve byly vytvořeny elementární části kódu, které byly postupně poskládány do dvou hlavních funkcí, `detect_PCA_SVD()` a `detect_PCA_GHA()`. Všechny vytvořené funkce nutné pro činnost detektoru shrnuje tabulka 2.2.

Tabulka 2.2: Tabulka vytvořených funkcí nutných pro činnost PCA detektoru.

Funkce	Účel
<code>detect_PCA_SVD()</code>	Hlavní rutina SVD detektoru
<code>detect_PCA_GHA()</code>	Hlavní rutina GHA detektoru
<code>SVD()</code>	Výpočet PCA z 1D signálu pomocí SVD
<code>sangerC()</code>	Výpočet PCA z 1D signálu pomocí GHA (MEX implementace v C ve formě 2.17)
<code>conv12D()</code>	Převod 1D signálu do podoby 2.20
<code>backProject()</code>	Projekce signálu na méně hlavních komponent

2.4.1 Výpočet PCA pomocí singulárního rozkladu

Hlavní funkcí pro volání detektoru s detekčním algoritmem SVD je `detect_PCA_SVD()`. Tato funkce zajistí zavolání funkce `SVD()` a pomocí vrácených vektorů kovarianční matice vytvoří zredukovaný signál funkcí `backProject()`. Dále provede usměrnění a nalezení epileptických hrotů, jejichž pozice vrátí na svém výstupu.

Funkce `SVD()` pro výpočet hlavních komponent využívá funkci Matlabu `pca()`, do níž jako vstupy vloží výstup funkce `conv12D()`, která převádí jednorozměrný vektor do matice.

2.4.2 Výpočet PCA pomocí algoritmu GHA

Algoritmus GHA byl implementován v několika podobách. Jelikož žádoucím výsledkem práce je pohodlně využitelný modul do stávajícího prohlížeče, který je vytvořený v Matlabu, prvotní implementace proběhla také v něm. Rovnice 2.17 bohužel vede

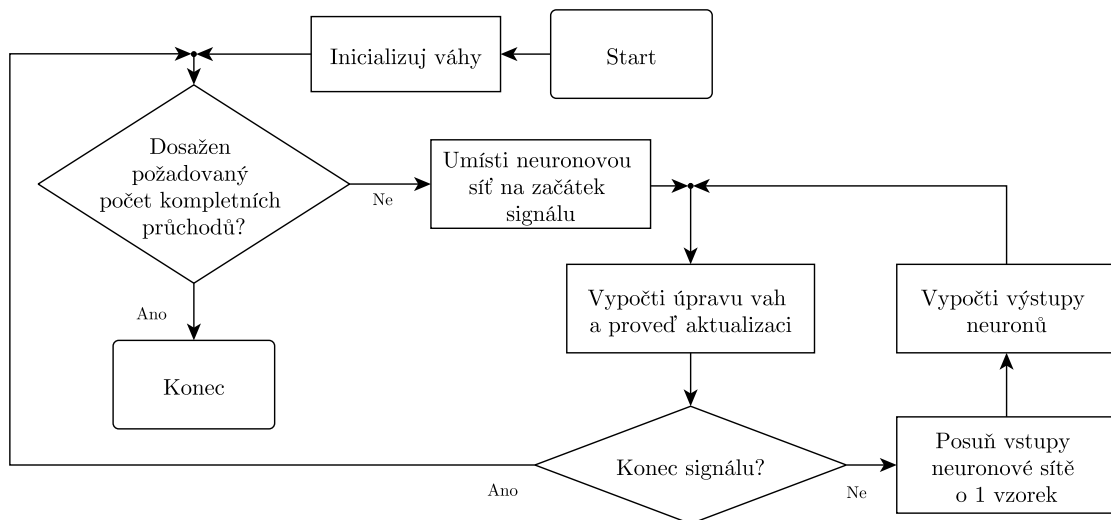
na vnořené for-cykly, což je, vzhledem k interpretované povaze Matlabu, poměrně nešťastné řešení. Algoritmus bylo tedy nutné využít ve tvaru: [40]

$$\mathbf{W}(t+1) = \mathbf{W}(t) + \eta [\mathbf{y}(t)\mathbf{x}^\top(t) - \text{LT} [\mathbf{y}(t)\mathbf{y}^\top(t)] \mathbf{W}(t)] \quad (2.24)$$

Kde LT označuje dolní trojúhelníkovou matici s nulami nad hlavní diagonálou a $\mathbf{x}(t)$ označuje řádky matice \mathbf{V} . Před vstupem do neuronové sítě jsou data vycentrována, tj. od každého sloupce matice \mathbf{V} je odečten jeho průměr.

Tato podoba algoritmu byla však v Matlabu stále pomalá, protože stále vyžaduje využití minimálně jednoho vnějšího cyklu, který bude procházet vektor se signálem, což může znamenat neúnosně vysoký počet iterací - například u jednoho kanálu ve dvacetiminutovém záznamu se vzorkovací frekvencí 250 Hz by to znamenalo zhruba 300000 iterací, když nepočítáme potřebu neuronové sítě provést adaptaci vícekrát, dokud váhy nedokonvergují s dostatečnou přesností k cílové hodnotě.

Z tohoto důvodu byl nakonec algoritmus implementován v jazyce C a byla z něj vytvořena MEX funkce, kód je tedy možno volat i z Matlabu. Zdrojový kód, z něž je možné vytvořit MEX funkci, je obsažen v souboru `sangerC.c`. Váhy jsou zde inicializovány funkcí `rand()` a jako seed je využit aktuální systémový čas.



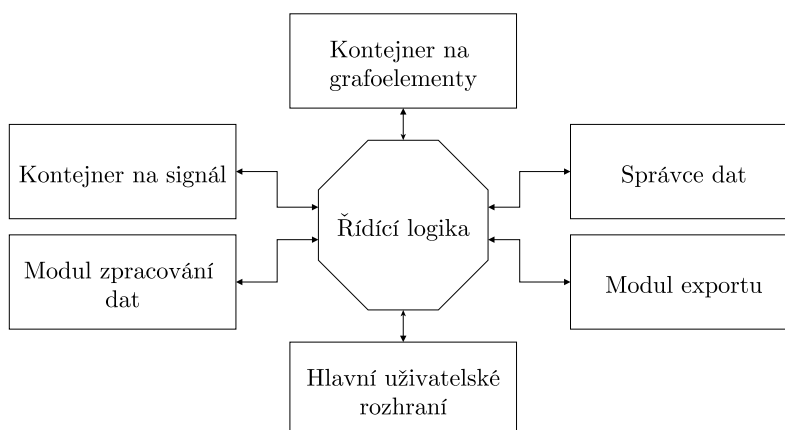
Obrázek 2.7: Implementovaný algoritmus GHA

2.5 Zakomponování do dosavadního systému

Po vytvoření a odladění byl detektor zakomponován do prohlížeče EEG signálu, který jsem vytvořil v rámci týmového projektu. Jedná se o modulární objektově řešený systém, který zatím umožňoval jen načítání, prohlížení a exportování signálu. Hlavním výstupem této části práce je funkční modul s přehledným uživatelským rozhraním umožňující provádět detekci grafoelementů.

2.5.1 Konečný stav systému

V konečném stavu se prohlížeč skládá ze šesti hlavních modulů (obr. 2.8), které jsou navzájem nezávislé a existují v kontextu hlavní třídy Program. Tato třída představuje řídicí logiku, která zajišťuje součinnost modulů tím, že reaguje na události vyvolané moduly spuštěním příslušných obslužných rutin.



Obrázek 2.8: Zjednodušené konceptuální schéma konečného stavu programu

Kvůli dosavadnímu objektově orientovanému přístupu bylo rozhodnuto v tomto paradigmatu pokračovat i u tvorby modulu detektoru. Při práci byly vytvořeny třídy shrnuté v tabulce 2.3.

Tabulka 2.3: Třídy vytvořené při implementaci detekčního modulu do prohlížeče

Třída	Účel
SpikeDetector	Abstraktní třída představující obecný detektor
SpikeDetector_PCA	Objektová implementace PCA detektoru
Spikes	Třída reprezentující hroty (představuje kontejner na grafoelementy na obr.2.8)
TemporalProfileClass	Třída reprezentující temporální profil

2.5.2 Modul detektoru

Jelikož je předpokládáno, že do dosavadního systému budou přidány další detektory, bylo vytvořeno standardní rozhraní představované abstraktní třídou `SpikeDetector`, která bude nadtřídou všech detektorů.

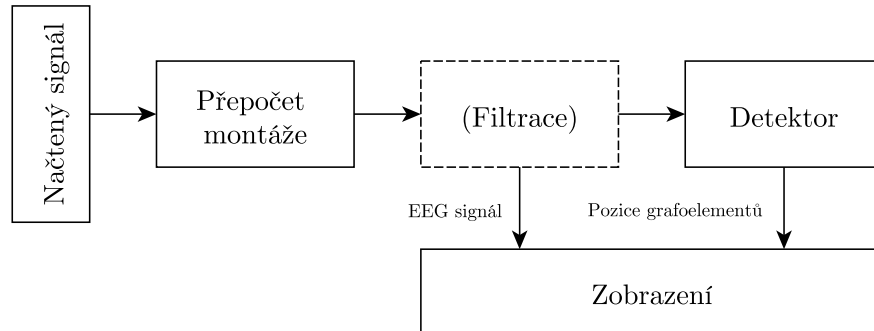
Obecné rozhraní detektoru

Metody vytvořené podtřídy, které nezbytně musí být implementovány, jsou `detect()` a `showGUI()`. První zmíněná metoda na vstupu požaduje vstupní signál v podobě instance třídy `ExtractedData`, která slouží v celém programu pro reprezentaci dat, spolu s volitelnými parametry, které budou záviset na specifických požadavcích konkrétního detektoru. Metoda `showGUI()` je volána v případě potřeby zobrazit uživatelské rozhraní pro výběr parametrů. Dále je nutné, aby detektor byl schopen v případě nastavení parametrů uživatelem vyvolat událost `ParamsChosen` a v případě aktivace nebo deaktivace událost `toggle`.

Konkrétní implementace pro PCA detektor

Vytvořený modul detektoru představuje třída `SpikeDetector_PCA`. Detektor se stal součástí modulu pro zpracování dat, který obsahuje řetězec navazujících bloků zpracování signálu, jak je ukázáno na obr. 2.9. Detektor může pracovat ve dvou režimech - online a offline, přičemž doporučeným je druhý zmíněný. U něj detektor provede detekci na základě celého signálu pouze jednou, při svém spuštění, což zajišťuje rychlejší odezvu programu a přesnější výsledky. Nicméně pokud je signál příliš

dlouhý na to, aby se vešel do operační paměti počítače, je nutné pracovat v režimu online, který detekci provádí při každém posunu stránky a využívá jen signál v ní obsažený.



Obrázek 2.9: Schéma činnosti detektoru v kontextu modulu pro zpracování dat. Blokem Filtrace v konečném stavu systému prochází signál beze změny, jelikož jeho funkcionality zatím není stabilně implementována.

Detektor je také vybaven vlastním, na prohlížeči nezávislým uživatelským rozhraním, které je spolu s ukázkou zobrazování výsledků detekce v prohlížeči podrobně popsáno v kapitole 3.

2.6 Metodika testování

Detektor byl testován na syntetických i reálných datech. Pro tvorbu syntetických dat byl vytvořen modul, který v prohlížeči signálů využívá rozhraní pro načítání reálných souborů. Implementován byl ve stejné filosofii jako celý systém, tedy objektivě v MATLABu verze 2015a. Pro práci s reálným signálem byly využita funkcionalita systému pro načítání souborů `.edf` a `Easys (.d)` vytvořená v průběhu týmového projektu. Kromě toho bylo nutné doplnit množinu otevíratelných souborů `BrainQuick` o typ 0 a 3, protože právě v nich má EEG team archivovány epileptické záznamy.

2.6.1 Syntetické signály

Při syntéze syntetických signálů byl signál pomyslně rozdělen na dvě části — relativně neměnná aktivita na pozadí a dále na signál obsahující artefakty a grafoelementy. Generování tranzientů zajišťují vytvořené funkce, které syntetizují jeho model a umístí ho na definovanou polohu do výsledného signálu.

Pro generování signálů byly využity tři přístupy. První, nejjednodušší signál, který vychází ze zadání práce, se skládá z kombinace úseků sinusoidy, obdélníkového signálu a simulovaných hrotů. Další model využívá superpozice sinusoid, opět s vloženými hroty, poslední a nejsložitější model signálu byl vytvořen na základě autoregresní filtrace bílého šumu, díky které lze imitovat části EEG signálu.

Polohy, trvání a amplitudy jednotlivých částí signálu jsou vygenerovány náhodně, v rozmezí hodnot zvolených tak, aby i při své jednoduchosti byly co nejuvěrnější aproximací skutečného EEG signálu. Pro výpočet náhodných čísel byl kvůli reprodukovatelnosti využit standardní generátor MATLABu Mersenne Twister s pevně nastaveným seedem na 0.

Z programátorského hlediska je modul pro generování syntetických signálů řešen jako třída, která je potomkem abstraktní třídy, od níž dědí všechny třídy podílející se na načítání dat ze souborů. Díky tomu je kompatibilní se všemi funkcemi, které dříve pracovaly jen s reálnými daty. Ukázka jeho uživatelského rozhraní se nachází v části 3.2.


Pro generování testovacích signálů byly vytvořeny funkce shrnuté v tabulce 2.4. Všechny tyto rutiny jsou volány z vytvořené instance třídy `reader_Generator()`, která pomocí nich skládá dále rozebrané složitější průběhy signálů.

Tabulka 2.4: Kód vytvořený v rámci práce na generátoru syntetického signálu

Funkce nebo třída	Účel
<code>reader_Generator</code>	Třída zahrnující všechny vytvořené generátory signálu
<code>arGenerator()</code>	Funkce generující signál z AR modelu
<code>GenerateSignal()</code>	Vytvoření sekvence hrotů
<code>PseudoSpike()</code>	Vytvoření jedné napodobeniny hrotu
<code>PseudoMuscle()</code>	Vytvoření napodobeniny svalového artefaktu
<code>PseudoRectangle()</code>	Vytvoření napodobeniny amplitudového artefaktu

Základní signál s hroty


Tento signál je použit prakticky ve všech dalších signálech k vytvoření složky odpovídající patologickým ostrým grafoelementům. Jeho generování zajišťuje funkce `GenerateSignal()`, která na základě svých vstupních argumentů vytvoří sekvenci trojúhelníkových pulzů o zadaných trváních, amplitudách, vzorkovací frekvenci a umístění.



Obrázek 2.10: Signál napodobující hroty

Signál Sin+Tri+Rec

Tento signál je pro testování nejdůležitější, jelikož byl vytvořen na základě zadání práce. Skládá se z obdélníkových pulzů napodobujících amplitudové artefakty, z úseků 15 Hz sinusoidy napodobujících svalové artefakty a ze základního signálu s hroty.



Obrázek 2.11: Signál Sin+Tri+Rec s označením hrotů umístěných generátorem


Signál Mukhopadhyay

Tento signál byl vytvořen podle článku [21] a je využíváný i jinými autory, jako například [24] a [19]. Je tvořen signálem na pozadí:

$$y(t) = \sin(\omega t) - \sin(2\omega t + \phi) + \sin(4\omega t) \quad (2.25)$$

Přičemž $\phi = \pi/2$ a $\omega = 2\pi/75$.

A signálem s hroty, který je k signálu $y(t)$ přičten. Hroty mají šířku dle definice z intervalu $\langle 20; 70 \rangle$ ms a amplitudu s rovnoměrným rozdělením z intervalu $\langle 2.5; 7.5 \rangle$ μV s náhodným znaménkem.



Obrázek 2.12: Signál Mukhopadhyay s označením hrotů umístěných generátorem

Autoregresní modely signálu

Nejsložitějším využitým modelem signálu jsou autoregresní modely. Pro vygenerování signálu byla využita filtrace bílého šumu pomocí autoregresních filtrů druhého řádu, tedy s přenosem ve tvaru:


$$G(z) = \frac{1}{1 + a_1 z^{-1} + a_2 z^{-2}} \quad (2.26)$$

Koeficienty modelů, převzaté ze článku [43], měly hodnoty uvedené v tabulce 2.5.


Tabulka 2.5: Shrnutí parametrů autoregresních modelů signálu. Převzato ze [43].

Název	a_1	a_2	A_{noise}
AR I	-1,386	0,81	1
AR II	-1,736	0,756	0,5
AR III	-1,25	0,39	1
AR IV	-1,692	0,81	1,1


Přičemž bílý šum měl hodnoty z intervalu $\langle -A_{\text{noise}}; A_{\text{noise}} \rangle$. Po provedení konvoluce filtru a bílého šumu musel být každý výstupní signál vynásoben pěti, aby se více blížil amplitudě skutečného EEG signálu.




(a) Signál AR I



(b) Signál AR II



(c) Signál AR III




(d) Signál AR IV

Obrázek 2.13: Signály AR I, AR II, AR III a AR IV

Tyto signály samy o sobě nebyly využívány k testování detektoru, ale jsou důležitým stavebním prvkem dalšího, již využitého signálu, který obsahuje i epileptické hroty. Základem je čistá sekvence hrotů jako na obr. 2.10, přičemž amplitudy jsou z intervalu $\langle -70; 70 \rangle$ μV . Podle sekvence hrotů je vytvořen signál, který obsahuje

jedničku ve všech bodech, kde je přítomen hrot, a nulu tam, kde přítomen není. Poté stačí zderivováním detekovat sestupné a náběžné hrany a každý segment mezi hroty vyplnit jedním z autoregresních modelů signálu. Výsledek je zachycen v grafu 2.14.

Výběr typu modelu pro každý segment zajišťuje generátor náhodných čísel, který je na začátku celého procesu inicializován se seedem 0. Tento signál má oproti ostatním nastavenou pevnou vzorkovací frekvenci 200 Hz.



Obrázek 2.14: Komplexní autoregresní signál s označenými hroty umístěnými generátorem

2.6.2 Reálné signály

Pro práci s reálnými daty byly využity anonymizované záznamy s epileptickou aktivitou. Jelikož se jedná teprve o pilotní studii, bylo vybráno devět záznamů, které byly ohodnoceny panem prim. MUDr. Ing. Svojmilem Petránkem, CSc., MBA. K jejich využití byl k roku 2012 udělen souhlas etické komise, jejímž předsedou byl prof. MUDr. Michal Holub, Ph.D. Záznamy mají různou délku, vzorkovací frekvenci 128 Hz a pocházejí od epileptických pacientů. U všech záznamů byly manuálně označeny epileptické hroty pomocí nejnovější verze prohlížeče. Shrnutí záznamů je v tabulce 2.6. Při vyhodnocování bylo rozhodnuto, že potenciál každé elektrody bude vztažen k průměrnému potenciálu všech EEG elektrod, využívá se tedy AVG unipolární reference. Výhoda zapojení spočívá v tom, že slouží jako jednoduchý filtr potlačující části signálu, které jsou ve všech kanálech shodné. Pokud signál z jedné elektrody v danou chvíli není výrazně odlišný od ostatních, například díky výskytu artefaktů, a nedojde ke kontaminaci, má toto zapojení výhodu i v potlačení šumu a vyrovnání driftu izolinie.

Tabulka 2.6: Souhrn využitých záznamů. Celkové uvedené trvání je vypočteno jako součin celkového trvání záznamu a počtu EEG kanálů.

Pacient	Záznam	Počet kanálů	T [min]	Označené hroty
A	1	19	11	66
A	2	19	13,3	27
B	1	19	12,3	892
B	2	19	24	1191
C	1	19	10,6	43
C	2	19	13,4	250
D	1	19	8,3	19
E	1	19	22,6	55
F	1	19	8,3	471
Celkem:			2352,2	3014

2.6.3 Semikvantitativní testování detektoru

Nad rámec zadání práce bylo provedeno testování detektoru, jehož výstupem jsou kvantitativní výsledky. Pro jeho účel bylo vytvořeno programové vybavení, které umožňuje provést automatický výpočet charakteristik detektoru na základě počítání správně pozitivních, falešně pozitivních a falešně negativních detekcí. Problémem u detektorů tohoto typu je, že pracují s nesegmentovaným signálem a je obtížné definovat správně negativní případy, teoreticky by správně negativní mohl být téměř každý vzorek signálu. Z tohoto důvodu budou využívány pouze charakteristiky, které počet TN nevyžadují. [45]

V souladu s často využívanými charakteristikami byla vybrána senzitivita (2.27) a $FP Rt$ (ve významu dle vztahu 2.28).

$$S = \frac{TP}{TP + FN} \quad (2.27)$$

$$FP Rt = \frac{FP}{t} \quad (2.28)$$

Kde TP , FP a FN je počet správně pozitivních, falešně pozitivních a falešně negativních případů, t je celkové trvání záznamu. $FPRt$ poté vyjadřuje počet falešně pozitivních detekcí za jednotku času.

Tyto charakteristiky byly počítány pro jednotlivé záznamy při různém nastavení parametrů detektoru a následně srovnány, čímž je umožněno vyhodnocení stability detekce při aplikaci na různé pacienty.

Kromě toho byla snaha vyhodnotit chování detektoru jako celku. Pro tento účel bylo o všech signálech uvažováno jako o jednom dlouhém záznamu s jedním kanálem. Poté je dle [46] pro výpočet senzitivity možné využít vztah:

$$tSEN = \frac{\sum_{i=1}^M TP_i}{\sum_{i=1}^M (TP_i + FN_i)} \quad (2.29)$$

Kde M je počet samostatných záznamů, u kterých jednotlivě provádíme detekci. Pro výpočet $FPRt$ do vztahu 2.28 poté dosazujeme součet trvání jednotlivých záznamů a celkový počet falešně pozitivních detekcí ve všech záznamech. Pro výpočet charakteristiky $FPRt$ je možné stále využít vztah 2.28, s tím, že čas t vyjadřuje trvání celého sloučeného záznamu.

Algoritmus vyhodnocení

Při následném testování a optimalizaci byly vypočteny charakteristiky 2.27 a 2.28 pro každou navrženou kombinaci nastavení prahu a šířky okna detektoru, následně byly vytvořeny ROC křivky s tím, že byly chápány jako závislost senzitivity na $FPRt$ ve smyslu vztahu 2.28, jako v [46].

Jako ukazatel kvality dané ROC křivky byla zvolena plocha pod křivkou (AUC), přičemž integrál byl počítán od $FPRt = 0 \text{ min}^{-1}$ do $FPRt = 20 \text{ min}^{-1}$. Pokud ROC křivka nezačínala v první zmíněné integrační mezi, byla provedena lineární extrapolace.

Pro usnadnění hodnocení byl vytvořen program, který automaticky načte předložené soubory se signálem a s označenými hroty, provede detekce s nastavenými parametry a po porovnání detekovaných hrotů s referencí vypočte hlavní charakteristiky detektoru. To vše je úkolem rutin v tabulce 2.7.

Tabulka 2.7: Vytvořené rutiny pro testování charakteristik detektoru

Skript nebo funkce	Účel
TraverseFiles	Spouštěcí skript vyhodnocení
evaluateDetector()	Funkce spouštějící detektor s různým nastavením a počítající TP, FP a FN
processResults()	Funkce provádějící výpočet konkrétních charakteristik detektoru

Po spuštění skriptu `TraverseFiles` je nutné do několika následujících dialogových oken zadat parametry, pro jaké bude probíhat testování. Program po zadání parametrů inicializuje detektor a v cyklech bude detekovat hroty postupně se všemi kombinacemi nastavení pro každý záznam. Následně je porovnána shoda mezi výsledky detekce a známými pozicemi hrotů a vyhodnocena úspěšnost, a to podle následujících empirických definic:

- **Správně pozitivní detekce:** v intervalu ± 0.1 s okolo detekovaného hrotu je nalezen hrot označený expertem
- **Falešně pozitivní detekce:** v intervalu ± 0.1 s okolo detekovaného hrotu není nalezen hrot označený expertem
- **Falešně negativní detekce:** v intervalu ± 0.1 s okolo expertem označeného hrotu není nalezen hrot označený detektorem

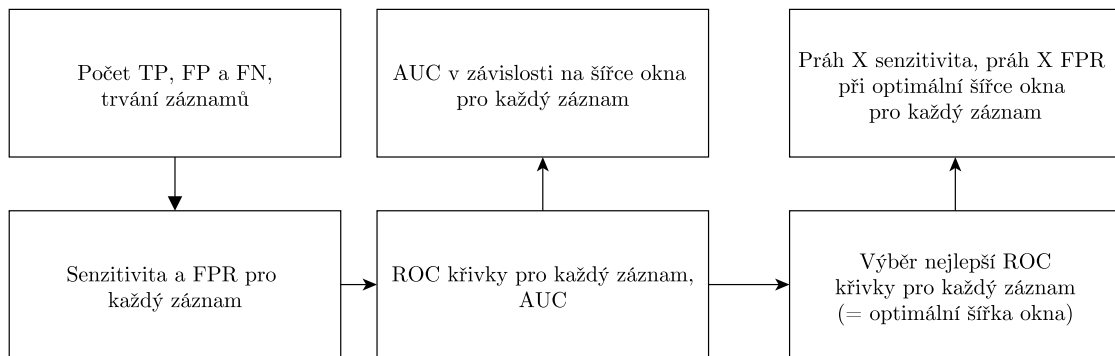
Přebírání hrotů probíhá postupně, tedy v každém záznamu jsou nejprve vybrány TP, které jsou poté vyřazeny z dalšího porovnání, následně jsou ze zbylých událostí vybrány a odstraněny FP a nakonec stejným způsobem FN.

Výsledky se uloží do souboru `.mat` a poté je nutné provést další zpracování.

Závěrečné zpracování

Funkce `processResults()` provádí analýzu souboru výsledků předchozího testování podle diagramu 2.15. Pro každý záznam je vypočtena senzitivita a FP_{Rt} , následně jsou pro každý záznam z testovací množiny vytvořeny ROC křivky, pro každou nastavenou šířku okna jedna.

Z nich je pomocí AUC v každém záznamu vybrána ta nejlepší — čímž pro každý soubor získáváme optimální šířku okna detektoru. Jelikož naše ROC křivka je závislost mezi senzitivitou a FPR_t při různých nastaveních prahu, můžeme z ní udělat dvě křivky, z nichž jedna bude obsahovat závislost senzitivity na prahu a druhá FPR_t na prahu. Druhým výstupem funkce `processResults()` je AUC pod nejlepší ROC křivkou každého záznamu pro různá nastavení šířky okna.



Obrázek 2.15: Schéma závěrečného zpracování pomocí funkce `processResults()`

Po provedení výpočtu je nutno zkombinovat výsledky pro jednotlivé záznamy do snadno srozumitelného souhrnu. V prvním případě byl pro každý práh do grafů zanášen horní a dolní kvartil senzitivity a FPR_t , ve druhém případě to byl horní a dolní kvartil AUC pro jednotlivá nastavení šířky okna.

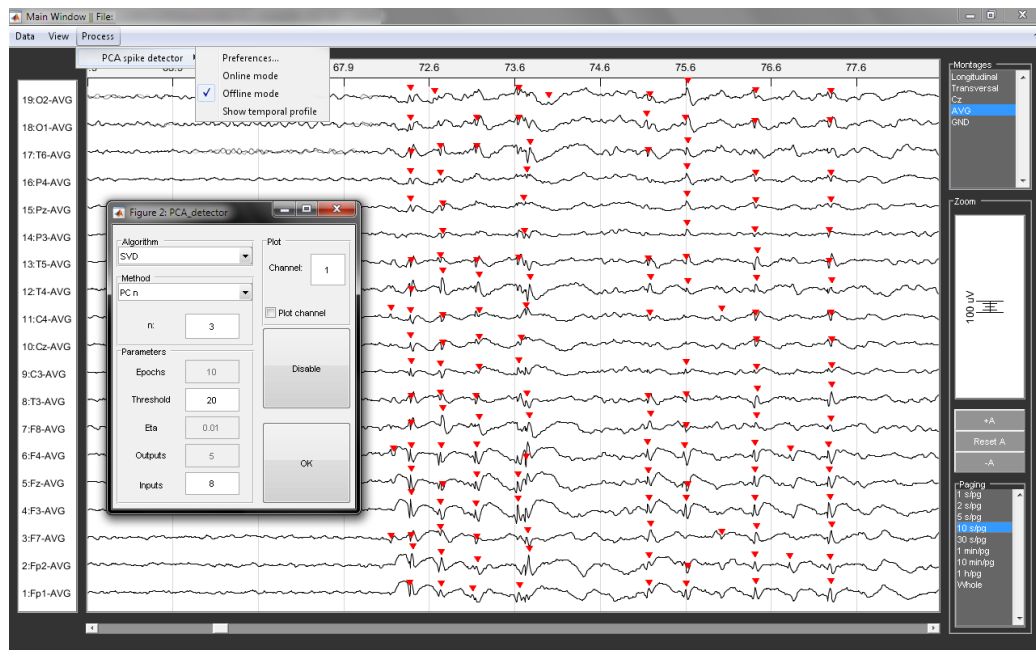
Výsledky

Cílem této kapitoly je prezentace výsledků práce. V první části je věnována pozornost konečné podobě implementovaného detektoru a generátoru syntetického signálu, v další části se nachází praktické ukázky detekce na reálných i syntetických signálech. Nakonec jsou shrnuty výsledky testů detektoru provedené nad rámec zadání této práce.


3.1 Zobrazení výsledků detekce

Detektorem označené pozice grafoelementů se zobrazují přímo v hlavním okně prohlížeče, které je ukázáno na obr. 3.1. Detektor může pracovat ve dvou režimech — online a offline. V režimu online probíhá detekce jen v datech z aktuálně zobrazeného okna, v režimu offline detekce proběhne po spuštění detektoru pouze jednou nad daty z celého načteného souboru. Jedná se o doporučený režim, jelikož je přesnější. Režim online je vhodný pro práci s dlouhými záznamy, které způsobují problémy se stabilitou počítače.

Pro zvýšení pohodlí byla přidána funkce zobrazení temporálního profilu. Jedná se o graf, který umožňuje udělat si představu o pozicích hrotů v celém záznamu, kromě toho reaguje na kliknutí levým tlačítkem myši zobrazením příslušné části signálu. Tento graf je zobrazen po volbě *Show temporal profile* v rozbalovacím menu prohlížeče (obr. 3.2).



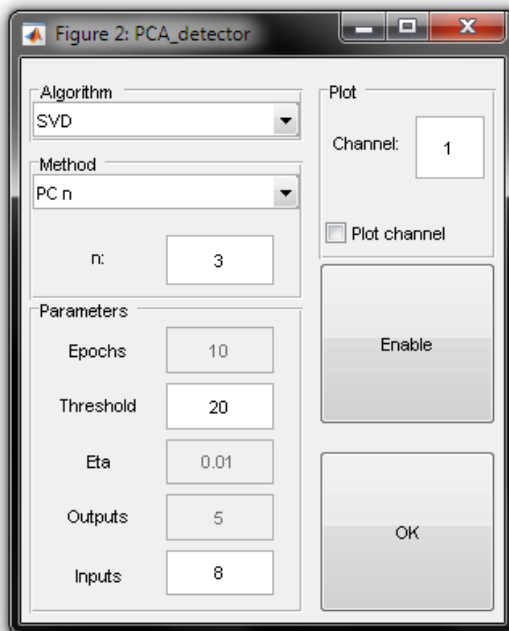
Obrázek 3.1: Hlavní okno prohlížeče signálu spolu s uživatelským rozhraním detektoru a detektorem označenými epileptickými hroty



Obrázek 3.2: Hlavní okno prohlížeče signálu se zobrazeným temporálním profilem (pod grafy signálu), který umožňuje udělat si souhrnnou představu o rozložení detekovaných tranzientů v celém záznamu.

3.1.1 Uživatelské rozhraní detektoru

Detektor má vlastní uživatelské rozhraní, které je zavoláno po volbě *Preferences...* z menu *Process* (obr. 3.1). Vyvolané uživatelské rozhraní je zachyceno na obr. 3.3.



Obrázek 3.3: Uživatelské rozhraní detektoru

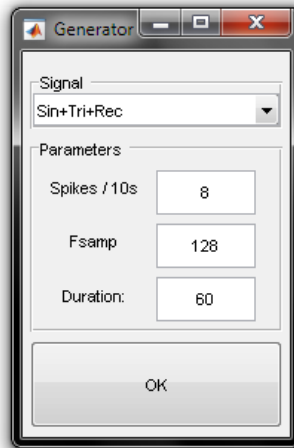
Po načtení souboru je detektor implicitně vypnutý a je nutné ho aktivovat pomocí tlačítka *Enable*. Poté detektor na základě nastavených parametrů vyhledá pravděpodobné pozice epileptických hrotů a výsledky zobrazí v uživatelském rozhraní prohlížeče.

Uživatelské rozhraní umožňuje volit mezi detekcí pomocí singulárního rozkladu a GHA algoritmem, dále je možné vybírat metodu vytvoření detekčního signálu a nastavit parametry detekčního algoritmu. Jelikož ty jsou specifické pro oba z nich, příslušné nepřístupné volby jsou vždy deaktivovány.

Kromě toho je možné v panelu *Plot* zaškrtnout volbu *Plot channel*, což způsobí, že po každém proběhnutí detekce budou v grafech zobrazeny detekční signály pro zvolený kanál.

3.2 Generátor syntetického signálu

Další modul, který byl v rámci práce vytvořen, je generátor syntetického signálu. Jeho podrobnější technický popis se nachází v části 2.6.1. Jedná se o modul s velmi jednoduchým uživatelským rozhraním, díky němuž lze jednoduše vytvořit všechny v této práci využitě syntetické signály.



Obrázek 3.4: Uživatelské rozhraní generátoru syntetických signálů

Modul je opět možné spustit z uživatelského rozhraní prohlížeče, tentokrát z menu *Data* výběrem položky *Artificial source*. Poté se zobrazí uživatelské rozhraní z obr. 3.4, v němž je možné nastavit hustotu simulovaných epileptických hrotů v záznamu, vzorkovací frekvenci a délku simulovaného signálu.

3.3 Ukázky výsledků detekce

V této části jsou k dispozici ukázky činnosti detektoru s výsledky označenými přímo v signálu, a to v syntetickém i reálném.

3.3.1 Syntetické signály


K nastavení parametrů detektoru v této části bylo přistupováno individuálně pro každý ze simulovaných signálů, jelikož jejich tvar se od skutečného EEG záznamu morfologicky poměrně odlišuje. Nešlo tedy očekávat, že nastavení bude přenositelné. Shrnutí je obsaženo v tabulce 3.1.

Tabulka 3.1: Shrnutí nastavení detektoru pro detekci na syntetických signálech

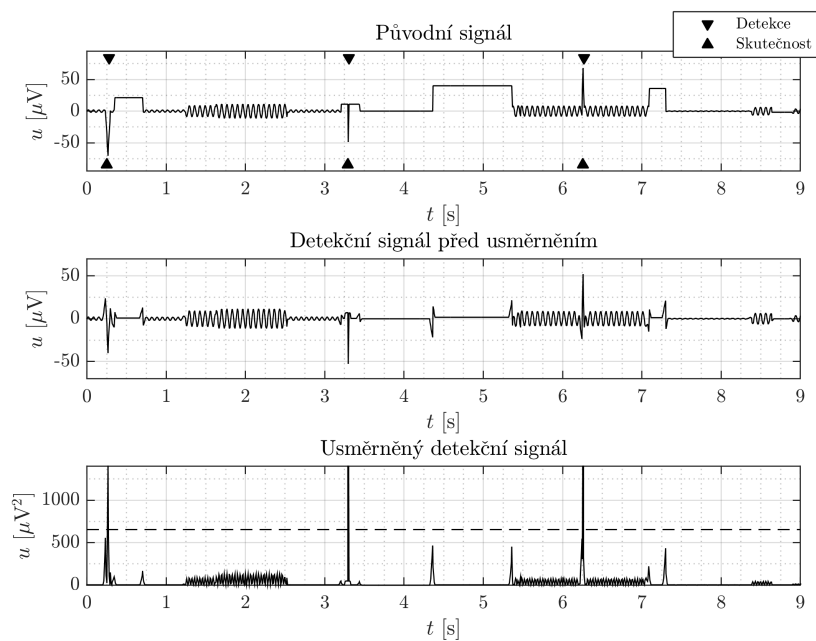
Signál:	Sin+Tri+Rec	Mukhopadhyay	AR complex
Práh [-]:	20	10	10
Vstupní okno [Vzorky]:	9	8	8

Dále následují ukázky detekce pro metody *Subtrakce PC 1* a *PC 3*. Pro každý signál a metodu byly do grafů zachyceny průběhy původního signálu, signálu detekčního před usměrněním a nakonec po usměrnění. Zároveň byly v signálech označeny pozice hrotů detekovaných i simulovaných generátorem. V grafech s usměrněným signálem je naznačena hladina mezní hodnoty (tedy u_{thr} ze vztahu 2.23). Všechny parametry generátoru syntetického signálu byly nastaveny na výchozí hodnoty.

Signál Sin+Tri+Rec



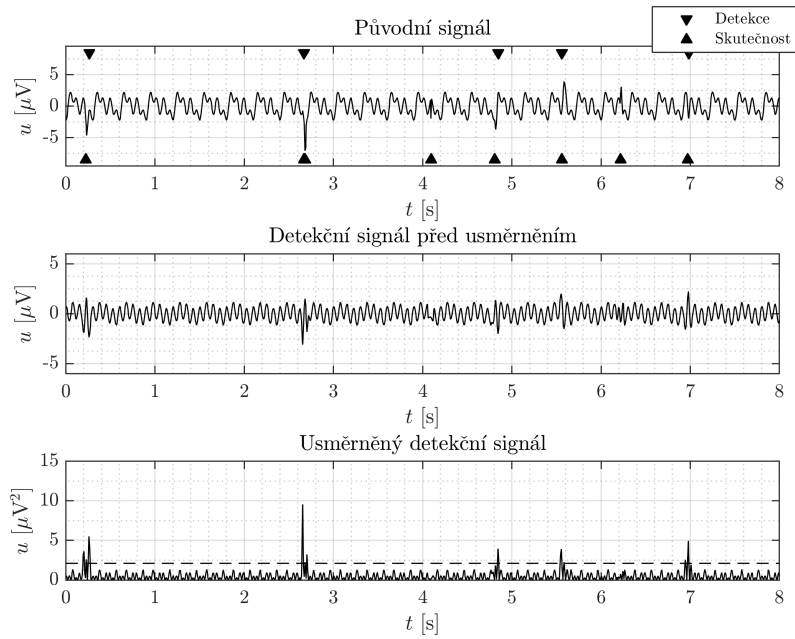
(a) Metoda *PC 3*



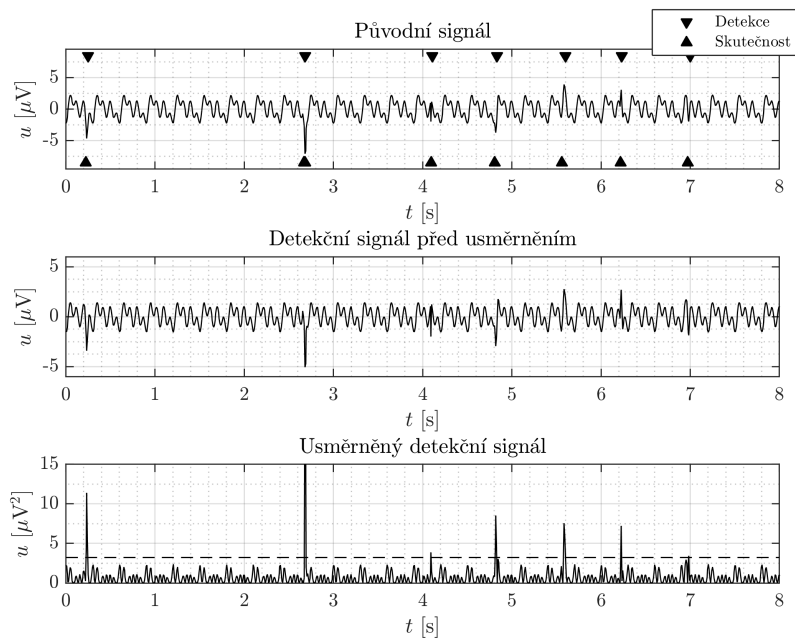
(b) Metoda *Subtrakce PC 1*

Obrázek 3.5: Ukázka činnosti detektoru u signálu Sin+Tri+Rec ze zadání práce

Signál Mukhopadhyay



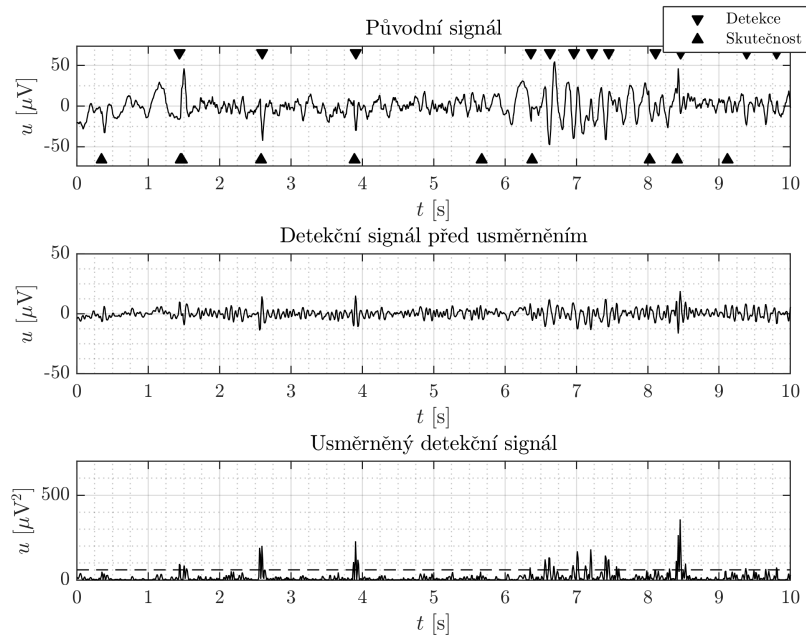
(a) Metoda *PC 3*



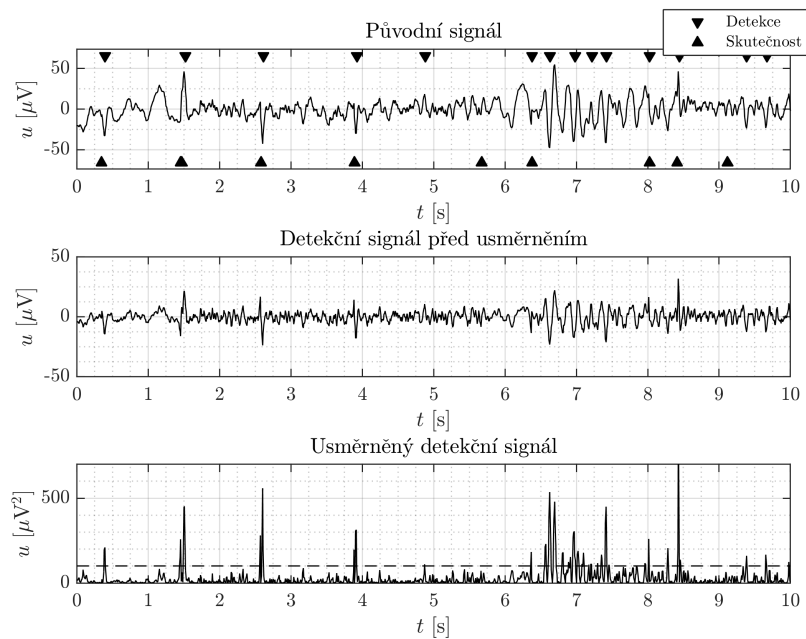
(b) Metoda *Subtrakce PC 1*

Obrázek 3.6: Ukázka detekce na signálu Mukhopadhyay

Signál AR Complex



(a) Metoda *PC 3*



(b) Metoda *Subtrakce PC 1*

Obrázek 3.7: Ukázka činnosti detektoru u signálu AR Complex

3.3.2 Reálné signály


V této části práce se nachází ukázky detekce na reálném signálu. Ze záznamů byly vybrány různé artefakty a epileptické hroty, na nichž je ukázán průběh detekčních signálů u metod *Subtrakce PC 1* a *PC 3*. Výsledky metody *PC auto* nejsou prezentovány, neboť u dostupných reálných záznamů o vzorkovací frekvenci 128 Hz podává výsledky prakticky stejné jako metoda *PC 3*. Parametry, se kterými byly ukázky nasnímány, jsou shrnuty v tabulce 3.2.

Tabulka 3.2: Nastavení detektoru pro detekci reálného signálu


Algoritmus:	SVD
Výběr PC:	PC 3, Subtrakce PC 1
Práh [-]:	20
Počet vstupů ve vzorcích:	9

Prezentována je opět podoba signálu v různých částech detektoru. Jednak je to signál na vstupu, dále detekční signál před usměrněním a po něm. V původním signálu byly označeny detekce detektoru, v usměrněném signálu je přerušovaná čarou zobrazena mezní hodnota.

Epileptické hroty




(a) Metoda *PC 3*




(b) Metoda *Subtrakce PC 1*

Obrázek 3.8: Ukázka detekce reálných epileptických hrotů

EMG artefakt




(a) Metoda *PC 3*




(b) Metoda *Subtrakce PC 1*

Obrázek 3.9: Ukázka reakce detektoru na reálný EMG artefakt

Artefakt způsobený pohyby očí




(a) Metoda *PC 3*




(b) Metoda *Subtrakce PC 1*

Obrázek 3.10: Ukázka reakce detektoru na reálný artefakt způsobený pohyby očí

Amplitudový artefakt



(a) Metoda *PC 3*



(b) Metoda *Subtrakce PC 1*

Obrázek 3.11: Ukázka reakce detektoru na reálný amplitudový artefakt

3.4 Ověření činnosti detektoru

Tato část prezentuje výsledky semikvantitativních testů detektoru na reálných datech, které již byly provedeny nad rámec zadání. Bylo postupováno podle metodiky uvedené v části 2.6.3. Zkoušky byly prováděny, protože oproti zadaným kvalitativním testům umožňují makroskopický souhrnný pohled na vliv jednotlivých parametrů a při vývoji umožnily exaktněji nalézt optimální nastavení. Na začátku je poukázáno na problém s nestabilní rychlostí konvergence algoritmu GHA, dále je řešena otázka výběru optimální hlavní komponenty a následně je zkoumán vliv nastavení šířky detekčního okna a prahu na spolehlivost systému.

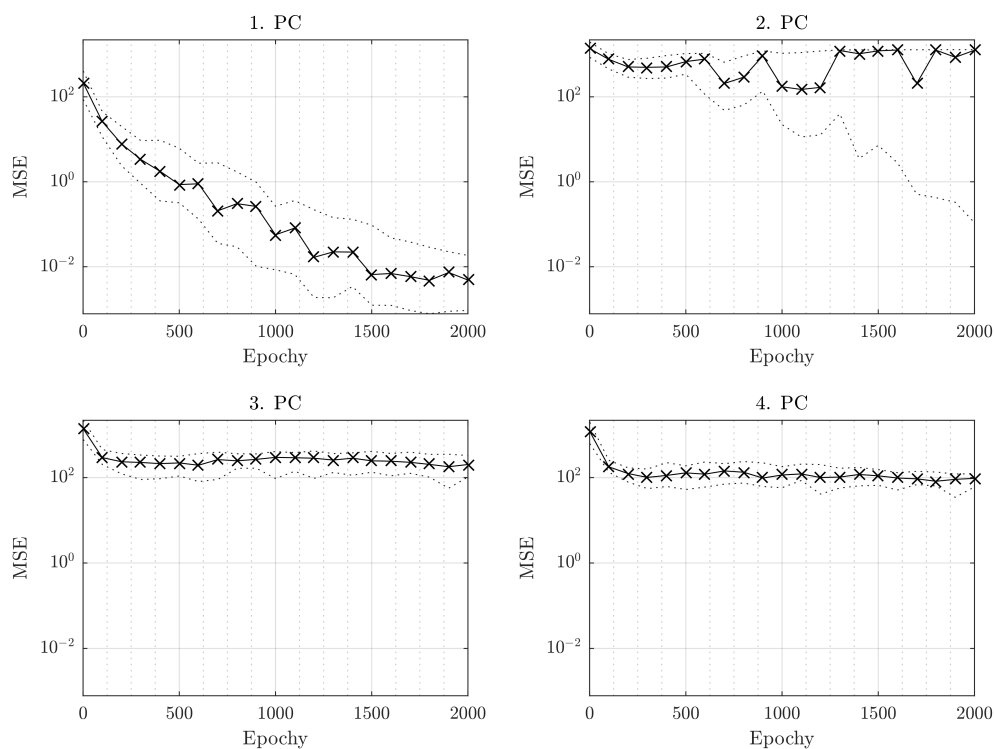
3.4.1 Optimální nastavení parametrů

Před provedením testování bylo nutné rozhodnout, které parametry detektoru nebudou při testování měněny. Mezi ně patří výběr hlavní komponenty využitě pro detekci a, jak se v průběhu testování ukázalo, i detekční algoritmus.

Konvergence algoritmu GHA

Algoritmus GHA má nevýhodu v tom, že se jedná o pouhý stochastický aproximátor. Jelikož je pokaždé inicializován s jinými vahami, výsledky nejsou při opakovaně spouštěné detekci stálé a hroty blízko mezní prahovací hodnoty jsou označeny různým způsobem.


V tomto testu se pracovalo s reálným signálem o délce 1000 vzorků se vzorkovací frekvencí 128 Hz. Šířka okna detektoru byla nastavena na 9 vzorků, rychlost učení neuronové sítě η byla 0,00001. Neuronová síť byla vždy natrénována na určitý počet epoch a následně určena střední kvadratická chyba jí vypočtených hlavních komponent vůči výsledkům získaným singulárním rozkladem. Celý experiment byl proveden celkem třicetkrát, do grafů 3.12 byly následně zanášeny mediány, horní a dolní decily kvadratických chyb.



Obrázek 3.12: Závislost střední kvadratické chyby neuronové sítě při aproximaci prvních čtyř hlavních komponent z devíti oproti výsledkům SVD na počtu trénovacích epoch. Horní a spodní tečkované křivky označují horní a dolní decil chyby, plná křivka značí medián. Nastavený parametr $\eta = 0,00001$ zaručuje stabilní konvergenci pro první dvě hlavní komponenty, ta je ale tak pomalá, že pro dosažení nižší chyby v dalších hlavních komponentách není dostatečných ani 2000 trénovacích epoch.


Metoda výběru hlavní komponenty

Výběr hlavní komponenty, která bude usměrněna a na jejímž základě bude prováděna detekce, byl proveden empiricky. Typická ukázka detekčních signálů je v grafech 3.13. Lze si povšimnout, že první hlavní komponenta je silně odlišná od těch, co následují. Odráží složky signálu o menší frekvenci a pro detekci ostrých grafoelementů, jako jsou epileptické hroty, se příliš nehodí. Druhá hlavní komponenta je již lepší, nicméně stále reaguje na pomalejší aktivitu, jako je grafoelement v čase přibližně 2,8 s. Třetí hlavní komponenta je již robustnější, což je stejný závěr, k jakému došli autoři článku [1]. Její volbou získáváme metodu *PC 3*. Další hlavní komponenty se již kromě amplitudy příliš neliší, ale stávají se náchylnějšími na případný šum a vysokofrekvenční složky s nízkou amplitudou.



Obrázek 3.13: Ukázka reálných detekčních signálů. První graf shora je reálný signál, následující grafy zachycují detekční signály vzniklé usměrněním hlavních komponent promítnutých zpět do původního signálového prostoru. Jedná se o signál ze záznamu E1, přičemž celkem bylo vypočteno deset hlavních komponent, z toho šest je zobrazeno ve vzestupném pořadí shora dolů s první hlavní komponentou ve druhém grafu shora.

Další pomůcka, využitá pro určení nejlepší hlavní komponenty, byl tzv. scree plot, který zachycuje procento variance vysvětlené danou hlavní komponentou. Jeho ukázka je v grafu 3.14. V grafu je jasně pozorovatelný zlom u druhé hlavní komponenty, za třetí hlavní komponentou jsou rozdíly již minimální. Tato myšlenka se stala základem metody *PC auto*, u které se detektor snaží využít tu hlavní komponentu, která je nejbližší k vysvětlení 5 % celkové variance, což je hodnota empiricky stanovená ze scree plotů.



Obrázek 3.14: Graf zachycující procenta z celkové variance vstupního signálu vysvětlená jednotlivými hlavními komponentami. Ukázka je vypočtena ze stejných dat jako v grafech 3.13.


Metoda *Subtrakce PC 1* by měla dosahovat stabilnějších výsledků, ale jelikož je od signálu odečítána pouze první hlavní komponenta a příspěvky ostatních v signálu zůstanou, bude trpět zvýšeným počtem falešně pozitivních detekcí například díky svalovým artefaktům a šumu. To je ukázáno v grafu 3.9.

Nejlepší dosažitelná ROC křivka

Při výpočtu nejlepší dosažitelná ROC křivky byl celý soubor záznamů považován za jediný dlouhý signál o délce 2352 minut s celkem 3014 manuálně označenými hroty. Záznam opakovaně procházel detektorem pro větší množství kombinací nastavené šířky okna a prahu a pro každou kombinaci spočítal počet TP, FP a FN (viz část 2.6.3). Na jejich základě je poté možné pro každou testovanou šířku okna vytvořit ROC křivku a spočítat její *AUC*, z toho poté vybrat tu nejlepší. Tento postup byl proveden u všech tří testovaných metod pro kombinace parametrů z tabulky 3.3, nejlepší ROC křivky pro každou z metod byly vyneseny do grafu 3.15 spolu se zaznamenanou křivkám odpovídající šířkou okna.

Tabulka 3.3: Vektory parametrů, pomocí nichž proběhlo testování. Detektor byl testován pro každou jejich kombinaci.

Šířky okna [vzorky]:	0 2 4 6 8 10 12 14 16 18 20 22 24 28 32
	36 40 48 52 60 68 76 84 92
Prahy [-]:	3 5 6 7 8 9 10 11 12 15 20 25 30 35 40



Obrázek 3.15: Nejlepší dosažitelné ROC křivky, pokud testované záznamy považujeme za jediný dlouhý navazující signál.

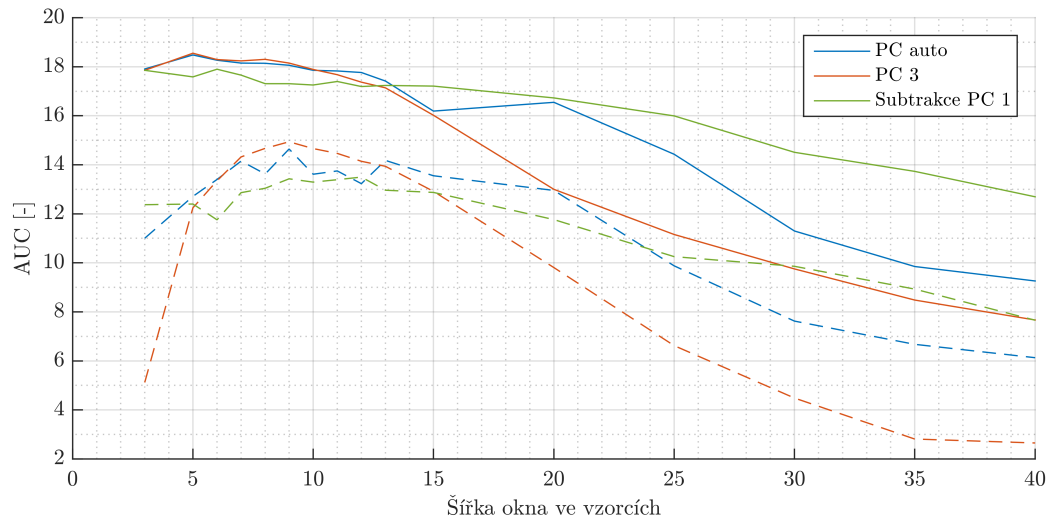
Optimální nastavení prahu a šířky okna

V této části testování bylo cílem především identifikovat, do jaké míry je detektor s pevně nastavenými parametry přenositelný mezi jednotlivými záznamy. Pro každý záznam byla vypočtena senzitivita a $FPRt$ pro kombinace parametrů uvedené v tabulce 3.3 a vše bylo dáno do vzájemného kontextu podle metodiky popsané v části 2.6.3.


Následující grafy znázorňují výsledky testů charakteristik detektoru pro různá nastavení parametrů a metod výběru hlavní komponenty. Graf 3.16 je vhodný pro nastavení nejlepší šířky okna detektoru pro různé detekční metody a zároveň ukazuje schopnost daných metod fungovat stabilně při různých šířkách okna.

Graf 3.17a je vhodný pro nalezení optimálního nastavení prahu s ohledem na senzitivitu. Představuje nejlepší možné senzitivity detektoru, jakých lze dosáhnout, pokud bychom v každém záznamu zvolili neoptimálnější šířku okna. Odpovídající $FPRt$ lze poté nalézt v grafu 3.17b. Tento graf je opět pro neoptimálnější možnou šířku okna. Původním záměrem bylo využití krabicových grafů, nicméně grafické vyjádření kvan-


tilů muselo být mírně upraveno, jelikož výsledky byly kvůli vysoké hustotě bodů velmi nepřehledné.



Obrázek 3.16: Závislost plochy pod ROC křivkou na šířce vstupního okna detektoru pro všechny tři metody výběru hlavní komponenty. Plná čára znázorňuje 75 % kvantil, přerušovaná 25 % kvantil AUC mezi záznamy v testovacím souboru. Body, kterými prochází plná čára, tedy značí kombinace šířky okna a AUC , pro které platí, že detektor ve 25 % záznamů dosáhl lepšího AUC , než je uvedeno v grafu. Přerušovaná čára vyjadřuje naopak body, ve kterých bylo u 25 % záznamů dosaženo horšího AUC . Čím je vzdálenost mezi plnou a přerušovanou čarou při dané šířce okna větší, tím je větší rozptyl kvalit ROC křivek mezi jednotlivými záznamy.



(a) Závislost senzitivity na prahu



(b) Závislost počtu falešně pozitivních detekcí na prahu

Obrázek 3.17: Vyhodnocení charakteristik detektoru pro různá nastavení prahu. Plnou čarou je znázorněn 75 % kvantil, čárkovaně 25 % kvantil. Význam je takový, že u 50 % záznamů pracoval detektor se senzitivitou v rozmezí mezi oběma křivkami. Jedná se o nejvyšší možnou senzitivitu a nejnižší možný počet falešně pozitivních detekcí, jakých je možno dosáhnout bez ohledu na nastavenou šířku vstupního okna, jelikož ta byla u každého souboru nastavena automaticky na nejlepší hodnotu.

Diskuze

První částí práce po provedení rešerše byla implementace neuronové sítě adaptující se pomocí algoritmu GHA, jelikož to byla metoda od začátku vytipovaná jako optimální [1]. Implementace proběhla nejprve v MATLABu, nicméně díky cyklům byl výpočet extrémně pomalý. Tento problém se nakonec vyřešil implementací v jazyce C a následným zkompilováním do MEX-funkce, kterou lze volat z MATLABu, čímž se podařilo dosáhnout dostatečného zrychlení.

Při následném testování bylo zjištěno, že se nejedná o neoptimálnější metodu. Přestože se zobecněný hebbovský algoritmus k analýze hlavních komponent v praxi využívá, v našem případě se vyskytl problém s nekonzistencí výsledků detekce. Po každém spuštění detekce neuronová síť sice vždy konvergovala, ale s jistou chybou, která byla pokaždé jiná a závislá na počátečním nastavení vah, což je důsledek jejich náhodné inicializace. Ve výsledku jsou při každém spuštění detektoru se stejnými parametry označeny jiné grafoelementy, které se nachází blízko prahu. Řešením by mohla být inicializace vah neuronové sítě na konstantní hodnoty, čímž by ale detektor získal další parametr ovlivňující výsledky detekce, což zvyšuje složitost jeho analýzy i ovládání. Další možnost řešení by mohla spočívat v nastavení maximální přípustné chyby, po jejímž dosažení by se adaptace neuronové sítě automaticky zastavila.

Místo neuronové sítě byl tedy pro analýzu hlavních komponent využit maticový singulární rozklad, který zaručil stabilně korektní výpočet PCA. Oproti neuronové síti je jeho nevýhodou především paměťová náročnost, jelikož v okamžiku výpočtu je nutné mít v paměti celý signál. Takový detektor tedy není možné využívat pro detekci v reálném čase, stejně tak ho nelze využít na zpracování celého velmi dlouhého a objemného signálu po částech.

Experimentální testování rychlosti obou algoritmů je obtížné, rychlost totiž velmi závisí na implementaci a konkrétním počítači. Překážkou k teoretickému srovnání časové složitosti je to, že pro výpočet hlavních komponent pomocí singulárního rozkladu byly využity funkce ze standardní knihovny Matlabu, tudíž neznáme podrobnosti implementace, nicméně z uživatelského hlediska je celý systém integrovaný v prohlížeči bezproblémově použitelný i na v dnešní době podprůměrném počítači (notebook Lenovo ThinkPad X200, Intel Core2Duo P8400 2.26 GHz, 4GB RAM), alespoň při práci se záznamy o délkách řádově desítek minut.

Po otestování funkčnosti jednotlivých elementárních bloků detektoru byl detektor zkoušen na reálných i syntetických datech, kvůli čemuž byl vytvořen generátor umělého signálu. V souladu se zadáním bylo provedeno kvalitativní hodnocení výkonnosti, při němž byly vybrány reprezentativní úseky signálu s detekovanými grafoelementy a graficky prezentovány.

Nakonec došlo k implementaci detektoru do stávajícího prohlížeče EEG signálu, který jsem vytvořil v rámci předcházejícího Týmového projektu. Detektor má podobu samostatně fungujícího modulu s možností ovládní pomocí vlastního uživatelského rozhraní a je využitelný i mimo prohlížeč, nicméně při spuštění v jeho kontextu umožňuje přehledné zobrazování výsledků detekce včetně temporálního profilu, zároveň nabízí online a offline režim detekce. Zatím nedořešeným problémem prohlížeče je nekompatibilita se staršími verzemi MATLABu. Program byl vytvořen ve verzi 2015a a jeho funkčnost byla ověřena i ve verzi 2015b. S verzí 2013a současná verze prohlížeče bohužel kompatibilní není.

V poslední části práce bylo nad rámec zadání provedeno semikvantitativní testování detektoru, pro které byly vytvořeny rutiny umožňující automatické otestování detektoru pro různé kombinace nastavených parametrů. Díky výsledkům bylo následně možné nalézt optimální nastavení výchozích hodnot, spolu s jejich rozsahem.

S výhledem do budoucna by detektor měl být porovnán s dalšími algoritmy, a to pomocí jednotné metodiky. Mezi potenciálně zajímavé algoritmy patří například mediánový [10] a aritmetický detektor [42, 25]. Kromě toho by bylo vhodné dále pracovat s algoritmem GHA a pokusit se vyřešit problém s vlivem inicializace vah na stabilitu

výsledků detekce. Nutným, čistě technickým problémem, který by měl být odstraněn, je nekompatibilita prohlížeče se staršími verzemi MATLABu.

Závěr

Všechny cíle práce byly úspěšně splněny, navíc oproti zadání byla detektor semikvantitativně testován. V souladu se zadáním práce byl vytvořen generátor syntetického signálu, který primárně generuje signál s hroty a umělými artefakty skládající se ze špiček, 15 Hz sinusoid a obdélníků. Kromě toho umožňuje vytvářet i další typy signálů, například na základě autoregresních modelů.

Následně byla pro výpočet analýzy hlavních komponent v jazyce C implementována neuronová síť adaptující se algoritmem GHA, nicméně se ukázalo, že nejde o optimální řešení. Proto byl nakonec pro filtraci signálu zvolen singulární rozklad.

Vyfiltrovaný signál byl odečítán od signálu původního, po usměrnění a porovnání rozdílů s detekční mezí byly označeny hroty v signálu. Procedura byla následně zopakována i pro reálný signál. Kromě porovnávání prahu s rozdílem (tzv. metoda *Subtrakce PC 1*) byly prováděny experimenty s porovnáváním prahu a přímo jedné z hlavních komponent po jejím promítnutí do původního signálového prostoru (tzv. metoda *PC n*), přičemž bylo zjištěno, že takový režim dosahuje vyšší senzitivity s podobným množstvím falešně pozitivních detekcí. Jako zobecnění byla navržena metoda automatického výběru optimální hlavní komponenty (tzv. metoda *PC auto*).

Konečným výsledkem byla realizace navrženého detekčního systému v podobě modulu do prohlížeče EEG signálu vytvořeného v rámci Týmového projektu. Zároveň byla sepsána uživatelská dokumentace.

Nad rámec zadání byla vytvořena metodika automatizovaného semikvantitativního testování detektorů pro větší množství reálných záznamů pro vybrané kombinace nastavení vstupních parametrů. Díky tomu bude možné jednoduše srovnávat výkonnost různých detekčních algoritmů. V dosavadní práci byly výsledky této analýzy využity pro nalezení optimálního nastavení výchozích detekčních parametrů.

Na jejich základě je také možné shrnout výhody jednotlivých metod výběru hlavních komponent.

Metoda *Subtrakce PC 1* má vysokou stabilitu v širším rozsahu nastavení šířky okna detektoru, ale nejvyšší citlivost na správné nastavení prahu. Při pohledu do vytvořené ROC křivky tato metoda vychází jako nejhorší. Metoda *PC n* pro $n = 3$ má velkou citlivost na nastavení šířky okna a malou citlivost na nastavení prahu. Metoda *PC auto* je svými výsledky kompromisem mezi metodami *Subtrakce PC 1* a *PC 3*.

Literatura

- [1] KRAJČA, V., S. PETRÁNEK, J. HOŘEJŠÍ a V. PROCHÁZKOVÁ. Application of neural networks based principal component analysis for epileptic spike detection. *42. Internationales Wissenschaftliches Kolloquium*. Technische Universität Ilmenau, 1997, , 156-161.
- [2] SANEI, Saeid a Jonathon A CHAMBERS. *EEG signal processing*. Hoboken, NJ: John Wiley, 2007. ISBN 04-700-2581-6.
- [3] JOHN G. WEBSTER, John G.editor in chief. *Encyclopedia of medical devices* [online]. 2nd ed. New York: Wiley, 2006 [cit. 2015-12-29]. ISBN 978-047-1732-877.
- [4] Medium cap, 256 channels, ABC layout. In: *Bio-Semi* [online]. Amsterdam [cit. 2016-04-15]. Dostupné z: http://www.biosemi.com/pics/cap_160_medium4_large.jpg
- [5] Reusable Cup Electrodes. In: *Technomed Europe* [online]. 2013 [cit. 2016-04-24]. Dostupné z: <http://www.technomed-europe.com/wp-content/uploads/2013/06/09-ReuseableElectrode-Gold.jpg>
- [6] USAKLI, Ali Bulent. Improvement of EEG Signal Acquisition: An Electrical Aspect for State of the Art of Front End. *Computational Intelligence and Neuroscience* [online]. 2010, , 1-7 [cit. 2016-04-15]. DOI: 10.1155/2010/630649. ISSN 1687-5265. Dostupné z: <http://www.hindawi.com/journals/cin/2010/630649/>
- [7] FISCH, Bruce. *Fundamentals of EEG interpretation*. Louisiana State University, New Orleans. Dostupné také z:

<https://wiki.umms.med.umich.edu/download/attachments/133925074/Fundamentals+of+EEG.pdf?version=1&modificationDate=1392310119000>

- [8] KARL E. MISULIS, THOMAS C. HEAD., Karl E. Misulis, Thomas C. Head. *Essentials of clinical neurophysiology*. 3rd ed. Burlington, MA: Butterworth-Heinemann, 2003. ISBN 978-075-0674-416.
- [9] GOTMAN, J. a P. GLOOR. Automatic recognition and quantification of interictal epileptic activity in the human scalp EEG. *Electroencephalography and Clinical Neurophysiology*. 1976, **41**(5), 513-529. DOI: 10.1016/0013-4694(76)90063-8. ISSN 00134694. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/0013469476900638>
- [10] KRAJČA, Vladimír a Jitka MOHYLOVÁ. *Číslíkové zpracování neurofyziologických signálů*. 1. vyd. V Praze: České vysoké učení technické, 2011. ISBN 978-80-01-04721-7.
- [11] PANG, C.C.C., A.R.M. UPTON, G. SHINE a M.V. KAMATH. A comparison of algorithms for detection of spikes in the electroencephalogram. *IEEE Transactions on Biomedical Engineering* [online]. 2003, **50**(4), 521-526 [cit. 2016-02-28]. DOI: 10.1109/TBME.2003.809479. ISSN 0018-9294. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1193787>
- [12] LÜDERS, Hans O. a Soheyl NOACHTAR. *Atlas and classification of electroencephalography*. 1. Philadelphia: Saunders, 2000. ISBN 978-072-1665-542.
- [13] WILSON, S.B., R.N. HARNER, F.H. DUFFY, B.R. THARP, M.R. NUWER a M.R. SPERLING. Spike detection. I. Correlation and reliability of human experts. *Electroencephalography and Clinical Neurophysiology* [online]. 1996, extbf98(3), 186-198 [cit. 2016-04-15]. DOI: 10.1016/0013-4694(95)00221-9. ISSN 00134694. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0013469495002219>
- [14] TZALAS, Alexandros T., Markos G. TSIPOURAS, Dimitrios G. TSA-LIKAKIS, Evaggelos C. KARVOUNIS, Loukas ASTRAKAS, Spiros

- KONITSIOTIS a Margaret TZAPHLIDOU. Automated Epileptic Seizure Detection Methods: A Review Study. In: *Epilepsy - Histological, Electroencephalographic and Psychological Aspects* [online]. InTech, 2012, s. 75-90 [cit. 2016-02-28]. DOI: 10.5772/31597. ISBN 978-953-51-0082-9. Dostupné z: <http://www.intechopen.com/books/epilepsy-histological-electroencephalographic-and-psychological-aspects/automated-epileptic-seizure-detection-methods-a-review-study>
- [15] KRAJČA, V. a S. PETRÁNEK. "Wave-Finder": a new system for an automatic processing of long-term EEG recordings. In: *Quantitative EEG Analysis - Clinical Utility and New Methods*. Jena: Universitätsverlag GmbH, 1993, s. 103-105.
- [16] PILLAI, Jyoti a Michael R. SPERLING. Interictal EEG and the Diagnosis of Epilepsy. *Epilepsia* [online]. 2006, **47**(s1), 14-22 [cit. 2016-05-12]. DOI: 10.1111/j.1528-1167.2006.00654.x. ISSN 00139580. Dostupné z: <http://doi.wiley.com/10.1111/j.1528-1167.2006.00654.x>
- [17] KRAJČA, V. a S. PETRÁNEK. Supplementum: Počítačová encefalografie: Úvod do problematiky. *Česká a slovenská neurologie a neurochirurgie*. 1995, **58**(91), 1-36. ISSN 1210-7859.
- [18] OIKONOMOU, V.P., A.T. TZALLAS a D.I. FOTIADIS. A Kalman filter based methodology for EEG spike enhancement. *Computer Methods and Programs in Biomedicine* [online]. 2007, **85**(2), 101-108 [cit. 2016-03-03]. DOI: 10.1016/j.cmpb.2006.10.003. ISSN 01692607. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0169260706002422>
- [19] RADMEHR, Mehdi a Seyed MAHMOUD ANISHEH. EEG Spike Detection using Stationary Wavelet Transform and Time-Varying Autoregressive Model. *International Journal of Computer Applications* [online]. 2013, **83**(13), 1-3 [cit. 2016-03-19]. DOI: 10.5120/14505-2117. ISSN 09758887. Dostupné z: <http://research.ijcaonline.org/volume83/number13/pxc3892117.pdf>
- [20] JAMES, C.J., M.T. HAGAN, R.D. JONES, P.J. BONES a G.J. CARROLL. Multireference adaptive noise canceling applied to the EEG. *IEEE*

- Transactions on Biomedical Engineering* [online]. 1997, **44**(8), 775-779 [cit. 2016-03-03]. DOI: 10.1109/10.605438. ISSN 00189294. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=605438>
- [21] MUKHOPADHYAY, S. a G.C. RAY. A new interpretation of nonlinear energy operator and its efficacy in spike detection. *IEEE Transactions on Biomedical Engineering* [online]. 1998, **45**(2), 180-187 [cit. 2016-03-03]. DOI: 10.1109/10.661266. ISSN 00189294. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=661266>
- [22] KAISER, J.F. On a simple algorithm to calculate the 'energy' of a signal. In: *International Conference on Acoustics, Speech, and Signal Processing*. Albuquerque: IEEE, 1990, s. 381-384. DOI: 10.1109/ICASSP.1990.115702. ISSN 1520-6149. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=115702>
- [23] KAISER, J.F. Some useful properties of Teager's energy operators. In: *IEEE International Conference on Acoustics Speech and Signal Processing*. Minneapolis: IEEE, 1993, 149-152 vol.3. DOI: 10.1109/ICASSP.1993.319457. ISBN 0-7803-0946-4. ISSN 1520-6149. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=319457>
- [24] MALARVILI, M.B., H. HASSANPOUR, M. MESBAH a B. BOASHASH. A HISTOGRAM-BASED ELECTROENCEPHALOGRAM SPIKE DETECTION. In: *Proceedings of the Eighth International Symposium on Signal Processing and Its Applications, 2005*. IEEE, 2005, s. 207-210. DOI: 10.1109/ISSPA.2005.1580232. ISBN 0-7803-9243-4. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1580232>
- [25] KRAJČA, V., S. PETRÁNEK, et. al. Automatic epileptic spike detection by median filtering and simple arithmetic sharp transient detector: a clinical evaluation. In: *Proc. VI Mediterranean Conference on Medical a Biological Engineering*. 1. Capri (Italy), 1992, s. 209-212.

- [26] SMITH, Jack R. Automatic Analysis and Detection of EEG Spikes. *IEEE Transactions on Biomedical Engineering* [online]. 1974, **BME-21**(1), 1-7 [cit. 2016-03-04]. DOI: 10.1109/TBME.1974.324354. ISSN 00189294. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4120710>
- [27] XU, Guanghua, Jing WANG, Qing ZHANG a Junming ZHU. An Automatic EEG Spike Detection Algorithm Using Morphological Filter. In: *2006 IEEE International Conference on Automation Science and Engineering* [online]. IEEE, 2006, s. 170-175. DOI: 10.1109/COASE.2006.326875. ISBN 1-4244-0310-3. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4120341>
- [28] HAYDARI, Z., Y. ZHANG a H. SOLTANIAN-ZADEH. Semi-automatic epilepsy spike detection from EEG signal using Genetic Algorithm and Wavelet transform. In: *2011 IEEE International Conference on Bioinformatics and Biomedicine Workshops (BIBMW)*. Atlanta: IEEE, 2011, s. 635-638. DOI: 10.1109/BIBMW.2011.6112443. ISBN 978-1-4577-1613-3. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6112443>
- [29] GANESAN, M., P.S. SATHIDEVI a K.P. INDIRADEVI. A Novel Approach for the Analysis of Epileptic Spikes in EEG. In: *International Conference on Computational Intelligence and Multimedia Applications (ICCIMA 2007)* [online]. Sivakasi: IEEE, 2007, **1**, s. 297-312. DOI: 10.1109/ICCIMA.2007.316. ISBN 0-7695-3050-8. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4426596>
- [30] DAVEY, B. L. K., W. R. FRIGHT, G. J. CARROLL a R. D. JONES. Expert system approach to detection of epileptiform activity in the EEG. *Medical* [online]. 1989, **27**(4), 365-370 [cit. 2016-03-05]. DOI: 10.1007/BF02441427. ISSN 0140-0118. Dostupné z: <http://link.springer.com/10.1007/BF02441427>
- [31] INDIRADEVI, K.P., Elizabeth ELIAS a P. S. SATHIDEVI. Automatic Detection of Epileptic Spikes in the Long Term Electroencephalogram Using Wavelet Transform. In: *International Conference on Computational Intelligence and*

- Multimedia Applications (ICCIMA 2007)* [online]. Sivakasi: IEEE, 2007, s. 552-556. DOI: 10.1109/ICCIMA.2007.169. ISBN 0-7695-3050-8. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4426637>
- [32] KO, Cheng-Wen a Hsiao-Wen CHUNG. Automatic spike detection via an artificial neural network using raw EEG data: effects of data preparation and implications in the limitations of online recognition. *Clinical Neurophysiology* [online]. 2000, **111**(3), 477-481 [cit. 2016-03-05]. DOI: 10.1016/S1388-2457(99)00284-9. ISSN 13882457. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1388245799002849>
- [33] PATNAIK, L.M. a Ohil K. MANYAM. Epileptic EEG detection using neural networks and post-classification. *Computer Methods and Programs in Biomedicine*. 2008, **91**(2), 100-109. DOI: 10.1016/j.cmpb.2008.02.005. ISSN 01692607. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S0169260708000539>
- [34] SAMMUT, Claude a Geoffrey I WEBB. *Encyclopedia of machine learning* [online]. London: Springer, 2010 [cit. 2016-03-07]. ISBN 978-038-7301-648. Dostupné z: <http://80.link.springer.com/dialog.cvut.cz/referencework/10.1007/978-0-387-30164-8>
- [35] JOHNSON, Richard A. a Dean W. WICHERN. *Applied multivariate statistical analysis*. 6th ed. Harlow: Pearson, 2014. ISBN 978-129-2024-943.
- [36] STRANG, Gilbert. *Linear algebra and its applications*. 4th ed. Belmont, CA: Thomson, Brooks/Cole, c2006. ISBN 00-301-0567-6.
- [37] LI, Feifei. Singular Value Decomposition. In: *The University of Utah: School of computing* [online]. Utah [cit. 2016-05-13]. Dostupné z: <http://www.cs.utah.edu/~lifeifei/cis5930/lecture12-a.pdf>
- [38] HEBB, D. *The organization of behavior: a neuropsychological theory*. 4. Print. New York: J. Wiley, 1957.
- [39] OJA, Erkki. Simplified neuron model as a principal component analyzer. *Journal of Mathematical Biology* [online]. 1982, **15**(3), 267-273

- [cit. 2016-03-10]. DOI: 10.1007/BF00275687. ISSN 0303-6812. Dostupné z: <http://link.springer.com/10.1007/BF00275687>
- [40] SANGER, Terence D. Optimal unsupervised learning in a single-layer linear feedforward neural network. *Neural Networks* [online]. 1989, **2**(6), 459-473 [cit. 2016-03-10]. DOI: 10.1016/0893-6080(89)90044-0. ISSN 08936080. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0893608089900440>
- [41] HAYKIN, Simon. *Neural networks: a comprehensive foundation*. 2nd ed. Delhi: Pearson Education, 1999. ISBN 8178083000.
- [42] QIAN, J., J.S. BARLOW a M.P. BEDDOES. A simplified arithmetic detector for EEG sharp transients-preliminary results. *IEEE Transactions on Biomedical Engineering* [online]. 1988, **35**(1), 11-18 [cit. 2016-04-30]. DOI: 10.1109/10.1331. ISSN 00189294. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1331>
- [43] KRAJČA, Vladimír, Svojmil PETRÁNEK, Ivana PATÁKOVÁ a Alpo VÄRRI. Automatic identification of significant graphoelements in multi-channel EEG recordings by adaptive segmentation and fuzzy clustering. *International Journal of Bio-Medical Computing*. 1991, extbf28(1-2), 71-89. DOI: 10.1016/0020-7101(91)90028-D. ISSN 00207101. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/002071019190028D>
- [44] MATLAB Documentation: Control random number generator. *MathWorks* [online]. 2016 [cit. 2016-03-21]. Dostupné z: <http://www.mathworks.com/help/matlab/ref/rng.html>
- [45] CASSON, Alexander J., Elena LUNA a Esther RODRIGUEZ-VILLEGAS. Performance metrics for the accurate characterisation of interictal spike detection algorithms. *Journal of Neuroscience Methods*. 2009, extbf177(2), 479-487. DOI: 10.1016/j.jneumeth.2008.10.010. ISSN 01650270. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S0165027008006110>

- [46] JANČA, Radek. *Analýza invazivních EEG signálů v epileptologii*. Praha, 2014.
Disertační práce. ČVUT, Fakulta elektrotechnická, katedra teorie obvodů.

Seznam příloh

V elektronické podobě je k práci přiložena uživatelská dokumentace, zdrojové kódy a samostatně spustitelná zkompileovaná verze programové části bakalářské práce.

Tabulka 3.4: Přílohy

Soubor/složka	Význam
Manual.pdf	Uživatelská dokumentace
Zdrojovy kod\Detektor	Složka se zdrojovým kódem detektoru a prohlížeče
Zdrojovy kod\Rutiny testovani\traverseFiles.m	Spouštěcí skript pro testování detektoru
Kompilace\eegBrowserInstaller.exe	Instalační soubor prohlížeče s detektorem