



---

**ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE**  
**FAKULTA BIOMEDICÍNSKÉHO INŽENÝRSTVÍ**  
Katedra biomedicínské techniky

# **Metody automatické detekce EEG epileptických hrotů**

## **Methods for EEG sharp transients detection**

Bakalářská práce

Studijní program: Biomedicínská a klinická technika

Studijní obor: Biomedicínský technik

Autor bakalářské práce: Jan Hubený

Vedoucí bakalářské práce: doc. Ing. Vladimír Krajča CSc.

---

**Kladno 2017**

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

Student: **Jan Hubený**  
Obor: Biomedicínský technik  
Téma: **Metody automatické detekce EEG epileptických hrotů**  
Téma anglicky: Methods for EEG sharp transients detection

Zásady pro vypracování:

Vytvořte syntetický signál s hroty a umělými artefakty (špička, obdélník, sinusovka 15 Hz). Zpracujte takto vytvořený signál pomocí mediánové filtrace a jednoduchého aritmetického detektoru. Odečtěte originální a filtrovaný syntetický signál. Výsledek usměrněte a porovnejte s mezí pro detekci. Označte epileptické hroty přímo v signálu. Totéž ověřte pro reálný EEG signál s transiency. Součástí práce je též podrobná uživatelská dokumentace k vytvořenému programu.

Seznam odborné literatury:

- [1] Krajča V., Mohylová J., Číslíkové zpracování neurofyzilogických 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] Nieminen A., Neuvo Y., EEG spike detection based on median type filters, Proc. of Int. Conf. on Digital Signal Processing, Florence, Italy, September, 1987, 559-563 s.
- [4] Qian J., Barlow J.S., Beddoes M.P, A simplified arithmetic detector for EEG sharp transients - preliminary results, IEEE Trans. Biomed. Eng, ročník 35, číslo 1, 1988, 11-17 s.
- [5] 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

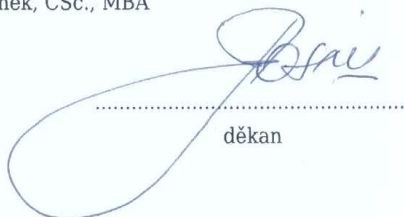
zadání platné do: 30.09.2017

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

EEG je neurofyzilogický signál, který se v praxi měří a vyhodnocuje mimo jiné pro zjištění vážného onemocnění, jakým může být například epilepsie. EEG záznam vyžaduje vzhledem ke stochastickému charakteru samotného EEG signálu vyhodnocení pomocí experta, což je časově náročné. Epileptické grafoelementy jsou skryty v opakujících se segmentech fyziologické aktivity, a tak se zde nabízí možnost využití metod automatické detekce epileptických grafoelementů jako pomocného nástroje experta při klasifikaci epileptických segmentů. Tato práce se zabývá metodami automatické detekce epileptických hrotů pomocí jednoduchého aritmetického detektoru a detektoru, který pracuje na základě mediánové filtrace. V práci je realizován kombinovaný detektor, který spojuje výhody metody jednoduchého aritmetického detektoru a mediánové metody. Výsledkem práce je realizace a následná implementace metod automatické detekce do již vytvořeného prohlížeče EEG záznamů v podobě uživatelsky přístupného modulu, který umožňuje široké nastavení parametrů samotným uživatelem. Součástí práce je testování jednotlivých detektorů na simulovaném a reálném EEG záznamu s transieny.

**Klíčová slova:** EEG, epilepsie, ostré transieny, detektor hrotů, mediánová filtrace, aritmetický detektor, kombinovaný detektor

## Abstract

EEG is a neurophysiological signal which is measured and analyzed for detection of serious diseases such as epilepsy. Due to the stochastic nature of the EEG signal it needs to be analyzed by an expert which is time consuming. Epilepticform parts of the signal are hidden in repeating segments of physiological activity. Automatic methods for detection of sharp EEG transients can be used to help experts with finding a specific epilepticform segments. This work is using simple arithmetic detector and detector based on median filtration to find epileptic spikes in signals. The advantages of the two previous methods are combined in a combined detector in this thesis. The output of this work is realization and implementation of a graphical user interface which includes the detection methods into existing EEG browser. The graphical user interface allows the user to set wide range of the parameters. This thesis includes testing of the detectors on simulated signals and on real EEG recording with transients.

**Keywords:** EEG, epilepsy, sharp transients, spike detector, median filtration, arithmetic detector, combined detector

## **PROHLÁŠENÍ**

Prohlašuji, že jsem bakalářskou práci s názvem Metody automatické detekce EEG epileptických hrotů vypracoval samostatně a použil k tomu úplný výčet citací použitých pramenů, které uvádím v seznamu přiloženém k diplomové 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 Kladně

.....

Jméno autora

## **Poděkování**

Rád bych tímto poděkoval svému vedoucímu práce panu doc. Ing. Vladimíru Krajčovi za ochotu, trpělivost a především vedení. Dále bych rád poděkoval Ing. Václavě Piorecké ,Ing. Haně Schaabové a celému BRAIN týmu za věcné připomínky a pomoc.

# Obsah

Seznam tabulek .....	3
Seznam obrázků .....	4
Seznam použitých zkratek.....	6
<b>1 Úvod do problematiky.....</b>	<b>7</b>
1.1 Biologické signály.....	7
1.2 EEG signál .....	7
1.2.1 Charakteristika signálu EEG .....	7
1.2.2 Měření EEG .....	8
1.2.3 EEG montáže .....	9
1.2.4 Zesílení a převod signálu na číslicový tvar .....	10
1.3 Artefakty v signálu EEG .....	11
1.4 Epilepsie.....	11
1.4.1 Současný přístup k analýze EEG .....	12
1.5 Cíle práce .....	15
<b>2 Metody .....</b>	<b>16</b>
2.1 Data .....	16
2.1.1 Simulovaná data .....	16
2.1.2 Reálné EEG záznamy.....	16
2.2 Programové vybavení.....	17
2.3 Návrh vlastního řešení .....	17
2.3.1 Automatická detekce pomocí mediánového filtru .....	17
2.3.2 Jednoduchý aritmetický detektor .....	22
2.3.3 Kombinovaný detektor.....	25
2.4 Implementace do prohlížeče EEG signálů .....	26
2.5 Metodika hodnocení jednotlivých detektorů.....	27

<b>3</b>	<b>Výsledky</b>	29
3.1	Grafické uživatelské rozhraní	29
3.2	Vyznačení hrotů v záznamu	30
3.3	Aplikace detektorů na uměle vytvořené signály	31
3.3.1	Signál sinus, hroty a obdélníky	31
3.3.2	Signál dle Mukhopadhyaye	32
3.3.3	Signál AR complex	33
3.4	Aplikace detektorů na reálné EEG záznamy	35
3.4.1	Detekce epileptických hrotů	35
3.4.2	Reakce detektorů na jednotlivé artefakty	39
3.5	Statistické vyhodnocení detektorů	43
3.5.1	Syntetické signály	43
3.5.1	Reálné EEG záznamy	44
<b>4</b>	<b>Diskuze</b>	45
<b>5</b>	<b>Závěr</b>	47
	Literatura	48

## Seznam tabulek

Tabulka 1: Senzitivita a specificita pro simulovaný signál sinus, hroty a čtverce.....	43
Tabulka 2: Senzitivita a specificita pro simulovaný signál dle Mukhopadhyaye .....	43
Tabulka 3: Senzitivita a specificita pro simulovaný signál AR complex.....	43
Tabulka 4: Tabulka použitých reálných EEG záznamů .....	44
Tabulka 5: Senzitivita a specificita pro reálný EEG záznam A .....	44
Tabulka 6: Senzitivita a specificita pro reálný EEG záznam B.....	44
Tabulka 7: Senzitivita a specificita pro reálný EEG záznam C.....	45



## Seznam obrázků

Obrázek 1.1: Aktivity patrné v EEG záznamech .....	8
Obrázek 1.2: Rozložení elektrod v systému 10-20 pro měření EEG .....	9
Obrázek 1.3: Komplex hrot-vlna v reálném EEG záznamu .....	12
Obrázek 1.4: Epileptický hrot v reálném EEG záznamu .....	12
Obrázek 1.5: Základní blokové schéma možného třístupňového detektoru .....	13
Obrázek 2.1: Původní signál a signál filtrovaný mediánovou filtrací.....	19
Obrázek 2.2: Srovnání původního, filtrovaného a rozdílu těchto signálů.....	20
Obrázek 2.3: Porovnání detekčních signálů.....	21
Obrázek 2.4: Zjednodušené blokové schéma realizovaného detektoru .....	22
Obrázek 2.5: Signál původní a signál filtrovaný pomocí diferenčního filtru .....	23
Obrázek 2.6: Srovnání původního, filtrovaného a detekčního signálu .....	24
Obrázek 2.7: Zjednodušené blokové schéma jednoduchého aritmetického detektoru .....	24
Obrázek 2.8: Ukázka detekčních signálů pro kombinovaný detektor.....	25
Obrázek 2.9: Zjednodušené blokové schéma kombinovaného detektoru.....	26
Obrázek 2.10: Zjednodušené blokové schéma vytvořeného modulu.....	27
Obrázek 3.1: Grafické uživatelské rozhraní modulu.....	29
Obrázek 3.2: Označené transienty v reálném EEG záznamu.....	30
Obrázek 3.3: Ukázka detekce na simulovaném signálu sinus,hroty a obdelníky.....	31
Obrázek 3.4: Ukázka detekce na simulovaném signálu sinus,hroty a obdelníky.....	32
Obrázek 3.5: Ukázka detekce na simulovaném signálu dle Mukhopadhyaye.....	32
Obrázek 3.6: Ukázka detekce na simulovaném signálu dle Mukhopadhyaye.....	33
Obrázek 3.7: Ukázka detekce na simulovaném signálu AR complex.....	33
Obrázek 3.8: Ukázka detekce na simulovaném signálu AR complex.....	34
Obrázek 3.9: Ukázka detekce epileptických hrotů.....	35
Obrázek 3.10: Ukázka detekce epileptických hrotů.....	36
Obrázek 3.11: Ukázka detekce epileptických hrotů.....	36

Obrázek 3.12: Ukázka detekce epileptických hrotů (komplex hrot-vlna).....	37
Obrázek 3.13: Ukázka detekce epileptických hrotů (komplex hrot-vlna).....	37
Obrázek 3.14: Ukázka detekce epileptických hrotů (komplex hrot-vlna).....	38
Obrázek 3.15: Reakce detektorů na amplitudový artefakt. ....	39
Obrázek 3.16: Reakce detektorů na amplitudový artefakt. ....	39
Obrázek 3.17: Reakce detektorů na EMG artefakt.....	40
Obrázek 3.18: Reakce detektorů na EMG artefakt.....	40
Obrázek 3.19: Reakce detektorů na EMG artefakt.....	41
Obrázek 3.20: Reakce detektorů na EOG artefakt. ....	41
Obrázek 3.21: Reakce detektorů na EOG artefakt. ....	42

## Seznam použitých zkratk

AR .....	AutoRegressive
AVG .....	Averaged
CMRR .....	Common-Mode Rejection Ration
EEG .....	ElektroEncefaloGram
EKG.....	ElektroKardioGram
EMG .....	ElektroMyoGram
EOG.....	ElektroOkuloGram
FIR.....	Finite Impulse Response
FN.....	False Negative
FP .....	False Positive
LAMSTAR.....	Large Memory SStorage And Retrieval
MA .....	Moving Average
PCA.....	Principal Component Analysis
ROC.....	Receiver Operating Characteristics
SOM .....	Self-Organizing Map
TN.....	True Negative
TP .....	True Positive
WF.....	Wafe-Finder

# 1 Úvod do problematiky

Následující kapitola se věnuje teoretickému úvodu do problematiky. Jsou zde vysvětleny základní principy a přehled současného přístupu k problematice. Závěrem kapitoly jsou vydefinované cíle práce.

## 1.1 Biologický signál

Biologický signál vzniká na základě nervového vzruchu. Nervový vzruch je fyzikálně chemický děj, při kterém vzniká potenciál na membráně nervové buňky. Vzruch se poté šíří po nervových tkání a výsledkem této aktivity je přenos a zaznamenání informace popřípadě příslušná reakce. Abychom těmto dějům lépe porozuměli, je klíčové umět tyto signály zaznamenat a řádně popsat. [4] [5]

Biologické signály a jejich klasifikace mají významný podíl na určení diagnózy. Z tohoto důvodu je nezbytné, aby jejich zobrazení a klasifikace byly co nejvíce zřejmé a unifikované. Elektroencefalografie je metoda používaná v diagnostice, která zaznamenává elektrickou aktivitu mozku v čase. Jako první tyto elektrické potenciály mozku objevil Caton v roce 1875 a první elektroencefalograf byl sestaven v roce 1929 Bergerem v Jeně. [1] [4]


## 1.2 EEG signál

EEG je signál biologického původu, který se projevuje z matematického hlediska jako stochastický signál. Z tohoto důvodu není zcela možné signál úplně determinovat. Jedná se o vícekanálový signál. Elektroencefalogram vzniká součinností thalamu a kortexu, kde thalamus má funkci generátoru rytmů. Hlavním zdrojem EEG je pravděpodobně elektrická aktivita synaptodendritických membrán v povrchních vrstvách kortexu. Normální nepatologické EEG bývá většinou rytmické a má spíše sinusoidní tvar. [1] [4]

### 1.2.1 Charakteristika signálu EEG

EEG signál je z technického hlediska signál nestacionární, protože jeho frekvenční a amplitudová charakteristika se mění v čase. Pro zjednodušení lze předpokládat, že signál je kvazi-stacionární, tedy po částech stacionární. Amplitudový rozsah signálu je přibližně 2 až 100  $\mu\text{V}$  a frekvenční rozsah se pohybuje do 100 Hz. Nejvíce výkonu signálu pak nalezneme v rozmezí 0,5 až 30 Hz. V EEG záznamu můžeme najít nejznámější aktivity mimo jiné Alfa, Beta, Delta, Theta a Gama. Alfa aktivita je charakteristická svojí frekvencí 8 až 13 Hz a amplitudou většinou kolem 50  $\mu\text{V}$ . Je lépe patrná při zavřených očích a je fyziologicky

dominantní až u zralého mozku. Beta aktivita je rytmická aktivita o frekvenci 14 až 30 Hz s amplitudou většinou menší než  $30 \mu V$ . Beta aktivita je obvykle fyziologická, patologicky se objevuje po léčích. Delta je více nebo méně rytmická aktivita o frekvenci do 4 Hz a amplitudy 10 až  $300 \mu V$ . Fyziologická delta se objevuje do 3 let života a v hlubokém synchronním spánku. Aktivita Theta se vyskytuje ve frekvenčním rozmezí 4 až 8 Hz s amplitudou do  $30 \mu V$ . Můžeme jí zaznamenat u dětí v bdělém stavu. Gama aktivita se nalézá ve frekvencích 30 až 60 Hz s nízkou amplitudou do  $10 \mu V$ . Gama aktivita se dává do souvislosti se stresovými mechanismy. Vzhledem k frekvencím, ve kterých se gama vyskytuje, je nutné odlišit tuto aktivitu od artefaktů jako je síťový brum a svalová aktivita. [1] [4]




Obrázek 1.1: Aktivity patrné v EEG záznamech, Time (s): čas v sekundách. Převzato z článku [33]

### 1.2.2 Měření EEG

Měření EEG se provádí pomocí elektroencefalografu. Jedná se o systém elektrod v různém zapojení. V praxi se používá běžně 19 kanálů, ale využívají se i více kanálové systémy, v některých případech až 256 kanálů. Rozložení elektrod se běžně řídí podle jednoduchého

antropometrického měření podle H. Jaspera. Jedná se o systém 10-20, to znamená, že vzdálenost elektrod od sebe je 10% nebo 20% v sagitální rovině mezi nasion a inion i v rovině frontální mezi oběma zevními zvukovody. Propojení elektrod pak závisí na režimu měření. [1] [4] [8]



Obrázek 1.2: Rozložení elektrod v systému 10-20 pro měření EEG (převzato z článku Signal processing detection methods [8])

### 1.2.3 EEG montáže

Elektrody ke snímání EEG potenciálů bývají většinou argentchloridové. Problematiku propojení snímacích elektrod řeší montáže. V praxi se používají převážně následující montáže [1]:

- Unipolární
- Bipolární
- Zapojení se společnou elektrodou

Unipolární zapojení je základní zapojení elektrod vůči referentní elektrodě, kterou tvoří elektrody umístěné na uších. Unipolárním zapojením získáme vstupní data. Odečtením hodnot sousedních elektrod pak můžeme virtuálně dostat bipolární zapojení. Takové zapojení pak představuje výhodu v podobě eliminace pohybových artefaktů. Zapojení se společnou elektrodou se může někdy označovat jako zapojení common reference (společná reference) nebo AVG (průměrná reference). Toto zapojení vznikne virtuálně tak, že ze všech hodnot

potenciálů elektrod vypočteme aritmetický průměr a tím získáme hypotetickou hodnotu společného potenciálu. Následně tuto hodnotu odečteme od hodnot v každém kanále. Montáž AVG může dobře sloužit jako předzpracování signálu. Konkrétně dokáže potlačit pohybové aktivity. [1]

#### 1.2.4 Zesílení a převod signálu na číslicový tvar

Problematika zesilovačů a převodu analogového signálu na digitální je velmi obsáhlá, komplexní a dynamicky se rozvíjející oblast. Technické nároky na zesilovač biologických signálů jsou vysoké a existuje mnoho parametrů, které ho popisují. V následujících odstavcích se zaměřím jen na základní a nejdůležitější vlastnosti zesilovače a analogově-digitálního převodníku.

Signál z elektrod je zaveden do zesilovače. Signál EEG, který je měřen povrchově, je tlumen lebkou, a tak je jeho amplitudový rozsah velmi malý. Z tohoto důvodu je důležité zajistit dostatečné zesílení alespoň  $A = 10^5$ . Dále, abychom napětí měřili, co možná nejpřesněji, je důležité, aby zesilovač měl vysoký vstupní odpor ideálně více než  $10^8 \text{ M}\Omega$ . Další klíčový parametr je schopnost potlačit souhlasné rušení, který vyjadřuje činitel CMRR. Hodnota CMRR by měla být vyšší než  $10^7$ . [32]

Zesílený signál je dále potřeba převést na číslicový tvar. Analogový signál se nejprve vzorkuje a následně kvantuje. Jinými slovy ke každému vzorku se v čase přiřadí příslušná hodnota napětí, která je vyjádřena binárním tvarem. Vznikne tak diskrétní signál tvořený posloupností hodnot napětí v příslušném čase. Základní vlastností analogově-digitálního převodu je vzorkovací frekvence. Vzorkování musí splňovat Nyquistův teorém: [1]

$$f_s = 2 \cdot f_{\max} \quad (1.1)$$

Kde  $f_s$  je vzorkovací frekvence a  $f_{\max}$  je hodnota nejvyšší frekvence obsažené v signálu.

V případě, že je vzorkovací frekvence je příliš nízká a nesplní se Nyquistův teorém, může dojít k aliasingu, a tak z nasbíraných vzorků následně není možné zrekonstruovat původní signál. Vyšší hodnoty vzorkovací frekvence znamenají větší kvalitu digitálního signálu, ale také vyšší paměťové nároky výpočetní techniky. V praxi se pro měření EEG signálů používají vzorkovací frekvence 128 až 256 Hz. Ke každému vzorku se pak přiřadí hodnota podle kvantizačního kroku. [1]

### 1.3 Artefakty v signálu EEG

Artefakty v EEG záznamech můžeme rozdělit na biologické, které mají projev biologického signálu, a na technické artefakty, které do měření zavádí přístrojová technika. Mezi biologické artefakty v EEG záznamu patří mimo jiné [1]:

- EMG – elektrická aktivita svalstva
- EOG – elektrická aktivita oka
- EKG – elektrická aktivita srdce

Mezi technické artefakty patří následující příklady:

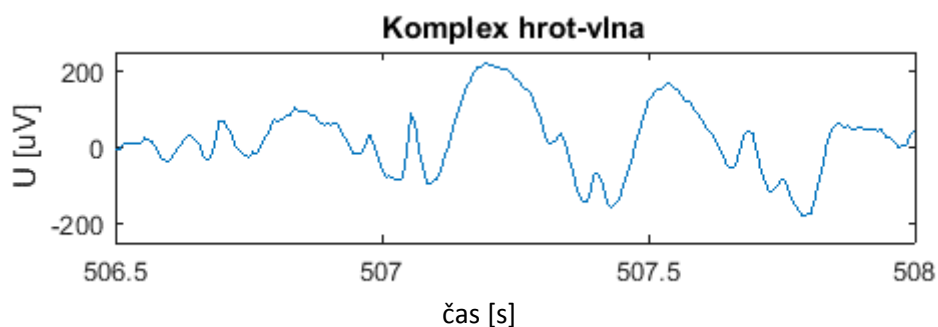
- Síťový brum (50 Hz)
- Elektromagnetické rušení
- Elektrostatické potenciály
- Amplitudový artefakt

Pro přesnou klasifikaci signálu je nutné tyto artefakty identifikovat nebo je lépe ze signálu odstranit. Odstranění EOG artefaktu ze záznamu se věnuje například článek [7].


### 1.4 Epilepsie

Epilepsie je nervové onemocnění mozku doprovázené opakujícími se záchvaty. Morfologické příčiny bývají různé, a tak se spíše jedná o skupinu syndromů. Z elektrofyziologického hlediska bývají epileptické záchvaty charakteristické zejména hypersynchronní aktivitou neuronů kortexu, kmene mozku a míchy, doprovázené vysokými hodnotami amplitudy a frekvence. Populace neuronů vysílají synchronně vysokofrekvenční nervové vzruchy s vysokou hodnotu amplitudy oproti nepatogennímu EEG. V EEG záznamu jsou tyto vzruchy reprezentovány epileptickými grafoelementy. [4]





Obrázek 1.3: Komplex hrot-vlna (epileptický grafoelement) v reálném EEG záznamu. Obrázek pochází z reálného EEG záznamu.




Obrázek 1.4: Epileptický hrot (epileptický grafoelement) v reálném EEG záznamu. Obrázek pochází z reálného EEG záznamu.

Na obrázku 1.2 můžeme vidět příklad epileptického grafoelementu v podobě komplexu hrot-vlna. Pomalé komplexy hrot-vlna jsou charakteristické svojí frekvencí o hodnotě méně než 2,5 Hz. Existují také komplexy hrot-vlna s frekvencí 3 Hz, které jsou většinou doprovázeny záchvatem a ztrátou vědomí. Na obrázku 1.3 můžeme vidět další typický grafoelement. Epileptický hrot, který trvá většinou 20 až 70 ms. Tyto hroty jsou pak často součástí komplexů hrot-vlna. Po inicializaci epileptického záchvatu se objevují podobné grafoelementy ve více kanálech ve stejný čas. [9]

#### 1.4.1 Současný přístup k analýze EEG

Metod pro odhalování grafoelementů v EEG signálu existuje v současné době velké množství a jejich vývoj se v uplynulých letech vydal různými směry. Metody detekce jsou také závislé na vývoji a zdokonalení výpočetní techniky. Od počátku vývoje detekčních metod se vývoj ubíral dvěma základními směry. Jedním směrem byla analýza epileptických záchvatů a druhým směrem byla analýza interiktálního EEG. Jinými slovy EEG záznam, kde nedochází k záchvatu, ale je možné v záznamu detekovat epileptické grafoelementy.

Jednodušší detektory epileptických hrotů můžeme obecně popsat jako třístupňový detektor. Jeho výstup je binární, tedy určuje, zdali se jedná nebo nejedná o epileptické grafoelementy v podobě hrotu. Detektor pak může vypadat následovně, jak je ukázáno na obrázku 1.5.



Obrázek 1.5: Základní blokové schéma možného třístupňového detektoru

Na obrázku 2.1 můžeme vidět základní blokové schéma třístupňového detektoru. Blok „Zpracování signálu“ může představovat různé filtry pro odstranění šumu, ale i některých artefaktů, jako například aktivitu EMG. Pro odstranění EMG aktivity se může například použít FIR (filtr s konečnou odezvou), který zanechá hroty a potlačí EMG artefakty. Nejvýznamnější část detektoru pak tvoří blok „Tvorba detekčního signálu“, který v signálu zvýrazní hroty. Detekční signál by pak měl obsahovat zvýrazněné složky signálu, které chceme detekovat. Tento detekční signál je poté v bloku „Detekční limit“ porovnán s mezní hodnotou, kde po splnění podmínky přesažení mezní hodnoty dochází k detekci a následnému vyznačení hrotu v EEG signálu. Většinu metod detekce můžeme rozdělit na [15]:

- Metody popisující signál v časové oblasti
- Metody popisující signál ve frekvenční oblasti
- Metody popisující signál v časově-frekvenční oblasti
- Nelineární metody

Například Sankar a Natour (1992) v článku [12] využívá autoregresní model k zachování pouze transientů v každém okně o délce 5 sekund. Transient se následně porovná s uloženými vzory a v případě shody se označí jako epileptický hrot. Hlavní myšlenkou je vytvořit filtr, který napodobí výkonové spektrum okna. Nestacionární části signálu pak najde inverzní filtr. Když vzorky přesáhnou nastavenou mez, jsou označeny jako potenciální hroty. Tyto potenciální hroty se poté porovnají s předešlými hroty, které byly nalezeny autoregresním modelem. Pokud je euklidovská vzdálenost mezi porovnávanými vzorky menší než nastavená mez, je transient klasifikován jako epileptický hrot.

Další metodou může být například automatická adaptační detekce pomocí dvojího čtení signálu, kterou zpracovali A. Nonclercq a spol. v článku [26]. Signál se nejprve předzpracuje derivací. Následně se umocní a vyhladí pomocí filtru typu MA (Moving average), který ze signálu odfiltruje vyšší frekvence, jako jsou například EMG artefakty. Signál je v prvním čtení

porovnán s uměle vytvořeným hrotem, který je vytvořen jako trojúhelník s amplitudou 300  $\mu\text{V}$  a délkou 60 ms. Druhé čtení je identické jako první s výjimkou, že je signál porovnán s již detekovanými hroty a je zvýšena korelační mez.

Dalším způsobem pro detekci hrotů může být velmi často využívaná vlnková transformace, kterou realizovali například v článku [11], kde ji využili k redukci artefaktů nebo také v článku [13], kde vlnkovou transformaci využili k extrakci příznaků pro vstup do klasifikace pomocí neuronové sítě. V článku [14] využívají víceúrovňovou vlnkovou transformaci k dekompozici signálu do podskupin aktivit Alfa, Theta, Delta, Beta a Gama. Extrakci konkrétně ostrých hrotů pomocí vlnkové transformace v signálu se věnují v článku [22]. Tato metoda je založená na časově-frekvenčním popisu signálu. U této metody je klíčový výběr referenční (mateřské vlnky). Další přístup založený na časově-frekvenčním popisu signálu je například metoda založená na Hilbertově transformaci. V článku [27] se mapují hroty pomocí okamžitého výkonu signálu a okamžité frekvence. Hrot je následně označen na pozici, kde jsou vyšší hodnoty výkonu signálu a stabilní frekvence současně. Metoda automatické detekce operující ve frekvenční oblasti signálu může být i postavená na předpokladu, že se signál skládá ze stacionárního pozadí a nestacionární části signálu, kterou tvoří ostré hroty. Tohoto předpokladu využili v článku [29], kde je pomocí adaptivního filtru odstraněna stacionární část signálu. Detekční signál, který vznikl následným rozdílem filtrovaného a původního signálu, se porovnal s mezí. Po přesáhnutí meze byl transient označen. Stejného předpokladu využívá i detektor [31], který využívá autoregresní model signálu s časově proměnnými koeficienty. Pro odhad koeficientů zde využili Kalmanovu filtraci. Výsledný signál je pak porovnán s mezí, která je počítána jako násobek střední hodnoty stacionární části signálu. K označení transientu dochází po překročení meze.

Další metodou pro detekci epileptických hrotů může být metoda PCA (Principal component analysis). Tato metoda operuje v časové oblasti signálu a pracuje na základě rozdělení signálu do jednotlivých komponent [15]. První hlavní komponenta u signálu EEG popisuje většinu variance vstupu a odráží tak nejpomalejší složky signálu [1]. Se stoupajícím pořadím komponent se zvyšuje obsah frekvenčních složek příslušné křivky. Podle volby se pak používá určitá komponenta jako detekční signál, který je následně porovnán s mezí [1]. Metody operující ve frekvenční oblasti signálu využívají výkonové spektrum signálu na základě Fourierovy transformace. V článku [16] využívají Polat a Gunes rychlou Fourierovu transformaci v kombinaci s Welchovou metodou pro klasifikaci epileptické aktivity v EEG záznamu.

Mezi nelineární metody můžeme zařadit metody, které využívají umělé neuronové sítě. Pro neuronovou síť je klíčové předzpracování signálu pro její učení. V článku [17] využil Nigam a Graupe neuronovou síť LAMSTAR (large memory storage and retrieval), která se vyznačuje efektivním využíváním velkého množství modulů SOM (self organized maps) v kombinaci se statistickými funkcemi. Kombinaci neuronové sítě a využití vlnkové transformace jako vstup neuronové sítě využili například v článku [19].

Výpočetně jednodušší metodu představil Gotman (1982). Základem tohoto přístupu bylo předzpracování signálu filtrem, který odstranil frekvence o hodnotě 60 Hz a následná dekompozice signálu do půlvln [20]. Další výpočetně nenáročnou metodou může být využití tvaru epileptického hrotu podle jeho definice. V článku [28] vycházejí autoři z časové definice epileptického hrotu a z předpokladu, že hrot má tvar trojúhelníku s náběžnou a sestupnou hranou o určité délce trvání a sklonu. V signálu se poté vypočítá pomocí první derivace sklon náběžné a sestupné hrany a následně je určena i doba trvání. Pokud se vypočtené údaje rovnají definovanému hrotu z předlohy, je hrot označen jako epileptický. Na podobném principu pracuje detektor [30], který provede extrakci příznaků na základě porovnání s definovaným tvarem epileptického hrotu ve více kanálech. Výsledná detekce pak závisí na korelaci příznaků ve více kanálech.

Vzhledem k rozsahu a dynamice rozvoje problematiky detekce epileptických hrotů byla nastíněna pouze část možných přístupů. Většina detekčních systémů využívá kombinaci metod, ať už se jedná o klasifikaci nebo předzpracování signálu. Příkladem takového komplexního systému pro automatické zpracování signálu je Wave-Finder (WF) [24].

## 1.5 Cíle práce

Cílem práce je realizace a aplikace detektorů epileptických hrotů pomocí metody jednoduchého aritmetického detektoru a detektoru, který využívá filtraci pomocí mediánu, do prohlížeče EEG záznamů již vytvořeného v programovém prostředí MATLAB. Dále je cílem práce otestovat tyto detektory na simulovaném a reálném EEG záznamu. Realizované metody se zapouzdří do modulu ke stávajícímu programu pro prohlížení EEG záznamů. Vytvořený modul bude uživatelsky přístupný a zároveň bude nabízet možnost volby metody a nastavení parametrů nezbytných pro dané metody. Modul, který je součástí celého programu, by měl sloužit jako pomocný nástroj odborníka.

## 2 Metody

V následující kapitole jsem se zaměřil na povahu použitých dat k měření a následně na vlastní návrh řešení od základů metody až po samotnou implementaci do již vytvořeného prohlížeče EEG signálů. V samotném závěru kapitoly je pak popsána metodika testování vytvořeného modulu.

### 2.1 Data

Pro testování modulů pro automatickou detekci epileptických grafoelementů jsou nezbytná data. Podle zadání jsem použil data simulovaná a reálné EEG záznamy.

#### 2.1.1 Simulovaná Data

Pro ověření funkčnosti jednotlivých detektorů bylo nejprve potřeba vytvořit syntetický signál, který předně simuloval EEG signál s typickými grafoelementy, ale zároveň také simuloval artefakty, například EMG aktivitu. V rámci implementace celé metody do již vytvořeného prohlížeče, na základě společné práce v týmovém projektu, jsem se rozhodl pro větší objektivitu testování využít testovací signály, stejné jako v bakalářské práci M. Jílka [18]. Testování detektorů proběhlo na trojici simulovaných signálů. První signál se podle zadání skládal z kombinace sinusovky o frekvenci 15 Hz (simulace svalové aktivity), obdélníkového signálu a hrotů. Hroty a artefakty jsou v signálu generovány náhodně. Druhý testovaný signál, AR complex, byl vytvořen na základě filtrace bílého šumu pomocí autoregresního filtru. Do signálu byly následně přidány hroty s náhodnou pozicí. Třetí testovaný signál dle Mukhopadhyaye, byl vytvořen na základě článku [23]. Všechny testovací signály jsou součástí generátoru syntetických signálů, který byl vytvořen jako součást bakalářské práce [18].

#### 2.1.2 Reálné EEG záznamy

Realizované detektory byly testovány i na reálných EEG záznamech, které byly naměřeny v Nemocnici Na Bulovce přístrojem BRAINQUICK podle systému 10-20 při standardních podmínkách. Záznamy pochází z klinického vyšetření EEG od pacientů s podezřením na epilepsii. Měření schválila Etická komise Nemocnice Na Bulovce v roce 2011.

## 2.2 Programové vybavení

Pro tvorbu programu jsem používal MATLAB verze 2015b. Program využívá komponenty MATLABu zejména `Signal processing toolbox` a `Statistics toolbox`.

## 2.3 Návrh vlastního řešení

V následující podkapitole se podrobně zaměřuji na realizaci jednotlivých metod detekce. Jsou zde zjednodušeně popsány algoritmy a rozepsány samotné použité výpočty, které dané metody definují.

### 2.3.1. Automatická detekce epileptických hrotů pomocí mediánové filtrace

Předzpracování a příprava signálu pro detekci epileptických hrotů je stěžejní disciplína, na které závisí přesnost a funkčnost celé metody. Jedna cesta z bohaté nabídky možností může být pomocí mediánové filtrace. Filtrace pomocí výpočtu mediánu potlačuje impulsní změny, tedy i EMG artefakty. Přesněji odstraňuje impulsní změny, které jsou kratší než délka zkoumaného okna [1]. Nevýhoda této metody spočívá ve výpočetní náročnosti z hlediska výpočtu mediánu a citlivosti na detekci EMG artefaktů. Využití této filtrace v detekci grafoelementů poprvé navrhli Nieminem a Neovo v roce 1986 [6], kteří zároveň přišli s návrhem zjednodušení výpočtu mediánu hybridním mediánovým filtrem v článku [21].

Pro seřazenou posloupnost čísel od nejnižší hodnoty po největší o liché hodnotě délky  $N$  platí obecný výpočet mediánu:

$$Me(X) = x_{(N+1)/2} \quad (2.1)$$

Pro stejnou posloupnost čísel u sudé hodnoty  $N$  bude výpočet mediánu:

$$Me(X) = \frac{x_{N/2} + x_{(N/2)+1}}{2} \quad (2.2)$$

Kde  $Me(X)$  je hodnota mediánu,  $x$  je hodnota prvku v posloupnosti,  $N$  je celkový počet prvků v posloupnosti

Máme-li vektor  $x(k_1, k_2, k_3, \dots, k_n)$ , který v našem případě představuje vstupní signál, kde platí  $k_1 < k_2 < k_3 < \dots < k_n$ , pak každý prvek vektoru spočítáme jako medián z  $n$  prvků vektoru. Pro symetrické okno filtru o velikosti  $n$  bude výpočet vypadat následovně:

Pokud je  $n$  liché:

$$y(k) = x(k - (n-1)/2; k + (n-1)/2) \quad (2.3)$$

Pak medián spočítáme:

$$y(k) = y_{(n+1)/2} \quad (2.4)$$

Pro sudé  $n$ :

$$y(k) = x(k - (n/2)/2; k + (n/2) - 1) \quad (2.5)$$

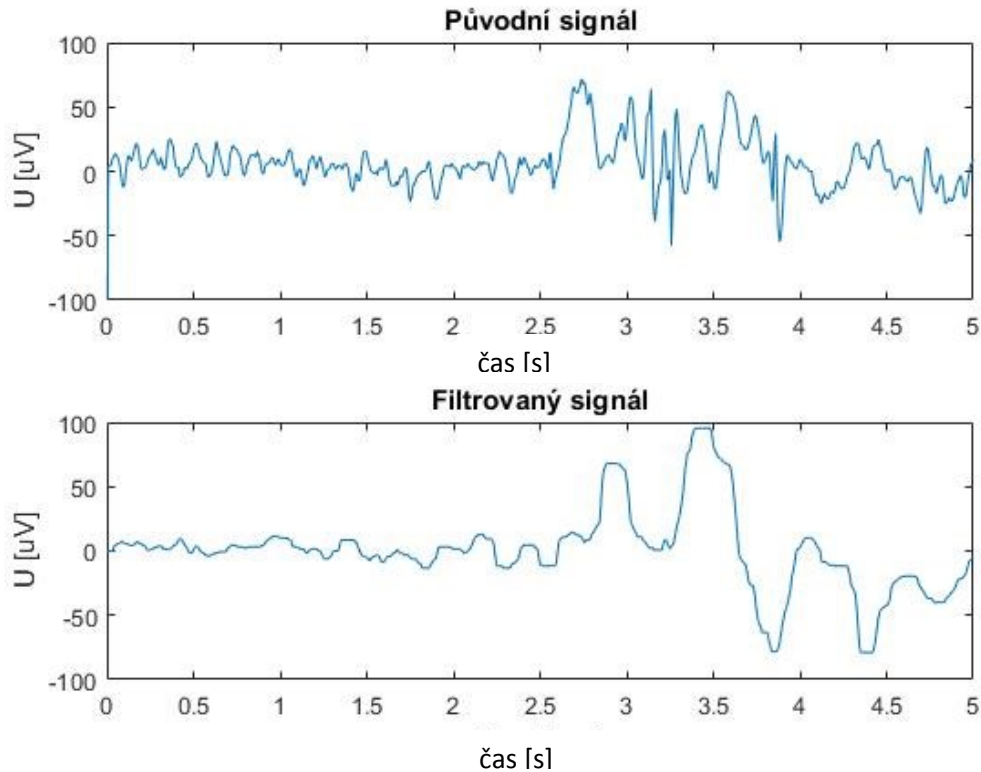
Medián bude pak vypadat:

$$y(k) = \frac{y_{(n/2)} + y_{(n/2)+1}}{2} \quad (2.6)$$

Kde  $n$  je hodnota řádu filtru,  $x(k)$  je vstupní signál a  $y(k)$  je filtrovaný signál. Rovnice 2.3, 2.4, 2.5 a 2.6 jsou převzaty z funkce MATLABu `medfilt1` [25].

Podle rovnice 2.3 můžeme vyvodit, že čím vyšší bude  $n$  (hodnota řádu filtru), tím více bude prvků ve vektoru, ze kterého se medián počítá. Na hodnotě řádu filtru závisí kvalita filtrovaného signálu. Čím bude hodnota řádu filtru větší, tím budou v signálu více potlačeny impulsní složky. Na výsledném rozdílu filtrovaného a původního signálu jsou pak lépe poznat impulsní změny. Vyšší hodnota řádu filtru pak ale znamená vyšší výpočetní náročnost.

Takto filtrovaný signál je oproti původnímu signálu vyhlazen. Mediánová filtrace z původního signálu odstraní frekvenční impulsy [6]. Mezi tyto frekvenční impulsy může patřit i grafoelement v podobě epileptického hrotu. Srovnání signálů můžeme vidět na obrázku 2.1.



Obrázek 2.1: EEG signál před a po mediánové filtraci. Pro obrázek 2.1 byl využit Matlab a jeho funkce `medfilt1` [25], která je součástí komponenty MATLABu `Signal processing toolbox`. Signál pochází z reálného EEG záznamu.

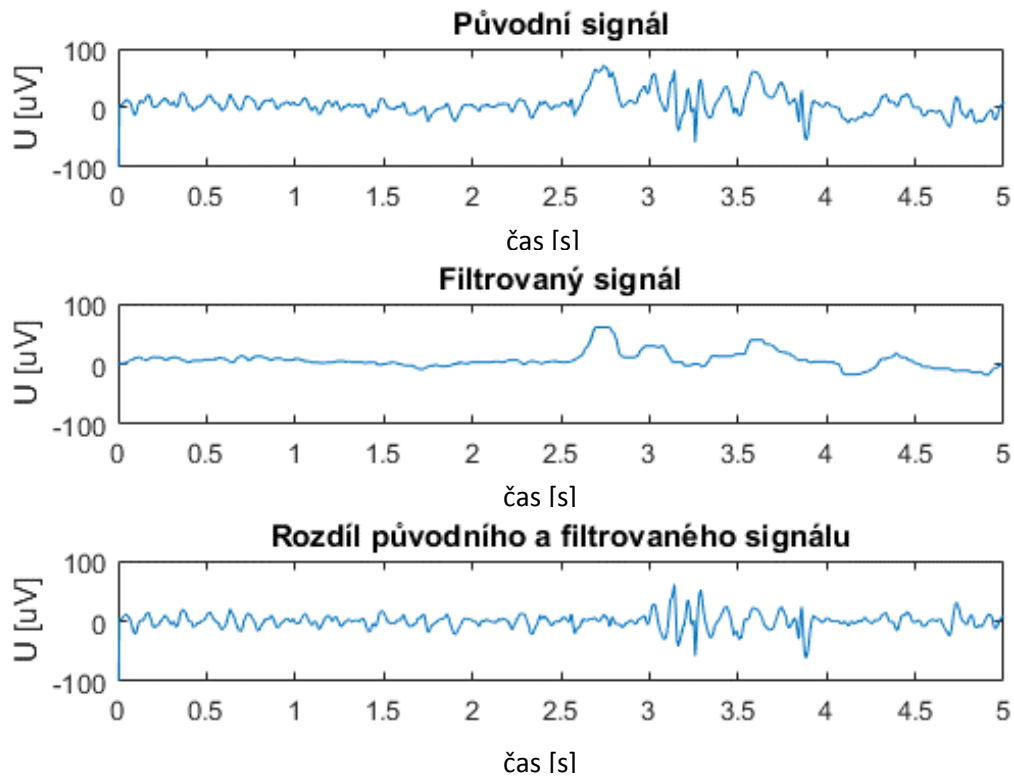
Pro filtraci pomocí výpočtu mediánu jsem se rozhodl využít již vytvořenou funkci v MATLABu `medfilt1`. Jedná se o funkci, která pracuje s jednorozměrným signálem. Výstup této funkce je filtrovaný signál pomocí mediánového filtru. Funkce vyžaduje jeden vstupní parametr v podobě hodnoty řádu filtru. Ve výsledném programu je tato hodnota volitelná uživatelem. Funkce `medfilt1` je dobře optimalizovaná na práci s velkými objemy dat, a tak se docílí menší výpočetní náročnosti.

Zpracovaný signál odečteme od původního signálu. Tím získáme detekční signál, který zvýrazní impulsní složky v signálu (hroty) [1]. Výsledný detekční signál  $z(k)$  pak spočteme jednoduše:

$$z(k) = |x(k) - y(k)| \quad (2.7)$$

Pro zvýraznění hrotů ještě umocníme signál  $z(k)$  druhou mocninou.






Obrázek 2.2: Srovnání původního, filtrovaného a rozdílu těchto signálů. Signál pochází z reálného EEG záznamu.

Na obrázku 2.3 můžeme vidět jednotlivé fáze tvorby detekčního signálu. Dále můžeme vidět, že v rozdílu původního a filtrovaného signálu jsou zachovány pouze rychlé frekvenční změny. Následným umocněním rozdílu původního a filtrovaného signálu vznikne detekční signál, kde jsou rychlé frekvenční změny zvýrazněny.

Detekční signál je závěrem porovnán s mezí pro detekci. Zde existuje více způsobů pro určení hranice, například pevná hodnota napětí nebo se také může hodnota statisticky určit pomocí výpočtu z daného signálu. V mé práci jsem se zaměřil na dvě možnosti určení meze pro detekci. První a základní mez pro tuto metodu je pevná hodnota napětí. Detekční signál se v tomto případě jednoduše porovná s pevnou hodnotou.

Alternativou k první možnosti může být výpočet kvantilu. Ze zobrazovaného okna se spočítá v detekčním signálu příslušná hodnota kvantilu. Detekční signál je následně porovnán s hodnotou kvantilu. V samotném signálu se epileptické hroty vyznačují svojí vysokou hodnotou amplitudy. Pokud vytvoříme detekční signál, který tyto hroty zvýrazní a usměrní, pak můžeme předpokládat, že hroty v detekčním signále budou nabývat velmi vysokých hodnot

kvantilu. Tímto docílíme větší objektivity při určení detekčního limitu. Zároveň je také třeba brát ohled na délku zobrazovaného okna a k tomu také hodnotu kvantilu přizpůsobit. Pro výpočet kvantilu jsem použil již vytvořenou funkci v MATLABu `quantile`. Funkce je součástí komponenty MATLABu `Statistics toolbox`.




Obrázek 2.3: Porovnání detekčního signálu vytvořeného pomocí mediánové filtrace s nastavenou mezí obrázek A: mez jako pevná hodnota, obrázek B: mez jako 99 % kvantil detekčního signálu. Jedná se o stejný signál jako je na obrázcích 2.2 a 2.3.

Na obrázku 2.4 můžeme vidět grafickou demonstraci porovnání detekčního signálu s nastavenou a vypočítanou mezí. Výsledkem obou způsobů je detekce čtyř epileptických hrotů. Hlavní výhodou určení detekčního limitu výpočtem kvantilu je adaptace meze na zkoumaný signál.

Nedostatek uvedeného postupu pro výpočet detekční hranice pomocí kvantilu nastává, když se v zobrazovaném okně v daném kanálu zobrazí pouze normální nepatogenní EEG. V tomto případě by algoritmus detekoval vše, co by odpovídalo zvolené hodnotě kvantilu. Tento nedostatek jsem vyřešil pomocí jednoduché podmínky, kde se hodnota kvantilu musí rovnat alespoň pevné hodnotě. V našem případě můžeme mluvit o offsetu pro porovnání s mezí

v podobě kvantilu. Tuto hodnotu offsetu jsem stanovil pevnou, neměnnou pro mediánový detektor a pro jednoduchý aritmetický detektor.

Návrh detektoru využívající mediánovou filtraci jsem realizoval podle základního blokového schéma na následujícím obrázku.



Obrázek 2.4. Zjednodušené blokové schéma realizovaného detektoru

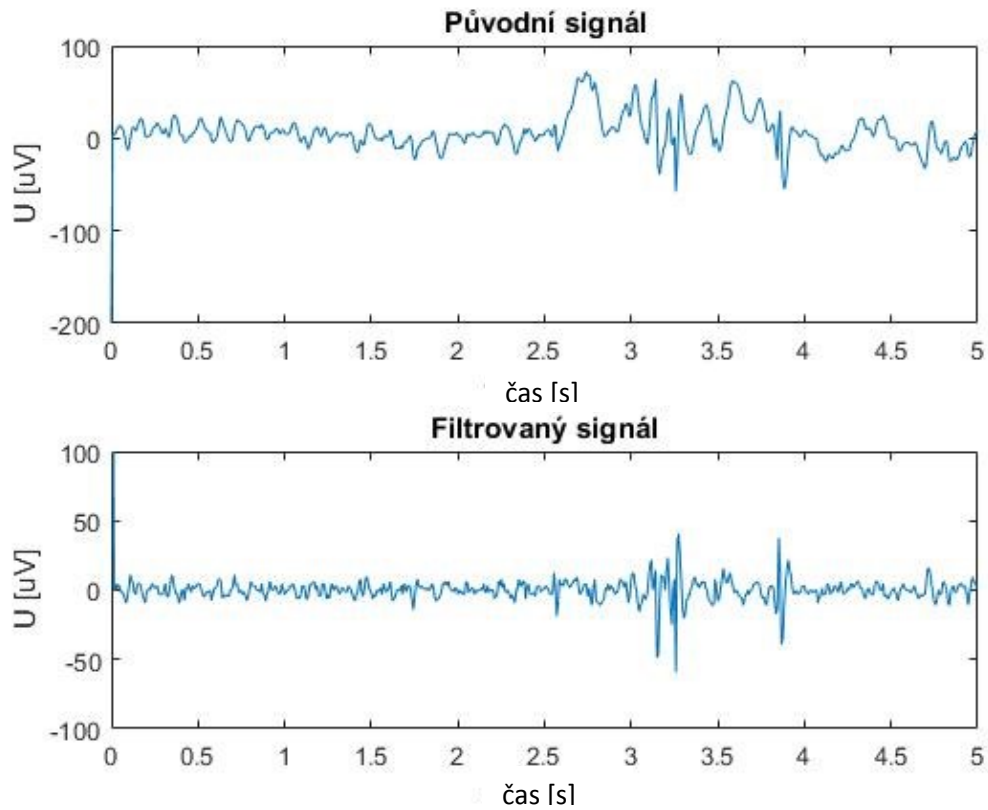
### 2.3.2. Jednoduchý aritmetický detektor

Základ jednoduchého aritmetického detektoru tvoří diferenční filtr druhého řádu. Tento filtr může být další možností, jak vyhladit signál a zvýraznit v signálu rychlé impulsní změny. Diferenční filtr funguje na základě výpočtu rozdílu dvou prvků za sebou a v signálu tak zvýrazňuje frekvenční komponenty hrotu. Jednoduchý aritmetický detektor je výpočetně méně náročný v porovnání s mediánovým detektorem a také méně detekuje EMG artefakty, avšak je citlivější na prudké změny amplitudy. Tento filtr byl aplikován při detekci hrotů v EEG signálu v článku [3]. Pokud bychom aplikovali diferenční filtr na jednorozměrný signál, respektive vektor o  $n$  prvcích, přepočtení signálu by mohl vypadat následovně:

Pro výchozí vektor  $x(k)$  o  $n$  prvcích:

$$y(k) = x(k) - x(k-1) \quad (2.8)$$

Kde  $y(k)$  je výsledný signál po filtraci a  $x(k)$  je vstupní signál před filtrací

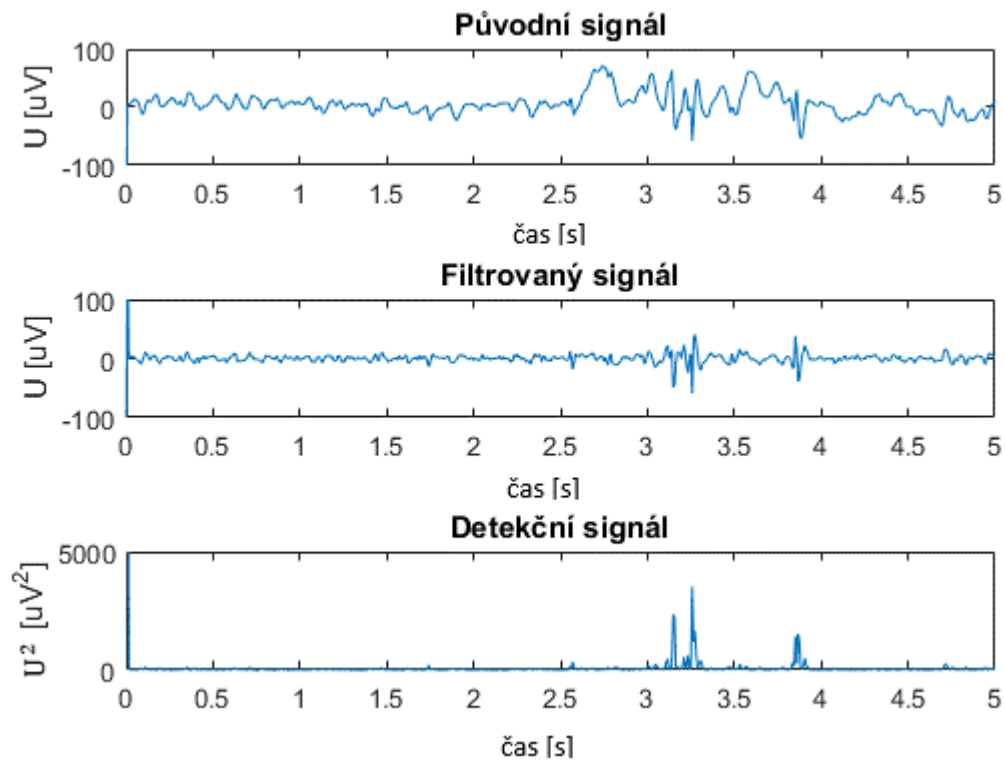


Obrázek 2.5: Signál původní a signál filtrovaný pomocí diferenčního filtru. Jedná se o stejný signál jako u obrázku 2.2 a 2.3.

Signál dále umocníme. Tím v signálu zvýrazníme rychlé impulsní změny s vyššími hodnotami amplitudy, které jsou pro epileptické hroty charakteristické. Výsledný detekční signál pak bude vypadat podle následující rovnice:

$$z(k) = y(k) \cdot y(k) \quad (2.9)$$


Kde  $z(k)$  je vektor, který reprezentuje detekční signál a vektor  $y(k)$  je signál před umocněním.



Obrázek 2.6: Srovnání původního, filtrovaného a detekčního signálu. Signál pochází z reálného EEG záznamu.

Nyní je detekční signál připraven pro porovnání s detekční hranicí. Způsob porovnání je zde stejný jako u předešlého detektoru, tedy porovnání s pevnou hodnotou nebo s hodnotou určenou na základě výpočtu kvantilu ze zobrazovaného okna. Oba způsoby jsou popsány již v podkapitole 2.2.1. Automatická detekce epileptických hrotů pomocí mediánové filtrace.

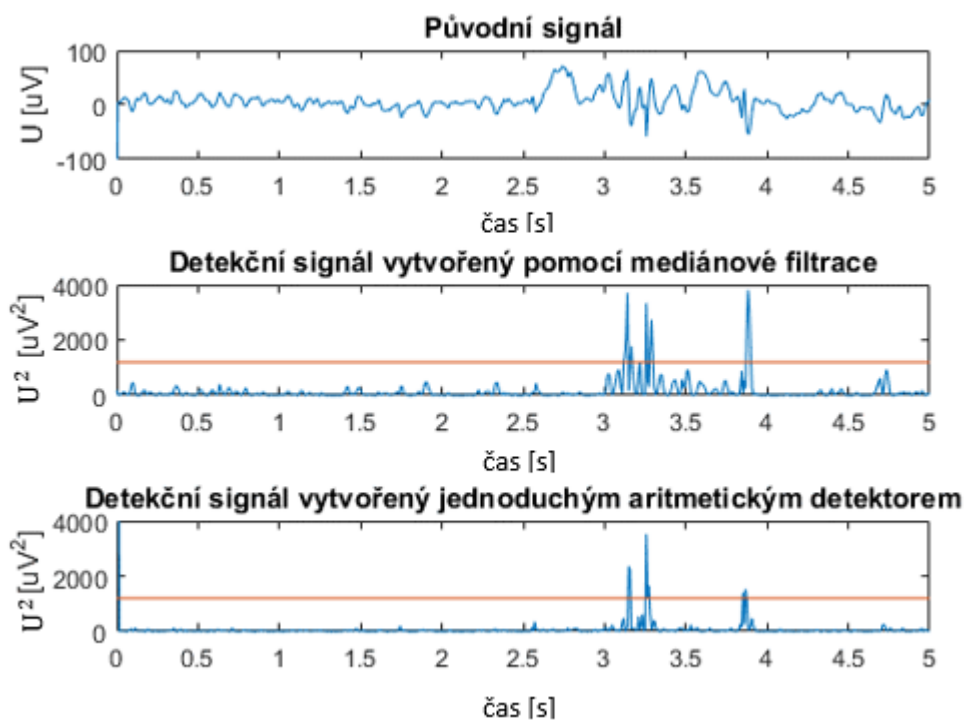
Návrh jednoduchého aritmetického detektoru jsem realizoval na základě článku [3]. Základní blokové schéma detektoru je na následujícím obrázku.



Obrázek 2.7. Zjednodušené blokové schéma jednoduchého aritmetického detektoru.

### 2.3.3 Kombinovaný detektor

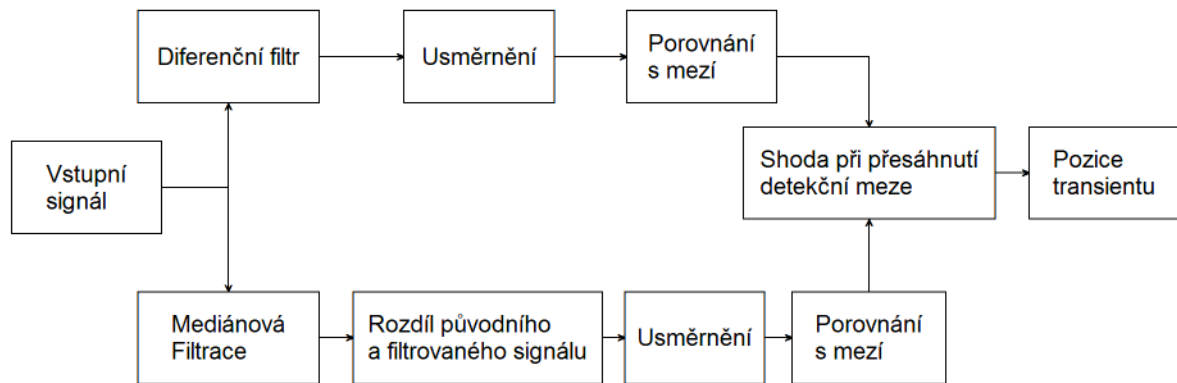
Kombinovaný detektor vychází z předešlých dvou metod. Jedná se o matematický průnik výsledků detekce jednoduchého aritmetického detektoru a detektoru využívajícího mediánovou filtraci. Detektor tak označí pozici transientu, pokud se obě metody shodnou na základě na sobě nezávislých detekcí. Tato metoda spojuje obě předešlé metody a kompenzuje do jisté míry jejich nedostatky. Metoda je výpočetně náročnější tím, že do algoritmu zavádíme operace pro dva detekční signály [1]. Grafické znázornění principu kombinovaného detektoru můžeme demonstrovat na následujícím Obrázku 2.7:



Obrázek 2.8: Ukázka detekčních signálů pro kombinovaný detektor. Signál pochází z reálného EEG záznamu.

Vzhledem k rozdílnosti detekčních signálů u kombinovaného detektoru na obrázku 2.7 jsem se rozhodl ponechat pouze porovnání s pevnou hodnotou meze. Výsledný výpočet kvantilu by pak byl rozdílný pro oba signály a hůře by se tak hledala shoda v detekovaných hrotech.

Návrh kombinovaného detektoru jsem realizoval podle schématu na následujícím obrázku:



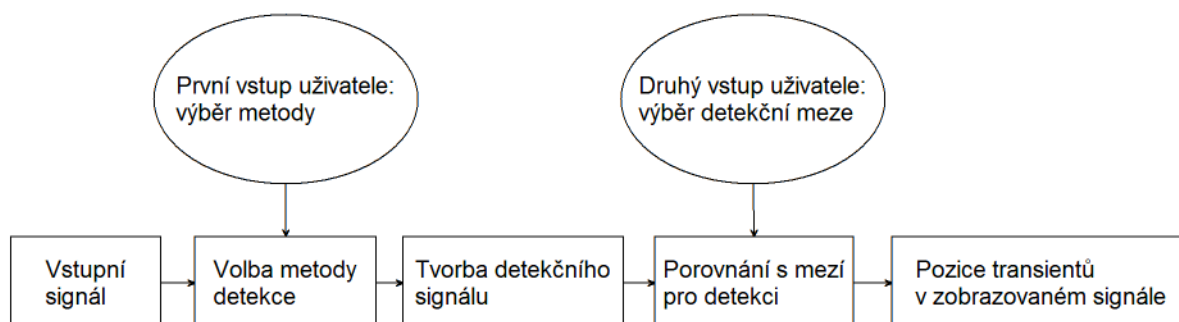
Obrázek 2.9: Zjednodušené blokové schéma kombinovaného detektoru.

## 2.4 Implementace do prohlížeče EEG signálů

Další součástí mé práce byla implementace modulu pro automatickou detekci do již vytvořeného prohlížeče EEG signálů, který byl vytvořen v rámci týmového projektu. Program byl napsán v programové prostředí MATLAB pomocí objektově orientovaného programování. Objektové programování v MATLABu umožňuje lepší práci s velkými objemy dat.

Modul automatické detekce je napsán jako třída `SpikeDetector_MedArit`, která přímo navazuje na hlavní třídu pro ostatní metody detekce programu `SpikeDetector`. Z hlavní třídy `SpikeDetector` pak třída `SpikeDetector_MedArit` dostane vstupní signál, který dále zpracovává a pomocí výše popsaných algoritmů v nich hledá epileptické hroty. Po označení jednotlivých detekcí pak vrací zpátky do hlavní třídy přesné pozice jednotlivých detekcí pomocí funkce `spikeIndices`. Následně proběhne přepočítání montáží v hlavním prohlížeči a v signálu se objeví hroty vyznačené šipkami. Detektor je primárně nastaven jako zapnutý, takže při načtení signálu dochází ihned k detekci. Vzhledem k výpočetní náročnosti se detekce provádí vždy na zobrazovaném okně.

V prohlížeči EEG signálů je modul graficky reprezentován jako uživatelské rozhraní, ve kterém si uživatel může vybrat metodu detekce a následně její parametry. U detekce pomocí mediánové filtrace je navíc i možnost volby řádu mediánového filtru. U mediánového filtru je řád primárně nastaven na hodnotu 20 z důvodu kvality filtrovaného signálu a optimalizace výpočetní náročnosti. Dále u nastavení meze pro porovnání s detekčním signálem je primárně zvolena možnost porovnání s pevnou hodnotou, kvůli výpočetní náročnosti při nahrávání signálu.



Obrázek 2.10: Zjednodušené blokové schéma vytvořeného poloautomatického modulu, kde je znázorněn vstup uživatele (experta) do systému.

Na obrázku 2.9 můžeme vidět základní blokové schéma vytvořeného modulu. Modul můžeme rozdělit na část, která pracuje nezávisle na uživateli a na část, kterou uživatel ovládá vstupními parametry. Část, která pracuje nezávisle na uživateli, tvoří výpočetní jádro detekčních metod. Zde se aplikují výše popsané metody podle výběru uživatele. Část, kterou ovládá uživatel, se skládá ze dvou uživatelských vstupů. Prvním vstupem je výběr detekční metody, kde má uživatel na výběr ze tří možností. Po zvolení metody následuje druhý vstup, kde uživatel zvolí způsob určení meze pro detekci a zadá příslušné parametry. Hodnota pevné meze pro porovnání se zadává v  $\mu\text{V}$  a je následně umocněna, aby se dala porovnat s již umocněným detekčním signálem. Nakonec se vše potvrdí tlačítkem a signál se podle zvolené metody podrobí detekci. Pokud uživatel nezvolí metodu a nezadá příslušné parametry, tak je modul primárně nastaven na detekci pomocí mediánové filtrace s pevnou hodnotou meze. Dodatečně ještě může uživatel zadat řád mediánového filtru.

## 2.5 Metodika hodnocení jednotlivých detektorů

Pro vyhodnocení navržených detektorů v rámci práce jsem využil ROC analýzu. Protože se v mé práci jedná o binární klasifikátory, je ROC analýza vhodným prostředkem pro statistické vyhodnocení navržených detektorů. Pomocí této analýzy se určuje přesnost zařazení elementů do následujících skupin. První skupina je správně pozitivní (TP – true positive), do které patří správně pozitivní detekce. Další skupina je správně negativní (TN – true negative), do které patří elementy, které byly detektorem správně vyhodnoceny jako negativní nález. Další neméně důležitou skupinu tvoří skupina falešně pozitivní (FP – false positive). Do této skupiny spadají detekce, které nesprávně detekují epileptické hroty tam, kde žádné nejsou. Poslední



skupinou je skupina falešně negativních (FN – false negative), do které patří nedetekované epileptické hroty. [2]

Na základě těchto skupin můžeme vyjádřit základní statické parametry jednotlivých detektorů pomocí senzitivity a specifity. Senzitivita zde vyjadřuje míru, se kterou detektor správně detekuje epileptický hrot v signálu. Senzitivita nebo také citlivost nabývá hodnot v intervalu od 0 do 1 včetně, popřípadě 0 až 100 %. Matematicky se dá popsat následující rovnicí. [2]

$$\text{senzitivita} = \frac{TP}{TP + FN} \quad (2.10)$$

kde  $TP$  je počet správných detekcí a  $FN$  je počet nezachycených epileptických hrotů.

Další důležitá vlastnost detektoru je specificita. Vyjadřuje, jak moc dokáže detektor správně vyhodnotit nálezy jako negativní. Nabývá hodnot v intervalu od 0 do 1 včetně, popřípadě 0 až 100 %. Matematicky lze vyjádřit podle následující rovnice. [2]

$$\text{specificita} = \frac{TN}{TN + FP} \quad (2.11)$$

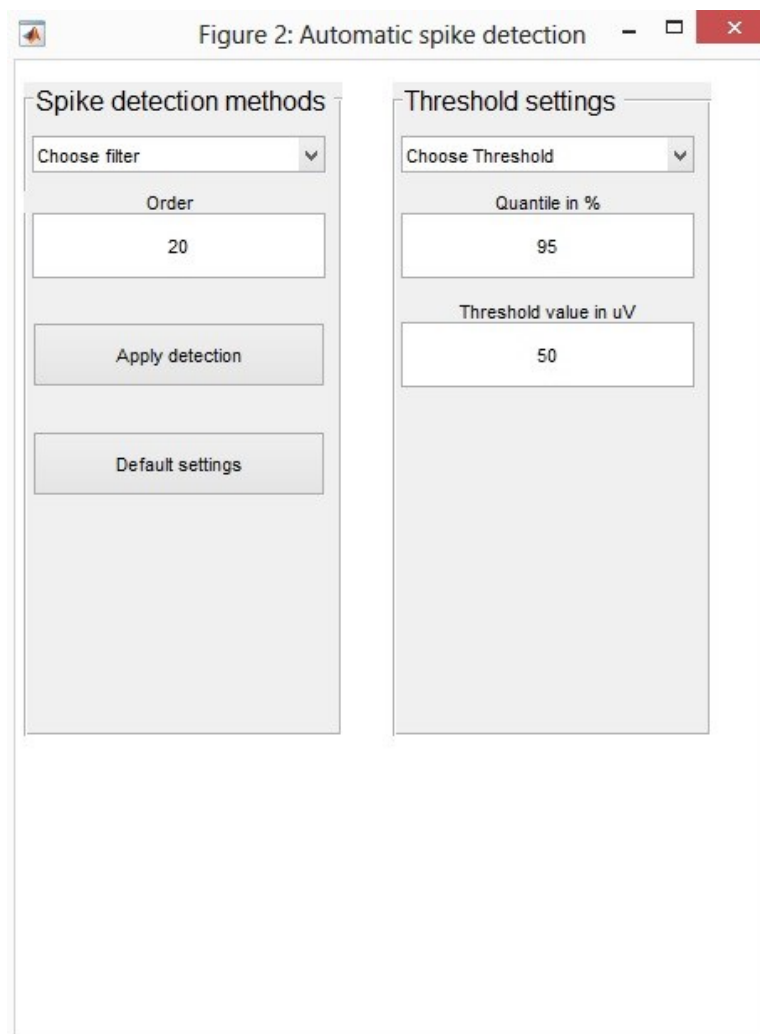
kde  $TN$  je počet elementů správně vyhodnocených jako negativní a  $FP$  je počet nesprávných detekcí, kde se nejednalo o epileptický hrot.

### 3 Výsledky

Následující kapitola je věnována výsledkům práce. Je rozdělena na část, kde prezentují vytvořený modul a jeho detekční schopnosti na simulovaném i reálném signálu a část, která se věnuje statistickému vyhodnocení jednotlivých detektorů.

#### 3.1 Grafické uživatelské rozhraní modulu

Modul pro automatickou detekci epileptických grafoelementů je uživatelsky přístupná část celého programu pro prohlížení EEG záznamů.




Obrázek 3.1: Grafické uživatelské rozhraní modulu

Na Obrázku 3.1 můžeme vidět modul vytvořený pro automatickou detekci epileptických hrotů. Uživatel má k dispozici řadu parametrů, které může nastavit. Prvním parametrem je volba detekční metody, kde uživatel zvolí metodu, podle které bude následně signál zkoumán. Na výběr má uživatel ze tří realizovaných metod tedy detekce pomocí mediánové filtrace, jednoduchý aritmetický detektor a kombinovaný detektor. Jako poslední možnost je zde

ukončení detekce, po které lze program využít pouze jako prohlížeč EEG signálů. Dále uživatel může v sekci pro nastavení detekční meze nastavit způsob volby meze. Na výběr jsou zde dvě možnosti. První možnost je zadání pevné hodnoty a druhá možnost je určení mezní hodnoty pomocí výpočtu kvantilu. U volby pevné hodnoty zadává uživatel požadovanou hodnotu v příslušném poli a u volby výpočtu kvantilu uživatel zadává požadovaný kvantil v procentech. Po zvolení parametrů se vše potvrdí tlačítkem „*Apply detection*“. Pro vrácení původního nastavení zde slouží tlačítko „*Default settings*“. Po nahrání libovolného záznamu je detektor primárně nastaven na detekci pomocí mediánové filtrace s pevnou hodnotou detekční meze.

### 3.2 Vyznačení hrotů v záznamu

Vyznačení jednotlivých detekovaných hrotů v zobrazovaném záznamu zde reprezentují černé šipky, které ukazují přesnou pozici transientu.




Obrázek 3.2: Označené transienty v reálném EEG záznamu v již hotovém prohlížeči EEG záznamů.

Na Obrázku 3.2 můžeme vidět vyznačené potenciální hroty v reálném záznamu. Hroty jsou vyznačené pomocí černých šipek, které ukazují přesnou polohu detekovaného hrotu. Detekce hrotů začíná ihned po nahrání záznamu, kdy je modul nastaven na své primární nastavení. Uživatelské rozhraní modulu se pak v hlavním programu vyvolá kliknutím na horní lištu prohlížeče na kartu „*process*“ a potvrdí tlačítkem „*Median Arit detection*“.

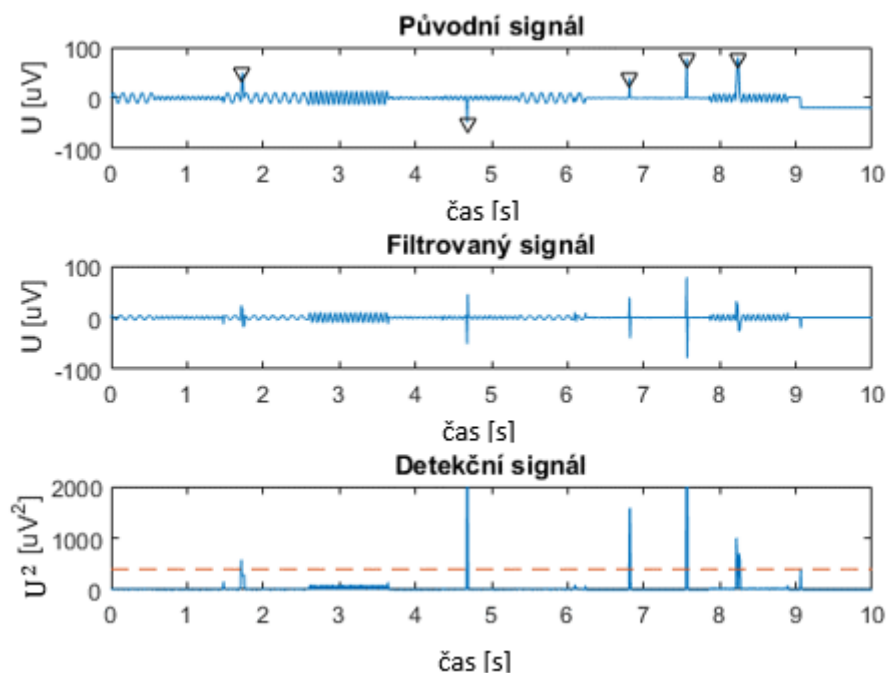
### 3.3 Aplikace detektorů na uměle vytvořené signály

V následující podkapitole jsou zobrazeny výsledky detekcí jednotlivých detektorů na synteticky vytvořených signálech.

#### 3.3.1. Signál sinus, hroty a obdélníky

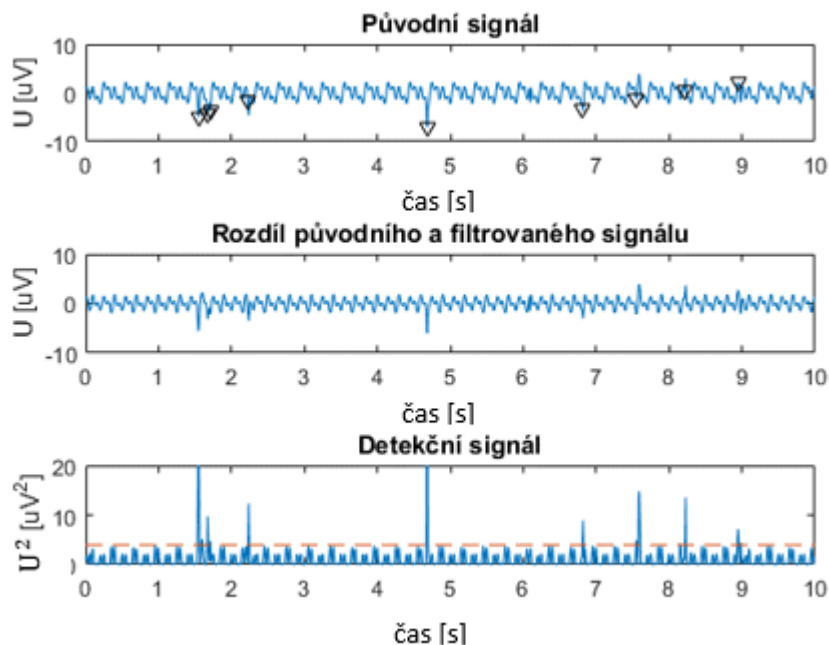


Obrázek 3.3: Ukázka detekce pomocí mediánové filtrace na simulovaném signálu složeném z kombinace sinusovky, hrotů a obdélníky. Detekční mez je nastavena na  $900 \mu V^2$ .

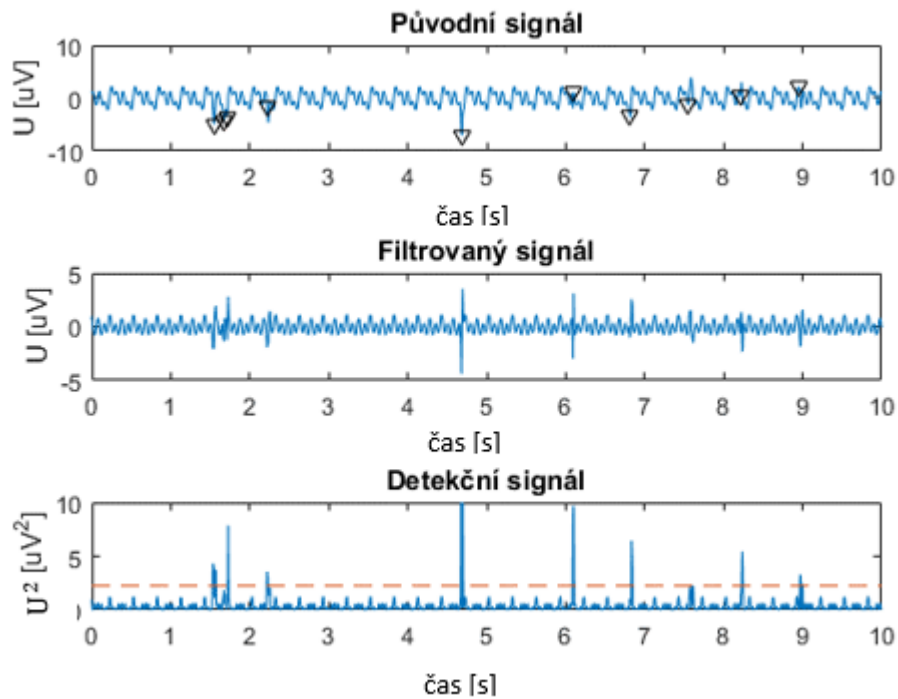


Obrázek 3.4: Ukázka detekce pomocí jednoduchého aritmetického detektoru na simulovaném signálu složeném z kombinace sinusovky, hrotů a obdélníků. Detekční mez je nastavena na  $400 \mu V^2$ .

### 3.3.2. Signál dle Mukhopadhyaye

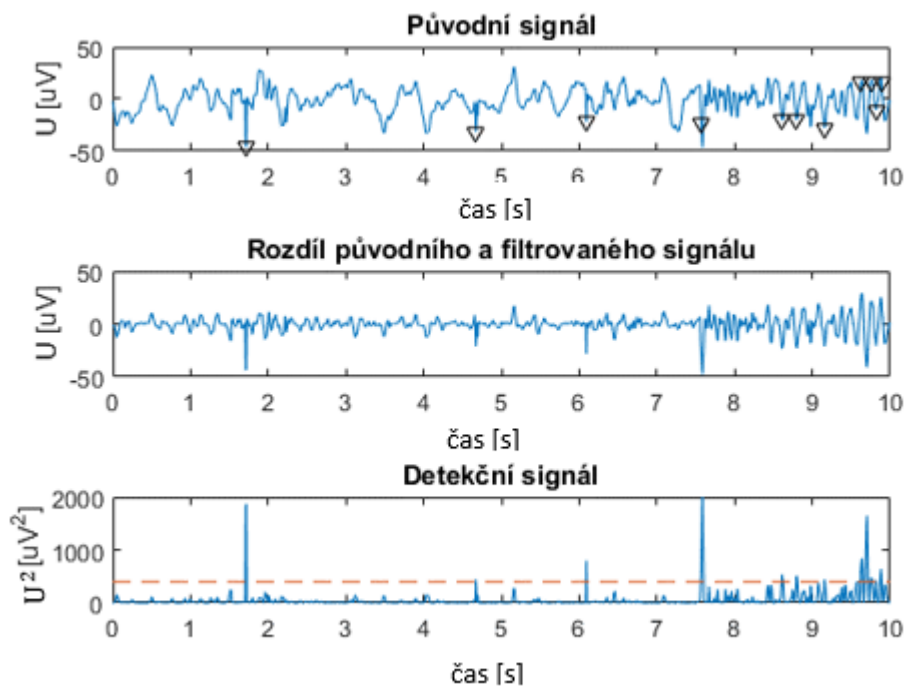


Obrázek 3.5: Ukázka detekce pomocí mediánové filtrace na simulovaném signálu dle Mukhopadhyaye. Detekční mez je nastavena na  $4 \mu V^2$ .

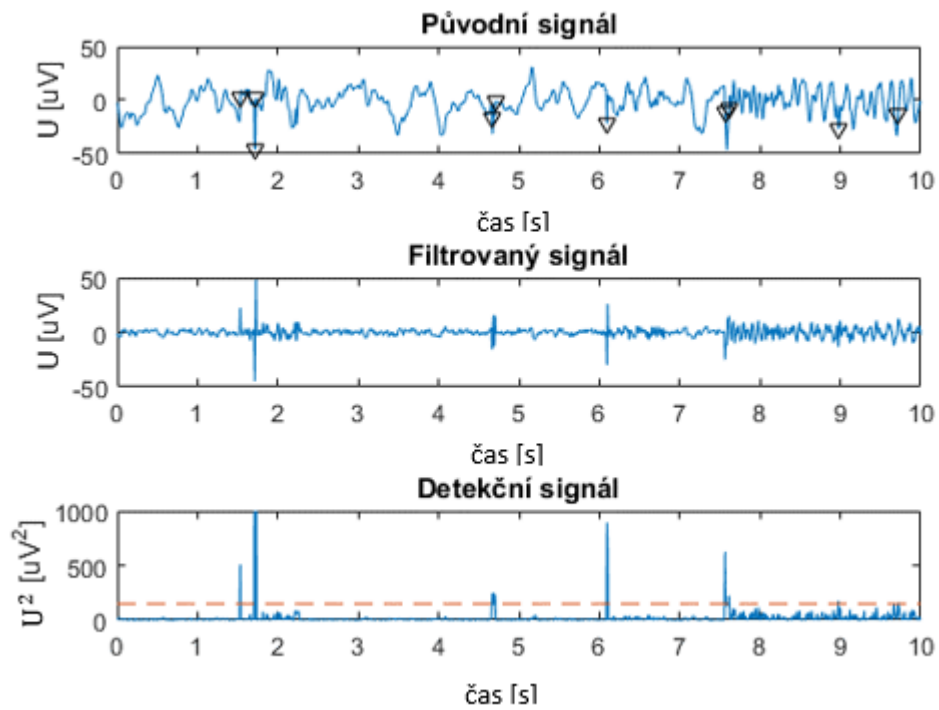


Obrázek 3.6: Ukázka detekce pomocí jednoduchého aritmetického detektoru na simulovaném signálu dle Mukhopadhyaye. Detekční mez je nastavena na  $2,25 \mu V^2$ .

### 3.3.3. Signál AR complex



Obrázek 3.7: Ukázka detekce pomocí mediánové filtrace na simulovaném signálu AR complex. Detekční mez je nastavena na  $400 \mu V^2$ .

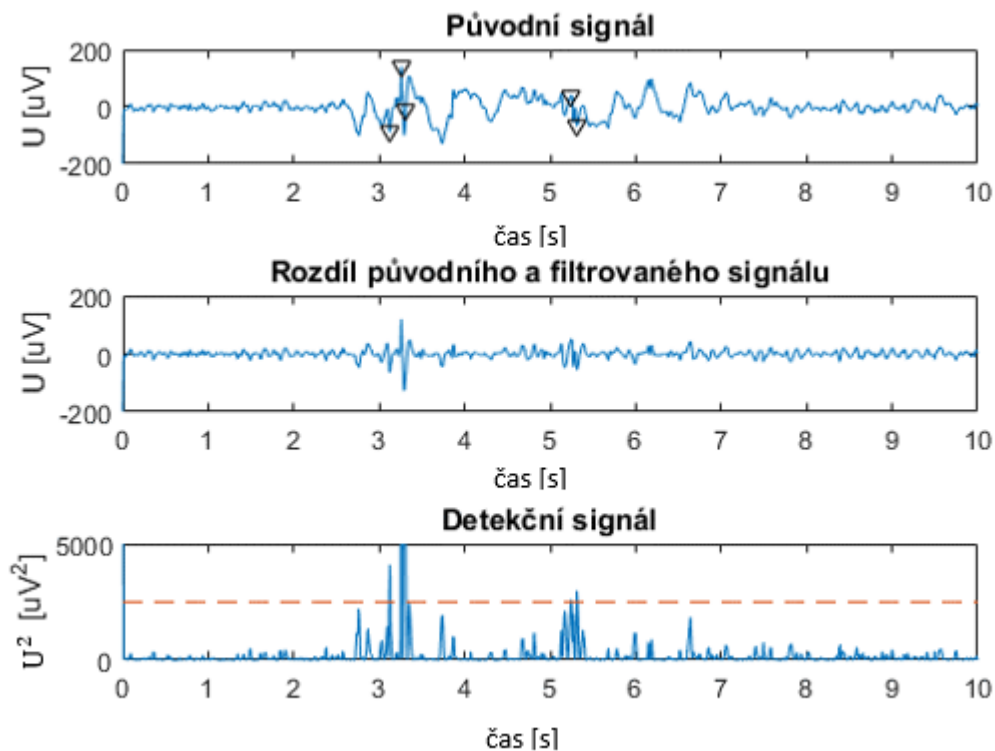


Obrázek 3.8: Ukázka detekce pomocí jednoduchého aritmetického detektoru na simulovaném signálu AR complex. Detekční mez je nastavena na  $150 \mu\text{V}^2$ .

### 3.4 Aplikace detektorů na reálné EEG záznamy


V následující podkapitole jsou zobrazeny výsledky detekcí jednotlivých detektorů na reálných EEG záznamech.

#### 3.4.1. Detekce epileptických hrotů

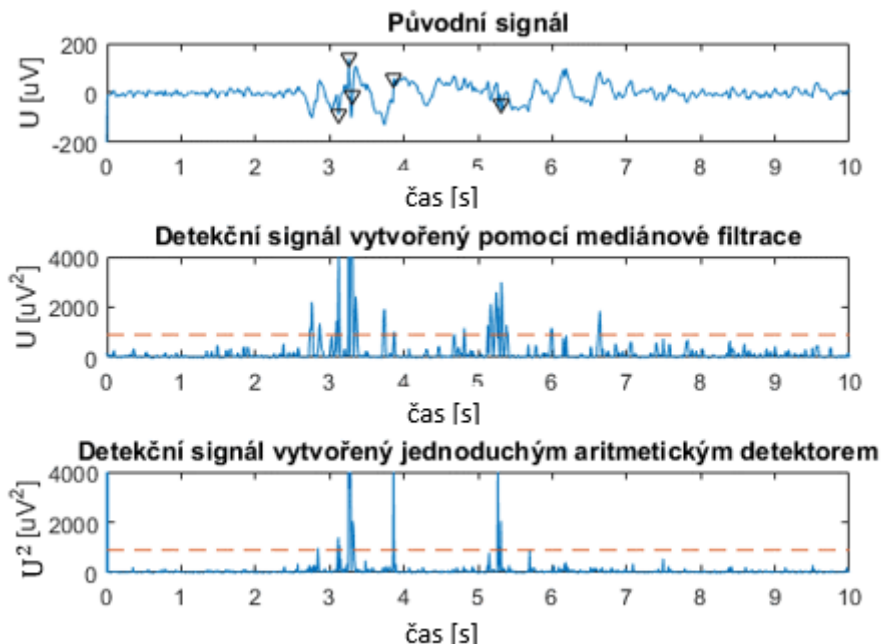


Obrázek 3.9: Ukázka detekce epileptických hrotů pomocí mediánové filtrace v reálném EEG záznamu s epileptickými grafoelementy. Detekční mez je nastavena na  $2500 \mu V^2$ .







Obrázek 3.10: Ukázka detekce epileptických hrotů pomocí jednoduchého aritmetického detektoru v reálném EEG záznamu s epileptickými grafoelementy. Detekční mez je nastavena na  $900 \mu V^2$ .




Obrázek 3.11: Ukázka detekce epileptických hrotů pomocí kombinovaného detektoru v reálném EEG záznamu s epileptickými grafoelementy. Tranzient je v původním signále vyznačen jako epileptický, když dojde ke shodě v obou detekčních signálech. Společná detekční mez je nastavena na  $900 \mu V^2$ .



Obrázek 3.12: Ukázka detekce epileptických hrotů pomocí mediánové filtrace v reálném EEG záznamu s epileptickými grafoelementy (komplex hrot-vlna). Detekční mez je nastavena na  $3025 \mu V^2$ .




Obrázek 3.13: Ukázka detekce epileptických hrotů pomocí aritmetického detektoru v reálném EEG záznamu s epileptickými grafoelementy (komplex hrot-vlna). Detekční mez je nastavena na  $1600 \mu V^2$ .




Obrázek 3.14: Ukázka detekce epileptických hrotů pomocí kombinovaného detektoru v reálném EEG záznamu s epileptickými grafoelementy (komplex hrot-vlna). Společná detekční mez je nastavena na  $1600 \mu\text{V}^2$ .


### 3.4.2 Reakce detektorů na jednotlivé artefakty




Obrázek 3.15: Ukázka reakce detektoru, který využívá mediánovou filtraci, na amplitudový artefakt. Detekční mez je nastavena na  $2500 \mu\text{V}^2$ .




Obrázek 3.16: Ukázka reakce jednoduchého aritmetického detektoru na amplitudový artefakt. Detekční mez je nastavena na  $2500 \mu\text{V}^2$ .



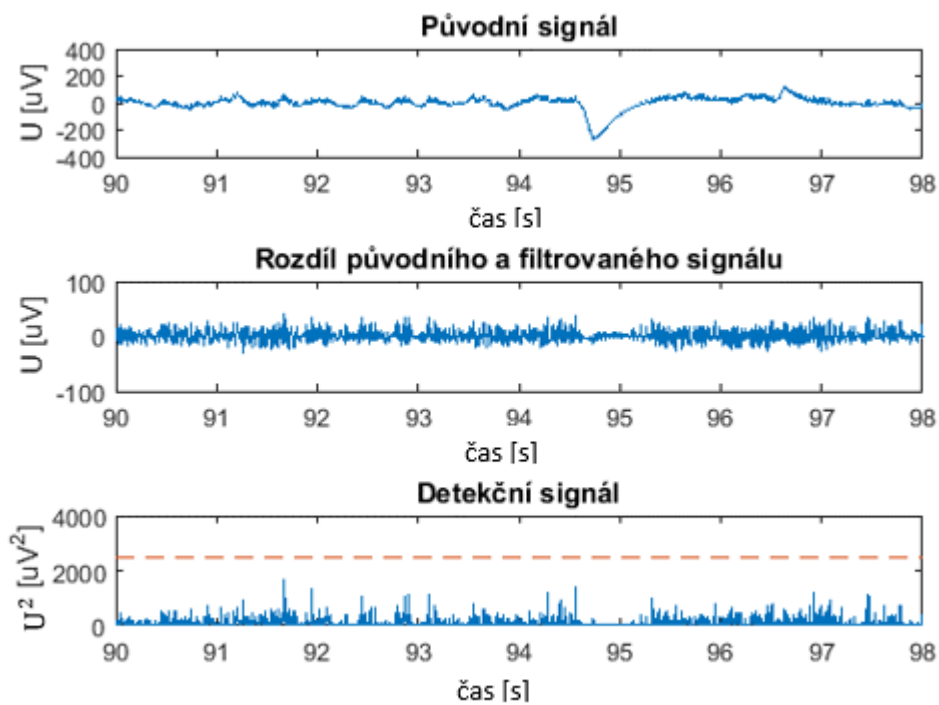
Obrázek 3.17: Ukázka reakce detektoru, který využívá mediánovou filtraci, na EMG artefakt. Detekční mez je nastavena na  $2500 \mu V^2$ .




Obrázek 3.18: Ukázka reakce jednoduchého aritmetického detektoru na EMG artefakt. Detekční mez je nastavena na  $2500 \mu V^2$ .



Obrázek 3.19: Ukázka reakce kombinovaného detektoru na EMG artefakt. Společná detekční mez je nastavena na  $2500 \mu V^2$ .



Obrázek 3.20: Ukázka reakce detektoru, který využívá mediánovou filtraci, na artefakt způsobený pohybem očí. Detekční mez je nastavena na  $2500 \mu V^2$ .



Obrázek 3.21: Ukázka reakce jednoduchého aritmetického detektoru na artefakt způsobený pohybem očí. Detekční mez je nastavena na  $2500 \mu V^2$ .

### 3.5 Statistické vyhodnocení detektorů

Následující podkapitola se věnuje statistickému vyhodnocení jednotlivých detektorů. Detektory byly nejprve testovány na syntetických signálech a poté i na reálných záznamech EEG s transieny.

#### 3.5.1 Syntetické signály

Testování proběhlo na třech simulovaných signálech. Správně označený hrot se nalézá v intervalu  $\pm 0,1$  sekundy v okolí pozice synteticky vytvořeného hrotu.

Tabulka 1: Nejlepší dosažitelná senzitivita a specificita jednotlivých detektorů pro signál sinus, hroty a obdélníky při nastavené hodnotě detekční meze.

Detektor	Senzitivita [-]	Specificita [-]	Detekční mez [ $\mu V^2$ ]
Mediánový detektor	1,00	0,87	200
Jednoduchý arit. detektor	0,87	0,95	100
Kombinovaný detektor	1,00	0,77	50

Tabulka 2: Nejlepší dosažitelná senzitivita a specificita jednotlivých detektorů pro signál dle Mukhopadhyaye při nastavené hodnotě detekční meze.

Detektor	Senzitivita [-]	Specificita [-]	Detekční mez [ $\mu V^2$ ]
Mediánový detektor	0,90	1,00	4
Jednoduchý arit. detektor	0,79	1,00	2
Kombinovaný detektor	0,92	1,00	1

Tabulka 3: Nejlepší dosažitelná senzitivita a specificita jednotlivých detektorů pro signál AR complex při nastavené hodnotě detekční meze.

Detektor	Senzitivita [-]	Specificita [-]	Detekční mez [ $\mu V^2$ ]
Mediánový detektor	0,92	0,45	200
Jednoduchý arit. detektor	0,90	0,68	100
Kombinovaný detektor	0,94	0,46	50



### 3.5.2 Reálné EEG záznamy

Celkem bylo označeno 879 hrotů ve třech reálných EEG záznamech (každý o délce deset minut). Správně označený epileptický hrot se nalézá v intervalu  $\pm 0,1$  sekundy v okolí skutečného označeného epileptického hrotu. Skutečně označené epileptické hroty byly označeny podle definice a po konzultaci s odborníkem.

Tabulka 4: Reálné EEG záznamy

Záznam	Počet označených hrotů	Délka [s]	Počet kanálů
Pacient A	491	600	14
Pacient B	199	600	16
Pacient C	189	120	5

Tabulka 5: Nejlepší dosažitelná senzitivita a specifická jednotlivých detektorů pro záznam A při nastavené hodnotě detekční meze.

Detektor	Senzitivita [-]	Specifická [-]	Detekční mez [ $\mu V^2$ ]
Mediánový detektor	0,73	0,98	2000
Jednoduchý arit. detektor	0,86	0,94	250
Kombinovaný detektor	0,85	0,95	250

Tabulka 6: Nejlepší dosažitelná senzitivita a specifická jednotlivých detektorů pro záznam B při nastavené hodnotě detekční meze.

Detektor	Senzitivita [-]	Specifická [-]	Detekční mez [ $\mu V^2$ ]
Mediánový detektor	0,78	0,94	2500
Jednoduchý arit. detektor	0,80	0,97	500
Kombinovaný detektor	0,81	0,94	250

Tabulka 7: Nejlepší dosažitelná senzitivita a specifická jednotlivých detektorů pro záznam C při nastavené hodnotě detekční meze.

Detektor	Senzitivita [-]	Specifická [-]	Detekční mez [ $\mu V^2$ ]
Mediánový detektor	0,57	0,87	2000
Jednoduchý arit. detektor	0,80	0,97	1000
Kombinovaný detektor	0,81	0,98	1000

## 4 Diskuze

V úvodu práce bylo potřeba zvolit optimální algoritmy pro realizaci detektorů. Při realizaci detektoru, který využívá filtraci pomocí mediánu, bylo klíčové optimalizovat výpočetní jádro detektoru, aby výpočet a následná detekce mohly probíhat v reálném čase při zobrazovaném okně. Původně bylo zamýšleno zvolit již vymyšlený algoritmus podle článku [21], který využívá k filtraci hybridní mediánový filtr s FIR podstrukturami. Výpočetně efektivnější ve vývojovém prostředí MATLAB se ukázalo využití komponenty MATLABu `signal processing toolbox`, který nabízí již vytvořenou funkci mediánové filtrace. V případě, že by se použité algoritmy realizovaly v jiném vývojovém prostředí než v MATLABu, tak by bylo vhodné využít hybridní mediánový filtr.

U jednoduchého aritmetického detektoru se používá ve většině případů pro zvýraznění hrotů umocnění detekčního signálu. Umocnění se realizuje vynásobením konkrétního prvku signálu prvkem, který je hned za ním. V mé práci jsem využil vynásobením konkrétního prvku prvkem stejným, jak je popsáno v druhé kapitole. Detekční signál byl po této změně lépe použitelný k samotné detekci, protože signál nebyl zpožděný.

Reakce detektorů na různé artefakty proběhla podle očekávání vzhledem metodickým nedostatkům detektorů a charakteru artefaktů. Detektor, který využívá mediánovou filtraci, detekoval EMG aktivitu (Obrázek 3.11). Na stejný artefakt reagoval i aritmetický detektor (Obrázek 3.12). Ačkoliv v případě EMG artefaktu reagovaly oba detektory falešně pozitivně, ve výsledné detekci shoda mezi detektory nenastala, a tak se nabízí možnost použití kombinovaného detektoru. V tomto případě je tedy kombinovaný detektor efektivní, protože potlačuje nedostatky mediánového i aritmetického detektoru. Aritmetický detektor je citlivější na skokové změny v amplitudě signálu, nicméně tento artefakt detekován nebyl. Reakce na artefakt způsobený pohybem očí byla v obou případech detektorů správně negativní.

U volby detekční meze pro porovnání jsem nakonec zvolil volbu ze dvou možností. První možností je pevná hodnota napětí v mikrovoltech, která je následně umocněna pro porovnání s detekčním signálem. Druhou možností je automaticky vypočítaná hodnota libovolného kvantilu v jednotlivém kanálu. Tato hodnota je závislá na délce zobrazovaného signálu, protože se hodnota počítá z délky zobrazovaného okna. Při aplikaci této možnosti je nutné dbát na délku zobrazovaného okna. V případě že by se zobrazil celý signál, mez by se pak počítala jako kvantil celého signálu v příslušném kanálu a tím by mohl tento výpočet do detekce vnášet nepřesnosti. V rámci další práce by bylo možné nastavit zobrazované okno pomocí parametru, který by uživatel (expert) zvolil. Pro kombinovaný detektor existuje pouze jediná varianta detekční meze a tím je pevná hodnota napětí. Vzhledem k rozdílnosti detekčních signálů obou detektorů by totiž nemohlo dojít ke shodě.

Kvalitativním hodnocením detektorů pomocí ROC analýzy se ukázalo, že detektory fungují na simulovaných signálech s větší senzitivitou (až 1,0) než na reálných EEG záznamech (maximálně 0,86). V simulovaných signálech mají hroty jasně definované vlastnosti a jsou lépe detekovatelné. V reálných EEG záznamech fungují detektory s pozoruhodnou specificitou (v záznamech A a B více než 0,9). Hodnota specifity je spojena s falešně pozitivní detekcí převážně artefaktů v signálu. Mediánový detektor se ukázal jako velmi citlivý na různé artefakty zejména na artefakty, které jsou způsobené svalovou aktivitou. Aritmetický detektor podle výsledků ROC analýzy pracoval s vyšší senzitivitou. Nejvyšších hodnot senzitivity a specificity dosahoval podle očekávání detektor kombinovaný, který svým principem využívá výhody aritmetického a mediánového detektoru. Kombinovaný detektor tak svojí senzitivitou a specificitou dokáže konkurovat i složitějším detektorům, které jsou založeny na neuronové síti (viz článek [2]). Pro přesnější analýzu navržených detektorů by do budoucna bylo vhodné otestovat jednotlivé detektory na více reálných EEG záznamech. Kvalitativní hodnocení neobsahuje variantu kvantilu jako meze pro porovnání vzhledem k problematice určení délky zobrazovaného okna. Další zkoumání a testování dynamicky počítané meze pomocí kvantilu by mohlo být předmětem další práce.

V rámci této bakalářské práce jsem upravil novou verzi prohlížeče EEG záznamů. Nynější verze vychází z verze programu, která byla vytvořena v rámci předmětu Týmový projekt ve spolupráci s kolegou M. Jílkem. Úspěšnou implementací modulu, který v sobě zahrnuje výše uvedené detekční metody, se potvrdila modulárnost celého programu. V budoucnu by tedy do programu bylo možné vkládat další moduly pro detekci epileptických hrotů. Celý program a vytvořený modul je napsán v objektově orientovaném jazyce MATLAB. Kombinovaný

detektor by mohl do budoucna sloužit jako první předzpracování signálu nebo první extrakce příznaků například pro neuronové sítě či jiné klasifikátory EEG signálu. V klinické praxi by realizované metody mohly sloužit jako pomocný nástroj odborníka.

## 5 Závěr

Byl vytvořen syntetický signál s hroty dle zadání (špička, obdélník a sinus 15 Hz), který byl následně zpracován pomocí mediánové filtrace a jednoduchého aritmetického detektoru. Totéž bylo provedeno pro reálné EEG záznamy s transieny. Detekované epileptické hroty byly označeny v EEG záznamu. V rámci práce bylo vytvořeno uživatelské rozhraní, které je součástí programu pro prohlížení EEG záznamů. Uživatelské rozhraní dovoluje uživateli nastavit a zvolit metody pro automatickou detekci epileptických grafoelementů. K práci je v příloze přiložena uživatelská dokumentace k vytvořenému programu. Nad rámec zadání byl vytvořen kombinovaný detektor. Dále byla vytvořena nová verze prohlížeče EEG záznamů, která v této práci umožňuje detekci pomocí kombinovaného, mediánového a aritmetického detektoru. Každý realizovaný detektor prošel pilotní zkouškou na třech simulovaných a třech reálných EEG záznamech (dohromady 2,8 miliony vzorků). Jednotlivé detektory byly statisticky ohodnoceny k určení jejich efektivity v závislosti na nastavení hodnoty meze a ve výsledku bylo vybráno nastavení s nejvyšší hodnotou senzitivity. Nejvhodnějším detektorem pro reálné EEG záznamy se ukázal podle statistických výsledků detektor kombinovaný. Modul a jeho metody automatické detekce mohou sloužit jako nástroj experta při analýze EEG záznamu nebo jako předzpracování signálu pro další analýzu. Předmětem další práce by mohlo být zdokonalení jednotlivých algoritmů z hlediska výpočetní náročnosti a další zkoumání a testování dynamicky počítané meze pomocí libovolného kvantilu.

## Literatura

- [1] KRAJČA, Vladimír., MOHYLOVÁ, Jitka., Číslicové zpracování neurofyziologických signálů, ed. 1. ČVUT Praha, 2011, 167 s., ISBN 978-80-01-04721-7
- [2] 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. 2017-04-24]. DOI: 10.1109/TBME.2003.809479. ISSN 0018-9294.  
Dostupné z: <http://ieeexplore.ieee.org/document/1193787/>
- [3] 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]. **35**(1), 11-18 [cit. 2017-04-24]. DOI: 10.1109/10.1331. ISSN 00189294. Dostupné z: <http://ieeexplore.ieee.org/document/1331/>
- [4] FABER, Josef. *Elektroencefalografie a psychofyziologie*. Praha: ISV, 2001. Lékařství. ISBN 80-85866-74-9.
- [5] AMBLER, Zdeněk. *Základy neurologie: [učebnice pro lékařské fakulty]*. 7. vyd. Praha: Galén, c2011. ISBN 978-80-7262-707-3.
- [6] NIEMINEN, A.; NEUVO, Y. Digital signal processing: proceedings of the international conference, Florence, Italy, 7-10 September, 1987. ed. / V. Cappellini; A.G. Constantinides. Florence, 1987. p. 559-563.
- [7] KENEMANS, J. Leon, Peter C.M. MOLENAAR, Marinus N. VERBATEN a Jef L. SLANGEN. Removal of the Ocular Artifact from the EEG: A Comparison of Time and Frequency Domain Methods with Simulated and Real Data. *Psychophysiology* [online]. 1991, **28**(1), 114-121 [cit. 2017-04-30]. DOI: 10.1111/j.1469-8986.1991.tb03397.x. ISSN 0048-5772.  
Dostupné z: <http://onlinelibrary.wiley.com/doi/10.1111/j.1469-8986.1991.tb03397.x/full>
- [8] ALOTAIBY, Turky, Fathi E Abd EL-SAMIE, Saleh A ALSHEBEILI a Ishtiaq AHMAD. A review of channel selection algorithms for EEG signal processing. *EURASIP Journal on Advances in Signal Processing* [online]. 2015, (1), - [cit. 2017-04-30]. DOI: 10.1186/s13634-015-0251-9. ISSN 1687-6180.  
Dostupné z: <http://asp.eurasipjournals.com/content/2015/1/66>
- [9] FROST J.D. Jr. Automatic recognition and characterization of epilepticform discharges in the human EEG. *Journal of Clinical Neurophysiology*. 1985;**2**(3):231-249

- [10] ANKAR, R. a J. NATOUR. Automatic computer analysis of transients in EEG. *Computers in Biology and Medicine* [online]. 1992, **22**(6), 407-422 [cit. 2017-05-01]. DOI: 10.1016/0010-4825(92)90040-T. ISSN 00104825.  
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/001048259290040T>
- [11] ISLAM, M.D. Kafiul, Amir RASTEGARNIA a Zhi YANG. A Wavelet-Based Artifact Reduction From Scalp EEG for Epileptic Seizure Detection. *IEEE Journal of Biomedical and Health Informatics* [online]. 2016, **20**(5), 1321-1332 [cit. 2017-05-02]. DOI: 10.1109/JBHI.2015.2457093. ISSN 2168-2194.  
Dostupné z: <http://ieeexplore.ieee.org/document/7158988/>
- [12] SANKAR, R. a J. NATOUR. Automatic computer analysis of transients in EEG. *Computers in Biology and Medicine* [online]. 1992, **22**(6), 407-422 [cit. 2017-05-02]. DOI: 10.1016/0010-4825(92)90040-T. ISSN 00104825.  
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/001048259290040T>
- [13] Guo, L., Rivero, D., Dorado, J., Rabunal, J.R. and Pazos, A. Automatic Epileptic Seizure Detection in EEG Based on Line Length Feature and Artificial Neural Network. *Journal of Neuroscience Methods*, 2010 191, 101-109.  
Dostupné z: <https://doi.org/10.1016/j.jneumeth.2010.05.020>
- [14] LI, Mingyang, Wanzhong CHEN a Tao ZHANG. Automatic epileptic EEG detection using DT-CWT-based non-linear features. *Biomedical Signal Processing and Control* [online]. 2017, **34**, 114-125 [cit. 2017-05-02]. DOI: 10.1016/j.bspc.2017.01.010. ISSN 17468094.  
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1746809417300186>
- [15] ACHARYA, U. Rajendra, S. VINITHA SREE, G. SWAPNA, Roshan Joy MARTIS a Jasjit S. SURI. Automated EEG analysis of epilepsy: A review. *Knowledge-Based Systems* [online]. 2013, **45**, 147-165 [cit. 2017-05-02]. DOI: 10.1016/j.knosys.2013.02.014. ISSN 09507051.  
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0950705113000798>
- [16] POLAT, Kemal a Salih GÜNEŞ. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform. *Applied Mathematics and Computation* [online]. 2007, **187**(2), 1017-1026 [cit. 2017-05-02]. DOI: 10.1016/j.amc.2006.09.022. ISSN 00963003.  
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0096300306012380>

- [17] NIGAM, Vivek Prakash a Daniel GRAUPE. A neural-network-based detection of epilepsy. *Neurological Research* [online]. 2013, **26**(1), 55-60 [cit. 2017-05-03]. DOI: 10.1179/016164104773026534. ISSN 0161-6412.  
Dostupné z: <http://www.tandfonline.com/doi/full/10.1179/016164104773026534>
- [18] JÍLEK, Martin. Využití hlavních komponent pro automatickou detekci EEG tranzientů. Praha, 2016. Bakalářská práce (Bc.), České vysoké učení technické, Fakulta biomedicínského inženýrství, Katedra biomedicínské techniky, Vedoucí práce doc. Ing. Vladimír Krajča CSc.
- [19] GUO, Ling, Daniel RIVERO, Julián DORADO, Juan R. RABUÑAL a Alejandro PAZOS. Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks. *Journal of Neuroscience Methods* [online]. 2010, **191**(1), 101-109 [cit. 2017-05-03]. DOI: 10.1016/j.jneumeth.2010.05.020. ISSN 01650270.  
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0165027010002803>
- [20] GOTMAN, J. Automatic recognition of epileptic seizures in the EEG. *Electroencephalography and Clinical Neurophysiology* [online]. 1982, **54**(5), 530-540 [cit. 2017-05-03]. DOI: 10.1016/0013-4694(82)90038-4. ISSN 00134694.  
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0013469482900384>
- [21] Wichman R, Astola J, Heinonen P, Neuvo Y: FIR-median hybrid filters with excellent transient response in noisy conditions. *IEEE Trans Acoust Speech Signal Process* [online]. 1990, 38:2108–17 [cit. 2017-05-03]. DOI: 10.1109/29.61537 ISSN 0096-3518. Dostupné z: <http://ieeexplore.ieee.org/document/61537/>
- [22] CHAVAKULA, Vamsidhar, Iván SÁNCHEZ FERNÁNDEZ, Jurriaan M. PETERS, Gautam POPLI, William BOSL, Sanjay RAKHADE, Alexander ROTENBERG a Tobias LODDENKEMPER. Automated quantification of spikes. *Epilepsy & Behavior* [online]. 2013, **26**(2), 143-152 [cit. 2017-05-03]. DOI: 10.1016/j.yebeh.2012.11.048. ISSN 15255050. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1525505012007421>
- [23] 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. 2017-05-03]. DOI: 10.1109/10.661266. ISSN 00189294.  
Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=661266>
- [24] KRAJČA, V. a S. PETRÁNEK. "Wave-Finder": A new system for an automatic processing of long-term EEG recordings. *Quantitative EEG Analysis – Clinical Utility and New Methods*. Jena: Universitätsverlag GmbH, 1993, s. 103-105.

- [25] MATLAB and Signal Processing Toolbox Release 2015b, The MathWorks, Inc., Natick, Massachusetts, United States.
- [26] NONCLERCQ, A., M. FOULON, D. VERHEULPEN, C. DE COCK, M. BUZATU, P. MATHYS a P. VAN BOGAERT. Spike detection algorithm automatically adapted to individual patients applied to spike and wave percentage quantification. *Neurophysiologie Clinical Neurophysiology* [online]. 2009, **39**(2), 123-131 [cit. 2017-05-10]. DOI: 10.1016/j.neucli.2008.12.001. ISSN 09877053.  
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0987705308001688>
- [27] WITTE, H., M. EISELT, I. PATAKOVA, S. PETRANEK, G. GRIESSBACH, V. KRAJCA a M. ROTHER. Use of discrete Hilbert transformation for automatic spike mapping: A methodological investigation. *Medical & Biological Engineering & Computing* [online]. 1991, **29**(3), 242-248 [cit. 2017-05-10]. DOI: 10.1007/BF02446705. ISSN 0140-0118. Dostupné z: <http://link.springer.com/10.1007/BF02446705>
- [28] SMITH, Jack R. Automatic Analysis and Detection of EEG Spikes. *IEEE Transactions on Biomedical Engineering* [online]. 1974, **BME-21**(1), 1-7 [cit. 2017-05-10]. DOI: 10.1109/TBME.1974.324354. ISSN 0018-9294.  
Dostupné z: <http://ieeexplore.ieee.org/document/4120710/>
- [29] 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]. **44**(8), 775-779 [cit. 2017-05-10]. DOI: 10.1109/10.605438. ISSN 00189294.  
Dostupné z: <http://ieeexplore.ieee.org/document/605438/>
- [30] GLOVER, John R., Periklis Y. KTONAS, Narasimhan RAGHAVAN, Jose M. URUNUELA, Syama S. VELAMURI a Edward L. REILLY. A Multichannel Signal Processor for the Detection of Epileptogenic Sharp Transients in the EEG. *IEEE Transactions on Biomedical Engineering* [online]. 1986, **BME-33**(12), 1121-1128 [cit. 2017-05-10]. DOI: 10.1109/TBME.1986.325689. ISSN 0018-9294.  
Dostupné z: <http://ieeexplore.ieee.org/document/4122221/>
- [31] 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. 2017-05-10]. DOI: 10.1016/j.cmpb.2006.10.003. ISSN 01692607.  
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0169260706002422>



- [32] JOHN G. WEBSTER a EDITOR IN CHIEF. *Encyclopedia of medical devices & instrumentation*. 2nd ed. New York: Wiley, 2006. ISBN 9780471732877.
- [33] Campisi R. Rocca D. Scarano G. EEG for automatic person recognition. *Computer* [online]. 2012, 45 (7), 87-89 [cit. 2017-05-16]. DOI: 10.1109/MC.2012.233. ISSN 0018 9162.

## Přílohy

K práci jsou v elektronické podobě ve složce přílohy přiloženy zdrojové kódy, uživatelská dokumentace a spustitelná aplikace vytvořeného programu a modulu pro automatickou detekci v rámci programové verze bakalářské části.