



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

## ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

## NÁSTROJ PRO AUTOMATICKÉ HODNOCENÍ KVALITY EEG DAT

TOOLBOX FOR AUTOMATIC EEG DATA QUALITY ASSESSMENT

### DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

Bc. Jan Meloun

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Martin Lamoš, Ph.D.

BRNO 2023

# Diplomová práce

magisterský navazující studijní program **Bioinženýrství**

Ústav biomedicínského inženýrství

**Student:** Bc. Jan Meloun

**ID:** 186676

**Ročník:** 2

**Akademický rok:** 2022/23

**NÁZEV TÉMATU:**

## Nástroj pro automatické hodnocení kvality EEG dat

### POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši zpracování dat skalpové elektroencefalografie (EEG), zaměřte se na hodnocení kvality naměřených záznamů. 2) Na základě literatury definujte minimálně 5 metrik hodnocení kvality dat. 3) Navrhněte koncept nástroje, který by umožňoval automaticky ohodnotit předložený EEG záznam pomocí definovaných metrik kvality. Nástroj by měl umožňovat i rozšiřitelnost o další metriky hodnocení kvality. 4) Implementujte takto navržený nástroj v programovém prostředí MATLAB, výstupem nástroje by měl být přehledný report o kvalitě předloženého záznamu. 5) Otestujte použitelnost nástroje (spolehlivost jednotlivých metrik, skórovacího algoritmu, výsledného reportu) na reálných EEG datech z Laboratoře multimodálního a funkčního zobrazování CEITEC MU. 6) Diskutujte dosažené výstupy jednotlivých bodů zadání.

### DOPORUČENÁ LITERATURA:

- [1] MICHEL, Christoph M., et al. (ed.). Electrical neuroimaging. Cambridge University Press, 2009.
- [2] FICKLING, Shaun D., et al. Good data? The EEG quality index for automated assessment of signal quality. In: 2019 IEEE 10th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON). IEEE, 2019. p. 0219-0229.

**Termín zadání:** 6.2.2023

**Termín odevzdání:** 14.8.2023

**Vedoucí práce:** Ing. Martin Lamoš, Ph.D.

**doc. Ing. Radim Kolář, Ph.D.**  
předseda rady studijního programu

### UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

## **ABSTRAKT**

Tato práce se zabývá návrhem nástroje pro automatické hodnocení kvality elektroencefalografických dat. V teoretické části práce se nachází teoretický základ z oblasti anatomie centrální nervové soustavy a mozku, následuje popis vzniku a šíření akčního potenciálu nervovou soustavou. Dále se teoretická část práce věnuje elektroencefalografii (EEG) a popisem EEG záznamu včetně typických artefaktů v něm. Následuje popis používaných metod pro detekci a odstranění artefaktů. Především se jedná o metody extrahující příznak kvality dat. V praktické části práce se nachází popis návrhu nástroje pro automatické hodnocení kvality EEG, jeho testování na umělých a reálných datech. Poslední část práce se věnuje diskusi výsledků s ohledem na úspěšnost detekce kanálů nebo úseků s artefakty a možné další rozšíření nástroje.

## **KLÍČOVÁ SLOVA**

Elektroencefalografie, skalpový záznam EEG, kvalita EEG dat, automatické hodnocení kvality dat, extrakce příznaků, koeficient špičatosti, maximální gradient, odhad hustoty výkonového spektra, amplituda kvadratického průměru, míra průchodu nulou, metoda podpůrných vektorů, MATLAB, sada nástrojů FieldTrip

## **ABSTRACT**

This thesis deals with designing a tool for automatically evaluating the quality of electroencephalographic data. In the theoretical part of the thesis, there is a theoretical basis in the anatomy of the central nervous system and the brain, followed by a description of the origin and propagation of the action potential through the nervous system. Furthermore, the theoretical part of the work is devoted to electroencephalography (EEG) and the description of the EEG recording, including typical artefacts in it. The following describes the methods used to detect and remove artefacts. These are primary methods for extracting data quality features. The practical part of the thesis contains a description of the design of a tool for automatic EEG quality assessment and its testing on artificial and real data. The last part of the work is devoted to the discussion of the results of the success of the detection of channels or sections with artefacts and the possible further extension of the tool.

## **KEYWORDS**

Electroencephalography, EEG scalp recording, EEG data quality, automatic data quality assessment, feature extraction, kurtosis, maximum gradient, power spectrum density estimation, root mean square amplitude, zero crossing rate, support vector machine, MATLAB, FieldTrip toolbox

MELOUN, Jan. *Nástroj pro automatické hodnocení kvality EEG dat*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2023, 64 s. Diplomová práce. Vedoucí práce: Ing. Martin Lamoš, Ph.D.

## Prohlášení autora o původnosti díla

<b>Jméno a příjmení autora:</b>	Bc. Jan Meloun
<b>VUT ID autora:</b>	186676
<b>Typ práce:</b>	Diplomová práce
<b>Akademický rok:</b>	2022/23
<b>Téma závěrečné práce:</b>	Nástroj pro automatické hodnocení kvality EEG dat

Prohlašuji, že svou závěrečnou práci jsem vypracoval samostatně pod vedením vedoucí/ho závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno .....

.....

podpis autora\*

---

\*Autor podepisuje pouze v tištěné verzi.

## PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu diplomové práce panu Ing. Martinu Lamošovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Dále bych rád poděkoval rodině, přátelům, bývalým spolužákům a především svému dlouholetému příteli Ing. Marku Zemkovi za podporu a motivaci.

# Obsah

Úvod	11
<b>1 Skalповý záznam elektroencefalografie</b>	<b>12</b>
1.1 Vznik a šíření potenciálu	12
1.1.1 Morfologie neuronu	13
1.1.2 Rytmy a vlny v elektroencefalografických datech	15
1.2 Přístrojové řešení záznamu EEG signálu	17
1.2.1 Elektrody	18
1.2.2 Montáže	19
1.2.3 Další komponenty přístroje	21
1.3 Artefakty a rušení v elektroencefalografických datech	22
1.3.1 Artefakty biologického původu	22
1.3.2 Artefakty nebiologického původu	24
<b>2 Kvalita elektroencefalografických dat</b>	<b>25</b>
2.1 Analýza elektroencefalografického signálu	25
2.2 Extrakce příznaků kvality	27
2.2.1 Šum signálu	27
2.2.2 Frekvenční rozsah	28
2.2.3 Odlehlé hodnoty	28
2.2.4 Další příznaky kvality	29
2.3 Extrakce příznaků popisujících artefakty	30
2.3.1 Artefakty způsobené pohyby očí	30
2.3.2 Artefakty způsobené svalovou činností	31
2.3.3 Artefakty způsobené srdeční činností	31
2.3.4 Artefakty způsobené síťovým rušením	32
2.3.5 Artefakty způsobené poppingem	32
2.4 Metody detekce odlehlých hodnot	33
2.4.1 Statistické metody	33
2.4.2 Metody založené na učení	34
<b>3 Návrh a testování nástroje</b>	<b>35</b>
3.1 Načtení elektroencefalografických dat	36
3.2 Přípravné práce se signálem	37
3.3 Výpočet příznaků	38
3.4 Vyhodnocení příznaků a klasifikace	40
3.5 Report o kvalitě dat	42

3.6	Testování implementovaného nástroje . . . . .	42
3.6.1	Testování extrahovaných příznaků . . . . .	43
3.6.2	Testování klasifikátoru . . . . .	44
3.6.3	Implementace nástroje na reálných datech . . . . .	46
<b>4</b>	<b>Diskuze naměřených výsledků</b>	<b>48</b>
4.1	Senzitivita příznaků . . . . .	48
4.2	Klasifikátor . . . . .	49
4.3	Detekce úseků signálu s artefakty v reálných datech . . . . .	51
	<b>Závěr</b>	<b>53</b>
	<b>Literatura</b>	<b>54</b>
	<b>Seznam zkratk</b>	<b>58</b>
	<b>Seznam příloh</b>	<b>60</b>
<b>A</b>	<b>Report o kvalitě dat</b>	<b>61</b>
<b>B</b>	<b>Obsah elektronické přílohy</b>	<b>64</b>



# Seznam obrázků

1.1	Vnější a vnitřní anatomické oblasti mozku . . . . .	13
1.2	Morfologie neuronu . . . . .	14
1.3	Pyramidový neuron vrstvy II/III . . . . .	15
1.4	Základní EEG rytmy . . . . .	16
1.5	Rozložení elektrod systému 10-20 . . . . .	18
1.6	Rozložení elektrod systému využívajícího 256 elektrod . . . . .	19
1.7	Schéma zapojení bipolární montáže . . . . .	20
1.8	Schéma zapojení referenční montáže . . . . .	20
1.9	Schéma zapojení průměrovací montáže . . . . .	21
2.1	Obecné blokové schéma zpracování EEG signálu . . . . .	25
2.2	Harmonický signál a jeho amplitudové spektrum . . . . .	26
2.3	Přenosová charakteristika antialiasingového filtru . . . . .	29
2.4	EEG záznam s artefakty způsobenými srdeční činností . . . . .	31
3.1	Blokové schéma navrženého nástroje . . . . .	35
3.2	Obecné blokové schéma výpočtu příznaků . . . . .	38
3.3	Blokové schéma výpočtu příznaků navrženého nástroje . . . . .	39
3.4	Rozložení normativního skórování . . . . .	41
3.5	Ukázka procesu celkového hodnocení . . . . .	41
3.6	Vteřinový úsek uměle vygenerovaného EEG signálu . . . . .	43
3.7	Vteřinové úseky uměle generovaného EEG signálu s artefakty . . . . .	45
4.1	Grafy s chybovými úsečkami pro každý příznak . . . . .	48
4.2	Rozdělení přesnosti klasifikace SVM . . . . .	50

# Seznam tabulek

1.1	Základní EEG rytmy . . . . .	15
3.1	Seznam podporovaných datových formátů podle výrobců . . . . .	36
3.2	Hodnoty koeficientů $\alpha$ . . . . .	44
3.3	Seznam s veškerými poskytnutými soubory a jejich vlastnostmi . . . .	46
3.4	Seznam unikátních značek, jejich četností a čísla kanálu EKG . . . .	47
4.1	Naměřené statistické veličiny detekce úseků signálu . . . . .	51

# Úvod

Skalповá elektroencefalografie je neinvazivní neurovizuální technika, která zaznamenává elektrickou aktivitu z povrchu mozku. Ukázalo se, že je cenným nástrojem v různých oblastech neurověd, včetně kognitivní psychologie a klinické diagnostiky. Kvalita záznamů EEG však hraje zásadní roli při zajištění spolehlivé a přesné analýzy a interpretace zaznamenaných dat. Proto je nezbytné vyvinout účinné metody pro hodnocení kvality naměřených EEG signálů. Tato práce si klade za cíl řešit problém hodnocení kvality dat EEG provedením komplexního přehledu literatury o zpracování dat EEG na skalpu, se zvláštním zaměřením na hodnocení kvality naměřených záznamů.

Na základě poznatků z rešerše literatury bude tato práce definovat alespoň pět metrik hodnocení kvality dat. Tyto metriky budou sloužit jako kvantitativní měřítka pro hodnocení spolehlivosti a věrnosti EEG záznamů, zachycující různé aspekty, jako je poměr signálu k šumu, impedance elektrody, spektrální charakteristiky a další relevantní parametry. Výběr těchto metrik se bude řídit jejich zavedeným významem v oboru a jejich potenciálem poskytnout komplexní pohled na kvalitu EEG dat.

Dále tato práce navrhne koncept nástroje, který umožní automatické vyhodnocení zaslaných EEG záznamů pomocí definovaných ukazatelů kvality. Nástroj bude navržen tak, aby byl flexibilní a rozšiřitelný, což umožní snadnou integraci dalších metrik hodnocení kvality. Implementace nástroje bude provedena v programovacím prostředí MATLAB s využitím volně dostupného Fieldtrip toolboxu.

K ověření účinnosti a použitelnosti vyvinutého nástroje budou využita skutečná EEG data z laboratoře CEITEC MU Multimodálního a funkčního zobrazovací. Testování odhalí účinnost detekce artefaktových kánlů či úseků signálu. Výsledky těchto testů poskytnou cenné poznatky o výkonu nástroje a jeho potenciálních nedostacích.

Na závěr si tato práce klade za cíl přispět do oblasti zpracování EEG dat skalpu poskytnutím komplexního přehledu metod hodnocení kvality, definováním nových metrik kvality dat a navržením a implementací nástroje pro automatické vyhodnocování EEG záznamů. Výsledky výzkumu mají potenciál zvýšit spolehlivost a validitu analýzy dat EEG a usnadnit pokrok v různých oblastech neurovědního výzkumu a aplikací.

# 1 Skalповý záznam elektroencefalografie


Elektroencefalografie (EEG) je elektrofyziologická metoda záznamu elektrické aktivity mozkové kůry. Tuto aktivitu lze pozorovat jako časově proměnlivé hodnoty elektrického potenciálu v rozmezí mikrovoltů ( $\mu\text{V}$ ). Z průběhu naměřeného EEG signálu lze usuzovat funkční stav jednotlivých oddílů mozku, proto tato metoda patří mezi základní diagnostické metody v neurologii a psychiatrii. [24], [28], [31]

Z hlediska záznamu dat se zpravidla jedná o neinvazivní metodu, založenou na přikládání nepolarizovatelných elektrod na pokožku hlavy. Méně často je tato metoda invazivní, kdy jsou použity podkožní vpichové, nasofaryngeální či intracerebrální elektrody. Z pohledu místa snímání signálu rozlišujeme skalповý nebo intrakraniální záznam EEG. U prvně zmíněného záznamu jsou malé elektrody umístěny na pokožce hlavy. Zde je nutný dobrý mechanický a elektrický kontakt. Pro intrakraniální záznam EEG jsou speciální elektrody implantované do mozku. Zvláštním případem měření EEG je metoda elektrokortikogram, při němž je měření prováděno přímo z povrchu kůry mozkové pomocí subdurálních elektrod. V této práci je využit skalповý záznam EEG. [20], [31]

## 1.1 Vznik a šíření potenciálu

Pro pochopení EEG dat je nutné vysvětlit vznik a šíření akčního potenciálu (AP) centrální nervovou soustavou člověka (CNS). AP představuje šířící se vzruch buňkami jako pulzní vlnu napětí. CNS je tvořena mozkem (*cerebrum*) a míchou (*medulla spinalis*), kde mozek se dále dělí na tři hlavní části: koncový mozek (*telencephalon*), mozeček (*cerebellum*) a mozkový kmen (*truncus cerebri*). Základní dělení CNS je znázorněno na obrázku 1.1. Nejvýznamnějším oddílem CNS je mozková kůra (*cortex cerebri*) tvořící plášť koncového mozku. Pro zvětšení funkční plochy je plášť koncového mozku rozčleněn na závity. V koncovém mozku rozlišujeme levou a pravou hemisféru oddělenou centrální rýhou. Základní dělicí jednotkou koncového mozku je lalok (*lobus*), dále se skládající ze závitů (*gyrus*) od sebe oddělených pomocí zářezů (*sulcus*). [6], [24], [28], [31]

Základními funkčními jednotkami nervového systému jsou neurony a podpůrné buňky neuroglie, které mají velký rozsah funkcí. Neurony a neuroglie jsou uspořádány do sítě. Neuroglie například tvoří podporu neuronální sítě, zajišťují výživu neuronů, provádějí fagocytózu a fungují jako izolanty tvorbou myelinu. Stavbě a funkci neuronu jakožto zdroji EEG signálu je věnovaná následující sekce. [6], [28]

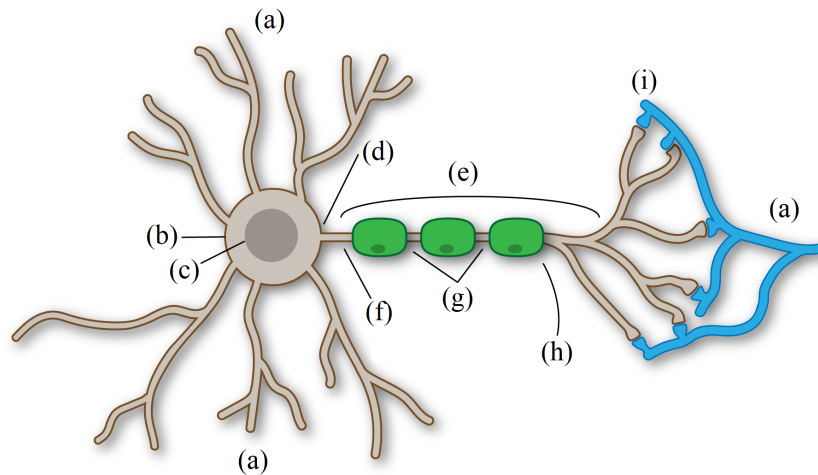


Obr. 1.1: Vnější a vnitřní anatomické oblasti mozku. (převzato a upraveno z [31])

### 1.1.1 Morfologie neuronu

Neuron znázorněný na obrázku 1.2 tvořící základní stavební jednotkou CNS se skládá z buněčného těla, dendritů a axonu. Uvnitř buněčného těla (*soma*) se nachází jediné jádro (*nucleus*) a probíhá zde většina buněčného metabolismu. Druhou význačnou částí neuronu jsou krátké a velmi bohatě větvené výběžky - dendrity, které jsou spojeny buď s axony nebo jinými dendrity okolních neuronů. Z dendritů vystupují dendritické trny účastnící se synapsí. Jako synapse je označované spojení mezi dvěma neurony nebo neuronem a smyslovou buňkou za účelem předávání vzruchů. Další základní stavební jednotkou neuronu je axon (*neurit*). Ten bývá zpravidla obalen myelinovými pochvami, mezi kterými se nachází Ranvierovy zářezy. Lipoproteinový komplex myelin se chová jako elektrický izolant a je produkován Schwannovými buňkami, což jsou jedny z dříve zmíněných neuroglií. Pochvy a zářezy jsou významné pro zrychlení přenosu informací, což je popsáno v následující sekci. Taktéž důležitý je axonový hrbol, protože u myelinizovaných axonů přechází v iniciální segment - úsek mezi axonem a místem, kde začíná myelinová pochva. V iniciálním segmentu je místní elektrická odpověď při dosažení prahových hodnot převáděna na AP. [6], [21], [24], [31]

V CNS je velké množství neuronů propojeno do složité prostorové sítě, kde AP probíhá po nervovém vláknech a šíří se centrifugálně - od těla jednoho neuronu k jeho periférii. Rychlost šíření je závislá na vlastnostech nervového vlákna. Šíření vzruchu je vždy jednosměrné a bez dekrementu. Díky přítomnosti myelinu se rychlost šíření zvyšuje díky saltatornímu vedení, kdy AP neprobíhá po celém vláknech neuronu, ale přeskakuje mezi Ranvierovými zářezy. Takto vzruch doputuje skrze axon až ke synapsi. Základním typem synapse je synapse chemická, v níž z presynaptické membrány jsou do synaptické štěrbině uvolněny mediátory - molekuly schopné přenášet infor-



Obr. 1.2: Morfologie neuronu: (a) - dendrity, (b) - tělo neuronu, (c) - jádro, (d) - axonový hrbol, (e) - axon, (f) - iniciální segment, (g) - Ranvierovy zářezy, (h) - Schwannovy buňky, (i) - synapse. (převzato a upraveno z [23])

maci mezi buňkami. Množství uvolněného mediátoru je přímo úměrné vzruchové aktivitě. Z prostoru štěrby jsou mediátory navázány na postsynaptickou membránu u níž můžou způsobit hyperpolarizaci nebo depolarizaci. Hodnota klidového membránového napětí se pohybuje okolo  $-70\text{ mV}$  a je dána rozdílnými koncentracemi iontů v buňce a jejím okolí. Hyperpolarizace označuje zápornou změnu klidového membránového napětí, zatímco depolarizace označuje kladnou změnu klidového membránového napětí. V některých případech může membránové napětí vlivem depolarizace nabývat i kladných hodnot. Excitační postsynaptický potenciál označuje depolarizaci postsynaptické membrány vlivem navázání mediátorů, takže se vzruch šíří dále. Dostatečné množství stimulů se projeví vybavením akčního potenciálu na axonovém hrbolku. Inhibiční postsynaptický potenciál je zapříčiněn inhibicí z důvodu hyperpolarizace postsynaptické membrány, což má za následek přerušení šíření vzruchu mozkovou tkání. [6], [21], [31]

Většina signálu pochází z postsynaptických proudů pyramidových neuronů v šedé hmotě, které se propagují na kůži hlavy. Pyramidové neurony patří mezi největší neurony v mozku a jsou typické svým tvarem znázorněným na obrázku 1.3. Aktivace velkého množství těchto neuronů může generovat potenciál dostatečně velký na to, aby jej bylo možné zaznamenat elektrodami na povrchu hlavy. Aktivace pyramidových neuronů v určité oblasti mozku se do okolích oblastí projevuje jako potenciálová pole s klesající hodnotou napětí v závislosti na vzdálenosti. [17], [31], [33]



Obr. 1.3: Pyramidový neuron vrstvy II/III. (převzato z [33])

### 1.1.2 Rytmus a vlny v elektroencefalografických datech

Mozková kůra projevuje pravidelnou elektrickou aktivitu označovanou jako rytmus. Pro popis rytmů se využívá jejich relativní amplituda a rozsah frekvencí. Amplituda je dána mírou synchronizace, s níž neurony kůry interagují. Vysoká amplituda je výsledkem sumace signálů ze součinných neuronů v závislosti na čase. Pokud dojde k opakování výše zmíněných synchronních excitací, vzniká tak rytmický EEG signál obsahující rytmy s vysokou amplitudou, zatímco asynchronní excitace produkuje nepravidelný EEG signál s nízkou amplitudou. [28], [31]

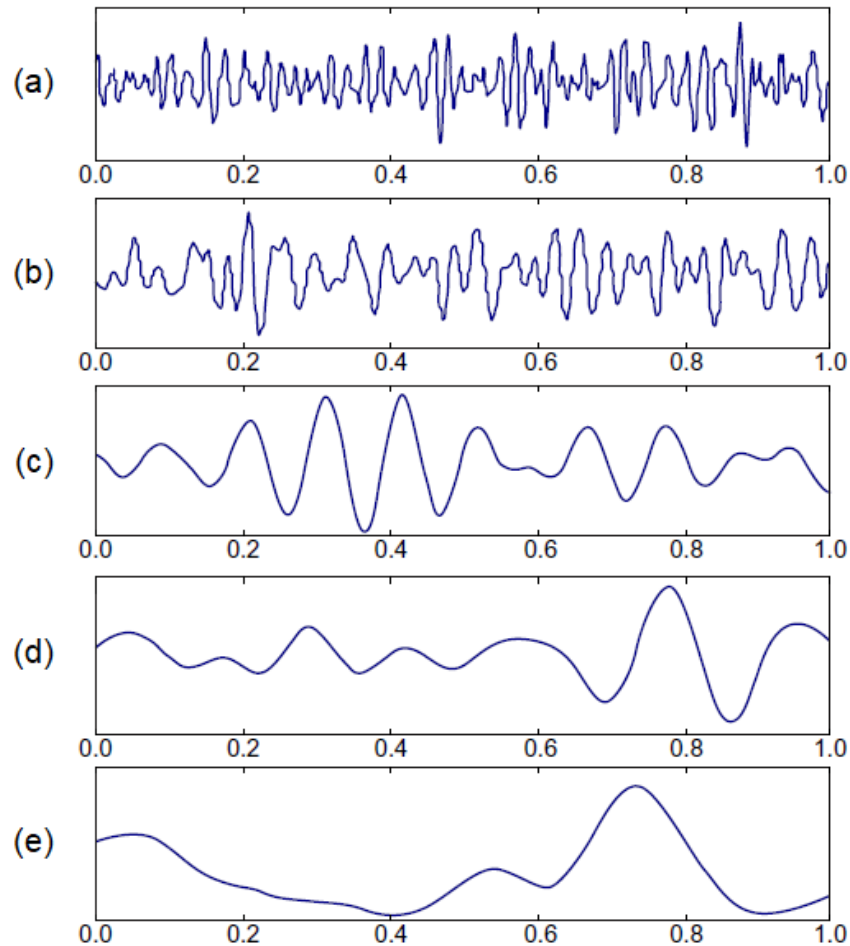
Ve zdravém mozku je typicky určitý stupeň asymetrie v EEG aktivitě mezi levou a pravou hemisférou. Tato asymetrie odráží lateralizaci mozkových funkcí, přičemž různé kognitivní a motorické procesy jsou lokalizovány převážně v jedné hemisféře. Pokud se aktivita EEG stane příliš symetrickou, znamená to abnormální funkci mozku nebo potenciální patologické stavy. Toto narušení může být způsobeno různými faktory, jako je poranění mozku, neurologické poruchy nebo jiné patologické stavy. V některých případech může nadměrná symetrie znamenat ztrátu specializovaných mozkových funkcí nebo zhoršenou komunikaci mezi hemisférami. [17], [28], [31]

Tab. 1.1: Základní EEG rytmy

Rytmus	Frekvenční rozsah [ $Hz$ ]	Amplituda [ $mV$ ]
$\delta$	do 4	20 - 200
$\theta$	4 - 7	5 - 100
$\alpha$	8 - 13	5 - 100
$\beta$	18 - 25	2 - 20
$\gamma$	více než 30	2 - 10

Pro skalpový záznam EEG dosahuje amplituda až  $100 \mu V$  a frekvence se pohy-

buje od 0,5 do 40  $Hz$ . Podle behaviorálního stavu se v tomto frekvenčním rozsahu nachází pět rozlišitelných specifických frekvenčních pásem:  $\alpha$ ,  $\beta$ ,  $\gamma$ ,  $\delta$  a  $\theta$  znázorněných na obrázku 1.4. Souhrn základních vlastností těchto pásem je uveden v tabulce 1.1. Interpretace naměřených dat se odvíjí od pacientova věku, stavu vědomí, medicíny a podmínek provádění měření. [13], [19], [31]



Obr. 1.4: Základní EEG rytmy: (a) -  $\gamma$ , (b) -  $\beta$ , (c) -  $\alpha$ , (d) -  $\theta$  a (e) -  $\delta$ . (převzato z [2])

Výskyt každého rytmu je typický pro jiný stav pacienta. Pro dospělého subjekt je přítomnost  $\delta$  rytmu typická a důležitá při hlubokém spánku, zatímco u bdění je patologická a svědčí o poškození mozku. U subjektů v kojeneckém věku je přítomnost  $\delta$  rytmu v bdělém stavu běžná. [13], [17], [19]

U dospělých subjektů se  $\theta$  rytmus vyskytuje při bdělém stavu a otevřením očí dochází k útlumu rytmu. Někdy může tento rytmus chybět úplně. Pro podezření z patologického procesu na mozku by asymetrie mezi hemisférami neměla přesáhnout 50 %.[17], [19]



U zdravých dospělých subjektů se  $\alpha$  rytmus projevuje v klidu, bdění a zavřených očích. Při otevření očí  $\alpha$  rytmus vymizí a po jejich uzavření a zklidnění subjektu se opět objeví. K vymizení  $\alpha$  rytmu může taktéž dojít z důvodu ospalosti nebo spánku vyšetřovaného pacienta. U zdravých subjektů by frekvence měla být konstantní v rámci měření a též by neměla být rozdílná mezi hemisférami. Avšak s rostoucím věkem může frekvence klesnout. Taktéž lze usuzovat, že frekvence  $\alpha$  rytmu je úměrná prokrvení mozku. [17], [19], [31]

Rytmus  $\beta$  je měřitelný v celé snímané oblasti hlavy, avšak je nejvíce zřetelný nad frontálními laloky v přední části skalpu a na temeni hlavy. Běžně se vyskytuje při normální až zvýšené pozornosti v bdělém stavu. Asymetrie  $\beta$  rytmu mezi hemisférami značí patologii. S rostoucím věkem roste i zastoupení  $\beta$  rytmu a obecně je vyšší u žen než u mužů. Krátkodobý vzrůst  $\beta$  rytmu je pozorovatelný při usínání. [17], [19]

Rytmus  $\gamma$  vychází z mozkové kůry a hrbolu mezimozkového (*thalamus*) a je odrazem aktivního zpracovávání informace kůrou za účelem kognitivní nebo motorické funkce. [13], [17], [19], [31]

Krom výše popsaných základních rytmů lze v EEG signálu pozorovat rovněž rytmy  $\kappa$ ,  $\lambda$  rytmus nebo K-komplex a spánková vřetena. Krom výše zmíněných pravidelných rytmů se v signálu mohou náhodně vyskytovat strmé vlny nebo specifické hroty s nepravidelností a nepředvídatelností. Výskyt těchto útvarů je typický pro subjekty se špatnou funkcí neuronů, často trpícími epilepsií nebo jinými mozkovými chorobami. [17], [28], [29]

## 1.2 Přístrojové řešení záznamu EEG signálu

EEG signál s hodnotami v řádu mikrovoltů ( $\mu V$ ) je nutné zesílit na řády voltů ( $V$ ). Zesílení umožňuje měřicím zařízením EEG mít vyšší citlivost, což dovoluje detekci jemné mozkové aktivity. To je důležité pro zachycení drobných rytmů a variací mozkových vln, které jsou kritické pro analýzu a interpretaci EEG. Signály EEG mají široký dynamický rozsah a mohou se výrazně lišit v závislosti na mozkové aktivitě a umístění elektrod. Zesílení signálů EEG na standardní rozsah napětí činí data kompatibilní s dalšími zařízeními používanými při záznamu EEG, jako jsou analogové filtry, A/D převodník a systémy digitálního zpracování signálu. Zesílení taktéž umožňuje efektivní škálování rozsahu signálu, aby se přizpůsobil limitům analogově-digitálního převodníku (A/D převodník) používaného pro digitalizaci. To zajišťuje, že signály EEG mohou být přesně reprezentovány v digitální podobě bez ztráty cenných informací. Zvýšení amplitudy zesílením signálů EEG také zlepšuje poměr signálu k šumu (SNR, z angl. *Signal to Noise Ratio*), protože jak signál, tak

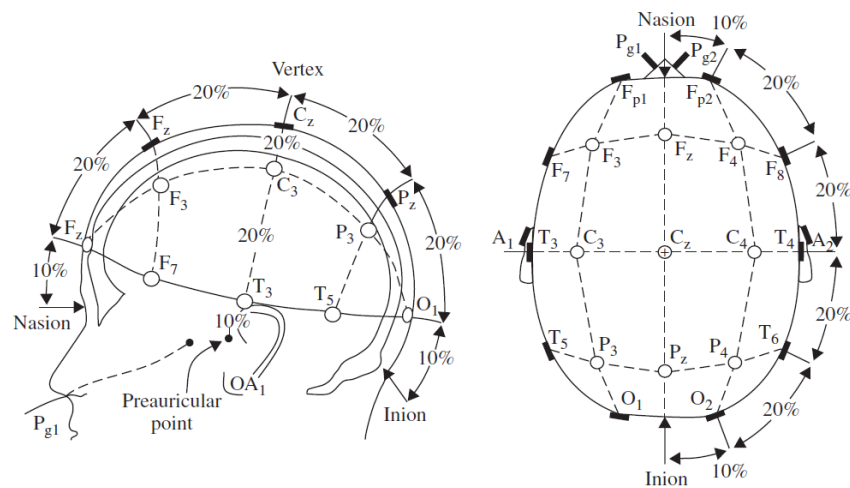
jakýkoli šum pozadí jsou zesíleny proporcionálně. Vyšší SNR vede k lepší kvalitě dat a spolehlivější interpretaci dat EEG. [13], [17], [31]

Lidská hlava se skládá z několika vrstev tkání, které různou mírou tlumí signál postsynaptických proudů detekovaný na jejím povrchu. Mezi tři druhy tkáně které se nejvíce podílí na útlumu patří pokožka hlavy, lebka a mozek. Lebka (*cranium*) tlumí výrazně signál oproti měkké tkáni, chová se jako filtr typu dolní propust. Další dvě zmíněné vrstvy jsou zdrojem šumu v signálu - mozek generuje interní šum, zatímco pokožka hlavy (*epidermis*) vytváří systémový nebo vnější šum. [28], [29], [31]

### 1.2.1 Elektrody

Pro snímání elektrické aktivity v mozku z povrchu hlavy jsou nejčastěji použity stříbrné argentchloridové elektrody (Ag/AgCl), ale jako vodivá část elektrody může být použit i jiný kov jako například zlato či platina. Pro zajištění vyšší vodivosti je využíván vodivý gel, který se aplikuje mezi elektrodu a kůži. Podle systému měření je zvoleno množství elektrod v sadě pro měření. [12], [28]

Nejčastěji využívaný systém 10-20 pracuje s 19 elektrodami a až dvěma referenčními elektrodami. Vhodnými lokacemi pro umístění referenčních elektrod jsou temeno hlavy, spojené levé a pravé ucho, spojené bradavkovité výběžky lebky (*processus mastoideus*), špička nosu a další. Rozložení elektrod je znázorněno na obrázku 1.5. V tomto systému je změřena vzdálenost mezi kořenem nosu (*nasion*) a konco-




Obr. 1.5: Rozložení elektrod systému 10-20. (převzato z [28])

vým hrbolkem v týlu (*inion*) v sagitální rovině. Na obou koncích jsou označeny body ve vzdálenosti rovnající se 10 % celkové naměřené vzdálenosti. Mezi těmito body je vzdálenost rozdělena na čtvrtiny, tudíž vzdálenost mezi těmito body se rovná 20 % celkové naměřené vzdálenosti. Ve frontální rovině je naopak změřena vzdálenost od

levého chrupavčitého výstupku před zvukovodem (*tragus*) k pravému. Následný postup je stejný - odměření 10 % vzdálenosti na obou koncích a následně rozdělení zbytku na čtyři díly s 20 % původní délky. Rozměřování v transverzální rovině je taktéž založené na podobném principu, avšak zde se měří vzdálenosti od bodu, kde bylo v sagitální rovině změřeno 10 % od kořene nosu, až do bodu ve vzdálenosti 10 % od koncového hrbolku v týlu. [12], [16], [28]

Pro účely výzkumu lze využít i více elektrod, například 128 a více, protože systém s nižším počtem elektrod poskytuje nedostatečné pokrytí pacientova mozku. Zvolené množství elektrod odpovídá kompromisu mezi časovou náročností instalace elektrod a jejich údržbou vůči spolehlivé detekci veškeré mozkové aktivity. Detekce mozkové aktivity pracující s 64 až 256 elektrodami se označuje jako HD-EEG (z angl. *High Density Electroencephalography*). V této práci je využito záznamu využívajícího 256 elektrod, jak je znázorněno na obrázku 1.6. Jedná se o geodesické rozložení elektrod, v němž jsou elektrody pravidelně rozprostřeny po zakřivené ploše pacientovy hlavy. [12], [16], [29]




Obr. 1.6: Rozložení elektrod systému využívajícího 256 elektrod. (převzato z [16])

## 1.2.2 Montáže

Montáž označuje předpis pro vytvoření EEG signálu pomocí kombinace zvolených svodů. Používají se jak standardní montáže, tak i vlastní dle aplikace a účelu. Mezi používané druhy montáží patří bipolární, referenční, průměrovací a například také Laplaciánská. Vývod každé elektrody je připojen k diferenčnímu zesilovači. Tato součástka vychází z operačního zesilovače a její výstupní napětí je úměrné rozdílu


napětí na vstupech, tudíž stejné složky v obou signálech budou na výstupu silně potlačeny. Způsob připojení elektrod na vstupy zesilovače určuje druh montáže. [17], [28], [31]

Bipolární montáž využívá jako vstupy do zesilovače sousední elektrody zapojené do temporální řady. Tato montáž je vhodná pro lokalizaci místa vzruchu i včetně koncových elektrod. Výhodou této montáže je menší úroveň artefaktů, avšak největší nevýhodou je nízký výstupní signál pro sousední elektrody s podobnou aktivitou. Schéma zapojení bipolární montáže je znázorněno na obrázku 1.7. [17], [28], [31]




Obr. 1.7: Schéma zapojení bipolární montáže. (převzato z [14])

Referenční montáž označovaná jako unipolární porovnává daný svod s referenčním. Jako referenční svod mohou být vybrány různé elektrody podle vybraného vyšetření nebo patologie. U této snímákové montáže je místo vzruchu nalezeno jako maximální výchylka. Vzhledem k podstatě snímání nedochází při této montáži ke zkreslení tvaru či frekvence při stavu, kdy oba vstupy zesilovače jsou na stejném potenciálu. Ovšem při této montáži může nastat problém, pokud referenční elektroda detekuje také mozkovou aktivitu. Schéma zapojení referenční montáže je znázorněno na obrázku 1.8. [17], [29], [31]



Obr. 1.8: Schéma zapojení referenční montáže. (převzato z [14])

Průměrovací montáž řeší výše zmíněný problém s referenční elektrodou tak, že jako druhý vstup do zesilovače je použit průměr přes všechny elektrody, krom elektrod blízkých očím. Další možností je Laplaciánská montáž, kdy se jako reference použije průměr ze čtyřech okolních elektrod. Schéma zapojení průměrovací montáže je znázorněno na obrázku 1.9. [17], [29], [31]



Obr. 1.9: Schéma zapojení průměrovací montáže. (převzato z [14])

### 1.2.3 Další komponenty přístroje

Mezi další důležité komponenty přístroje patří A/D převodník a zesilovač. A/D převodník transformuje vstupní analogový signál na signál digitální, dále zpracovatelný počítačem. Proces digitalizace začíná vzorkováním s pevně daným časovým intervalem - vzorkovací perioda  $T_{vz}$ . Každý takto vzniklý vzorek je kvantován na digitální reprezentaci A/D převodníkem a uložen do paměti počítače. Kvantování je závislé na rozlišení převodníku. Běžně jsou převodníky minimálně osmibitové, častěji však 12-bitové. Volba vzorkovací frekvence se řídí podle Nyquistova teorému vyjádřeného vztahem

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

kde  $f_{vz}$  je vzorkovací frekvence v  $Hz$  a  $f_{max}$  je maximální frekvence vyskytující se v analogovém signálu v  $Hz$ . Platí, že efektivní užitečné pásmo frekvencí bývá obvykle nižší než je právě polovina vzorkovací frekvence. Při nedodržení tohoto teorému dochází k aliasingu, jevu, kdy jsou vysokofrekvenční složky ve spojitém signálu mylně reprezentovány jako nižší frekvence ve vzorkovaném signálu. Problém aliasingu je dnes vyřešen převážně instalací antialiasingového filtru do převodníku. V případě běžných A/D převodníků se jedná o filtr typu dolní propust realizovaný jako analogový frekvenční filtr. Jeho úkolem je odfiltrovat frekvence vyšší, než odpovídají Nyquistovu teorému. [9], [12]

V současné době při snímání biosignálů včetně EEG je využíváno převzorkování, tedy využití vzorkovací frekvence výrazně vyšší než je nutné. Benefitem je, že s vyšší vzorkovací frekvencí signálu klesají nároky na složitost filtrů použitých při jeho zpracování. Přitom použití vyšší frekvence neklade zvýšené finanční požadavky na A/D převodník. [9], [12]

Další důležitou součástí přístroje je zesilovač výstupního signálu. Na něj jsou kladeny požadavky jako vysoký zisk, aby zesílil slabé signály EEG, typicky v rozmezí 1000 až 50000krát nebo více. To zajišťuje, že i drobné mozkové elektrické signály jsou detekovatelné a měřitelné. Dále je nutný vysoký vstupní odpor, proto aby se zabránilo zatěžování elektrod a zkreslení nebo zeslabení signálů EEG. Vysoký vstupní odpor zajišťuje minimální tok proudu z elektrod při zachování věrnosti signálů. Malý výstupní odpor je nutný pro stabilní výstupní signál, který lze přenášet na velké vzdálenosti bez degradace. Pro minimalizování zesílení jakéhokoli nežádoucího elektrického rušení nebo šumu je důležitý malý vlastní šum. To pomáhá při zachování poměru signálu k šumu a získávání čistých záznamů EEG. Vysoká hodnota činitele potlačení soufázového zesílení (CMRR, z angl. *Common-Mode Rejection Ratio*) je nutná za účelem, aby se zabránilo rušení v běžném režimu, jako je okolní šum a vnější elektrické signály, které jsou zachycovány rovnoměrně všemi kanály. V neposlední řadě je důležitým parametrem zesilovače ochrana pacienta před unikajícím proudem z obvodu a před nebezpečným vstupním napětím. To je docíleno například galvanickým oddělením měřících od napájecích obvodů. [12]

## 1.3 Artefakty a rušení v elektroencefalografických datech

Jako artefakt je označována nežádoucí složka signálu. Artefakty tedy ovlivňují výsledný signál a je nutné je pro další zpracování potlačit či úplně odstranit. Artefakty popsané v následujících sekcích jsou extracerebrálního původu - zdroj není umístěn v mozku ale jeho okolí. Tyto artefakty lze podle jejich původu rozdělit do dvou skupin. [17], [28], [31]

### 1.3.1 Artefakty biologického původu

První velkým zdrojem artefaktů biologického jsou pohyby očí. Tyto artefakty lze rozdělit podle původu na mrknutí a laterální pohyb očí. Mrkání očí je jedním z nejběžnějších pozorovatelných artefaktů v EEG datech. V záznamu se vyznačuje velmi vysokou amplitudou negativních křivek na obou stranách přední části lebky - bifrontálních oblastech. Ve spektru signálu se toto projevuje jako vysokofrekvenční složky.

Artefakty vznikají díky Bellovu fenoménu vyznačujícím se stočením očí vzhůru při mrknutí. Z elektrického hlediska je rohovka očí kladně nabitá a sítnice záporně. Pro ilustraci propagace rušení jsou použity elektrody systému 10-20. Tedy při mrknutí se oči mírně stočí a rohovka se přiblíží k čelním elektrodám  $Fp1$  a  $Fp2$  za vzniku pozitivního signálu v EEG datech. Mrkání očí by mělo být skutečně vidět pouze ve frontálních svodech, bez jakéhokoli pole zadních oblastí. Podobný tvar vlny je vidět při zavření oka a jakýsi opačný tvar vlny s velkým bifrontálním záporným nábojem je vidět po otevření oka. Mrkání očí je běžnou součástí normálního EEG v bdělém stavu. Laterální pohyby očí se v záznamu EEG dat projevují opačnými polaritami ve svodech  $F7$  a  $F8$ , což je způsobeno rozdílnými náboji rohovky a sítnice, jak je zmíněno u Bellova fenoménu. Laterální pohyby očí produkují elektrickou aktivitu zaměnitelnou s pomalou EEG aktivitou zastoupenou zejména rytmy  $\theta$  a  $\delta$ . Oba dva tyto artefakty lze však snadno odstranit pomocí elektrookulografického signálu. Elektrookulografie (EOG) je metoda sledující pohyby oka a směru pohledu při pozorování určitého objektu. Je zkoumán vztah mezi potenciály rohovky a sítnice pomocí elektrod umístěných blízko oka. Naměřené napětí odpovídá úhlu pohledu a jeho velikost primárně závisí na blízkosti elektrody k oku a na směru, ve kterém se oko pohybuje. Pomocí korelace mezi EEG a EOG signály lze potlačit rušivou složku způsobenou pohyby očí v EEG signálu. [10], [17], [28]

Dalším možným zdrojem artefaktů je srdeční činnost. Mezi negativní projevy srdeční činnosti v EEG datech patří EKG artefakty a kardiobalistický artefakt. Druhý zmíněný je méně častým artefaktem, ve kterém je elektroda EEG umístěna těsně nad tepnou a každá pulsace tepny je zachycena jako pohybový artefakt v EEG záznamu. Srdeční činnost je měřitelná metodou elektrokardiografie (EKG). Artefakty EKG jsou křivky časově vázané na komplex QRS označující depolarizaci komor. Bývají přítomny více nebo úplně na levé straně, protože srdce je umístěno z větší části v levé polovině hrudníku, a mají tendenci mít relativně nízkou amplitudu. Pro odstranění obou artefaktů je vhodná metoda nezávislých komponent (ICA, z angl. *Independent Component Analysis*) [10], [17]

Artefakty svalové činnosti pochází ze svalových pohybů a nejčastěji se nachází ve frontálních, laterálních nebo temporálních oblastech. Vyznačují se vysokou frekvencí, často nízkou amplitudou aktivity překrývající normální mozkové rytmy a jsou obvykle nejvýraznější v bdělém stavu. Jakákoliv kontrakce svalu v blízkosti EEG elektrody se projeví rušením. Avšak jako u pohybů oka i zde je možné rušení potlačit pomocí záznamu elektrické aktivity svalů. Elektromyografie (EMG) je metoda měřící právě tuto aktivitu, její signál může být tvořen nízkými amplitudami až po šum připomínající signál. [10], [28], [31]

Artefakt žvýkání a pohyb jazyka (hypoglosální) je na EEG poměrně těžké přehlédnout. Artefakt žvýkání je ve skutečnosti jen svalový artefakt způsobený činností

temporálního svalu a vyznačuje se náhlým nástupem, přerušovanými vzruchy generalizované velmi rychlé aktivity (svalový artefakt). Žvýkáci artefakt obvykle nesdílí blízkou morfologii s jakoukoli jinou důležitou fyziologickou aktivitou. Největším rizikem je možná záměna s  $\beta$  frekvencí, která bývá o něco pomalejší a má nižší amplitudu. Hypoglosální artefakt je často, ale ne nezbytně vidět u žvýkáciho artefaktu. Vzniká z pohybu jazyka a jeví se jako pomalejší, difúzní aktivita podobná  $\delta$  rytmu. Tento artefakt je možné replikovat vyžádáním pacienta o promluvení. Dalšími možnými artefakty jsou artefakty potu. Ty se vyznačují velmi pomalou (typicky méně než 0,5 Hz), relativně nízkou amplitudou aktivity, která vzniká, protože chlorid sodný v potu nese náboj, který je zachycován elektrodami EEG. Projekce artefaktu potu je náhodná bez jakýchkoliv vzorů. [10], [17], [28], [31]

### 1.3.2 Artefakty nebiologického původu

Nejčastějším artefaktem nebiologického původu je síťové rušení. Ve spektru měřeného signálu se projevuje jako harmonická složka na frekvenci odpovídající kmitočtu elektrické sítě. Toto rušení lze jednoduše odstranit pomocí úzkopásmové zádrže - filtru, který z původního signálu odstraní úzký rozsah frekvenčních složek. [10], [17]

Dalším typickým artefaktem je elektrodivý popping, kdy díky poškozeným elektrodám nebo špatnému technickému stavu zařízení dojde ke změně impedance rozhraní elektroda/kůže. Toto se projevuje na jediné elektrodě jako velmi náhlý, strmý vzestup s pomalejším sestupem a absolutně žádným polem. Tomuto typu interference je nutné předcházet zajištěním vhodných podmínek pro průběh měření. Mezi tyto podmínky patří kontrola umístění elektrod včetně zemnicí a referenční a jejich kontaktu s pokožkou hlavy pacienta. Dále je to pak využití stíněných vodičů a kontrola impedance elektrod. Je vhodné zmínit, že do této kategorie taktéž spadají artefakty spjaté s nedokonalostmi zesilovačů a převodem na digitální signál. [10], [17]




## 2 Kvalita elektroencefalografických dat

Digitální zpracování EEG signálu je obvykle provedeno pomocí několika na sebe navazujících kroků znázorněných na obrázku 2.1. V prvním kroku jsou originální data předzpracována za účelem zvýšení kvality a odstranění šumu, poté jsou z dat extrahovány příznaky. Jen ty nejrelevantnější příznaky jsou selektovány metodami jako je metoda hlavních komponent nebo lineární diskriminační analýza. Vybraná data mohou být pro následnou analýzu zobrazena nebo klasifikována. [19], [31]

Účelem předzpracování je nalezení úseků signálu či celých kanálů s artefakty proto, aby artefakty byly v následující analýze odstraněny. Nalézt artefakty a rušení lze manuální kontrolou nebo využitím nástroje, který provede tuto analýzu automaticky a poskytne report s informacemi o nekvalitních úsecích signálu, či celých kanálech. [19], [28]

Odstranění artefaktů lze dosáhnout prostou filtrací nebo metodou ICA. Taktéž při předzpracování dat je vhodné provést kontrolu hodnot, zda se v signálu vyskytují chybějící a odlehlé hodnoty. Při běžném předzpracování poté následuje prostorová interpolace pro doplnění chybějících hodnot. V některých případech je vhodné provést standardizaci či normalizaci dat. [19], [28]



Obr. 2.1: Obecné blokové schéma zpracování EEG signálu.

Jak vyplývá z předchozího textu, tak je nutné zjistit kvalitu naměřených dat pro další analýzu. Tedy je nutné odhalit jestli jsou v signálu přítomny artefakty a rušení. Přítomnost artefaktů a rušení lze odhalit analýzou signálu v určité doméně, odkud jsou získány příznaky popisující kvalitu. [19], [28], [31], [36]

### 2.1 Analýza elektroencefalografického signálu


Analýza EEG signálů zahrnuje extrakci smysluplných informací ze zaznamenaných dat, aby bylo možné identifikovat vzory nebo abnormality. Použité metody se zaměřují na analýzu v časové, frekvenční, časově-frekvenční a prostorové oblasti. [7], [27], [36]

Analýza EEG signálů v časové oblasti hraje klíčovou roli v pochopení časové dynamiky a charakteristik mozkové aktivity. Amplitudová analýza poskytuje informace o síle a intenzitě nervové aktivity, zatímco míry jako průměr, rozptyl, šikmost a špičatost kvantifikují distribuci a statistické vlastnosti signálu. Frekvence průchodů signálu nulou odhaluje rychlost oscilací. Kromě toho Hjorthovy parametry, včetně aktivity, mobility a složitosti, zachycují různé aspekty energie signálu, změny tvaru vlny a nepravidelnosti. [9], [27]

Analýza ve frekvenční oblasti je dalším z možných přístupů v analýze EEG signálu využívající spektrální vlastnosti dat. Pro signál spojitého času je vztah pro výpočet Fourierovy transformace následující

$$F(\omega) = \int f(t) \cdot e^{-j\omega t} dt \quad (2.1)$$

kde  $\omega$  je úhlová frekvence [ $rad \cdot s^{-1}$ ],  $t$  je čas [s]. Použitím Fourierovy transformace je EEG signál transformován z časové oblasti do frekvenční oblasti, jak je znázorněno na obrázku 2.2. To umožňuje zkoumat rozložení a sílu různých frekvenčních složek, jako jsou vlny  $\alpha$ ,  $\beta$ ,  $\theta$  a  $\gamma$ . Analýza ve frekvenční oblasti poskytuje cenné informace o dominantních frekvenčních pásmech a jejich relativních amplitudách a odhaluje důležité poznatky o oscilacích elektrické aktivity mozku. [9], [27], [34]



Obr. 2.2: Harmonický signál a jeho amplitudové spektrum, kdy na obrázku (a) je časový průběh harmonické funkce tvořené dvěma frekvencemi a na obrázku (b) je její amplitudové spektrum. [9]

Analýza signálu v časově-frekvenční oblasti kombinuje jak časové, tak spektrální vlastnosti dat. Tento přístup umožňuje zkoumat, jak se frekvenční obsah EEG signálu mění v průběhu času, čímž je zachycena dynamická povaha mozkové aktivity. Mezi používané techniky patří krátkodobá Fourierova transformace a vlnková transformace. Aplikací těchto transformací na EEG data lze identifikovat a zkoumat

přechodné události, spektrální změny související s událostmi a frekvenční dynamiku, která nemusí být zřejmá v časové ani frekvenční doméně samotně. Časově-frekvenční reprezentace poskytuje detailní pohled na časově proměnnou distribuci výkonu nebo amplitudy v různých frekvenčních pásmech EEG signálu, odhaluje časový vývoj neurálních oscilací a jejich vztah ke kognitivním procesům. [9], [27], [32]

Analýza signálu v prostorové oblasti se zaměřuje na prostorovou distribuci a topografické charakteristiky mozkové aktivity. Tato analýza zahrnuje zkoumání elektrických potenciálů zaznamenaných elektrodami umístěnými na pokožce hlavy, aby se získal pohled na nervové procesy probíhající v různých oblastech mozku. Techniky jako jsou skalpové mapy a topografické grafy se běžně používají k vizualizaci amplitudy nebo distribuce výkonu napříč elektrodami, odhalující prostorové vzorce mozkové aktivity. Analýza prostorové domény umožňuje posouzení funkční konektivity mezi oblastmi mozku, identifikaci mozkových sítí a lokalizaci abnormalit nebo fokálních aktivací. [27], [32]

## 2.2 Extrakce příznaků kvality

Extrakce příznaků umožňuje extrakci relevantních informací ze předpracovaných EEG dat. Signály EEG jsou složité a obsahují velké množství informací, takže je nutné extrahovat specifické rysy, které zachycují základní charakteristiky mozkové aktivity nebo artefaktů a rušení. Metody extrakce příznaků zahrnují transformaci surových dat do souboru smysluplných a reprezentativních příznaků, které mohou zahrnovat například statistické míry, spektrální koeficienty, deskriptory časové domény nebo míry konektivity. Cílem extrakce příznaků v analýze kvality signálu EEG je odhalení přítomnosti artefaktů a rušení. [7], [36]

### 2.2.1 Šum signálu

Výpočet SNR je základním měřítkem kvality signálů EEG. SNR posuzuje relativní sílu požadované mozkové aktivity ve srovnání s šumem na pozadí. V kontextu analýzy dat EEG indikují vyšší hodnoty SNR spolehlivější signály, což umožňuje lepší detekci smysluplných vzorů v EEG signálu. Pro výpočet SNR se signály EEG obvykle dělí na signálovou a šumovou složku. Složka signálu představuje mozkovou aktivitu, zatímco složka šumu se skládá z různých zdrojů rušení, jako je síťové rušení nebo artefakty biologického původu. Výpočet SNR v jednotkách [dB] lze provést pomocí vztahu

$$SNR = 10 \cdot \log \frac{P_S}{P_N}, \quad (2.2)$$

kde  $P_S$  je průměrný výkon signálu a  $P_N$  je průměrný výkon šumu. Pro výpočet SNR je nutné znát referenční úsek signálu se šumem, pokud takový není lze použít

alternativními přístupy. Mezi tyto postupy patří například období aktivity, filtrace pásmovou propustí, statistický odhad a detekce artefaktů. [9]

Pokud EEG data obsahují úseky signálu bez aktivity před nebo po zkoumané mozkové aktivitě, je možné tyto úseky použít jako referenci pro odhad šumu. SNR je tedy možné vypočítat porovnáním výkonu signálu během zájmové aktivity s výkonem signálu bez aktivity. Výpočet výkonu signálu je detailněji popsán v následující sekci. [7], [9], [27], [36]

Pokud je známý frekvenční rozsah nebo specifické zdroje šumu, lze filtrem typu pásmová propust potlačujícíím zbylé frekvence získat odhad šumu. Výkon filtrovaného signálu pak lze použít k výpočtu SNR. [27], [36]

Charakteristiky šumu je možné odhadnout statisticky, místo využití konkrétního referenčního období. K tomu lze využít úseky EEG signálu zaznamenané během odpočinku nebo klidového stavu pacienta. V těchto úsecích lze očekávat nízkou míru užitečného signálu a převahu šumu. Odhadem rozptylu/směrodatné odchylky těchto období lze přibližně určit úroveň šumu a vypočítat SNR.

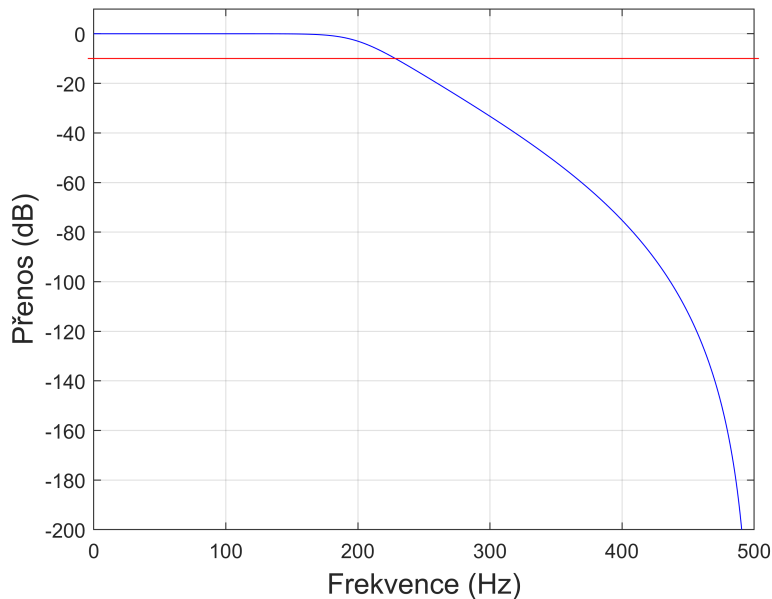
Poslední možností je využití anotací. Pokud EEG data obsahují anotace nebo štítky označující přítomnost specifických artefaktů (např. mrkání očí, svalová aktivita), lze tyto označené segmenty použít jako reference pro odhad šumu. Výběrem segmentů označených jako artefakty lze na základě jejich charakteristik odhadnout úroveň šumu a vypočítat SNR. [9]

### 2.2.2 Frekvenční rozsah

Validace frekvenčního rozsahu zkoumáním výkonového spektra signálů EEG zajišťuje, aby zaznamenaná data odpovídala očekávanému frekvenčnímu rozsahu typické aktivity EEG. Tato validace je nezbytná, protože signály EEG se skládají především ze specifických frekvenčních pásem spojených s mozkovými rytmy a nervovou aktivitou. Neobvyklé spektrální vzorce nebo přítomnost silného šumu ve specifických frekvenčních pásmech mohou svědčit o problémech s kvalitou dat nebo artefaktech. Nejčastěji se hodnotí vliv antialiasingového filtru na signál. Hledá se frekvence na přechodu filtru s poklesem o 10 *dB*, jak je znázorněno na obrázku 2.3. [7], [9], [27], [36]

### 2.2.3 Odlehlé hodnoty

Odlehlé hodnoty signálu jsou důležitým ukazatelem kvality EEG dat, protože mohou významně ovlivnit spolehlivost a přesnost následné analýzy. Identifikací a odstraněním odlehlých nebo extrémních hodnot v EEG datech se může účinně řešit potenciální poškození dat nebo chyby měření. K odhalení odlehlých hodnot v datech lze použít různá statistická měření, například z-skóre nebo robustní odhady. Odlehlé



Obr. 2.3: Přenosová charakteristika antialiasingového filtru pro vzorkovací frekvenci  $f_{vz} = 1000 \text{ Hz}$  a mezní frekvenci  $f_m = 200 \text{ Hz}$ . Červená čára označuje pokles o  $-10 \text{ dB}$ .

hodnoty mohou vznikat z různých zdrojů, včetně artefaktů, šumu nebo poruch elektrod. Jejich přítomnost může vést k zavádějícím interpretacím a ohrozit platnost pozdější analýzy. [7], [9], [27], [36]

## 2.2.4 Další příznaky kvality

Impedance elektrod poskytuje informace o kvalitě kontaktu elektrody s kůží. Vysoké hodnoty impedance elektrod mohou mít za následek špatnou kvalitu signálu, což vede k zašuměným a nespolehlivým záznamům EEG. V ideálním případě nízké hodnoty impedance indikují dobrý kontakt elektrody s kůží, což zajišťuje přesný a konzistentní sběr signálu. Zajištění optimálního kontaktu elektrod prostřednictvím hodnocení impedance je rutinní při snímání EEG dat, kdy hodnoty impedance nejsou uloženy do datového souboru. [7], [9]

Kontrola úplnosti dat zajišťuje, že shromážděná data splňují kritéria nezbytná pro přesnou a spolehlivou analýzu. Tato kontrola spočívá v detekci chybějících nebo neúplných segmentů v záznamu EEG nebo přítomností nečíselných hodnot vzorků signálu. Ověřováním přítomnosti požadované délky a počtu pokusů nebo epoch je zajištěno, že data jsou dostatečná pro spolehlivou analýzu. Chybějící segmenty nebo neúplné údaje mohou vést ke zkresleným nebo neprůkazným výsledkům, což ohrožuje celkovou platnost výsledků analýzy EEG. Problematickými jsou atypická mě-

ření, u kterých dojde ke saturaci kanálů, což se na výsledném záznamu projevuje signálem v hodnotě odpovídající maximální hodnotě dynamického rozsahu. [19]

Konzistence dat je zjištěna porovnáním jejich vzorců a korelace mezi různými kanály. Nekonzistence nebo velmi rozdílné signály mezi kanály mohou naznačovat potenciální problémy s umístěním elektrod, propojením nebo kvalitou záznamu. Identifikace a řešení takových nesrovnalostí je zásadní, protože tyto nesrovnalosti mohou vést k zavádějícím výsledkům a ohrozit celkovou integritu dat EEG. [19]

## 2.3 Extrakce příznaků popisujících artefakty

Detekce typických artefaktů v EEG datech je klíčovým krokem při hodnocení jejich kvality EEG dat, jehož cílem je identifikovat a kvantifikovat různé zdroje rušení, které mohou kontaminovat zaznamenané signály. Později detekované úseky signálu či celé kanály jsou v následné analýze pomocí metody ICA a dalších zbaveny artefaktů. [10]

### 2.3.1 Artefakty způsobené pohyby očí

Tyto artefakty se rozdělují do dvou skupin - mrknutí a laterální pohyb oka. Artefakty spojené s mrknutím lze popsat extrakcí příznaků jako je velikost amplitudy a její délka. Amplituda označuje velikost výchylky napětí během mrknutí. To lze provést výpočtem amplitudy od špičky k špičce nebo maximální absolutní amplitudy v rámci segmentu mrknutí. Délka mrknutí je definována jako časový interval mezi začátkem a koncem úseku mrknutí. [10]


Jedním z důležitých aspektů artefaktů souvisejících s pohybem očí je komponent pomalého pohybu očí, který zahrnuje jak drifty, tak sakády. Drifty představují pomalé, nepřetržité pohyby očí, které plynule posunují pohled, zatímco sakády jsou rychlé, diskrétní pohyby očí, které přeměrují pohled na nový cíl. Detekce a kvantifikace těchto očních pohybů může pomoci při identifikaci segmentů EEG ovlivněných artefakty souvisejícími s očima. Pro analýzu komponenty pomalého pohybu očí lze z dat EEG získat několik funkcí. Jednou z klíčových vlastností je amplituda pohybů oka, která odráží velikost odchylky oka od fixačního bodu. Větší amplitudy často ukazují na výraznější artefakty pohybu očí. Kromě toho lze hodnotit frekvenci očních pohybů, protože poskytuje pohled na rychlost, s jakou se během záznamu EEG objevují oční artefakty. Vysoké i nízké frekvence pohybu očí mohou naznačovat potenciální artefakty. [10]

### 2.3.2 Artefakty způsobené svalovou činností

Metody extrakce příznaků pro myogenní artefakty zahrnují zachycení jejich jedinečných spektrálních charakteristik, časových vzorů a distribuce amplitudy. Pro kvantifikaci úrovně přítomnosti myogenních artefaktů lze použít statistická měření, jako je výkon ve specifických frekvenčních pásmech, rozptyl signálu a špičatost. Příznaky časové domény, jako je prahování amplitudy, rozptyl signálu a analýza sklonu křivky, mohou také pomoci při detekci náhlých změn spojených se svalovou aktivitou. K oddělení myogenních artefaktů od skutečných cerebrálních signálů lze navíc využít techniky jako ICA využitím jejich prostorových rozdílů v distribuci. Extrakcí rysů souvisejících s výkonem ve specifických frekvenčních pásmech (50-100Hz) můžeme rozlišit segmenty silně ovlivněné svalovou aktivitou. [10]

### 2.3.3 Artefakty způsobené srdeční činností

Pro zjištění přítomnosti artefaktů způsobených srdeční činností lze využít informace z EKG signálu. U většiny EEG záznamů je současně nahráván i EKG signál. Porovnáním signálu s detekovanými R-vrcholy a EEG daty lze objevit souvislost. Využitím specializovaných algoritmů je možné identifikovat R vrcholy v EKG signálu. R-vrcholy odpovídají vrcholům v QRS komplexu EKG křivky a lze je použít k přesné lokalizaci jednotlivých srdečních tepů. Na obrázku 2.4 je znázorněno prolínání EKG s EEG signálem. [10], [22]



Obr. 2.4: EEG záznam s artefakty způsobenými srdeční činností. (převzato z [22])

Další možností je extrakce variability srdečního rytmu (HRV, z angl. *Heath Rate*

*Variability*), kdy informace v časové (např. směrodatná odchylka intervalů NN, kdy interval NN představuje časové rozdíly mezi R-vrcholy - RR intervaly, ale s přidaným filtrováním k odstranění artefaktů a šumu přítomných v datech, což činí některé intervaly RR nespolehlivé) a frekvenční oblasti (např. výkon ve vysokofrekvenčních a nízkofrekvenčních pásmech) slouží k zachycení změn v časových intervalech mezi po sobě jdoucími srdečními tepy. Abnormální vzorce HRV mohou indikovat segmenty kontaminované artefakty srdeční aktivity. [10]

Odhad výkonové spektrální hustoty se využívá pokud není EKG signál přítomný v záznamu EEG dat. Provádí se analýza výkonového spektra EEG signálu se zaměřením na frekvenční pásma související se srdeční aktivitou, např. 0,5-2 Hz. Toto pásmo obvykle obsahuje spektrální složky související se srdečními signály. Dále tak neobvyklé spektrální vzorce v cílových frekvenčních pásmech, jako je zvýšený výkon nebo periodické oscilace, mohou naznačovat artefakty způsobené srdeční aktivitou. [10], [19]

### **2.3.4 Artefakty způsobené síťovým rušením**

Analýzou frekvenčního rozsahu a odhadem výkonu pásma lze odhalit síťové rušení. Toho tak je možné dosáhnout výpočtem výkonu nebo amplitudy EEG signálu frekvenčním rozsahu odpovídajícím šumu elektrického vedení - 50 Hz. Ke kvantifikaci podílu frekvence elektrického vedení na celkovém signálu EEG se využívají techniky, jako je odhad pásmového výkonu nebo spektrální analýza. [9], [10]

Harmonická složka síťového rušení se také projevuje ve výsledném signálu, kdy její přítomnost zjistit analýzou frekvenčních složek. Analýza přítomnosti harmonických frekvencí (např. druhé nebo třetí harmonické) v signálu EEG, které se shodují s frekvencí elektrického vedení. Harmonické složky signalizují přítomnost rušivých vlivů vedení a lze je použít k rozlišení skutečné aktivity EEG od šumu. Další alternativou je zhodnocení relativní amplitudy pomocí porovnání relativní amplitudy harmonických složek vzhledem k základní frekvenci, pro ověření přítomnosti artefaktů šumu vedení. [10]

### **2.3.5 Artefakty způsobené poppingem**

Možným postupem detekce je derivační analýza, při které je vypočítána derivace EEG signálu a jsou identifikovány náhlé změny nebo skoky v hodnotách derivace. Tyto hroty indikují potenciální artefakty při přerušení kontaktu elektrody s pokožkou pacienta. Taktéž je možné provést detekci na základě prahových hodnot, kdy nastavená prahová hodnota pro hodnoty derivace. To lze použít k automatické identifikaci segmentů s náhlými změnami signálu, které mohou být způsobeny elektrodovým poppingem. [10], [19]



## 2.4 Metody detekce odlehlých hodnot

Metody detekce odlehlých hodnot při extrakci příznaků EEG mají za cíl identifikovat datové body nebo úseky, které se významně odchyľují od očekávaného nebo normálního chování. Tyto metody využívají různé techniky, jako jsou statistické přístupy, algoritmy strojového učení nebo doménově specifická heuristika, k identifikaci odlehlých hodnot a jejich odlišení od základního EEG signálu. [27], [36]

### 2.4.1 Statistické metody

Detekce odlehlých hodnot na základě histogramu je přístup, jehož cílem je identifikovat a označit datové body, které se výrazně odchyľují od očekávaného rozložení hodnot. Tato metoda zahrnuje sestavení histogramu, který odhaduje rozložení frekvence výskytu hodnot, a poté použití statistických technik k identifikaci odlehlých hodnot. Analýzou tvaru, šířeni a hustoty histogramu lze odlehlé hodnoty identifikovat jako datové body, které spadají mimo určitý rozsah nebo vykazují výrazně odlišné rozloženi. [11], [27]

Lokální odlehlý faktor (LOF, z angl. *Local Outlier Factor*) je robustní metoda detekce odlehlých hodnot. Funguje na principu posouzení stupně odlehlosti datového bodu na základě jeho místní hustoty. Srovnání je provedeno se sousedními datovými body. Zvážením místní hustoty datových bodů může LOF efektivně identifikovat odlehlé hodnoty, které se odchyľují od okolního kontextu. LOF počítá skóre pro každý datový bod, přičemž vyšší skóre značí vyšší pravděpodobnost, že se jedná o odlehlou hodnotu. V kontextu extrakce rysů EEG lze LOF použít k identifikaci abnormálních segmentů EEG nebo rysů, které vykazují neobvyklé vzory, jako jsou artefakty nebo vzácné fyziologické události. [5], [27]

Úhlový detektor odlehlých hodnot (ABOD, z angl. *Angle-Based Outlier Detector*) je výkonná metoda detekce odlehlých hodnot, která měří úhly mezi datovými body ve vícerozměrném prostoru. ABOD vypočítává relativní úhly vytvořené datovým bodem vzhledem k jeho sousedním datovým bodům, což metodě umožňuje identifikovat odlehlé hodnoty na základě jejich odchylky od očekávaných úhlových vzorů. Při zohlednění úhlů spíše než vzdáleností je ABOD méně citlivý na vliv irrelevantních nebo hlučných dimenzí v prostoru prvků. V kontextu extrakce rysů EEG lze ABOD využít k detekci anomálních vzorců EEG nebo rysů, které vykazují významné odchylky od sousedních bodů. [15], [27]

Lokálně selektivní kombinace v paralelních odlehlých souborech (LSCPOE, z angl. *Locally Selective Combination in Parallel Outlier Ensembles*) je pokročilá metoda detekce odlehlých hodnot zahrnující několik algoritmů v EEG datech. Selektivním kombinováním výsledků těchto algoritmů na základě místních charakteristik

a vzorů dosahuje LSCPOE robustní a přesné detekce odlehlých hodnot. Tento přístup je zvláště užitečný při práci s různými odlehlými vzory a složitými distribucemi dat. [27], [35]

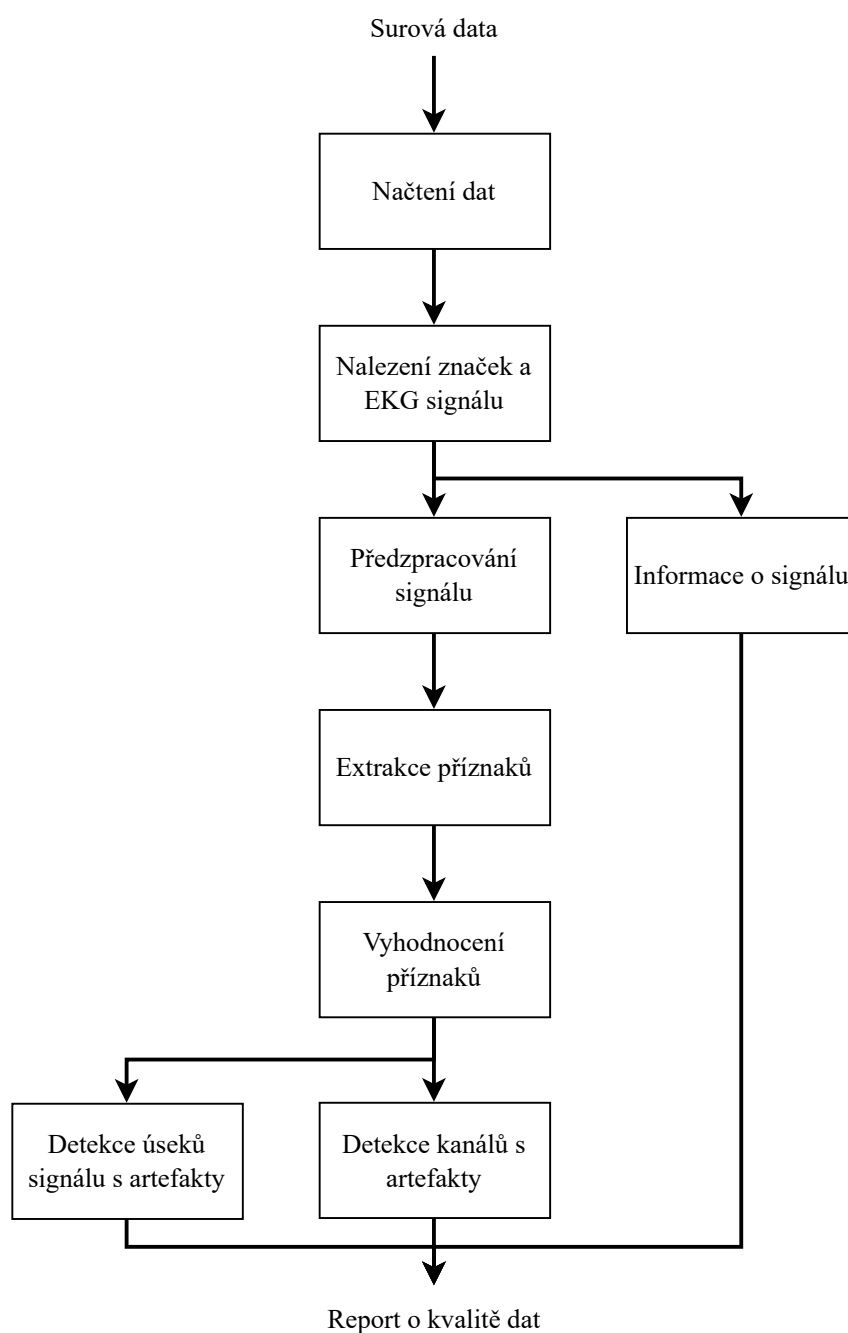
## 2.4.2 Metody založené na učení

Metody založené na učení jsou efektivními přístupy k detekci odlehlých hodnot. Tyto metody využívají sílu algoritmů strojového učení k automatickému rozpoznání vzorů a charakteristik normálních EEG signálů. Tréninkem na označených datech nebo použitím technik učení bez učitele mohou tyto metody zachytit přirozenou složitost a variabilitu EEG dat. Přístupy učení s učitelem využívají anotovaná tréninková data k trénování klasifikátorů, které dokážou rozlišit mezi normálními a abnormálními EEG vzory. Na druhé straně metody učení bez dozoru mají za cíl odhalit odlehlé hodnoty modelováním normální distribuce rysů EEG a identifikací případů, které se významně odchyľují od této naučené reprezentace. Metody založené na učení nabízejí výhody adaptability, škálovatelnosti a schopnosti zvládnout různé typy odlehlých hodnot, včetně artefaktů, anomálií nebo vzácných událostí. [3], [27]

Jednou z používaných metod založených na učení je jednotřídová metoda podpůrných vektorů (OCSVM, z angl. *One Class Support Vector Machine*). Jedná se o robustní metodu, kdy řízený algoritmus učení se učí charakteristiky normálních datových bodů a poté identifikuje odlehlé hodnoty jako datové body, které se výrazně odchyľují od naučeného normálního vzoru. Modelováním normálního chování funkcí EEG může detektor OCSVM účinně rozlišovat mezi normálními a abnormálními vzory. [1], [27]

### 3 Návrh a testování nástroje

Smysl navrženého nástroje je provést průzkumnou analýzu EEG dat a nalézt úseky signálu či celé kanály s artefakty a rušením. Nástroj automaticky nalezne a doporučí, o která místa se jedná. Výstupem nástroje je report o kvalitě dat. Nástroj je navržen tak, aby bylo možné jej rozšířit o další metriky kvality. Blokové schéma nástroje je znázorněno na obrázku 3.1.



Obr. 3.1: Blokové schéma navrženého nástroje.

## 3.1 Načtení elektroencefalografických dat

Prvním krokem nástroje je načtení naměřených dat z datové struktury měřícího přístroje. Cílem načtení je převedení dat do formátu vhodnějšího pro další zpracování. Toho lze dosáhnout s pomocí volně dostupné knihovny FileIO jež je součástí sady nástrojů Fieldtrip. Tato sada softwarových nástrojů pro interaktivní programové prostředí MATLAB je vhodná pro analýzu dat z EEG, magnetoencefalografie a intrakraniální elektroencefalografie. Tato knihovna nabízí předzpracování a pokročilé analytické metody, jako je časově-frekvenční analýza, rekonstrukce signálu pomocí dipólů a neparametrické statistické testování. [25]

EEG data mohou nabývat různých datových formátů a tudíž i struktur daných výrobcem snímacího zařízení. Seznam datových formátů a výrobců podporovaných použitou knihovnou je uveden v tabulce 3.1. [25], [27], [36]

Tab. 3.1: Seznam podporovaných datových formátů podle výrobců. [25]

Výrobce EEG přístroje	Datové formáty
ANT Neuro	.avr, .cnt, .trg
Besa	.avr, .swf
Biosemi BDF	.bdf
Brain Products	.eeg, .seg, .dat, .vhdr, .vmrk
Cambridge Electronic Design	.smr
EEGLAB	.set, .fdt
Magstim Electrical Geodesics, Inc.	.egis, .ave, .gave, .ses, .raw, .mff
NeuroScan	.eeg, .cnt, .avg
Nexstim	.nxe
TMSi	.Poly5
Generické standardní formáty	.edf, .gdf

Poskytnutá EEG data z laboratoře multimodálního a funkčního zobrazování Středoevropského technologického institutu Masarykovy univerzity (CEITEC MU) jsou pouze ve dvou datových formátech - Meta File Format (MFF) a Brain Vision File Format (BVFF) z důvodu použití EEG systémů od výrobců Magstim Electrical Geodesics, Inc. (Magstim EGI) a Brain Products (BP).

MFF je formát souboru speciálně navržen pro ukládání a organizování EEG dat spolu se souvisejícími metadaty. MFF poskytuje komplexní strukturu pro ukládání různých komponent EEG experimentů, včetně nezpracovaných EEG záznamů, značek událostí, pozic elektrod, informací o snímaných pacientech a experimentálních protokolů. Tento formát umožňuje snadný přístup, správu a sdílení dat EEG napříč

různými analytickými platformami a softwarovými nástroji. Formát MFF podporuje interoperabilitu a standardizaci v analýze signálu EEG a usnadňuje reprodukovatelnost výzkumných zjištění a spolupráci mezi výzkumníky v oblasti neurovědy. Veškeré informace je možné získat načtením souboru s koncovkou `.mff`. [25]

BVFF je široce používaný formát souborů při analýze signálu EEG od výrobce BP. Je speciálně navržen pro ukládání a výměnu EEG dat spolu s přidruženými metadaty. BVFF poskytuje standardizovanou strukturu pro ukládání nezpracovaných záznamů EEG, konfigurací elektrod, značek událostí a dalších relevantních informací. Tento formát podporuje kompatibilitu mezi různými systémy EEG a softwarovými nástroji, což usnadňuje sdílení dat a spolupráci mezi výzkumníky. Oproti předchozímu formátu je nutné pro správnou analýzu načíst tři samostatné soubory. Metadata jsou uložena v souboru s koncovkou `.vhdr`, soubor textových značek s koncovkou `.vmrk` obsahuje informace o událostech v datech a hodnoty napětí EEG jsou uloženy jako binární soubor s koncovkou `.eeg`. Výhoda BVFF oproti MFF je, že se jedná o schválený formát standardu Brain Imaging Data Structure (BIDS). Ten vznikl jako jednoduchý a snadno použitelný způsob organizace komplikovaných dat neurologických experimentů. [25]

## 3.2 Přípravné práce se signálem

Pro určení kvality EEG záznamu je taktéž nutné stanovit přítomnost značek v záznamu. Značky v datech EEG slouží k označení a pojmenování konkrétních událostí nebo časových bodů zájmu během záznamu EEG. Při snímání EEG dat je často snímán i EKG signál. Po odhalení přítomnosti EKG signálu je nalezený kanál odstraněn z dat pro další analýzu a do reportu o kvalitě je uložena logická hodnota o přítomnosti EKG.

Po načtení dat je nutné provést jejich předzpracování s co nejmenším vlivem na informaci v surových datech. Předzpracování se skládá z filtrace a transformace dat. Pro odstranění lineárního posunu v surových EEG datech je provedena filtrace filtrem typu horní propust s mezní frekvencí  $1\text{ Hz}$ . Specificky je použit Butterworthův filtr druhého řádu. Kvůli požadavkům funkce v MATLAB toolboxu je nutné normalizovat mezní frekvenci pomocí vztahu:

$$f'_m = \frac{f_m}{\frac{1}{2}f_{vz}}, \quad (3.1)$$

kde  $f'_m$  je normalizovaná mezní frekvence filtru  $[Hz]$ ,  $f_m$  je mezní frekvence filtru  $[Hz]$  a  $f_{vz}$  je vzorkovací frekvence  $[Hz]$ . Po provedení filtrace je provedeno zkrácení celkové délky dat na délku  $N'$ , protože metody v následné analýze extrahují příznak

pro úseky signálu o délce jedné vteřiny. Zkrácení lze popsat vztahem

$$N' = N - (N \bmod f_{vz}), \quad (3.2)$$

kde  $N'$  je délka zkrácených dat,  $N$  je délka původních dat a  $N \bmod f_{vz}$  je výsledek operace modulo - celočíselný zbytek po dělení původní délky dat vzorkovací frekvencí. Posledním krokem předzpracování je transformace dat z 2D do 3D struktury, která je vhodnější pro implementaci existujících funkcí v prostředí MATLAB. Původní 2D struktura označuje fakt, že každý z  $M$  kanálů obsahuje signál o stejné délce  $N$ .

### 3.3 Výpočet příznaků

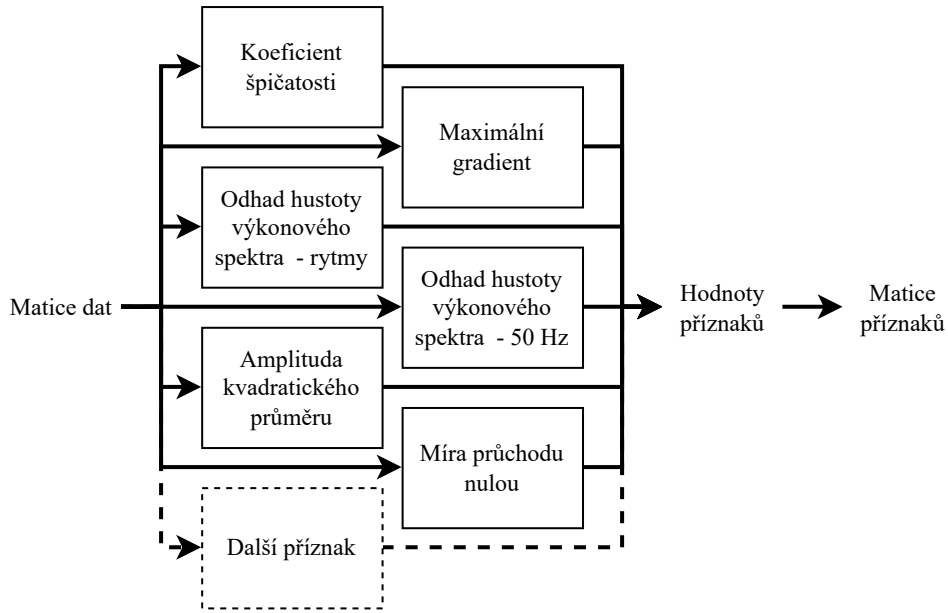
Obecné schéma předzpracování je znázorněno na obrázku 3.2. Proces výpočtu příznaků se skládá z aplikování různých funkcí na stejná data.



Obr. 3.2: Obecné blokové schéma výpočtu příznaků.

Na předzpracovaná data jsou aplikovány veškeré funkce extrakce příznaků podle schématu znázorněného na obrázku 3.3, které rozšiřuje předešlé schéma. Popis významu dílčích funkcí je uveden níže. Při dodržení stejného formátu vstupů a výstupů funkce je možné rozšířit toolbox přidáním dalších funkcí pro výpočet parametrů.

Koeficient špičatosti je standardní statistická míra závažnosti konců distribuce vzorků, tedy udává, s jakou pravděpodobností vzorek obsahuje odlehlou hodnotu. Čím vyšší je pravděpodobnost odlehlých hodnot ve vzorku, tím větší je hodnota



Obr. 3.3: Blokové schéma výpočtu příznaků navrženého nástroje.

koeficientu. Podobně, čím rovnoměrnější je rozdělení, tím nižší je koeficient špičatosti vzhledem k normálnímu rozdělení. Pomocí následujícího vztahu je možné vypočítat koeficient špičatosti pro signál  $x$  délky  $N$

$$K = \frac{\frac{1}{N} \sum_{n=1}^N (x(n) - \bar{x})^2}{\left[ \frac{1}{N} \sum_{n=1}^N (x(n) - \bar{x})^2 \right]^2}, \quad (3.3)$$

kde  $x(n)$  je hodnota vzorku signálu na aktuální pozici,  $\bar{x}$  je průměrná hodnota vzorků v okně.

Maximální gradient signálu EEG je největší rozdíl mezi všemi sousedními vzorky v okně. Toto je běžně používaná metoda detekce artefaktů v analýzách EEG, kde se krok  $10\mu V/ms$  často používá jako práh pro indikaci jakéhokoli vysokoamplitudového či vysokofrekvenčního artefaktu, který vytváří rychlé změny snímaného napětí. Maximální gradient lze vypočítat pomocí vztahu

$$MG = \max[x(n) - x(n - 1)], \quad (3.4)$$

kde  $MG$  je hodnota maximálního gradientu,  $x(n)$  je hodnota vzorku signálu na aktuální pozici a  $x(n - 1)$  je hodnota vzorku signálu na předešlé pozici.

Výpočet střední kvadratické amplitudy (RMSA, z angl. *Root Mean Square Amplitude*) slouží jako cenná metrika pro detekci nadměrné svalové aktivity. Výpočtem RMSA signálu EEG nebo specifických frekvenčních pásem můžeme přesně identifikovat segmenty s výraznými artefakty způsobenými svalovou aktivitou. Vyšší hodnoty RMSA v těchto segmentech ukazují na zvýšenou svalovou interferenci a kontaminaci

signálu. Výpočet lze provést pomocí vztahu

$$RMSA = \sqrt{\frac{1}{N} \sum_{n=1}^N |x_n|^2}, \quad (3.5)$$

kde  $N$  je délka signálu  $x$  a  $x_n$  označuje  $n$ -tý vzorek signálu. [10]

Míra průchodu nulou (ZCR, z angl. *Zero-crossing Rate*) určuje míru s jakou se signál mění z pozitivních na negativní hodnoty. Je to ukazatel frekvence, při které je většina energie soustředěna ve spektru signálu. ZCR by se mělo zvyšovat u vysokofrekvenčních artefaktů a klesat u nízkofrekvenčních artefaktů, které způsobují posun EEG stopy od nulové čáry. Pomocí vztahu lze vypočítat

$$ZCR = \frac{1}{N} \sum_{n=1}^N |sgn[x(n)] - sgn[x(n-1)]|. \quad (3.6)$$

Frekvenční rozsah 1 až 50  $Hz$  pokrývá standardní pásma mozkových vln  $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$  a nízkých  $\gamma$  vln. Jako parametr popisující výkon spektra je získán odhad výkonové spektrální hustoty. Odhad výkonové spektrální hustoty  $S$  pro frekvenci  $f$  lze provést pro spojitý signál  $x$  v čase  $t$  podle vztahu

$$S(f) = \left| \int_0^{\infty} x(t) \cdot e^{-2\pi ft} dt \right|^2. \quad (3.7)$$

Využitím odhadu výkonové spektrální hustoty lze určit parametr  $P$  odhadující míru postižení signálu síťovým rušením o frekvenci 50  $Hz$ . Míra  $P$  je získána pomocí vztahu

$$P = \frac{S(50)}{S(\bar{f})}, \quad (3.8)$$


kde  $S(50)$  je odhad výkonové spektrální hustoty signálu pro frekvenci 50  $Hz$  a  $S(\bar{f})$  je hodnota odhadu celkové výkonové spektrální hustoty signálu. [7], [10]

### 3.4 Vyhodnocení příznaků a klasifikace

Hodnoty příznaků jsou standardizovány pomocí normativního hodnocení. Normativní hodnocení vychází z předpokladu, že dané hodnoty budou mít normální rozložení a na základě toho jim bude přidělena hodnota popisující, kolik směrodatných odchylek se daná hodnota nachází od střední hodnoty. Rozložení normativního hodnocení je znázorněno na obrázku 3.4. Hodnoty  $\mu$  - aritmetický průměr a  $\sigma$  - směrodatná odchylka jsou získány jako průměrná hodnota a směrodatná odchylka pro daný kanál všech poskytnutých EEG dat bez artefaktů. [7]

Prvotním měřítkem hodnocení kvality EEG dat je spočítání skóre pro všechny segmenty daného kanálu  $S_1, S_2, \dots, S_n$ , jak je znázorněno na obrázku 3.5. Pro příznak





Obr. 3.4: Rozložení normativního skórování. (převzato a upraveno z [7])

$P_n$  je výpočet proveden pomocí vztahu

$$\bar{P}_n = \frac{S_1 + S_2 + \dots + S_n}{N}, \quad (3.9)$$

kde  $S_1, S_2, \dots, S_n$  jsou normativně hodnocené hodnoty n-tého příznaku. Pro každý příznak je též vypočítáno  $R_0$  - kolik procent segmentů signálu bylo normativně ohodnoceno nulou. Takto lze zjistit kvalitu kanálu pro každý příznak, ovšem je možné zjistit i celkovou kvalitu kanálu. Pomocí vztahu

$$\sum S_n = P_1 + P_2 + \dots + P_n, \quad (3.10)$$

kde  $P_1, P_2, \dots, P_n$  jsou normativní hodnoty příznaků pro n-tý segment signálu. V takto vzniklém vektoru je vypočítáno  $R$  - kolik procent segmentů signálu přes všechny příznaky bylo normativně ohodnoceno nulou.

	$S_1$	$S_2$							$S_n$	$\bar{P}$	$R_0$	
$P_1$	0	0	1	0	1	2	0	1	0	0	0.5	60
	0	1	0	0	0	0	0	0	0	0	0.1	90
$P_n$	1	0	2	0	0	1	0	0	1	0	0.5	60
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮		
$\sum S$	1	1	3	0	1	2	0	1	1	0	1	30

Obr. 3.5: Ukázka procesu celkového hodnocení. (převzato a upraveno z [7])

Pro určení, zda daný signál nebo úsek signálu obsahuje artefakty je vyžita metoda podpurných vektorů (SVM, z angl. *Support Vector Machine*), která binárně klasifikuje úsek signálu na základě hodnot extrahovaných příznaků. Třídy označují,

zde se artefakt v daném úseku signálu vyskytuje nebo ne. Specificky se jedná o SVM s lineárním jádrem a desetinásobnou křížovou validací. Křížová validace je technika používaná k hodnocení výkonu modelu strojového učení. Desetinásobná křížová validace zahrnuje rozdělení datové sady na 10 zhruba stejných částí. Model je trénován na 9 z těchto částech a testován na zbývajících. Tento proces se iterativně opakuje 10krát, přičemž každá část funguje jednou jako testovací data. Výsledky jsou zprůměrovány, aby poskytly robustnější odhad výkonnosti modelu. Lineární jádro je jeden typ jádrové funkce používaný v metodách strojového učení. Předpokládá, že data lze v prostoru příznaků oddělit přímkou (nadrovinou). Lineární jádro je jednodušší ve srovnání s jinými, jako jsou jádra s polynomiální nebo radiální bází. Proces trénování a testování tohoto klasifikátoru je popsán v sekci 3.6.2. [1], [7], [27]

### 3.5 Report o kvalitě dat

Výsledkem nástroje je .pdf report o kvalitě EEG záznamu. Report se skládá ze čtyř stran, zabývajících se různými aspekty kvality signálu. [7]

Na první straně se nachází základní popisné informace o souboru, jako jeho název, počet kanálů, počet vzorků signálu pro kanál a vzorkovací frekvence. Dále je uvedena tabulka se jmény a četnostmi unikátních značek. Taktéž je uvedeno, zda je v souboru přítomný EKG signál a číslo jeho kanálu. [7]

Na druhé straně reportu jsou graficky znázorněné procentuální četnosti výskytu úseku signálu ohodnocených jinak než nulou pro každý příznak. Je zvoleno barevné škálování pro hodnoty četnosti. Zelená barva odpovídá výskytu úseků nenulově ohodnocených mezi nula až pěti procenty, zatímco žlutá barva intervalu pět až 20 % a červená nad 20 %. Mimo jiné se zde nachází tabulka zobrazující grafické informace.[7]

Na třetí straně se nachází tabulka a grafické znázornění celkové kvality signálu a také je zde graficky znázorněn výstup z binárního klasifikátoru. Ukázka reálného reportu je A. [7]

### 3.6 Testování implementovaného nástroje

Nástroj byl implementován v prostředí MATLAB R2021b se sadou nástrojů FieldTrip ve verzi 20230613 na přenosném počítači s procesorem Intel Core i5-4210M taktovaném na 2,60 GHz s 16 GB paměti RAM. Nástroj je implementován pomocí samostatně spustitelného skriptu Main.m využívající toolbox s autorem naprogramovanými funkcemi. [25]

### 3.6.1 Testování extrahovaných příznaků


Příznaky popsané v sekci 3.3 byly vybrány aby splňovaly následující kritéria:

1. Jednotlivé příznaky by měly být citlivé na artefakty s různou amplitudou a trváním v úseku EEG signálu.
2. Kombinaci příznaků lze použít k rozlišení mezi uměle simulovanými úseky EEG signálu bez a s artefakty.
3. Kombinované skóre příznaků by mělo být citlivé na artefakty v delším segmentu EEG signálu.

Pro ověření účinnosti daného příznaku je provedeno testování na umělých EEG datech. Ty mohou být modelovány pomocí autoregresivní (AR) funkce popsanou vztahem

$$x(t) = \alpha_1 \cdot (t - 1) + \alpha_2 \cdot (t - 2) + \alpha_3 \cdot (t - 3) + r(t), \quad (3.11)$$

kde  $\alpha_1$ ,  $\alpha_2$  a  $\alpha_3$  jsou koeficienty AR funkce a  $r(t)$  je bílý šum. Pro generování umělých EEG dat jsou získány úseky signálu EEG bez rušení z kanálu Cz pro veškeré poskytnuté záznamy. K nalezení signálu bez artefaktů a rušení jsou využity anotace poskytnutých dat. Z těchto dat je náhodně vybráno 55 úseků signálu pro odhad koeficientů Burgovou metodou. Tato metoda odhadu AR parametrů je založená na minimalizaci dopředné a zpětné chyby lineární predikce. Aplikací Burgovy metody jsou získány koeficienty, jejichž hodnoty jsou uvedeny v tabulce 3.2. Příklad simulovaného čistého EEG signálu je na obrázku 3.6. [4], [7], [26]



Obr. 3.6: Vteřinový úsek uměle vygenerovaného EEG signálu.

Tab. 3.2: Hodnoty koeficientů  $\alpha$ .

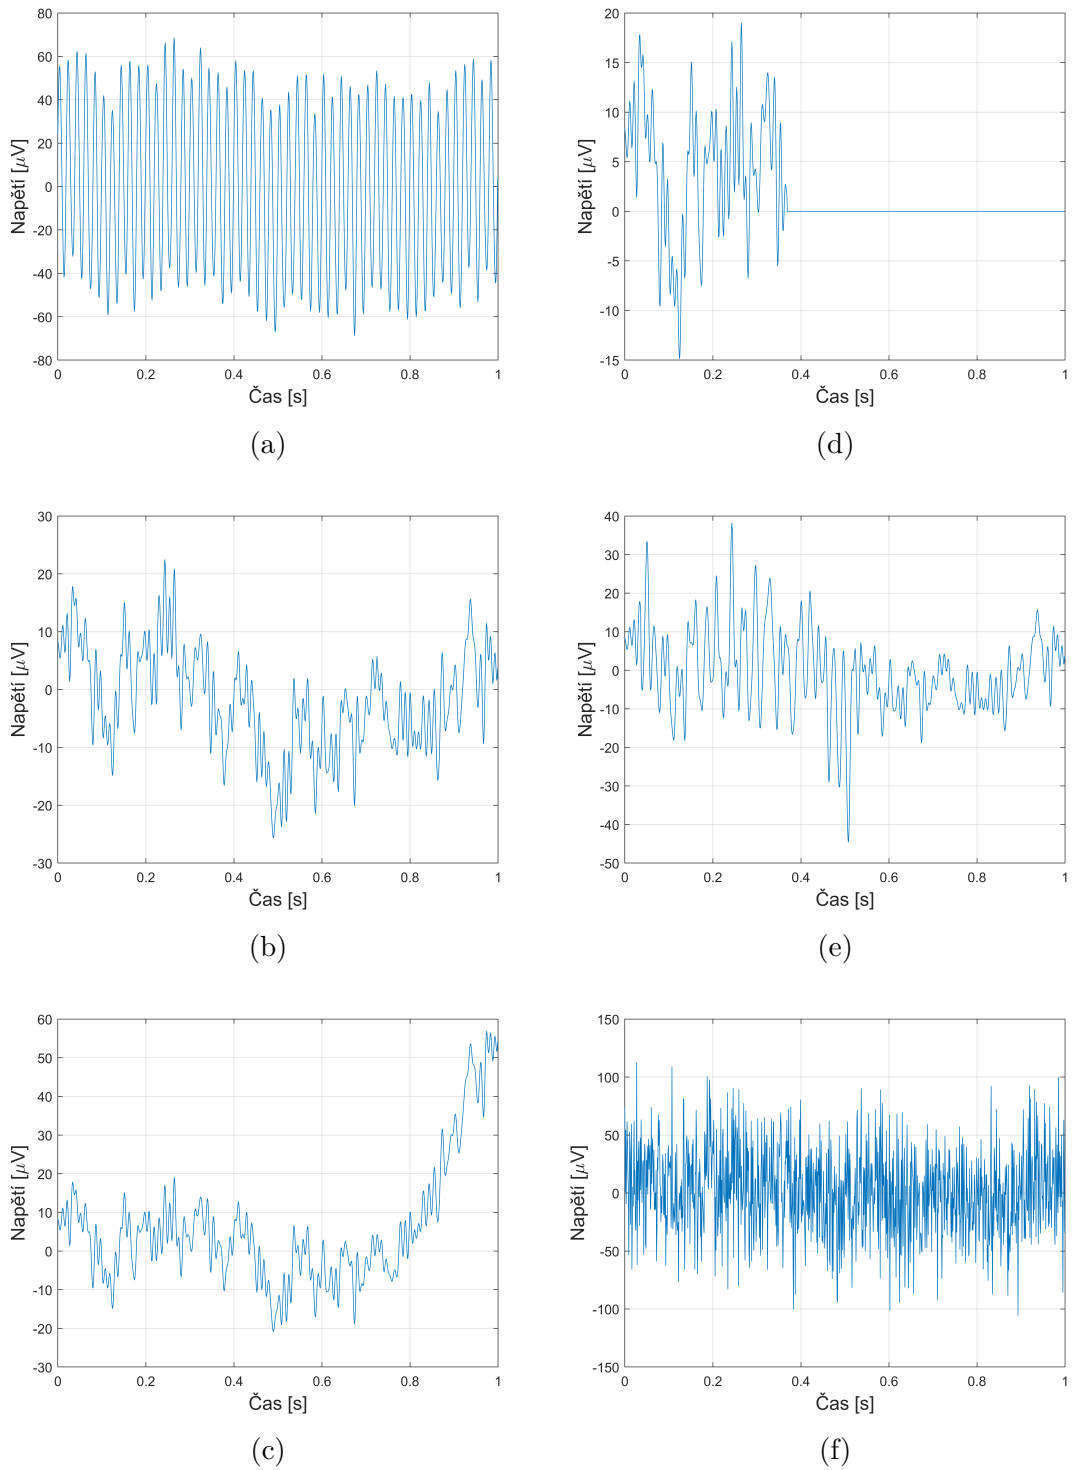
Koeficient	Hodnota
$\alpha_1$	-0,8820
$\alpha_2$	+0,2108
$\alpha_3$	-0,3287

Z veškerých artefaktů a rušení bylo pět druhů vybráno a simulováno za účelem přidání do umělého EEG signálu. Síťové rušení je simulováno jako sinusoida s frekvencí 50 Hz. Ztráta signálu, vznikající při ztrátách ve spojení s bezdrátovými EEG systémy, je modelována jako plochá čára. Nízkofrekvenční artefakty pohybů očí simulují mrknutí. Výsledný signál rušení je získán filtrací typu pásmová propust pro jeden až tři Hz signálu bílého šumu. Svalový artefakt, představující sevření čelistí nebo kontrakci obličejových a krčních svalů, je modelován bílým šumem filtrovaným pásmovou propustí mezi 20 až 60 Hz. Drift elektrody je simulován jako lineární funkce. Posledním simulovaným artefaktem je bílý šum, představující náhodný signál. Na obrázku 3.7 jsou znázorněny generované artefakty a bílý šum, ze kterého některé vychází. [7]

Pro posouzení citlivosti jednotlivých příznaků na každý z typů artefaktů různé je náhodně vytvořeno 100 úseků umělého EEG signálu o délce jedné vteřiny. Pro každý úsek jsou přidány artefakty s různou amplitudou (1  $\mu V$ , 2  $\mu V$ , 5  $\mu V$ , 10  $\mu V$ , 20  $\mu V$ , 50  $\mu V$  a 100  $\mu V$ ) a délkou trvání (0,25 s, 0,5 s a 1 s). Pro každou situaci - artefakt, amplituda a trvání je vypočítána hodnota příznaku. [7]

### 3.6.2 Testování klasifikátoru

Pro trénování klasifikátoru bylo náhodně vygenerováno 1000 segmentů signálu bez artefaktů od délce jedna sekunda a 1000 1sekundových segmentů signálu s artefakty. Typ artefaktu jeho amplituda a trvání byly náhodně přiřazeny. K otestování statistické významnosti SVM byla použita metoda neparametrické permutace. Klasifikační třídy - úsek signálu s artefaktem nebo bez jsou náhodně přerozděleny mezi všechny sady dat a klasifikátor SVM projde procesem učení. Takto je iterativně proveden výpočet 500krát, za účelem vytvoření nulového rozdělení, se kterým lze porovnat přesnost klasifikace. Metoda neparametrické permutace je statistická technika používaná k posouzení statistické významnosti výkonu modelu. Zahrnuje permutaci klasifikační třídy v datové sadě při zachování pozic příznaků, za účelem vytvoření nulové distribuce metrik výkonu. Porovnáním skutečného výkonu modelu s tímto nulovým rozdělením můžete určit, zda je výkon modelu lepší, než náhoda. [7]



Obr. 3.7: Vteřinové úseky uměle generovaného EEG signálu s artefakty: (a) - síťové rušení, (b) - oční artefakty, (c) - drift, (d) - ztráta kontaktu, (e) - svalový artefakt a (f) - bílý šum. [7]

### 3.6.3 Implementace nástroje na reálných datech

Na poskytnutá EEG data z laboratoře multimodálního a funkčního zobrazování CEITEC MU byla aplikována základní průzkumná analýza a zjištěné vlastnosti dat jsou uvedeny v tabulce 3.3. Mezi hledané atributy patří počet kanálů v záznamu, vzorkovací frekvence ( $f_{vz}$ ), počet vzorků signálu, přítomnost značek a EKG signálu.

Tab. 3.3: Seznam s veškerými poskytnutými soubory a jejich vlastnostmi.

ID souboru	Počet kanálů	$f_{vz}$	Počet vzorků	Značky	Přítomnost EKG
1	258	1000	211490	ANO	NE
2	258	1000	213745	ANO	ANO
3	258	1000	213595	ANO	ANO
4	258	1000	212691	ANO	ANO
5	258	1000	212652	ANO	ANO
6	258	1000	212159	ANO	ANO
7	258	1000	212479	ANO	ANO
8	258	1000	210927	ANO	ANO
9	258	1000	215159	ANO	ANO
10	258	1000	211591	ANO	ANO
11	258	1000	210961	ANO	ANO
12	258	1000	210401	ANO	ANO
13	258	1000	210975	ANO	ANO
14	258	1000	214494	ANO	ANO
15	258	1000	213861	ANO	ANO
16	258	1000	212603	ANO	ANO
17	258	1000	213856	ANO	ANO

Z tabulky vyplývá, že veškeré soubory mají stejný počet kanálů, vzorkovací frekvenci, obsahují značky a mají přibližně stejnou dobu trvání. Jediný první soubor se liší tím, že neobsahuje EKG signál v datech. První soubor se také proti zbytku liší tím, že se jedná o formát BVFF oproti ostatním ve formátu MFF.

Další analýzou dat byly získány informace v tabulce 3.4. Cílem této analýzy bylo nalezení unikátních jmen značek a jejich četností spolu s kanálem EKG. [25]

Tab. 3.4: Seznam unikátních značek, jejich četností a čísla kanálu EKG.

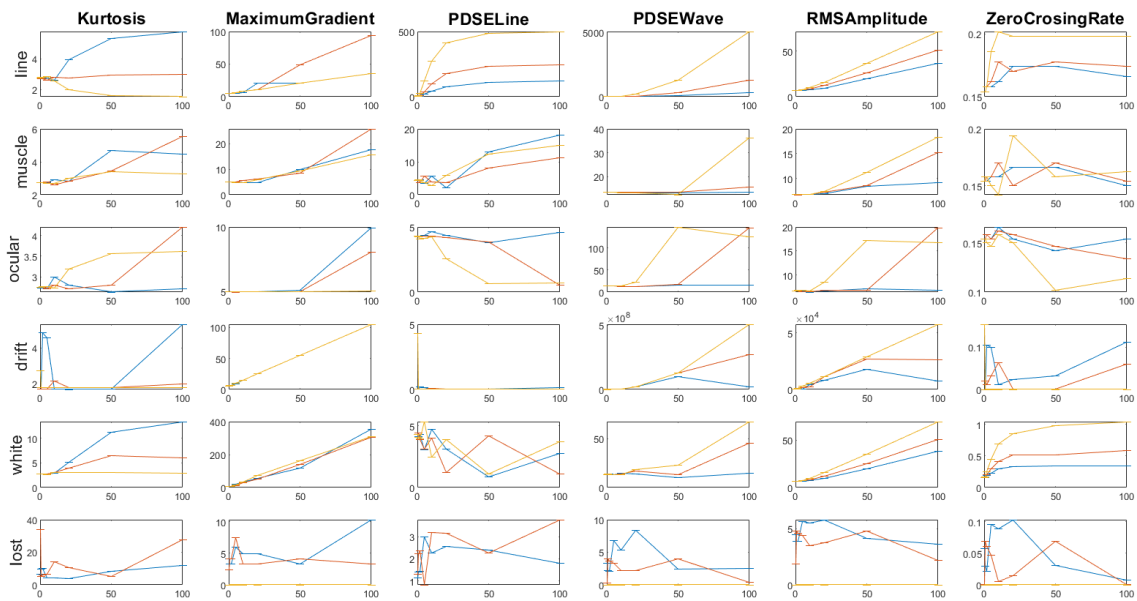
ID souboru	Jména značek	Četnosti značek	EKG kanál
1	DI16, DIN3	1, 102	-
2	DI16, DIN3	51, 50	258
3	DI16, DIN3	49, 50	258
4	DI16, DIN3	10, 50	258
5	DI16, DIN3	51, 50	258
6	DI16, DIN3	50, 50	258
7	DI16, DIN3	50, 50	258
8	DI16, DIN1, DIN3	46, 1, 50	258
9	DI16, DIN1, DIN3	50, 1, 50	258
10	DI16, DIN3	50, 50	258
11	DI16, DIN3	40, 50	258
12	DI16, DIN3	48, 50	258
13	DI16, DIN3	50, 50	258
14	DI16, DIN3	47, 50	258
15	DI16, DIN3	50, 50	258
16	DI16, DIN1, DIN3	50, 1, 50	258
17	DI16, DIN3	50, 50	258

## 4 Diskuze naměřených výsledků

V předchozí kapitole je popsán návrh a implementace nástroje pro automatické hodnocení kvality EEG dat. V této kapitole budou diskutovány výsledky a spolehlivost jednotlivých metrik, skórovacího algoritmu a výsledného reportu.

### 4.1 Senzitivita příznaků

Grafy s chybovými úsečkami pro každý příznak vzhledem k měnícím se amplitudám a trváním artefaktů jsou zobrazeny na obrázku 4.1. Řádky představují různé typy artefaktů a každý sloupec příznak kvality.



Obr. 4.1: Grafy s chybovými úsečkami pro každý příznak.

Z grafů vyplývá několik poznatků. Příznaky jsou vysoce citlivé na velikost amplitudy simulovaných artefaktů. Každý typ artefaktu se projeví na několika příznacích, ale ne každý příznak je ovlivněn každým z modelovaných typů artefaktů. Platí že, čím nižší je amplituda artefaktu, tím menší je rozdíl hodnoty příznaku od kontroly - úseku umělého signálu bez artefaktu. Hodnoty příznaku pro artefakty s amplitudou v rozsahu 1 až  $5 \mu V$  jsou obvykle v rozsahu hodnot pro umělý signál bez artefaktu. U příznaků maximální gradient (**MaximumGradient**) a odhad hustoty výkonového spektra pro  $50 \text{ Hz}$  (**PSDELine**) je zvýšená schopnost detekovat artefakty při nižších amplitudách. Příznaky jsou také citlivé na délku trvání artefaktu. Z grafů též vyplývá, že u některých příznaků je těžké rozlišit mezi různými délkami trvání artefaktu a amplitudami. U některých kombinací příznak - artefakt není výstup hledaná závislost.

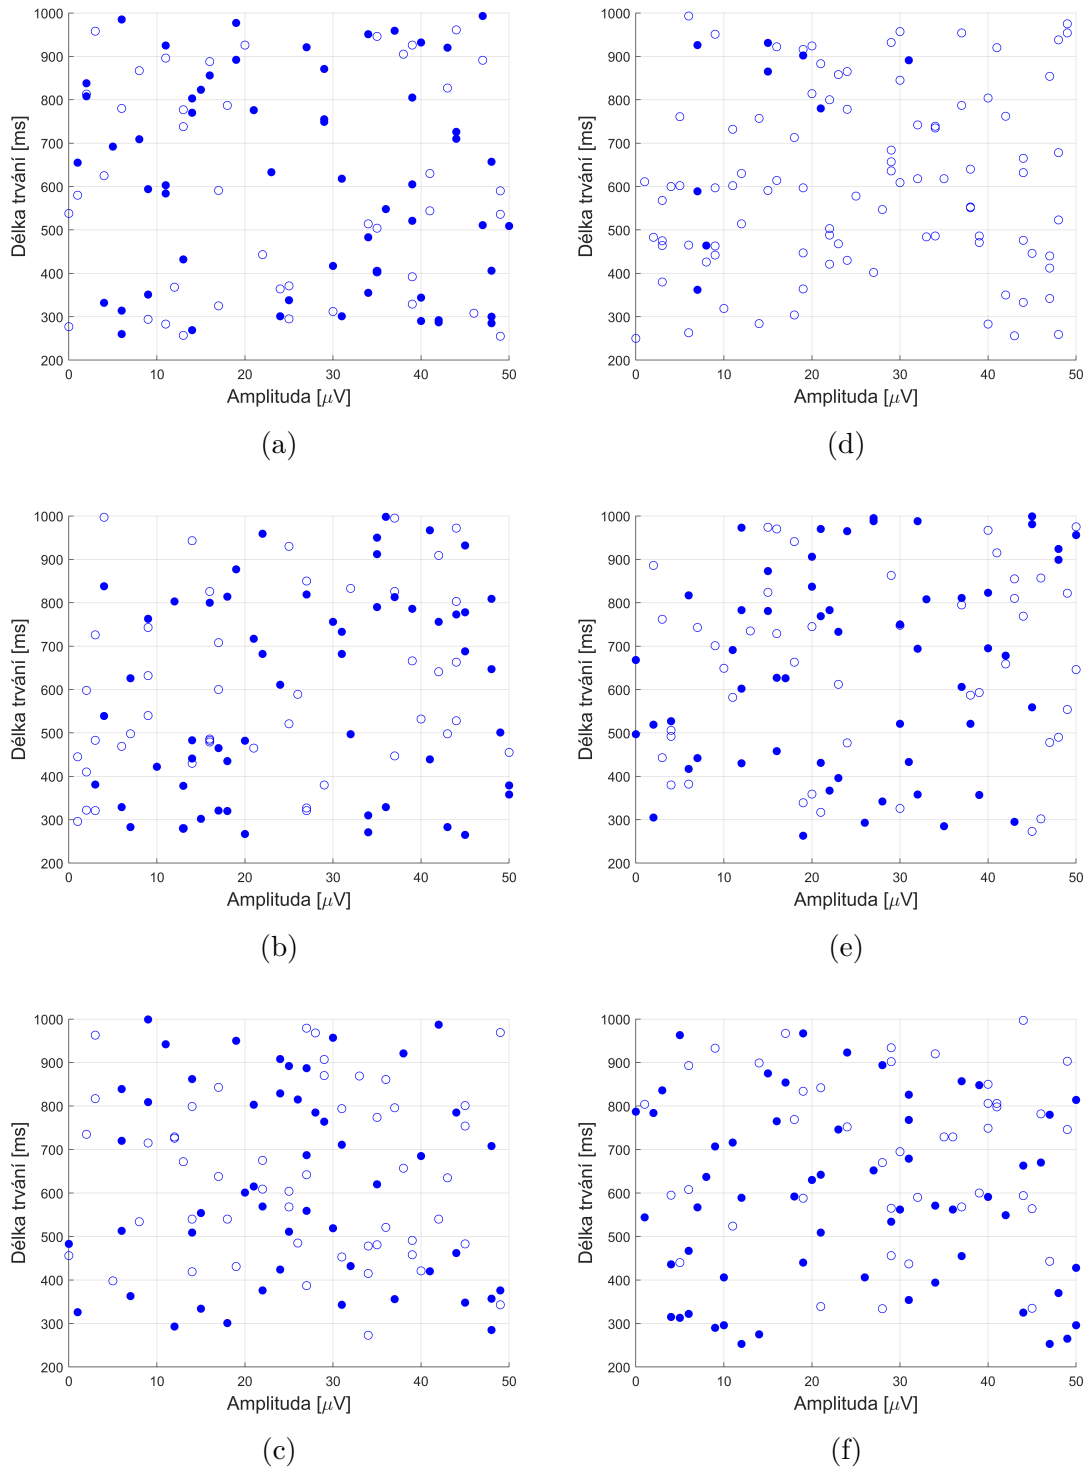


Trénování a testování extrakce příznaků bylo provedeno na simulovaných datech. Zatímco simulované úseky EEG signálu bez artefaktů byly modelovány na skutečném EEG signálu pomocí AR modelu, je možné, že některé úseky simulovaného EEG signálu nepředstavují skutečnou EEG signál zdravého člověka. Volba simulace EEG dat byla zvolena kvůli lepší kvantifikaci řízením vlastností artefaktu.

## 4.2 Klasifikátor

Klasifikátor dosáhl přesnosti 0,5960, senzitivity 0,1363 a specifity 1,000. Dosažená přesnost 0,5960 odráží celkovou správnost predikcí klasifikátoru. Tato hodnota ukazuje, že přibližně 0,5960 případů bylo klasifikováno správně, což zdůrazňuje schopnost klasifikátoru přesně rozlišovat mezi třídami. Je však důležité vzít v úvahu také metriky citlivosti a specifity, abyste získali komplexní pochopení výkonu klasifikátoru. Citlivost, známá také jako skutečná pozitivní míra, ukazuje na schopnost klasifikátoru správně identifikovat instance patřící do konkrétní třídy. V tomto případě získaná citlivost 0,1363 ukazuje, že klasifikátor účinně identifikoval pouze relativně malou část instancí patřících do pozitivní třídy. Na druhé straně specifita neboli skutečná negativní míra představuje kvalifikaci klasifikátoru ve správné klasifikaci instancí z negativní třídy. Se specifičností 1,000 vykazoval klasifikátor chvályhodnou schopnost přesně identifikovat instance z negativní třídy, čímž prokázal svou schopnost s vysokou přesností rozeznat nepozitivní instance. Jednotlivé výsledky klasifikace pro každý z druhů rušení jsou znázorněny na obrázku 4.2, kde modrý bod bez výplně označuje správnou klasifikaci, zatímco plný bod nesprávnou.

Výsledky testování na hladině významnosti  $p < 0,05$  potvrdily je statisticky významný výkon SVM, tudíž výsledek klasifikace není náhodný. Vzhledem k náhodnému vylosování typu artefaktu, amplitudy a trvání artefaktů použitých v podmínkách šumu byla úspěšnost detekce dostačující. Z výsledků vyplývá, že pro klasifikátor je problematické provést klasifikaci pro veškeré rušení krom ztráty kontaktu. Největší počet správných klasifikací se vyskytl u ztráty kontaktu a driftových artefaktů. Lze tedy usuzovat, že pro nízkofrekvenční rušení fungoval klasifikátor lépe. Vzhledem k extrémně nízké amplitudě těchto artefaktů vzhledem k EEG pozadí je však nepravděpodobné, že by tyto artefakty byly identifikovány také inspekcí. Podle autorů článku [7] bylo použito lineární jádro, ovšem použití jiného jádra, nebo využitím prostorové transformace by mohlo pomoci. Jak je zmíněno výše, tak možným zdrojem nedostatečně vysoké přesnosti klasifikace mohou být umělá EEG data.



Obr. 4.2: Rozdělení přesnosti klasifikace SVM vzhledem k délce trvání a amplitudě pro každý typ simulovaného artefaktu: (a) - síťové rušení, (b) - oční artefakty, (c) - drift, (d) - ztráta kontaktu, (e) - svalový artefakt a (f) - bílý šum. [7]

## 4.3 Detekce úseků signálu s artefakty v reálných datech

Využitím klasifikátoru popsaného výše jsou porovnány hodnoty z klasifikátoru proti anotovaným datům. Porovnávaly se úseky signálu s artefakty. Naměřené statistické veličiny pro každý soubor jsou uvedeny v tabulce

Tab. 4.1: Naměřené statistické veličiny detekce úseků signálu.

ID souboru	Přesnost	Senzitivita	Specifická
1	0,6950	0,3762	1,0000
2	0,8333	1,0000	0,0000
3	0,9777	1,0000	0,0000
4	0,9816	1,0000	0,0000
5	0,8592	1,0000	0,0000
6	0,9832	1,0000	0,0000
7	0,7410	1,0000	0,0000
8	0,9911	1,0000	0,0000
9	0,9665	0,9952	0,0008
10	0,9604	1,0000	0,0000
11	0,9991	1,0000	0,0000
12	0,9943	0,9952	0,0048
13	0,9963	1,0000	0,0000
14	0,9972	0,9948	0,0052
15	0,9173	1,0000	0,0000
16	0,8519	1,0000	0,0000
17	0,9299	1,0000	0,0000

Z výsledků v tabulce je patrné, že klasifikátor dosáhl vysoké přesnosti (průměrně nad 90%), což svědčí o dobré klasifikaci. Ovšem při bližším pohledu na senzitivitu a specifickou je patrné, že klasifikátor nedostatečně splnil svoji roli. Opakuje se případ klasifikátoru při klasifikaci hodnot příznaků.

Dalším možným důvodem nízké úspěšnosti může být fakt, že při práci se signál v kódu nástroje je rozdělen na vzájemně nepřekrývající se okna. Tudíž pokud počátek nebo konec artefaktu se nachází mezi vícero okny, krajní okna nebudou detekována. Dalším možným důvodem vysoký šum a rychlé změny hodnot napětí na začátku a konci měření.

Celkové zhodnocení nástroje je komplikované, neboť dílčí části nástroje samostatně fungují na testovacích datech, ale při aplikaci dat reálných dojde k výraz-

nému zhoršení výsledků. Prvním možným zlepšením je extrakce jiných příznaků, nebo použití metod redukce dimensionality jako je metoda hlavních komponent. Autoři článku [7] úspěšně použili metodu SVM s lineárním jádrem, ale při zkoumání rozložení dat se nabízí použití jiného jádra nebo použití jiné klasifikační metody (např. neuronová síť).

## Závěr

Tato práce ponořila do komplexního průzkumu návrhu inovativního nástroje pro automatizované hodnocení kvality elektroencefalografických (EEG) dat. Teoretický základ poskytl zasvěcené pochopení složité anatomie centrálního nervového systému a mozku a připravil půdu pro podrobné vysvětlení geneze a šíření akčních potenciálů v nervovém systému. Následné zaměření na EEG přineslo důkladný přehled postupů záznamu EEG, zahrnující identifikaci převládajících artefaktů, které mohou zkreslit zaznamenané signály. Metody objasněné pro detekci a odstranění artefaktů sloužily jako klíčové mechanismy pro odvození základních vlastností kvality dat.

Práce se přesunula do praktické oblasti a vydala se na pečlivou cestu nastínění procesu vývoje za automatickým nástrojem pro hodnocení kvality EEG. Tento nástroj byl důsledně hodnocen jak pomocí umělých, tak reálných datových scénářů, což podtrhuje jeho účinnost při hodnocení kvality dat se zvýšenou úrovní přesnosti a účinnosti. Integrace teoretických poznatků a praktické realizace podtrhla mnoho-  
rozměrný charakter tohoto úsilí.

V závěrečných kapitolách se práce zabývá výsledky výkonu nástroje se zvláštním důrazem na jeho schopnost identifikovat kanály nebo segmenty kontaminované artefakty. Kromě toho byly otevřeny možnosti potenciálního rozšíření tohoto nástroje.

## Literatura

- [1] ABE, Shigeo. *Support Vector Machines for Pattern Classification*. 2nd ed. 2010. London: Springer London, 2010. Advances in Computer Vision and Pattern Recognition. ISBN 978-1-84996-098-4.
- [2] ABHANG, Priyanka A., Bharti W. GAWALI a Suresh C. MEHROTRA. *Introduction to EEG- and Speech-Based Emotion Recognition*. London: Elsevier Health Sciences, 2016. ISBN 978-0-12-804490-2.
- [3] AGGARWAL, Charu C. *Data Mining: The Textbook*. Cham: Springer International Publishing, 2015. ISBN 978-3-319-14142-8.
- [4] BIN NG, Wei, A SAIDATUL, Y.F CHONG a Z IBRAHIM. PSD-Based Features Extraction For EEG Signal During Typing Task. *IOP Conference Series: Materials Science and Engineering*. 2019, 2019-06-01, **557**(1). ISSN 1757-8981. Dostupné z: doi:10.1088/1757-899X/557/1/012032
- [5] BREUNIG, Markus M., Hans-Peter KRIEGEL, Raymond T. NG a Jörg SANDER. LOF. *ACM SIGMOD Record*. 2000, **29**(2), 93-104. ISSN 0163-5808. Dostupné z: doi:10.1145/335191.335388
- [6] ČECH, Svatopluk a Drahomír HORKÝ. *Přehled obecné histologie*. 2., přeprac. vyd. Brno: Masarykova univerzita, 2011. ISBN 978-80-210-5543-8.
- [7] FICKLING, Shaun D., Careesa C. LIU, Ryan C. N. D'ARCY, Sujoy GHOSH HAJRA a Xiaowei SONG. Good data? The EEG Quality Index for Automated Assessment of Signal Quality. *2019 IEEE 10th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*. IEEE, 2019, 2019, 0219-0229. ISBN 978-1-7281-2530-5. Dostupné z: doi:10.1109/IEMCON.2019.8936246
- [8] HIRSCH, Lawrence J. a Richard P. BRENNER. *Atlas of EEG in Critical Care*. Chichester: John Wiley & Sons, 2010. ISBN 978-0-470-98786-5.
- [9] JAN, Jiří. *Medical image processing, reconstruction and restoration: concepts and methods*. 2. vydání. Boca Raton: Taylor & Francis, 2006. ISBN 0-8247-5849-8.
- [10] JIANG, Xiao, Gui-Bin BIAN a Zean TIAN. Removal of Artifacts from EEG Signals: A Review. *Sensors*. 2019, **19**(5). ISSN 1424-8220. Dostupné z: doi:10.3390/s19050987

- [11] KALAYCI, Ilker a Tuncay ERCAN. Anomaly Detection in Wireless Sensor Networks Data by Using Histogram Based Outlier Score Method. *2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*. IEEE, 2018, 2018, 1-6. ISBN 978-1-5386-4184-2. Dostupné z: doi:10.1109/ISMSIT.2018.8567262
- [12] KANIUSAS, Eugenijus. *Biomedical signals and sensors III: linking electric bio-signals and biomedical sensors*. Cham: Springer, [2019]. Biological and medical physics, biomedical engineering. ISBN 978-3-319-74916-7.
- [13] KAPLAN, Peter W. a Thien NGUYEN. *Clinical Electrophysiology: A Handbook for Neurologists*. Chichester: Wiley-Blackwell, 2011. ISBN 978-1-405-18529-5.
- [14] KRAJČA, Vladimír a Jitka MOHYLOVÁ. *Číslíkové zpracování neurofyziologických signálů*. V Praze: České vysoké učení technické, 2011. ISBN 978-80-01-04721-7.
- [15] KRIEGEL, Hans-Peter, Matthias SCHUBERT a Arthur ZIMEK. Angle-based outlier detection in high-dimensional data. *Proceedings of the 14th ACM SIG-KDD international conference on Knowledge discovery and data mining*. New York, NY, USA: ACM, 2008, 2008-08-24, 444-452. ISBN 9781605581934. Dostupné z: doi:10.1145/1401890.1401946
- [16] LUU, Phan, Zhongqing JIANG, Catherine POULSEN, Chelsea MATTSON, Anne SMITH a Don M. TUCKER. Learning and the Development of Contexts for Action. *Frontiers in Human Neuroscience*. 2011, **5**. ISSN 1662-5161. Dostupné z: doi:10.3389/fnhum.2011.00159
- [17] MARCUSE, Lara V., Madeline C. FIELDS a Jiyeoun YOO. *Rowan's Primer of EEG*. 2nd. Edinburgh: Elsevier Health Sciences, 2016. ISBN 978-0-323-35387-8.
- [18] MELOUN, Milan a Jiří MILITKÝ. *Kompendium statistického zpracování dat: metody a řešené úlohy včetně CD*. Praha: Academia, 2002. ISBN 80-200-1008-4.
- [19] MICHEL, Christoph M., Thomas KOENIG, Daniel BRANDEIS, Lorena R.R. GIANOTTI a Jiří WACKERMANN. *Electrical Neuroimaging*. New York: Cambridge University Press, 2009. ISBN 978-0-521-87979-8.
- [20] MORNSTEIN, Vojtěch. *Lékařská fyzika a biofyzika*. Brno: Masarykova univerzita, 2020. ISBN 978-80-210-8984-6.
- [21] MOUREK, Jindřich. *Fyziologie: učebnice pro studenty zdravotnických oborů*. 2., dopl. vyd. Praha: Grada, 2012. Sestra (Grada). ISBN 978-80-247-3918-2.

- [22] MULERT, Christoph a Louis LEMIEUX. *EEG - fMRI: Physiological Basis, Technique, and Applications*. Heidelberg: Springer Berlin, 2016. ISBN 978-3-662-50150-4.
- [23] NEVEU, Cutris. Anatomy of neuron. In: *Wikimedia Commons* [online]. [cit. 2023-08-09]. Dostupné z: [https://commons.wikimedia.org/wiki/File:Anatomy\\_of\\_neuron.png](https://commons.wikimedia.org/wiki/File:Anatomy_of_neuron.png)
- [24] NICHOLLS, John G. *Od neuronu k mozku*. Praha: Academia, 2013. ISBN 978-80-200-2155-7.
- [25] OOSTENVELD, Robert, Pascal FRIES, Eric MARIS a Jan-Mathijs SCHOFFELEN. FieldTrip: Open Source Software for Advanced Analysis of MEG, EEG, and Invasive Electrophysiological Data. *Computational Intelligence and Neuroscience*. 2011, **2011**, 1-9. ISSN 1687-5265. Dostupné z: doi:10.1155/2011/156869
- [26] PROAKIS, John G., Chrysostomos L. NIKIAS, Charles M. RADER, Fuyun LING, Marc MOONEN a Ian K. PROUDLER. *Algorithms for Statistical Signal Processing*. Upper Saddle River: Prentice Hall, 2002. ISBN 978-0-13-062219-8.
- [27] SABA-SADIYA, Sari, Eric CHANTLAND, Tuka ALHANAI, Taosheng LIU a Mohammad M. GHASSEMI. Unsupervised EEG Artifact Detection and Correction. *Frontiers in Digital Health*. 2021, **2**. ISSN 2673-253X. Dostupné z: doi:10.3389/fdgth.2020.608920
- [28] SANEI, Saeid a Jonathon A. CHAMBERS. *EEG Signal Processing*. Chichester: Wiley-Interscience, 2008. ISBN 978-0-470-02581-9.
- [29] SEECK, Margitta, Laurent KOESSLER, Thomas BAST, Frans LEIJTEN, Christoph MICHEL, Christoph BAUMGARTNER, Bin HE a Sándor BENICZKY. The standardized EEG electrode array of the IFCN. *Clinical Neurophysiology*. 2017, **128**(10), 2070-2077. ISSN 13882457. Dostupné z: doi:10.1016/j.clinph.2017.06.254
- [30] SHIN, Hyun-Chool, Xiaofeng JIA, Robert NICKL, Romergryko G. GEOCADIN a Nitish V. THAKOR. A Subband-Based Information Measure of EEG During Brain Injury and Recovery After Cardiac Arrest. *IEEE Transactions on Biomedical Engineering*. 2008, **55**(8), 1985-1990. ISSN 0018-9294. Dostupné z: doi:10.1109/TBME.2008.921093
- [31] SIULY, Siuly, Yan LI a Yanchun ZHANG. *EEG Signal Analysis and Classification: Techniques and Applications*. Cham: Springer International Publishing, 2017. ISBN 978-3-319-47652-0.



- [32] SÖRNMO, Leif a Pablo LAGUNA. EEG Signal Processing. *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. Elsevier, 2005, 2005, 55-179. ISBN 9780124375529. Dostupné z: doi:10.1016/B978-012437552-9/50003-9
- [33] SPRUSTON, Nelson. Pyramidal neurons: dendritic structure and synaptic integration. *Nature Reviews Neuroscience*. 2008, **9**(3), 206-221. ISSN 1471-003X. Dostupné z: doi:10.1038/nrn2286
- [34] TŮMA, Jiří. *Zpracování signálů získaných z mechanických systémů užitím FFT*. Praha: Sdělovací technika, 1997. ISBN 80-901-9361-7.
- [35] ZHAO, Yue, Zain NASRULLAH, Maciej K. HRYNIEWICKI a Zheng LI. LSCP: Locally Selective Combination in Parallel Outlier Ensembles. *Proceedings of the 2019 SIAM International Conference on Data Mining*. Philadelphia, PA: Society for Industrial and Applied Mathematics, 2019, 2019-05-06, 585-593. ISBN 978-1-61197-567-3. Dostupné z: doi:10.1137/1.9781611975673.66
- [36] ZHAO, Lingling, Yufan ZHANG, Xue YU, et al. Quantitative signal quality assessment for large-scale continuous scalp EEG from a big data perspective. *Physiological Measurement*. 2022. ISSN 0967-3334. Dostupné z: doi:10.1088/1361-6579/ac890d

## Seznam zkratek

<b>ABOD</b>	Úhlový detektor odlehlých hodnot (z angl. Angle-Based Outlier Detector)
<b>A/D</b>	Analogově-digitální
<b>AP</b>	Akční potenciál
<b>AR</b>	Autorekurzivní
<b>BIDS</b>	Brain Imaging Data Structure
<b>BP</b>	Brain Products
<b>BVFF</b>	Brain Vision File Format
<b>CMRR</b>	Činitel potlačení soufázového zesílení (z angl. Common-Mode Rejection Ratio)
<b>CNS</b>	Centrální nervová soustava
<b>ECoG</b>	Elektrokortikografie
<b>EEG</b>	Elektroencefalografie
<b>EMG</b>	Elektromyografie
<b>EOG</b>	Elektrookulografie
<b>EPSP</b>	Excitační postsynaptický potenciál
<b>FIR</b>	Konečná impulzní odezva (z angl. Finite Impulse Response)
<b>HD-EEG</b>	Elektroencefalografie s vysokou hustotou (z angl. <i>High Density Electroencephalography</i> )
<b>HRV</b>	Variabilita srdečního rytmu (z angl. Heart Rate Variability)
<b>ICA</b>	Analýza nezávislých komponent (z angl. Independent Component Analysis)
<b>iEEG</b>	Intrakraniální elektroencefalografie
<b>FN</b>	Falešně negativní (z angl. False Negative)
<b>FP</b>	Falešně pozitivní (z angl. False Positive)

<b>FIR</b>	Konečná impulzní odezva (z angl. Finite Impulse Response)
<b>IPSP</b>	Inhibiční postsynaptický potenciál
<b>LOF</b>	Lokální odlehlý faktor (z angl. Local Outlier Factor)
<b>LSCPOE</b>	Lokálně selektivní kombinace v paralelních odlehlých souborech (z angl. Locally Selective Combination in Parallel Outlier Ensembles)
<b>MAD</b>	Střední absolutní odchylka (z angl. Mean Absolute Deviation)
<b>MEG</b>	Magnetoencefalografie
<b>MFF</b>	Meta File Format
<b>MG</b>	Maximální gradient (z angl. Maximal Gradient)
<b>OCSVM</b>	Jednotřídová metoda podpůrných vektorů (z angl. One Class Support Vector Machine)
<b>PLV</b>	Hodnota fázového uzamčení (z angl. Phase Lock Value)
<b>RMSA</b>	Amplituda kvadratického průměru (z angl. Root Mean Square Amplitude)
<b>SD</b>	Směrodatná odchylka (z angl. Standard Deviation)
<b>SNR</b>	Poměr signál - šum (z angl. Signal to Noise Ratio)
<b>SVM</b>	Metoda podpůrných vektorů (z angl. Support Vector Machine)
<b>TN</b>	Skutečně negativní (z angl. True Negative)
<b>TNR</b>	Specifická (z angl. True Negative Rate)
<b>TP</b>	Skutečně pozitivní (z angl. True Positive)
<b>TPR</b>	Senzitivita (z angl. True Positive Rate)
<b>ZCR</b>	Míra průchodu nulou (z angl. Zero-Crossing Rate)

# Seznam příloh

A Report o kvalitě dat	61
B Obsah elektronické přílohy	64

# A Report o kvalitě dat

---

## **Kapitola 1. Obecné vlastnosti analyzovaného EEG záznamu**

Název souboru: STNDBS2\_1888E\_20220314\_092254

Počet kanálů: 258

Počet vzorků signálu v kanále: 213745

Vzorkovací frekvence: 1000Hz

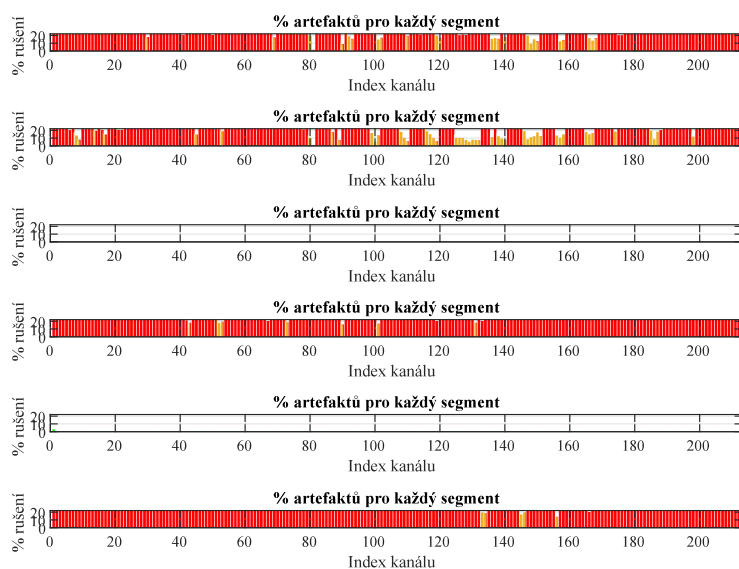
Značky v EEG datech: ANO

Marker name	Marker frequency
DI16	51
DIN3	50

EKG signál v EEG datech: ANO EKG kanál: 258

---

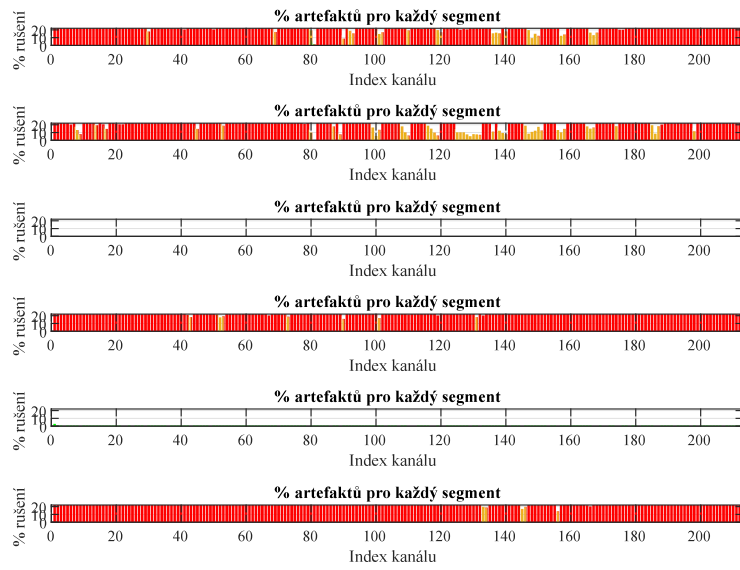
## Kapitola 2. Artefakty a rušení pro kanály



---

### Kapitola 3. Artefakty a rušení pro segmenty signálu

	PSDH	Kurt	50Hz	RMSA	MaxG	ZCRt
0-5%	1.00	1.00	256.00	0.00	256.00	0.00
5-20%	24.00	51.00	0.00	10.00	0.00	5.00
+20%	231.00	204.00	0.00	246.00	0.00	251.00



## B Obsah elektronické přílohy

/	kořenový adresář přiloženého archivu
+func	složka s funkcemi extrakce příznaků
Kurtosis.m	funkce výpočtu koeficientu špičatosti
MaximumGradient.m	funkce výpočtu maximálního gradientu
PDSELine.m	funkce výpočtu odhadu spektrální hustoty - 50 Hz
PDSEWave.m	funkce výpočtu odhadu spektrální hustoty - pásmo EEG rytmů
RMSAmplitude.m	funkce výpočtu amplitudy kvadratického průměru
ZeroCrossingRate.m	funkce výpočtu míry průchodu nulou
EventDetection.m	funkce detekce značek v signálu
FeatureEvaluation.m	funkce ohodnocení příznaků
FeatureExtraction.m	funkce extrakce příznaků
FiltECG.m	funkce detekce a odstranění EKG signálu
FormalNums.m	funkce transformace matice do tabulky
LoadData.m	funkce načtení dat a toolboxu
Main.m	hlavní spouštěcí skript
mu.m	matice s hodnotami aritmetického průměru
Preprocessing.m	funkce předzpracování dat
PDSEstimation.m	funkce odhadu hustoty spektrálního výkonu
Scoring.m	funkce skórovacího algoritmu
sigma.m	matice s hodnotami směrodatné odchylky
SignalQuality.pdf	report o kvalitě EEG dat