



**ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE**

---

**FAKULTA BIOMEDICÍNSKÉHO INŽENÝRSTVÍ**

**Katedra biomedicínské techniky**

**Redukce očních artefaktů z EEG záznamů za pomoci metody ICA  
s automatickou identifikací artefaktových komponent**

**Reduction of eye artifacts from EEG recordings using the ICA  
method with automatic identification of artifact components**

Bakalářská práce

Studijní program: Biomedicínská a klinická technika  
Studijní obor: Biomedicínský technik  
Vedoucí práce: Ing. Jan Štrobl

**Adam Hrabovský**

---

**Kladno 2023**

## I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Hrabovský** Jméno: **Adam** Osobní číslo: **491756**  
Fakulta: **Fakulta biomedicínského inženýrství**  
Garantující katedra: **Katedra biomedicínské techniky**  
Studijní program: **Biomedicínská a klinická technika**  
Studijní obor: **Biomedicínský technik**

## II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

**Redukce očních artefaktů z EEG záznamů za pomoci metody ICA s automatickou identifikací artefaktových komponent**

Název bakalářské práce anglicky:

**Reduction of eye artifacts from EEG recordings using the ICA method with automatic identification of artifact components**

Pokyny pro vypracování:

Analyzujte metody automatické identifikace ICA komponent obsahujících oční artefakty EEG signálů. Vyberte vhodnou metodu automatické identifikace očních artefaktů a spolu se základní metodou ICA jí implementujte v programovém prostředí MATLAB. Aplikujte implementovanou metodu na testovací EEG záznam. Na základě výsledků u testovacího záznamu a znalostí charakteru očního artefaktu navrhnete a následně implementujte vlastní úpravu metody automatické identifikace očních artefaktů u ICA komponent. Aplikujte jednotlivé implementované metody na validační EEG záznamy. Navrhnete statistickou analýzu výsledků a porovnejte pomocí ní vhodnost použití jednotlivých metod u validačních EEG záznamů.

Seznam doporučené literatury:

- [1] Vinay K. Ingle, John G. Proakis, Digital signal processing using MATLAB, ed. 3, CENGAGE Learning, 2012, ISBN 978-1-111-42737-5
- [2] Mike X. Cohen, Analyzing Neural Time Series Data: Theory and Practice, ed. 1, The MIT Press, 2014, ISBN 978-0-262-01987-3
- [3] Rakesh Ranjan, Bikash Chandra Sahana, Ashish Kumar Bhandari, Ocular artifact elimination from electroencephalography signals: A systematic review, Biocybernetics and Biomedical Engineering, ročník 41, číslo 3, 2021

Jméno a příjmení vedoucí(ho) bakalářské práce:

**Ing. Jan Štrobl**

Jméno a příjmení konzultanta(ky) bakalářské práce:

**Ing. Marek Piorecký, Ph.D.**

Datum zadání bakalářské práce: **14.02.2023**

Platnost zadání bakalářské práce: **20.09.2024**

doc. Ing. Martin Rožánek, Ph.D.  
vedoucí katedry

prof. MUDr. Jozef Rosina, Ph.D., MBA  
děkan

## PROHLÁŠENÍ

Prohlašuji, že jsem bakalářskou práci s názvem „Redukce očních artefaktů z EEG záznamů za pomoci metody ICA s automatickou identifikací artefaktových komponent“ vypracoval samostatně a použil k tomu úplný výčet citací použitých pramenů, které uvádím v seznamu přiloženém k bakalářské práci.

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

V Kladně dne 18.5.2023

.....

Adam Hrabovský

## **POĎAKOVANIE**

Chcel by som poďakoval vedúcemu práce, Ing. Janovi Štroblovi za odborné vedenie, rady a nápady pri spracovávaní tohto projektu. Ďalej by som sa rád poďakoval Ing. Ingrid Stanits za pomoc pri vytváraní algoritmu a Bc. Lei Poláčkovej, Bc. Jakubovi Kollárovi a Bc. Andrejovi Poloncovi za štylistickú korektúru textu.

## ABSTRAKT

### **Redukcia očných artefaktov z EEG záznamov za pomoci metódy ICA s automatickou identifikáciou artefaktových komponentov:**

**Úvod:** Elektroencefalografia (EEG) je diagnostická metóda v neuroológii, pri ktorej je snímaná elektrická aktivita mozgu pomocou elektród na hlave pacienta. Táto metóda je bohužiaľ náchylná na vznik kontaminujúcich artefaktov. Cieľom tejto práce je analyzovať metódy automatickej identifikácie komponentov reprezentujúcich očné artefakty pri použití metódy analýzy nezávislých komponentov (ICA), vhodnú metódu implementovať do programového prostredia MATLAB, upraviť a následne metódy medzi sebou porovnať. **Metódy:** Z odbornej literatúry bola vybratá jedna z metód automatickej identifikácie artefaktových komponentov, ktorá bola spoločne so základnou ICA implementovaná v programe MATLAB. Na základe jej výsledkov na testovacom zázname prebehla vlastná úprava tejto metódy pridaním ďalších štyroch klasifikačných parametrov. Vyhodnotenie a porovnanie oboch metód prebehlo pomocou navrhutej štatistickej analýzy výsledkov na desiatich validačných záznamoch, pri ktorej bola sledovaná úspešnosť z hľadiska presnosti identifikácie komponentov, úspešnosti potlačenia očných artefaktov a súčasného zachovania fyziologickej mozgovej aktivity. **Výsledky:** Základná metóda dosiahla z hľadiska identifikácie komponentov presnosť 84,29 %, s hodnotou senzitivity 94,74 % a špecificity 83,25 %. Upravená metóda mala celkovú presnosť a špecificitu vyššiu (92,86 % a 97,37 %), zároveň bola ale výrazne znížená senzitivita na 50 %. Z hľadiska potlačenia očných artefaktov dosiahla základná metóda lepšie výsledky a z hľadiska zachovania neurologickej aktivity bola naopak lepšia upravená metóda. V konečnom dôsledku obe z metód boli schopné vo validačných EEG záznamoch potlačiť očné artefakty. **Diskusia:** V rámci upravenej metódy bola zároveň vytvorená aj doplnková funkcia výberu potenciálnych artefaktových komponentov, ktoré je možné skontrolovať a prípadne manuálne odstrániť. Použitie metódy v tejto forme môže byť nápomocné pri expertnej identifikácii komponentov, pri ktorej už nebude nutné kontrolovať všetky, ale len menší počet potenciálnych komponentov, ktoré vybral algoritmus. **Záver:** V tejto práci boli implementované a porovnané dve metódy, ktoré môžu byť použité na automatickú identifikáciu artefaktových komponentov za účelom potlačenia očných artefaktov z EEG záznamov.

### **Kľúčové slová**

EEG, artefakt, ICA, *Infomax*, *FastICA*, automatická identifikácia ICA komponentov

## ABSTRACT

### **Reduction of eye artifacts from EEG recordings using the ICA method with automatic identification of artifact components:**

**Introduction:** Electroencephalography (EEG) is a diagnostic method in neurology in which the brain's electrical activity is detected using electrodes on the patient's head. This method is unfortunately prone to the formation of contaminating artifacts. The aim of this thesis is to analyse methods for the automatic identification of components representing ocular artifacts using the Independent Component Analysis (ICA) method, implement a one of the methods in the MATLAB programming environment, modify it and then compare both methods. **Methods:** One of the methods for the automatic identification of artifact components was selected from the literature and implemented in MATLAB together with the basic ICA. Based on its results on the test recording, a custom modification of this method was performed by adding four additional classification parameters. Evaluation and comparison of the two methods were performed using the proposed statistical analysis and ten validation records, in which the results were monitored in terms of accuracy of component identification, suppression of ocular artifacts, and simultaneous preservation of physiological brain activity. **Results:** The basic method achieved an accuracy of 84.29% in terms of component identification, with sensitivity and specificity values of 94.74% and 83.25%, respectively. The modified method had higher overall accuracy and specificity (92.86% and 97.37%, respectively), but at the same time, the sensitivity was significantly reduced to 50%. In terms of suppression of ocular artifacts, the basic method performed better and, conversely, the modified method performed better in terms of preservation of neurological activity. In conclusion, both methods were able to suppress ocular artifacts in the validation EEG recordings. **Discussion:** The modified method also included an additional feature of selecting potential artifact components that can be checked and if necessary, manually removed. Using the method in this form can be helpful for expert component identification, where it will no longer be necessary to check all of the components, but only a small number of potential components selected by the algorithm. **Conclusion:** In this work, two methods have been implemented and compared that can be used to automatically identify artifact components to suppress ocular artifacts from EEG recordings.

### **Keywords**

EEG, artifact, ICA, *Infomax*, *FastICA*, automatic identification of ICA components

# Obsah

<b>Zoznam symbolov a skratiek .....</b>	<b>9</b>
<b>1 Úvod .....</b>	<b>11</b>
<b>2 Prehľad súčasného stavu.....</b>	<b>12</b>
2.1 Kľudový a akčný membránový potenciál .....	12
2.2 Elektroencefalografia .....	13
2.3 Artefakty v EEG.....	16
2.3.1 Svalové artefakty .....	17
2.3.2 Aktivita srdca.....	17
2.3.3 Očné artefakty .....	17
2.4 Predspracovanie signálu.....	19
2.5 Analýza nezávislých komponentov ICA.....	20
<b>3 Ciele práce .....</b>	<b>25</b>
<b>4 Metódy .....</b>	<b>26</b>
4.1 Použité dáta .....	26
4.2 Predspracovanie EEG záznamov .....	27
4.3 Metódy slepej separácie zdrojov (BSS – Blind Source Separation) .....	28
4.4 ICA .....	30
4.4.1 Podmienky použitia ICA .....	31
4.4.2 Predspracovanie pred aplikáciou ICA .....	32
4.5 Automatická detekcia artefaktových komponentov .....	35
4.5.1 Základná metóda automatickej detekcie .....	35
4.5.2 Vlastná úprava základnej metódy, horizontálny pohyb očí.....	36
4.5.3 Vlastná úprava základnej metódy, vertikálny pohyb očí.....	37
4.5.4 Vyhodnotenie vlastnej úpravy metódy.....	39
4.5.5 Stanovenie prahových hodnôt .....	39
4.6 Vyhodnotenie výsledkov.....	41
4.6.1 Presnosť algoritmu .....	41
4.6.2 Úspešnosť potlačenia očných artefaktov .....	41
4.6.3 Zachovanie neurologickej aktivity .....	44
4.6.4 Štatistické testovanie .....	44

<b>5</b>	<b>Výsledky.....</b>	<b>46</b>
5.1	Predspracovanie dát.....	46
5.2	Metóda ICA.....	48
5.3	Potlačenie očných artefaktov a výber ICA algoritmu .....	53
5.4	ROC analýza a určovanie prahov .....	57
5.5	Porovnanie metód automatickej identifikácie artefaktových komponentov ..	58
5.5.1	Vyhodnotenie presnosti určovania komponentov .....	60
5.5.2	Porovnanie metód z hľadiska potlačenia očných artefaktov .....	60
5.5.3	Porovnanie metód z hľadiska zachovania neurologickej aktivity .....	62
<b>6</b>	<b>Diskusia.....</b>	<b>65</b>
<b>7</b>	<b>Záver .....</b>	<b>69</b>
	<b>Zoznam použitej literatúry .....</b>	<b>70</b>
	<b>Príloha A: Použité kanály pre výpočet jednotlivých metód a parametrov .....</b>	<b>77</b>
	<b>Príloha B: Tabuľky.....</b>	<b>79</b>
	<b>Príloha C: Obsah priloženého ZIP súboru.....</b>	<b>85</b>



# Zoznam symbolov a skratiek

## Zoznam symbolov

Symbol	Jednotka	Význam
$x$	$\mu\text{V}$	Stĺpcový vektor nameraných dát
$s$	$\mu\text{V}$	Stĺpcový vektor nezávislých komponentov
$\hat{s}$	$\mu\text{V}$	Stĺpcový vektor odhadu nezávislých komponentov
$a$	-	Mixujúci koeficient
$A$	-	Matica mixujúcich koeficientov – tzv. mixujúca matica
$W$	-	Demixujúca matica
$x'$	$\mu\text{V}$	„Vybielený“ stĺpcový vektor dát
$n$	-	Počet vzoriek nameraných dát
$m$	-	Počet nezávislých komponentov
$p(A)$	%	Pravdepodobnosť javu $A$
$p(B)$	%	Pravdepodobnosť javu $B$
$p(A, B)$	%	Pravdepodobnosť spoločného výskytu javov $A$ a $B$
$H(p)$	$\text{J} \cdot \text{K}^{-1}$	Entropia vektoru $p$
$N(p)$	$\text{J} \cdot \text{kg}^{-1} \cdot \text{K}^{-1}$	Negentropia vektoru $p$
$x(t)$	$\mu\text{V}$	Hodnota napätia v pôvodnom zázname v čase $t$
$y(t)$	$\mu\text{V}$	Hodnota naneseného polynómu v čase $t$
$z(t)$	$\mu\text{V}$	Upravená hodnota napätia v čase $t$
$\bar{x}$	$\mu\text{V}$	Stredná hodnota napätia v zázname
$\mathbf{a}_i$	$\mu\text{V}$	Priemerná hodnota výkonu z vybraných elektród
$z$	-	Hodnota dát po upravení pomocou z-skóre
$c$	$\mu\text{V}$	Pôvodná hodnota dát pred upravením pomocou z-skóre
$\mu$	$\mu\text{V}$	Stredná hodnota populácie
$\bar{c}$	$\mu\text{V}$	Stredná hodnota výberu z populácie
$\sigma$	$\mu\text{V}$	Smerodajná odchýlka populácie
$s$	$\mu\text{V}$	Smerodajná odchýlka výberu

## Zoznam skratiek

Skratka	Význam
EEG	Elektroencefalografia
EOG	Elektrookulografia
EMG	Elektromyografia
EKG	Elektrokardiografia
BSS	Slepá separácia zdrojov – Blind source separation
ICA	Analýza nezávislých komponentov – Independent component analysis
PCA	Analýza hlavných komponentov – Principal component analysis
SOBI	Slepá identifikácia druhého rádu – Second order blind identification
JADE	Spoločná aproximácia diagonalizácie vlastných matíc – Joint Approximation Diagonalization of Eigenmatrices
Fp	Pre-frontálna oblasť hlavy
F	Frontálna oblasť hlavy
P	Parietálna oblasť hlavy
O	Okcipitálna oblasť hlavy
C	Centrálna oblasť hlavy
T	Temporálna oblasť hlavy
Na <sup>+</sup>	Sodný kation
K <sup>+</sup>	Draselný kation
HP	Horný priepust
BP	Pásmová priepust – Band pass
NÚDZ	Národný ústav duševného zdravia
ASSR	Sluchová odpoveď v ustálenom stave – Auditory steady-state response
FIRWS	Filter s konečnou impulznou odozvou s vyhladením pomocou funkcie <i>sinc</i> – Finite impulse response with windowed <i>sinc</i>
SVM	Prístroj s pomocnými vektormi – Support vector machine
$Q_1$	Dolný kvartil
$Q_3$	Horný kvartil
<i>IQR</i>	Medzikvartilový rozsah – Inter quartile range
ANOVA	Analýza rozptylu – Analysis of variance
HSD	Úprimne významný rozdiel – Honest significant difference
TP	Skutočne pozitívny – True positive
TN	Skutočne negatívny – True negative
FP	Falošne pozitívny – False positive
FN	Falošne negatívny – False negative
ROC	Krivka charakteristiky prijímacieho operátora – Receiver operating characteristics

# 1 Úvod

Bunky ľudského tela sú zdrojom viacerých biosignálov, pomocou ktorých je možné získať veľké množstvo informácií o stave a funkcii skúmaných buniek, tkanív a orgánov. Elektroencefalografia (EEG) je vyšetровacia metóda v neurológii, pri ktorej je snímaná elektrická aktivita buniek mozgovej kôry prejavujúca sa ako zmeny elektrického potenciálu na povrchu hlavy vyšetovaného človeka [1]. EEG má veľké využitie v klinickej praxi aj vo výskumnej oblasti. Bohužiaľ, snímané amplitúdy signálov aktivity mozgu sú veľmi malé, rádovo v mikrovoltoch, a tak je zaznamenaný signál takmer vždy ovplyvnený príspevkami elektrických potenciálov z iných zdrojov. Tieto nechcené príspevky v signáloch sa nazývajú artefakty.

Artefakty, či už biologické alebo technické, kontaminujú nahrávaný signál a prekážajú v jeho analýze a interpretácii. Niektorým druhom artefaktov je možné sa do určitej miery vyhnúť už počas nahrávania záznamu. Od pacientov je napríklad žiadané, aby boli počas vyšetrení v kľude a obmedzovali pohyby hlavy a tela. Na druhú stranu, žmurkanie alebo malé pohyby očí sa dajú vedome ovplyvniť len do určitej miery a v EEG záznamoch sú zahrnuté takmer vždy. Očné artefakty tak patria medzi tie druhy artefaktov, ktoré je nutné v záznamoch potlačiť. Odstráneniu artefaktov sa venuje fáza predspracovania signálu. Táto fáza je veľmi dôležitá, pretože jej cieľom je doručiť lekárovi čo najkvalitnejší signál s čo najväčšou výpovednou hodnotou. Pri predspracovaní je zároveň dôležité dávať pozor na to, aby spoločne s artefaktami bolo odstránené len minimum informácií o mozgovej aktivite.


Metóda analýzy nezávislých komponentov (ICA) predstavuje efektívny a rozšírený nástroj slúžiaci na potlačenie očných artefaktov z EEG záznamov. Pri jej použití predstavuje najväčšiu prekážku klasifikácia jednotlivých zdrojov a identifikácia tých, ktoré reprezentujú artefakty. Identifikácia môže prebiehať manuálne, ale tento proces je časovo aj personálne náročný a z tohto dôvodu sa v súčasnej dobe intenzívne pracuje na jeho zautomatizovaní. V tejto práci tak bola z odbornej literatúry vybraná jedna z metód automatickej identifikácie artefaktových komponentov a na základe výsledkov na testovacom zázname prebehla jej vlastná úprava. Pomocou navrhutej štatistickej analýzy následne prebehlo porovnanie oboch metód a bola posúdená ich vhodnosť na identifikáciu a následné potlačenie očných artefaktov v EEG záznamoch.

## 2 Prehľad súčasného stavu

Ľudské telo počas svojho života generuje viacero druhov biologických signálov, ktoré môžu byť významným zdrojom informácií o stave a funkcií buniek, ktoré signál vyvolali. Jedným z nich je aj signál elektrickej aktivity mozgu. Príčina jeho vzniku, popis metódy, pomocou ktorej je možné tento signál zaznamenávať z povrchu hlavy a jej výhody a nevýhody sú uvedené v nasledujúcich kapitolách.

### 2.1 Kľudový a akčný membránový potenciál

Takmer všetky bunkové membrány v ľudskom tele, ale aj v iných živočíchoch, rastlinách, alebo hubách udržiavajú rôznu koncentráciu elektricky nabitých iónov na vonkajšej a vnútornej strane bunky [2]. Tento stav sa nazýva kľudový membránový potenciál a v typickej ľudskej bunke dosahuje hodnotu okolo  $-70$  mV a táto hodnota sa prakticky nemení. Za existenciu kľudového membránového potenciálu sú zodpovedné hlavne sodné ( $\text{Na}^+$ ) a draselné ( $\text{K}^+$ ) ióny [3]. Existujú však aj excitabilné bunky a tkanivá (napríklad svalové alebo nervové), ktoré sú elektricky aktívne v tom zmysle, že ich hodnota membránového potenciálu kolíše v čase, vid' obrázok 2.1. Tieto zmeny sú vo všeobecnosti známe ako akčný potenciál [2]. Akčný potenciál vzniká meniacou sa priepustnosťou iónových kanálov pre  $\text{Na}^+$  a  $\text{K}^+$  na membránach excitabilných buniek. Tieto kanály sú zatvorené, keď má membránový potenciál hodnotu blízku kľudovému potenciálu, ale dokážu sa rýchlo otvoriť po prekročení určitého prahového napätia. Tým umožnia prísun  $\text{Na}^+$  iónov do vnútra bunky a vyvolajú tak tzv. depolarizáciu [2]. Počas depolarizácie rapídne vzrastie hodnota membránového potenciálu na krátky čas do kladných hodnôt, v prípade nervových buniek je to k  $30$  mV [3]. Po krátkom čase je depolarizácia ukončená repolarizáciou, kedy sa začnú otvárať napäťovo riadené kanáliky pre  $\text{K}^+$ , ktorý tak môže rýchlo opúšťať bunku a hodnota membránového potenciálu sa vráti naspäť do záporných hodnôt. Nervová bunka pokračuje v repolarizácii, až pokiaľ sa membránový potenciál nedostane na hodnotu okolo  $-75$  mV, čo je hodnota nižšia ako pri kľudovom membránovom potenciáli [4]. Táto fáza sa nazýva hyperpolarizácia. Počas hyperpolarizácie bunky sú jej  $\text{Na}^+$  kanály inaktivované a tým pádom počas tzv. absolútnej refrakternej periódy nie možné spustiť ďalší akčný potenciál. Sodné kanáliky sa z uplynulého akčného potenciálu musia „zotaviť“, pričom tento proces je závislý na napätí aj na čase. Týmto spôsobom je zabezpečené, že sa akčný potenciál šíri len v jednom smere. Prichádzajúci akčný potenciál v jednom mieste spôsobí depolarizáciu buniek v miestach „pred“ ním a vzniká tak reťazová reakcia, pomocou ktorej si napríklad nervové bunky dokážu posúvať informácie [3; 5]. Tým, že je naraz aktivovaný veľký počet buniek, rastie amplitúda elektrického signálu v takej miere, že je ho možné snímať a zaznamenávať z povrchu tela a následne interpretovať.



Obrázok 2.1: Grafický priebeh akčného potenciálu. Kľudový membránový potenciál je na hodnote -70 mV. Vplyvom stimulu vzrástla jeho hodnota nad -55 mV a nastala depolarizácia. Po dosiahnutí špičkového akčného potenciálu na približne 30 mV sa otvorili membránové kanály pre  $K^+$  a začali repolarizáciu. Na obrázku je zobrazená aj hyperpolarizácia, kde na krátky čas klesla hodnota membránového potenciálu pod hodnotu kľudového membránového potenciálu. Prevzaté a upravené z [6].

## 2.2 Elektroencefalografia

Elektroencefalografia (EEG) je neinvazívna diagnostická metóda používaná v neurológií, pri ktorej je snímaná elektrická aktivita neurónov v pacientovom mozgu pomocou elektród umiestnených na jeho hlave [1]. Zaznamenávaná elektrická aktivita je výsledkom sumácie akčných potenciálov tisícov až miliónov neurónov s rovnakou priestorovou orientáciou. Existuje presvedčenie, že sa konkrétne jedná o veľké pyramídové bunky v mozgovej kôre, pretože sa nachádzajú v blízkosti povrchu pacientovej hlavy, sú správne orientované a svoju elektrickú aktivitu vysielajú naraz [7]. Naopak, z dôvodu, že intenzita elektrického poľa klesá s druhou mocninou vzdialenosti od zdroja, je náročné zaznamenať aktivitu buniek z hlbokých častí mozgu [8]. To tiež znamená, že nie všetky neuróny prispievajú do EEG záznamu rovnakým dielom.

Zaznamenávané zmeny napätia na povrchu hlavy umožňujú vyšetriť mozgovú aktivitu pacienta. EEG je v klinickej praxi v najväčšej miere používané na diagnostiku epilepsie, ktorá formuje typické abnormality v EEG záznamoch [9]. Okrem toho sa dajú pomocou neho vyšetriť poruchy spánku, stavy po úrazoch hlavy, mŕtviciach a nádoroch, alebo napríklad hĺbka anestézie počas operačných výkonov [7; 10]. V neposlednom rade má elektroencefalografia významné miesto vo výskumnej činnosti v oblastiach psychických porúch alebo spánku [11].

Aktivita mozgu, a teda aj EEG signál vo forme mozgových vln, sa vyznačuje určitou periodicitou. Typicky sa môže aspoň časť tejto aktivity rozdeliť a popísať pomocou frekvenčných pásiem, ktoré majú svoj typický rozsah, priestorové rozloženie a sú častokrát spájané s určitým stavom fungovania mozgu (napríklad stavom bdenia alebo spánku) [12]. Na základe výskytu alebo absencie určitej aktivity mozgu pri konkrétnom stave pacienta je možné konkrétnejšie určiť jeho diagnózu. Charakteristika EEG pásiem je uvedená v tabuľke 2.1:

Tabuľka 2.1: Základné typy aktivity mozgu, ich frekvenčné pásmo a typický výskyt [13; 14; 15].

Názov pásma	Frekvenčný rozsah (Hz)	Výskyt
Delta	0,5–4	Aktivita dospelého mozgu počas spánku, normálny výskyt u novorodencov. Má tendenciu mať najnižší frekvenčný a najvyšší amplitúdový rozsah.
Théta	4–7,5	Aktivita mozgu pri ospalosti, vzrušení, alebo počas meditácie, normálny výskyt u mladších detí.
Alfa	8–13	Aktivita zdravého, bdélého a zrelaxovaného mozgu v okcipitálnej oblasti pri zatvorených očiach.
Beta	14–30	Aktivita mozgu pri stavoch ostražitosti, aktívneho sústredenia a myslenia. Je potlačovaná počas aktívneho pohybu.
Gama	30–100	Aktivita mozgu pri spracovávaní zmyslových vnemov a kognitívnych úlohách zahŕňajúcich pamäť a pozornosť. Pozmenená gama aktivita bola pozorovaná pri poruchách ako schizofrénia alebo Alzheimerova choroba.


EEG je technologicky založené na princípe diferenciálneho zosilnenia. Pri unipolárnom zapojení je každá meracia elektróda pripojená na jeden vstup diferenciálneho zosilňovača biopotenciálov, zatiaľ čo na jeho druhom vstupe je pre všetky kanály spoločná referenčná elektróda. Pre referenčnú elektródu neexistuje jedna štandardná pozícia, musí však byť umiestnená na inom mieste ako sú merné elektródy. Typicky sa používa referencia tzv. spojených uší, pričom ide o fyzické alebo matematické prepojenie elektród umiestnených na pacientových ušných lalôčikoch alebo na *processus mastoidei*.

Pri bipolárnom zapojení je snímané napätie medzi dvomi mernými elektródami. Toto zapojenie sa používa na zvýraznenie zložiek signálu, ktoré pri štandardnom unipolárnom snímaní môžu zostať skryté, napríklad horizontálne pohyby očí. Jeden EEG kanál reprezentuje rozdielové napätie medzi oboma vstupmi zosilňovača (teda medzi mernou a referenčnou elektródou). Napätie každého kanálu je zosilnené a následne digitalizované.

Štandardné elektroencefalografické vyšetrenie je dvadsaťkanálové, používaných je dvadsať merných a jedna referenčná elektróda, ktoré sú usporiadané na pacientovej hlave použitím medzinárodného 10-20 systému [16]. Tento systém presne definuje miesta, na ktoré sa umiestnia elektródy pomocou rozmerov pacientovej hlavy. Názov 10-20 sa vzťahuje na to, že sa konkrétne vzdialenosti medzi jednotlivými elektródami rovnajú 10 % alebo 20 % celkovej dĺžky alebo šírky pacientovej hlavy [16]. Na výskumné účely sa ale častokrát používa tzv. *High Density* hardware (hardware s veľkou hustotou elektród), kde systém 10-5 dokonca umožňuje použitie viac ako 300 kanálov [16]. Z praktického hľadiska sa jednotlivé elektródy vkladajú do špeciálnych čapíc, ktoré rešpektujú definované pozície a vzdialenosti medzi elektródami a pri vyšetrení sa len nasadia pacientovi na hlavu a vyplnia vodivým gélom. Grafické zobrazenie umiestnenia elektród pri použití systému 10-20 je na obrázku 2.2.

Počas nahrávania môžu byť pacienti špeciálnym spôsobom stimulovaní, alebo inštruovaní na vykonávanie určitých činností súvisiacich s konkrétnym vyšetrením. Ich cieľom je vyvolať tzv. evokované potenciály, čo sú odpovede mozgu na určité podnety, ktoré sa pri kľudovom stave nemusia prejaviť. Typicky sú skúmané reakcie na zvukové, zrakové alebo hmatové stimulácie [17].

Napriek tomu, že pri konvenčnom EEG vyšetrení jedna elektróda sníma aktivitu veľkého počtu buniek, je amplitúda týchto signálov len v rádoch desiatok, maximálne stoviek mikrovoltov ( $\mu\text{V}$ ) [18]. Signály sú totiž vo veľkej miere utlmované biologickými filtrami – kožou, mozgovými plenami a v najväčšej miere lebkou [7]. Do mozgových signálov sa tak veľmi ľahko dostávajú rušivé elementy – artefakty, ktoré prekážajú v ich analýze a interpretácii [15; 19].



Obrázok 2.2: Grafické zobrazenie rozmiestnenia EEG elektród pri použití medzinárodného 10-20 systému. Každá elektróda má svoje špecifické označenie, ktoré udáva jej presnú polohu v rámci systému. Písmená označujú, nad ktorou oblasťou mozgu sa elektróda nachádza: Fp – pre-frontálna, F – frontálna, T – temporálna, C – centrálna, P – parietálna, O – okcipitálna oblasť. Elektródy A značia umiestnenie na ušných lalôčkoch / *processus mastoidei*. Čísla pri elektródach odkazujú na to, či sa elektróda nachádza na pravej (párne čísla), alebo ľavej (nepárne čísla) hemisfére. Označenie „Z“ (zero) referuje na polohu v stredovej sagitálnej rovine lebky. Prevzaté a upravené z [20].

## 2.3 Artefakty v EEG

EEG artefakty sú elektrické signály zaznamenávané na povrchu hlavy, ktorých pôvod nie je v mozgovej aktivite [21]. Artefakty svojimi potenciálovými príspevkami kontaminujú merané dáta. V porovnaní s amplitúdami meraného signálu sú ich amplitúdy relatívne vysoké a tým pádom dokážu „prehlušiť“ a zamaskovať aktivitu mozgu, ktorá prebieha v pozadí. Rovnako môžu ovplyvniť interpretáciu meraných dát, pretože niektoré druhy artefaktov vizuálne pripomínajú kognitívnu aktivitu a tak môžu napríklad svojím frekvenčným rozsahom ľahko zapadnúť do určitého EEG pásma [22]. Podľa pôvodu zdroja artefaktov sa delia na technické a biologické. Zdrojom technických artefaktov nie je ľudské telo. Vznikajú napríklad z dôvodu použitia poškodených elektród, ich pohybu na povrchu hlavy pacienta (nedokonalým spojením), zanášania 50 Hz rušenia z elektrickej siete, zmenou impedancie elektród atď. Technické artefakty sa často dajú odstrániť jednoduchšie, a to použitím presnejšej techniky alebo dôkladnejším spôsobom práce [15; 21].

Biologické artefakty sú elektrické signály vznikajúce z iných ako mozgových buniek človeka, ktoré sú zaznamenané v EEG zázname [21]. Patrí sem napríklad elektrická aktivita srdca alebo svalov, dýchanie či pohyby očí. Namerať EEG signál bez



biologických artefaktov je takmer nemožné, preto sa ich odstráneniu musí venovať značná pozornosť. Základné biologické artefakty sú popísané v nasledujúcich kapitolách.

### **2.3.1 Svalové artefakty**

Elektrická aktivita svalových vlákien je významným zdrojom rušenia EEG signálu. Elektromyografický (EMG) artefakt môže spôsobiť akékoľvek svalové vlákno blízko umiestnenia elektródy zaznamenávajúcej signál [15]. Typicky môže vzniknúť pri mimických pohyboch tváre pacienta, pri rozprávaní, prehltaní, kýchaní atď. [15; 23]. Amplitúdu a tvar vlny svalového artefaktu dokáže okrem toho ovplyvniť aj miera svalovej kontrakcie vlákna [15].

### **2.3.2 Aktivita srdca**

Artefakty spôsobené aktivitou srdca môžu takisto preniknúť do EEG záznamu. Relatívne silné elektrické pole srdca svojimi potenciálovými príspevkami dokáže interferovať s povrchovými elektrickými signálmi generovanými mozgom, ktoré sú zaznamenávané na povrchu hlavy [24]. Charakteristická repetitívna podoba srdcovej aktivity ju však umožňuje od aktivity mozgu oddeliť jednoduchšie ako iné artefakty, napríklad súčasným nahrávaním elektrokardiogramu (EKG) [15; 24]. Ďalšie artefakty spôsobené srdcom môžu vzniknúť keď sa elektróda na hlave pacienta umiestni do blízkosti cievy. Z dôvodu pravidelnej systoly a diastoly cieva pulzuje v kludovom stave s frekvenciou okolo 1,2 Hz, čo sa prenáša do EEG záznamu [15].


### **2.3.3 Očné artefakty**

Oči pacienta sú pri štandardnom EEG zázname významným zdrojom artefaktov hlavne z dôvodu, že sa oči nachádzajú vo veľkej blízkosti mozgu. Tým pádom priamo prekrývajú a ovplyvňujú EEG aktivitu vo frontálnej oblasti. Niektoré štúdie dokonca tvrdia, že očné artefakty majú na EEG signál najväčší vplyv, lebo dokážu zmeniť amplitúdu samotného signálu z mozgu [25]. Očné artefakty sú v najväčšej miere spôsobené žmurkaním a očnými pohybmi. Majú široké frekvenčné spektrum, pričom najviac sú zastúpené frekvencie pod 4 Hz [25]. Aby sa znížila ich prítomnosť v záznamoch, sú pacienti žiadaní, aby počas nahrávania obmedzovali žmurkanie, alebo aby mali pohľad fixovaný na jeden bod. Účinnosť týchto metód môže byť sporná, najmä v prípadoch vyšetrení detí alebo pacientov s psychickými poruchami. Je diskutabilné, či pridanie sekundárnej úlohy pre pacienta nevedie k ovplyvneniu skúmanej oblasti mozgovej aktivity [26]. Napriek tomu, pri dlhšom vyšetrení s otvorenými očami sa človek


žmurkaniu, ani menším očným pohybom s najväčšou pravdepodobnosťou aj tak nedokáže vyhnúť [23].

Artefakty spôsobené žmurkaním sa v signáli javia ako výrazné napät'ové špičky, ktorých amplitúda môže dosahovať až rádovo vyššie hodnoty ako zvyšok signálu a dajú sa tak v zázname ľahko rozpoznať, vid' obrázok 2.3 [27; 28]. Tieto artefakty majú zvyčajne veľmi krátke trvanie, okolo 200–400 ms a dosahujú ostrejších vrcholov voči okolitému signálu. Pri žmurkaní sa mení elektrická vodivosť oka v dôsledku zmien kontaktu rohovky a očného viečka [15]. Okrem toho sa však v rámci signálu dá žmurknutie charakterizovať aj ako vertikálny očný pohyb, pretože pri ňom dochádza k mimovoľnej zmene polohy rohovky smerom nahor – tzv. Bellov fenomén [29].

Pri horizontálnych a krúživých očných pohyboch naopak vznikajú signály štvorcového tvaru s nižšou amplitúdou, ktoré trvajú dlhšie (obrázok 2.4). Rohovka a sietnica sa chovajú ako elektrický dipól a pri očnom pohybe sa mení jeho priestorová orientácia, zanášajúca do EEG rušenie [15]. Horizontálne očné pohyby sa dajú zvýrazniť použitím bipolárneho zapojenia elektród. Elektrické signály oka je možné merať pomocou elektrookulografu (EOG). Amplitúda EOG signálu klesá približne s druhou mocninou jeho vzdialenosti od zdroja, preto sú očnými artefaktami kontaminované hlavne frontálne kanály EEG [23].



Obrázok 2.3: Ukážka vybraných kanálov EEG záznamu, v ktorom sú prítomné artefakty spôsobené žmurkaním. Na vertikálnej osi je amplitúda signálu v  $\mu\text{V}$ . V žltom obdĺžniku je vyznačený úsek jedného žmurknutia vyznačujúci sa vysokou amplitúdou a krátkou dobou trvania. Je vidieť, že kanály Fp1 a Fp2 sú artefaktami postihnuté najviac. Prevzaté a upravené z [30].



Obrázok 2.4: Ukážka vybraných kanálov EEG záznamu, v ktorom sú prítomné artefakty spôsobené horizontálnymi pohybmi očí. Na vertikálnej osi je amplitúda signálu v  $\mu\text{V}$ . V žltom obdĺžniku je vyznačený jeden úsek štvorcového tvaru signálu spôsobeného pohybom očí zľava doprava. Je vidieť opačnú polaritu tohto artefaktu v kanáloch F7 a F8 z dôvodu umiestnenia meracích elektród na pravej (F8) a ľavej (F7) strane hlavy a dipólového charakteru očí. Prevzaté a upravené z [30].

## 2.4 Predspracovanie signálu

Pretože je takmer nemožné nahráť primárny EEG záznam bez toho, aby v ňom nebol zahrnutý nejaký druh artefaktu, je fáza predspracovania signálu dôležitá venovať značnú pozornosť za účelom minimalizácií ich vplyvu. Cieľom tejto fázy je dopracovať sa k výslednému signálu, ktorý v sebe bude zahŕňať čo najmenej rušivých elementov. Zároveň je treba dbať na to, aby spoločne s artefaktami bolo odstránené čo najmenej mozgovej aktivity [31].

V minulosti výrazne prevládala analýza EEG dát expertami, ktorí na základe vlastných skúseností a dlhoročnej praxe dokázali určiť typ artefaktu a jeho zdroj. Nevýhodou ručného odstraňovania však je, že sa zo záznamu musia vystrihnúť celé úseky, v ktorých EEG signál potom jednoducho chýba. V dnešnej dobe niektoré vyšetrenia vyžadujú 24 hodinové nahrávanie EEG záznamu a manuálna analýza takých dlhých záznamov nie je prakticky reálna [32]. Ďalším problémom je obrovské množstvo dát na analýzu, keďže sa napríklad vo výskumnej činnosti používajú záznamy až z 256 kanálov [16; 32]. Z týchto dôvodov prebieha intenzívny vývoj automatizovanej detekcie a odstraňovania jednotlivých druhov artefaktov, ktoré lekárom dokáže priniesť veľkú úsporu času a energie.

Existuje značné množstvo metód a techník, pomocou ktorých je možné odstrániť konkrétne druhy artefaktov, veľa z nich je už štandardne zahrnutých vo fáze predspracovania. Patrí sem odfiltrovanie určitých frekvencií zo záznamu, odstránenie nenulovej jednosmernej zložky (offsetu) a nízkofrekvenčného trendu, či možnosť

celkového odstránenia určitého objemu dát, v ktorom sa predpokladá, že sa nachádza artefakt [31]. V tomto prípade je asi najrozšírenejšia základná metóda amplitúdového prahovania, kde sa zo signálu odstráni všetky úseky, v ktorých amplitúda presahuje určitú predom definovanú prahovú hodnotu. Napriek tomu, že je tento spôsob redukcie artefaktov jednoduchý, jasný a rýchly, vymazaním celého úseku signálu dochádza k strate značného množstva informácie [25]. Ďalším príkladom, kedy použitím metódy na odstránenie artefaktu môže dôjsť k poškodeniu nameraných dát je aj štandardné použitie hornopriepustného (HP) filtra. HP filtrácia sa používa na potlačenie nízkofrekvenčnej zložky nameraného signálu, typicky pod hranicou 0,1 Hz ktorá nemá pôvod v mozgovej aktivite, vid' tabuľka 2.1 [33]. HP filter zvyčajne býva citlivý na prítomnosť temporálne lokalizovaných krátkych rušivých impulzov, ktoré môžu spôsobiť nové, tzv. ringing artefakty [31].

EOG artefakty majú tendenciu mať vysokú amplitúdu a nízku frekvenciu, a tak je ich teoreticky možné odstrániť aj pomocou upravenej HP filtrácie s vyššie posunutou prahovou frekvenciou. Hlavným problémom ale je, že sa očné artefakty spektrálne prekrývajú s hlavnými pásmami EEG, a tak by sa použitím takéhoto typu filtra v zázname spoločne s artefaktami potlačila aj mozgová aktivita [34; 35].

Existujú však aj iné techniky, ktoré sa snažia zachovať čo najväčšiu časť EEG signálu a odstrániť z neho iba samostatné artefakty. Do týchto metód patrí aj skupina BSS (Blind Source Separation – metódy slepej separácie zdrojov) a jednou z najvýznamnejších z nich je analýza nezávislých komponentov ICA – Independent Component Analysis. Tá sa veľmi často používa na odstránenie výrazných EOG artefaktov [25].

## 2.5 Analýza nezávislých komponentov ICA

Vo viacerých výskumoch sa osvedčilo aplikovanie metódy analýzy nezávislých komponentov (ICA). ICA bola v rámci problematiky spracovania EEG signálov zavedená hlavne ako metóda separácie mozgovej aktivity od očných artefaktov. Pri jej použití platí predpoklad, že aktivita mozgu a očí sú anatomicky a fyziologicky oddelené procesy a ich nezávislosť reflektuje štatistický vzťah medzi elektrickými signálmi, ktoré sú generované oboma procesmi [26].

Pri aplikácii ICA sa na EEG signál môžeme pozerat' ako na sumáciu neurologickej informácie a artefaktov, ktoré sú na sebe nezávislé. Metóda ICA dokáže oddeliť tieto nezávislé „zdroje“ prispievajúce do vysoko korelovaného EEG záznamu na základe ich špecifických štatistických charakteristík bez ohľadu na ich fyzické umiestnenie alebo konfiguráciu [36]. Po získaní jednotlivých zdrojov (komponentov) je ich nutné následne klasifikovať a určiť tie, ktoré z nich sú zdrojom artefaktov a ktoré sú zdrojom mozgovej aktivity. Identifikované artefaktové komponenty sa zo signálu odstráni a použitím inverzného ICA algoritmu sa zo zvyšných zdrojov spätne zrekonštruuje EEG signál bez prítomnosti artefaktov.

Základ problému extrakcie nezávislých entít v rámci kompozitných signálov položili Jeanny Héroult a Bernard Ans už v polovici osemdesiatych rokov dvadsiateho storočia, pričom zdokonalený a funkčný matematický algoritmus pre metódu ICA popísal Pierre Comon vo svojom článku v roku 1994 [37]. Odvtedy bolo v oblasti ICA vyvinutých viacero rôznych algoritmov. Je náročné určiť ich absolútnu kvalitu hlavne z dôvodu, že nie sme schopní samostatne merať individuálne signály, z ktorých pozostáva výsledný EEG záznam. V tejto situácii je teda vhodné zvoliť taký algoritmus, ktorého použité predpoklady najbližšie zodpovedajú konkrétnemu problému, ktorý chceme použitím ICA vyriešiť [38]. Pri spracovaní mozgových signálov sa používajú hlavne štyri nasledujúce algoritmy [39]:

1. *Infomax*
2. *FastICA*
3. *SOBI* – Second Order Blind Identification (Slepá identifikácia druhého rádu)
4. *JADE* – Joint Approximation Diagonalization of Eigenmatrices (Spoločná aproximácia diagonalizácie vlastných matic)

Každý z týchto algoritmov je založený na inom štatistickom princípe a tým pádom má každý z nich v hardwarovej implementácii trochu iné vlastnosti. Pri signálovej analýze sú dôležité časová a výpočtová náročnosť – požiadavky na hardware a taktiež presnosť algoritmu – kvalita dosiahnutého výsledku [37].

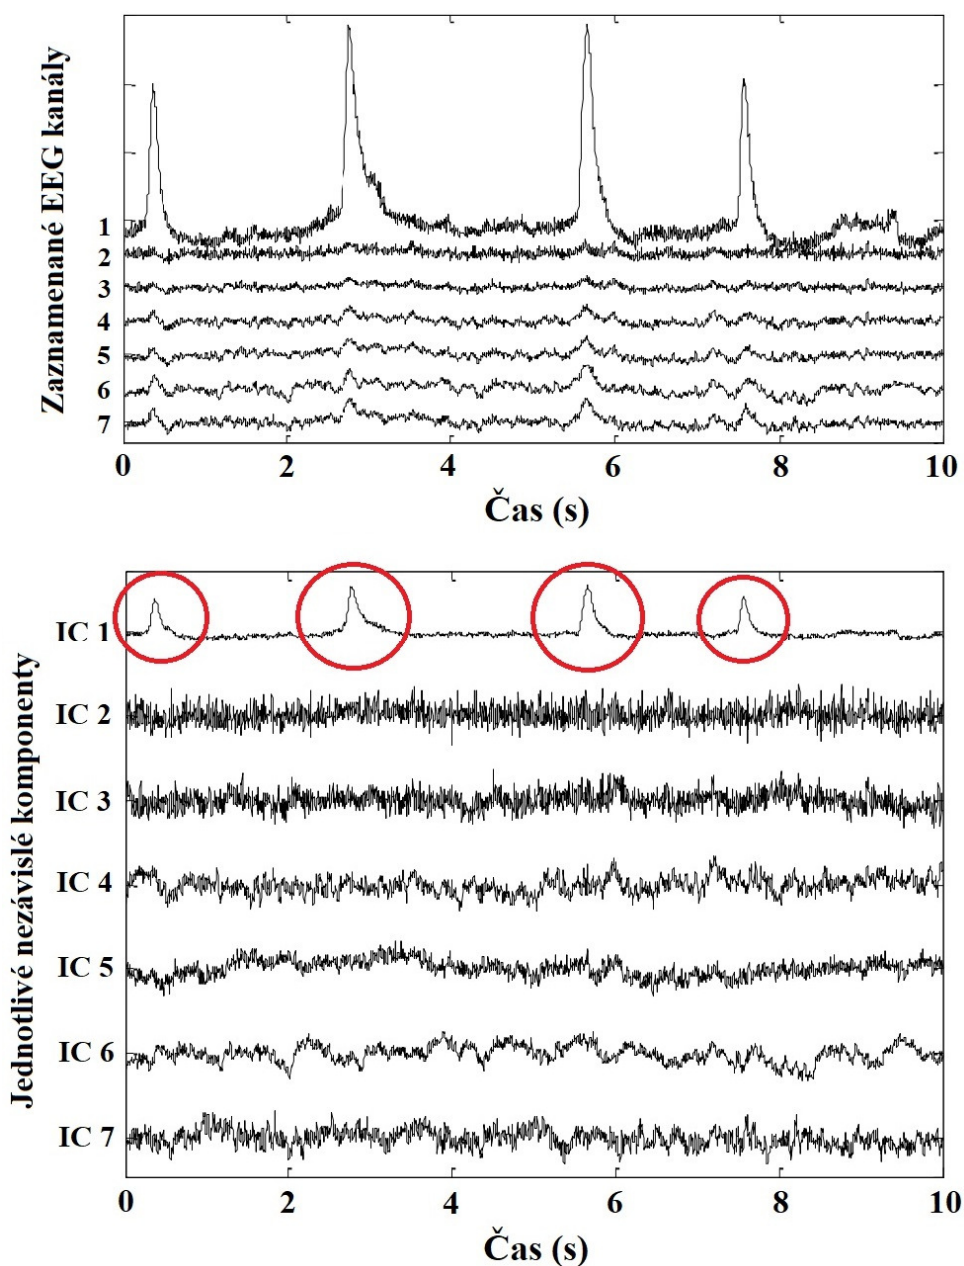
Najväčším problémom metódy ICA je samotná klasifikácia jednotlivých komponentov, pretože pri jej použití primárne nedochádza k ich zoradovaniu [25]. Klasifikácia komponentov môže prebiehať manuálne, alebo automatizovane. Moderné softwary umožňujú analyzovať nielen časové priebehy jednotlivých zdrojov, ale aj ich priestorovú aktivitu na základe interpolácie ich aktivity na povrch hlavy.

Priestorová topografia komponentov je nápomocná pri manuálnej interpretácii toho, či sa jedná o nezávislý komponent obsahujúci aktivitu pochádzajúcu z mozgu alebo artefakt [40]. Z jednotlivých máp sa dá jednoznačne určiť oblasť hlavy, z ktorej pochádza hlavná zložka konkrétneho úseku signálu. V prípade, že je na mape vidieť zdroj signálu vo frontálnej oblasti hlavy v blízkosti očí a so zvyšujúcou sa vzdialenosťou sa jeho aktivita postupne znižuje, podľa všetkého sa jedná o vertikálny pohyb očí [41]. Ak je naopak na topomape vidieť, že v oblasti jedného oka je výrazná kladná polarita a v oblasti druhého oka prevláda záporná polarita, je vysoko pravdepodobné, že ide o horizontálny očný pohyb a toto priestorové rozloženie spôsobil ich elektrický dipól, vid' obrázok 2.6 vpravo [41].


Rovnako nápomocná pri identifikácii zdrojov je analýza ich časových priebehov, na ktorých sa dajú vidieť určité typické charakteristiky signálu rozdelené do jednotlivých komponentov. Napríklad v komponentoch obsahujúcich artefakty spôsobené žmurkaním bývajú zahrnuté charakteristické krátke a vysoké amplitúdové špičky typické pre tento typ artefaktu pozorovaného v EEG záznamoch, vid' obrázok 2.5. V ideálnom prípade je

zároveň v týchto komponentoch zahrnuté len minimálne množstvo mozgovej aktivity – keďže sa jedná o nezávislé komponenty [42].

Vigário [26] prezentoval jednu z prvých štúdií zameriavajúcich sa na odstránenie očných artefaktov z EEG záznamu pomocou ICA. V tomto prípade sa jednalo hlavne o demonštráciu, že ICA a použitý *FastICA* algoritmus sa dá využiť na separáciu zdrojov prispievajúcich do EEG záznamu. Identifikácia očných artefaktov bola manuálna a z toho dôvodu autor odporúčal súčasné nahrávanie EOG záznamu.



Obrázok 2.5: Príklad EEG záznamu obsahujúceho očné artefakty spôsobené žmurkaním a ich rozdelenie na nezávislé komponenty. V hornom grafe je 7 EEG kanálov kontaminovaných žmurkaním subjektu. Žmurkanie sa prejavuje ako 4 špičky, ktoré sa vyskytujú vo všetkých kanáloch, najviac zreteľné sú v kanáli č.1. V dolnom grafe je zobrazený časový priebeh jednotlivých nezávislých komponentov (IC1 – IC7). Očné artefakty zo všetkých kanálov sú v tomto prípade sústredené do komponentu IC 1 – vyznačené červenými krúžkami. Prevzaté a upravené z [43].



Obrázok 2.6: Priestorová topografia komponentov so zahrnutými očnými artefaktami. Na ľavom komponente je vidieť žmurkanie subjektu – najväčšia aktivita vychádza z frontálnej oblasti a s rastúcou vzdialenosťou od očí sa znižuje. Pravý komponent zobrazuje horizontálny pohyb očí – polarita v oblasti pravého oka je kladná v porovnaní s oblasťou ľavého oka, kde prevláda záporná polarita. Prevzaté a upravené z [44].

V dnešnej dobe sa už čoraz viac pristupuje k použitiu automatizovaných metód identifikácie artefaktových komponentov. Automatická identifikácia eliminuje subjektivitu spojenú s neautomatizovanými metódami, je výrazne časovo efektívnejšia a znižuje nápor na lekárov [27; 41]. Na automatickú identifikáciu artefaktových komponentov je vyvinutých viacero algoritmov založených na rôznych princípoch, pričom sa stále pracuje na ich zdokonalení.

Prvú poloautomatickú metódu prezentovali Delrome a kol. vo svojom článku [45]. Táto metóda bola zameraná na odstránenie viacerých druhov artefaktov, pričom na základe analýzy pravdepodobnostného rozdelenia a špicatosti komponentov dokázala detegovať tie, ktoré sa vyznačovali neobvyklou aktivitou. Obsluha potom mohla označené komponenty skontrolovať a v prípade, že boli skutočne artefaktové aj odstrániť. Delsanto a kol. [46] skúmali podobnosť topografických máp a spektrálne vlastnosti jednotlivých komponentov, na základe ktorých vyvinuli už plne automatizovanú metódu detekcie zdrojov žmurkania. V tejto štúdií však autori neriešili horizontálne pohyby očí ani žiadny iný typ artefaktu.

Ting a kol. vo svojej štúdií [41] vytvorili automatickú metódu identifikácie komponentov zo signálov zameraných na evokované potenciály, pričom sa ich metóda sústredila na viaceré typy artefaktov. Na výpočet komponentov autori použili algoritmy využívajúce len štatistiku druhého rádu. Automatická identifikácia komponentov s očnými artefaktami spočívala v použití priestorovej distribúcie výkonu signálu v jednotlivých komponentoch a referenčných EOG kanáloch. Vypočítané parametre boli porovnávané s prahovou hodnotou a ak bola v niektorom z komponentov táto hodnota prekonaná, komponent bol odstránený.

Joyce a kol. vo svojom článku [38] používali na identifikáciu komponentov frekvenčné spektrum signálu a koreláciu s referenčným EOG záznamom. Komponenty, ktoré dosahovali vysoký výkon v pásme nižších frekvencií a ktoré zároveň korelovali nad určitú hodnotu s EOG boli označené ako artefaktové. Naopak, Zhou a Gotman sa vo svojej štúdií [27] zameriavajú na automatizovanú identifikáciu a potlačenie očných artefaktov bez nutnosti referenčného EOG záznamu. V tejto štúdií prebiehala identifikácia zdrojov s príspevkami očných artefaktov pomocou dipólového momentu s využitím *JADE* algoritmu.

Na klasifikáciu komponentov je možné použiť aj určitý stupeň umelej inteligencie, ako dokázali Sai a kol. [21]. Autori štúdie tvrdia, že používanie manuálne definovaného prahu na určovanie komponentov je nevhodné, pretože môže viesť k falošnej detekcii neartefaktových komponentov, prípadne nezachytiť tie, ktoré artefaktové skutočne sú. Navyše jedna stanovená prahová hodnota nemusí byť vhodná na použitie na datasey z iných meraní. V tejto štúdií bol tak použitý tzv. *support vector machine* (SVM), čo je rozšírený nástroj strojového učenia pod dohľadom (supervised machine learning). SVM bol použitím dát z rôznych komponentov „natrénovaný“ na vyhľadávanie žmurkania v signáloch a tie komponenty, ktoré označil ako artefaktové boli následne výpočtom ďalších štyroch parametrov ďalej testované a použitím vlnkovej-ICA odstránené.

Všetky zmienené metódy boli publikované v odborných časopisoch. Úspešnosť ich použitia v rámci klasifikácie komponentov a konečnom odstránení artefaktov z EEG záznamov bola určovaná rôzne. V niektorých článkoch (Sai a kol., [21], Delsanto a kol., [46]) boli komponenty, ktoré identifikoval algoritmus porovnávané s expertnou identifikáciou. Zo získaných informácií bola vypočítaná senzitivita, špecificita a celková presnosť algoritmu. Iné štúdie (napr. Vigário, [26]) porovnávali signály pred a po použití metódy ICA a vizuálne dokazovali, že boli artefakty odstránené. Týmto spôsobom bola vlastne hodnotená samotná ICA a jej vhodnosť na potlačenie EEG artefaktov. Ďalšou možnosťou hodnotenia ICA je výpočet korelačného koeficientu pred a po potlačení artefaktov, keďže cieľom odstraňovania artefaktov je nielen ich odstrániť, ale zároveň zachovať čo najviac neurologickej informácie. Korelačný koeficient dokáže povedať do akej miery bol signál použitím akejkoľvek metódy na odstránenie artefaktov zmenený. Z tohto dôvodu jeho výpočet použili v štúdiách napríklad Sai a kol. [21] alebo Zhou a Gotman [27]. V rámci mojej rešerše som ale našiel len jednu štúdiu, (Nolan a kol., [47]), v ktorej boli výsledky metódy hodnotené na základe štatistických testov.

Pretože nie je možné od pacienta očakávať, že počas celého nahrávania EEG záznamu nebude pohybovať očami ani žmurkať, očné artefakty sa pri vyšetrení s otvorenými očami vždy dostanú do nahraného záznamu. Metóda ICA sa v mnohých výskumoch osvedčila a ukázala sa byť vhodným, a v tejto chvíli už štandardným nástrojom na redukciu očných artefaktov. Rovnako existuje mnoho metód automatickej klasifikácie komponentov, pričom ale žiadna zatiaľ nedosahuje stopercentnej spoľahlivosti a tak sa na ich vývoji a zdokonalení stále pracuje.



### 3 Ciele práce

Pokročilá analýza biologických signálov dokáže priniesť veľké množstvo informácií o procesoch prebiehajúcich vnútri ľudského tela. Táto práca sa venuje EEG signálom a metóde analýzy nezávislých komponentov ICA pre potreby potlačenia očných artefaktov z EEG záznamov. Prvým cieľom tejto práce je analyzovať rôzne metódy automatickej identifikácie ICA komponentov obsahujúcich očné artefakty, vybrať vhodnú metódu a spoločne so základnou ICA ju implementovať do programového prostredia MATLAB. Ďalším cieľom je na základe charakteru komponentov reprezentujúcich očné artefakty navrhnúť a v programe MATLAB implementovať vlastnú úpravu tejto metódy. Posledným cieľom je pomocou dát získaných z validačných záznamov a navrhutej štatistickej analýzy výsledkov porovnať základnú a upravenú metódu identifikácie artefaktových komponentov z hľadiska ich vhodnosti na potlačenie očných artefaktov z EEG záznamov.

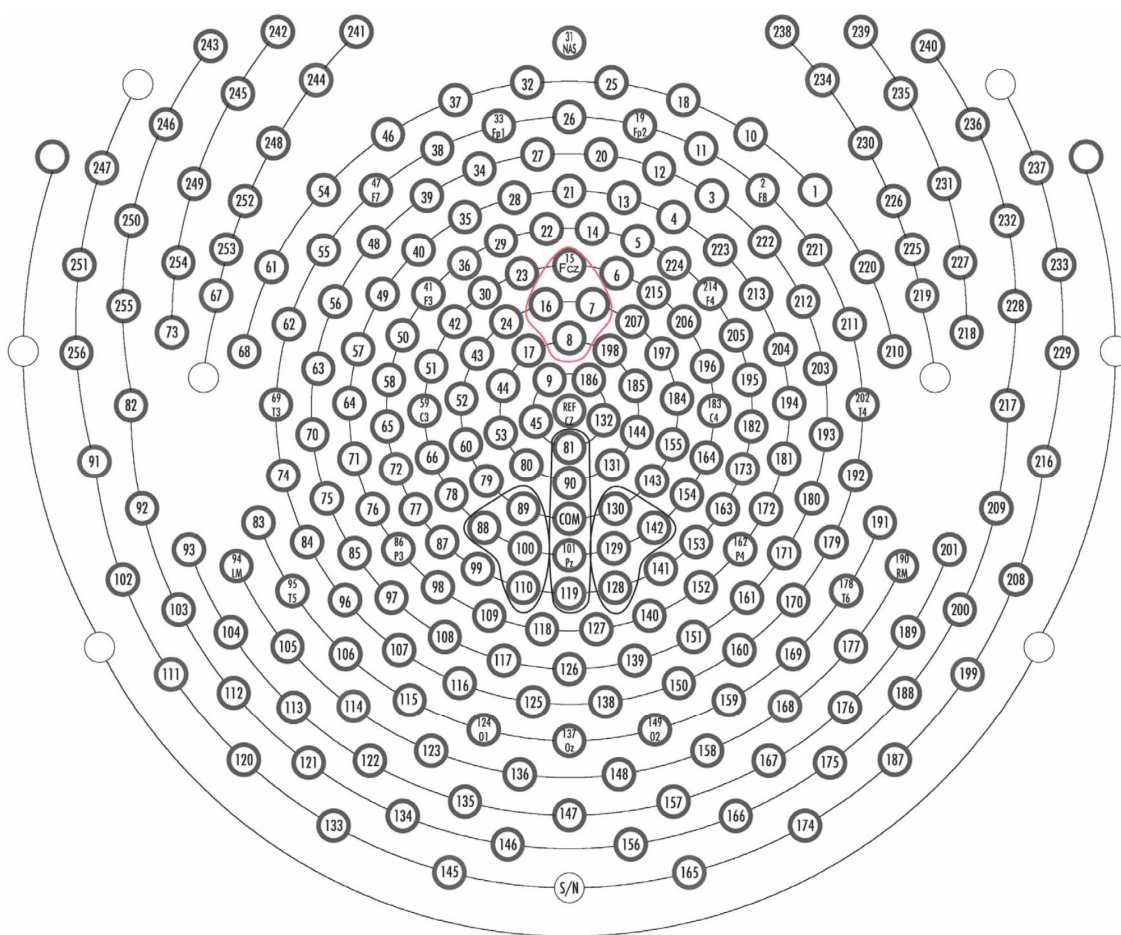
## 4 Metódy

Táto práca sa zaoberá softwarovou úpravou EEG záznamov. Záznamy boli analyzované a upravované pomocou softwaru MATLAB, verzia R2020a [48] a jeho dodatkového rozšírenia FieldTrip [49], ktorý je priamo navrhnutý na spracovanie elektroencefalografických signálov. Nasledujúce kapitoly sa venujú popisu dát, ktoré boli v tomto projekte použité a konkrétnym metódam, pomocou ktorých boli záznamy upravované a úpravy vyhodnocované. V prvom rade bolo na záznamy aplikované prvotné predspracovanie a následne dva algoritmy metódy ICA. Na základe manuálnej analýzy komponentov bol vybraný jeden z algoritmov, ktorý bol následne rozšírený o základnú metódu automatickej identifikácie. Ďalej prebehla vlastná úprava tejto základnej metódy a nakoniec na základe navrhutej štatistickej analýzy boli metódy medzi sebou porovnané.

### 4.1 Použité dáta

Na spracovanie tejto práce boli použité elektroencefalografické záznamy poskytnuté Národným ústavom duševného zdravia (NÚDZ). Jednalo sa konkrétne o záznamy jedenástich dobrovoľníkov, ktorí podstúpili ASSR experiment (auditory steady state response – skúmanie odpovede mozgu na sluchový podnet) s takzvanou „click train“ stimuláciou (podnety mali formu zvukových „klikov“) [50]. Dobrovoľníkom obsluha počas nahrávania EEG púšťala do slúchadiel „click train“ stimulácie s frekvenciou 40 Hz. Tieto podnety mali v EEG záznamoch vyvolať odpoveď mozgu na rovnakej frekvenčnej úrovni 40 Hz. Celé nahrávanie prebiehalo vo vnútri Faradayovej kľetky, cieľom čoho bolo potlačenie technických artefaktov, hlavne rušenia z elektrickej siete. Všetci probandi boli pri nahrávaní v kľude, oči mali otvorené a boli inštruovaní fixovať svoj pohľad na fixačný kríž, aby sa aspoň čiastočne zabránilo vzniku pohybových očných artefaktov. EEG záznamy boli nahrávané pomocou výskumného systému EGI 256 hdEEG, použitých bolo 256 elektród, vid' obrázok 4.1. Dĺžka záznamov bola vo všetkých prípadoch viac ako 200 sekúnd, každý obsahoval 150 ASSR stimulov a nahrávanie prebiehalo so vzorkovacou frekvenciou 1000 Hz.

Experiment bol schválený etickou komisiou NÚDZ a každý zo subjektov pred nahrávaním podpísal informovaný súhlas. Pre analýzu potlačenia očných artefaktov boli použité práve tieto záznamy, pretože pri nahrávaní mali dobrovoľníci otvorené oči a tak do záznamov automaticky zahŕňali pohyby očí a žmurkanie. Množstvo zahrnutých artefaktov bolo však typické pre daný typ experimentu. Jeden zo záznamov slúžil na implementáciu automatizovanej metódy potlačenia očných artefaktov a zvyšných desať na jej štatistické testovanie.



Obrázok 4.1: Grafické rozloženie systému na nahrávanie EEG záznamov EGI 256 hdEEG. Elektródy z hornej časti obrázku (napríklad 37, 32, 25, 18) sú umiestnené na čele pacienta, elektródy z dolnej časti obrázku (napríklad 123, 136, 148, 158) má pacient pripevnené na zátýlku. Prevzaté z [51].

## 4.2 Predspracovanie EEG záznamov

Predtým ako môže prebehnúť samotná analýza signálu, je nutné upraviť signál tzv. predspracovaním. V rámci tejto práce boli na predspracovanie použité metódy *demean*, *detrend* a filtrácia signálu. Metóda *demean* v princípe zbavuje dáta nenulovej jednosmernej zložky (offsetu) [31]. Je možné ju realizovať pomocou nasledujúceho vzťahu:

$$z(t) = x(t) - \bar{x} \quad (1)$$

kde  $x(t)$  je hodnota napätia pôvodného signálu v čase  $t$ ,  $\bar{x}$  je stredná hodnota napätia v zázname,  $z(t)$  je upravený signál zbavený nenulového offsetu v čase  $t$ .

Metóda *detrend* je veľmi podobná metóde *demean* s tým rozdielom, že *detrend* odstraňuje celkový nízko-frekvenčný trend z EEG záznamov [31]. Na skúmaný záznam sa naniesie krivka (polynóm), ktorá kopíruje jeho nízko-frekvenčný trend a následne sa od pôvodného signálu odčíta. Rozdiel oproti *demeanu* je teda v tom, že sa od pôvodného signálu neodčíta priamka rovnobežná s izolíniou, ale krivka. Pre metódu *detrend* platí:

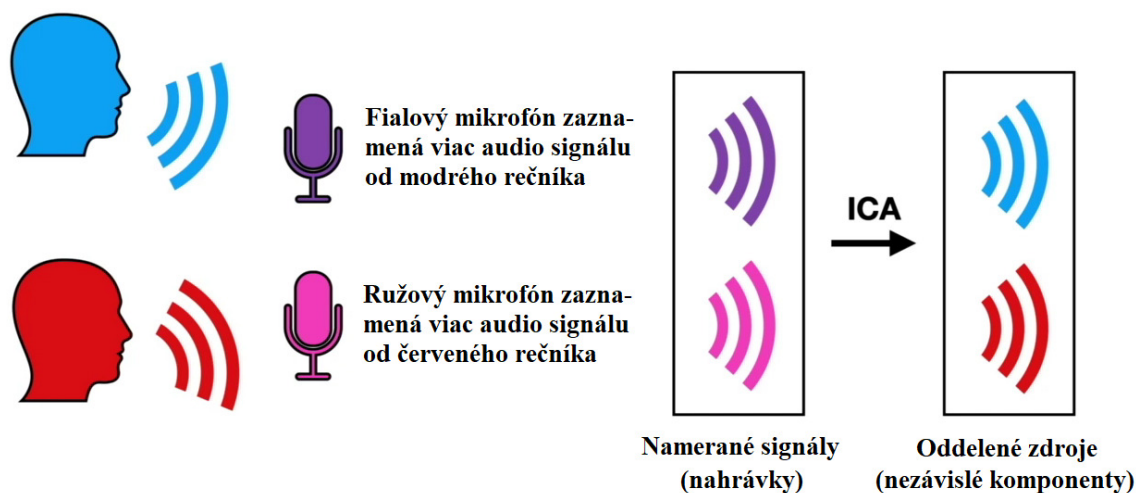
$$z(t) = x(t) - y(t) \quad (2)$$

kde  $x(t)$  je hodnota napätia pôvodného signálu v čase  $t$ ,  $z(t)$  je upravený signál zbavený nízkofrekvenčného trendu v čase  $t$ ,  $y(t)$  je nanesená krivka kopírujúca trend záznamu.

Ďalším krokom predspracovania analyzovaných signálov v tejto práci bola ich filtrácia. Použitý bol digitálny filter typu pásmová priepust (Band-Pass – BP) so zlomovými frekvenciami nastavenými na  $f_1 = 0,5$  Hz a  $f_2 = 30$  Hz. Filter tak zo signálu, ktorý bol už upravený metódami *demean* a *detrend* potlačil všetky frekvencie nižšie ako 0,5 Hz a vyššie ako 30 Hz. Konkrétne sa jednalo o filter typu FIRWS (Finite Impulse Response with Windowed Sinc – filter s konečnou impulznou odozvou s použitím vyhladenej funkcie *sinc* pomocou Hanningovho váhovaciego okna). Rád filtru bol 3100.

### 4.3 Metódy slepej separácie zdrojov (BSS – Blind Source Separation)

Ďalšie metódy používajúce sa pri potlačovaní EEG artefaktov patria do skupiny slepej separácie zdrojov BSS, medzi ktoré sa radí aj analýza nezávislých komponentov ICA. Ich problematiku najlepšie ilustruje takzvaný *cocktail-party problem* (problém / fenomén koktejlovej párty). Predstavme si situáciu, v ktorej sa dvaja ľudia rozprávajú na koktejlovej párty a každý z nich má pred sebou umiestnený jeden mikrofón. Obidva mikrofóny zaznamenávajú audio záznam oboch ľudí, ale jeden mikrofón je vždy umiestnený bližšie k jednému rečníkovi a druhý k druhému rečníkovi. Každý z mikrofónov tak nahrá viac audio signálu od toho rečníka, ku ktorému je bližšie. Vo výsledku sú k dispozícii dve nahrávky, kde obe obsahujú celý rozhovor, ale v jednej je výraznejší audio signál od rečníka číslo 1 a v druhej od rečníka číslo 2. Otázkou je, ako je možné tieto dve nahrávky od seba oddeliť tak, aby v každej z nových nahrávok bola prítomná iba časť rozhovoru pochádzajúca od rečníka číslo 1, resp. 2.



Obrázok 4.2: Grafické znázornenie *cocktail-party problému* ilustrujúceho princíp BSS metód. Fialový mikrofón je umiestnený bližšie k modrému rečníkovi, preto je vo fialovej nahrávke prítomná väčšia zložka signálu od modrého rečníka. Ružový mikrofón je bližšie k červenému rečníkovi, a tak je v ružovej nahrávke zaznamenaného viac „červeného“ signálu. Metódy BSS (napríklad ICA) sú schopné fialovú a ružovú nahrávku rozdeliť na dva pôvodné samostatné zdroje. Prevzaté a upravené z [52].

Situácia s EEG je v skutočnosti veľmi podobná *cocktail-party problému*. Vo výsledku je k dispozícii záznam obsahujúci zmes komponentov, ktoré sú generované z rôznych zdrojov (elektrická aktivita buniek mozgu spoločne so všetkými druhmi artefaktov), pričom ale pre lekára je relevantná len neurologická aktivita. Metódy BSS sú schopné zabezpečiť toto „oddelenie“ – či už zdrojov z nahrávok audio záznamu dvoch rečníkov, alebo zdrojov prispievajúcich do komplexného EEG záznamu. Tým pádom je ich použitie vhodné na odstránenie artefaktov [52; 42].

Základný algoritmus metód BSS popisuje namerané navzorkované dáta (vektory)  $x_1, x_2, x_3, \dots, x_m$  ( $m$  je konečný počet vektorov) ako lineárnu kombináciu vzoriek náhodných nezávislých komponentov  $s_1, s_2, s_3, \dots, s_n$  a ich mixujúcich koeficientov  $a_1, a_2, a_3, \dots, a_n$ . ( $n$  je celkový počet vzoriek vektoru  $x$  a tým pádom aj nezávislého komponentu  $s$ ) [25]. Tento vzťah je možné popísať nasledujúcou rovnicou:

$$x_i = a_{i1} \cdot s_1 + a_{i2} \cdot s_2 + a_{i3} \cdot s_3 + \dots + a_{in} \cdot s_n \quad (3)$$

kde  $x_i$  je  $i$ -tý vektor v množine dát,  $s_1$  je prvá vzorka náhodného nezávislého komponentu, a  $a_{i1}$  je mixujúci koeficient prvej vzorky náhodného nezávislého komponentu v  $i$ -tom vektore. Pre väčší počet vektorov je tento vzťah lepšie reprezentovateľný vo forme nasledujúcej matice [25]:

$$\begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_m(t) \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \dots & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix} \cdot \begin{bmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_m(t) \end{bmatrix} \quad (4)$$

Táto matica sa dá zjednodušene napísať ako:

$$x = A \cdot s \quad (5)$$

kde  $x$  je stĺpcový vektor nameraných dát,  $s$  je stĺpcový vektor nezávislých komponentov (zdrojov) a  $A$  je tzv. mixujúca matica.

Pri prenesení uvedených predpokladov na EEG záznamy,  $x$  sú jednotlivé kanály, ktoré sa pri vyšetrení nahrajú,  $s$  sú jednotlivé nezávislé komponenty (inak povedané nezávislé zdroje rôznych druhov signálov zakomponovaných v celom EEG zázname),  $m$  je ich celkový počet a  $n$  je počet vzoriek každého z kanálov. Koefficienty  $A$  a  $s$  sú neznáme. Úlohou BSS metód je na základe znalosti  $x$  určiť odhad jednotlivých nezávislých komponentov  $\hat{s}$  tak, že výsledkom bude:

$$\hat{s} = W \cdot x \quad (4)$$

$W$  sa v tomto prípade rovná inverznej matici k  $A$ , tzv. demixujúca matica [42]. Po určení odhadu nezávislých zdrojov  $\hat{s}$  nasleduje ich analýza a identifikácia tých, ktoré reprezentujú artefakty. Vybrané zdroje sa spomedzi všetkých zdrojov odstránia – vynulujú a pomocou inverzného algoritmu dôjde k spätnej rekonštrukcii záznamu  $x$ , v ktorom sú identifikované artefakty potlačené [27].

## 4.4 ICA

Metóda analýzy nezávislých komponentov ICA je jedna z metód slepej separácie zdrojov. Jej cieľom je transformácia množiny vektorov pomocou demixujúcej matice  $W$  do novej množiny tak, aby jednotlivé odhadnuté zdroje (komponenty)  $\hat{s}$  boli na sebe maximálne štatisticky nezávislé [52]. Nezávislosť je možné dosiahnuť dvomi hlavnými spôsobmi.

Prvou možnosťou je použiť algoritmus, ktorý vytvorí maticu  $W$  tak, že minimalizuje spoločnú informáciu obsiahnutú v rámci všetkých nezávislých komponentov [39; 53]. Príkladom takéhoto algoritmu je *Infomax*, algoritmus založený na maximalizácii entropie. Entropia môže byť definovaná ako miera neistoty, neurčitosti systému. Čím je jej hodnota nižšia, tým viac vzájomnej informácie o systéme jednotlivé komponenty obsahujú. *Infomax* funguje opačným smerom: maximalizuje entropiu a tým pádom dochádza k minimalizácii spoločnej informácie v rámci jednotlivých zdrojov a vznikajú tak komponenty, ktoré sú na sebe maximálne nezávislé [39].

Druhý významný typ algoritmov ICA sa zameriava na maximalizáciu „ne-Gaussovského“ rozdelenia pravdepodobnosti medzi jednotlivými zdrojmi [42]. Pri

použití ICA sa automaticky predpokladá, že jednotlivé zdroje nemajú Gaussovské rozdelenie (viď kapitola 4.4.1). Tieto algoritmy sa však pri výpočte nezávislých komponentov snažia prinútiť ich byť od normálneho rozdelenia čo „najďalej“ pomocou tzv. negentropie. Negentropia  $N(p)$  je miera „vzdialenosti“ od normálu a je definovaná pomocou vzťahu:

$$N(p) = H(p_{Gauss}) - H(p) \quad (6)$$

kde  $p$  je náhodný vektor s „ne-Gaussovským“ rozdelením,  $H(p)$  je jeho entropia a  $H(p_{Gauss})$  je entropia náhodného vektoru s Gaussovským rozdelením, ktorého kovariančná matica je zhodná s kovariančnou maticou vektoru  $p$  [42; 53].

Negentropiu je však náročné vypočítať podľa vzťahu (6), preto sa na jej určenie používajú rôzne aproximácie. Jednu z nich vo svojom článku [42] navrhli Hyvärinen a Oja a tá sa stala základom ich algoritmu na výpočet nezávislých komponentov *FastICA*. V tejto práci boli pri výpočte nezávislých zdrojov použité oba spomenuté algoritmy, *Infomax* aj *FastICA*.

#### 4.4.1 Podmienky použitia ICA

Použitie ICA ako metódy na odstraňovanie artefaktov z EEG záznamov je podmienené splnením nasledujúcich podmienok [21; 52; 42]:

1. Jednotlivé zdroje musia byť na sebe štatisticky nezávislé. Štatistická nezávislosť znamená, že prítomnosť jedného javu nijakým spôsobom neovplyvňuje pravdepodobnosť, že nastane jav druhý. Dva náhodné javy  $A$  a  $B$  sú nezávislé práve vtedy, keď sa pravdepodobnosť ich spoločného výskytu  $p(A, B)$  rovná súčinu pravdepodobnosti výskytu javu  $A$   $p(A)$  a javu  $B$   $p(B)$  [52]:

$$p(A, B) = p(A) \cdot p(B) \quad (5)$$

Pri odstraňovaní očných artefaktov je možné túto podmienku považovať za splnenú, keďže platí predpoklad, že elektrická aktivita očí a mozgu sú dva fyziologicky nezávislé procesy, pričom jeden neovplyvňuje druhý [26].

2. Jednotlivé zdroje nesmú mať normálne (Gaussovské) rozdelenie pravdepodobnosti. Spôsob, akým mozog generuje signály, túto podmienku automaticky splňuje [53].
3. Celkový počet vzoriek každého z meraných kanálov ( $n$ ) musí byť väčší alebo rovný počtu nezávislých komponentov ( $m$ ) [21]. Táto podmienka je tiež splnená, pretože v rámci použitých záznamov sa  $m$  rovná 256 a  $n$  najmenej 200 000 –  $n$  je závislé na dĺžke nahrávania záznamu a vzorkovacej frekvencii.

## 4.4.2 Predspracovanie pred aplikáciou ICA

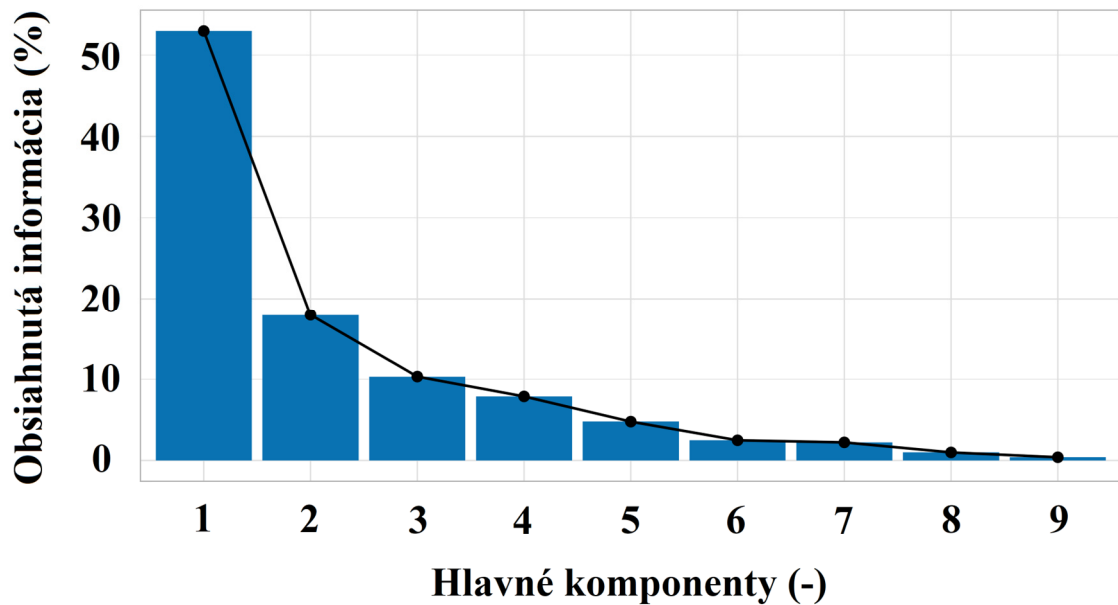
*Centering* (centrovanie dát) je základný spôsob úpravy dát pred ICA, ktorý je v skutočnosti úplne zhodný s metódou *demean* (viď kapitola 4.2). Zo záznamu je odstránená jeho stredná hodnota. Tento krok predspracovania sa robí z toho dôvodu, že sa ním zjednoduší výpočet nezávislých komponentov. V prípade, že je potrebné exaktné určenie mixujúcej matice  $A$ , je možné odstrániť vektor strednej hodnoty k matici pripočítať späťne [42]. V prípade tejto práce bolo možné pred samotnou ICA *centering* vynechať, pretože už v predchádzajúcom kroku bola na signály aplikovaná metóda *demean*.

*Whitening* (bielenie dát) je po centrovaní ďalším krokom predspracovania signálu. Ide o lineárnu transformáciu známeho vektoru  $x$  tak, že vo výsledku vznikne nový „biely“ vektor  $x'$ . Premenné vo vektore  $x'$  sú nekorelované a každá z nich má rozptyl rovný 1. Inými slovami, kovariančná matica vektoru  $x'$  je rovná jednotkovej matici [42].

Pre správnu aplikáciu ICA je ďalej vhodné znížiť dimenzionalitu dát. Na tento krok sa dá využiť napríklad štatistická metóda analýzy hlavných komponentov (PCA – Principal Component Analysis). PCA funguje tak, že sa pomocou matematických algoritmov transformuje veľká sada premenných na menší set s tým, že aj menší set v sebe zahŕňa väčšinu informácie pôvodnej sady [54]. Hlavnou myšlienkou je znížiť počet premenných v dátach, čím sa zjednoduší ich vizualizácia a analýza. Tento kompromis je výhodný aj za cenu toho, že dôjde k strate malého percenta informácie obsiahnutej v pôvodnom datasete. Metóda PCA je takisto jednou z metód slepej separácie zdrojov, viď kapitola 4.3.

Hlavné komponenty sú vlastne nové premenné, ktoré sú vytvorené ako lineárna kombinácia premenných z pôvodného datasetu. Pôvodné premenné sú transformované tak, aby sa maximum pôvodnej informácie dostalo do prvého komponentu, potom maximum zostatkovej informácie do druhého komponentu, a tak ďalej, viď obrázok 4.3. Reorganizácia informácie z datasetu týmto spôsobom umožní pri analýze zbaviť sa komponentov s malým obsahom informácie.

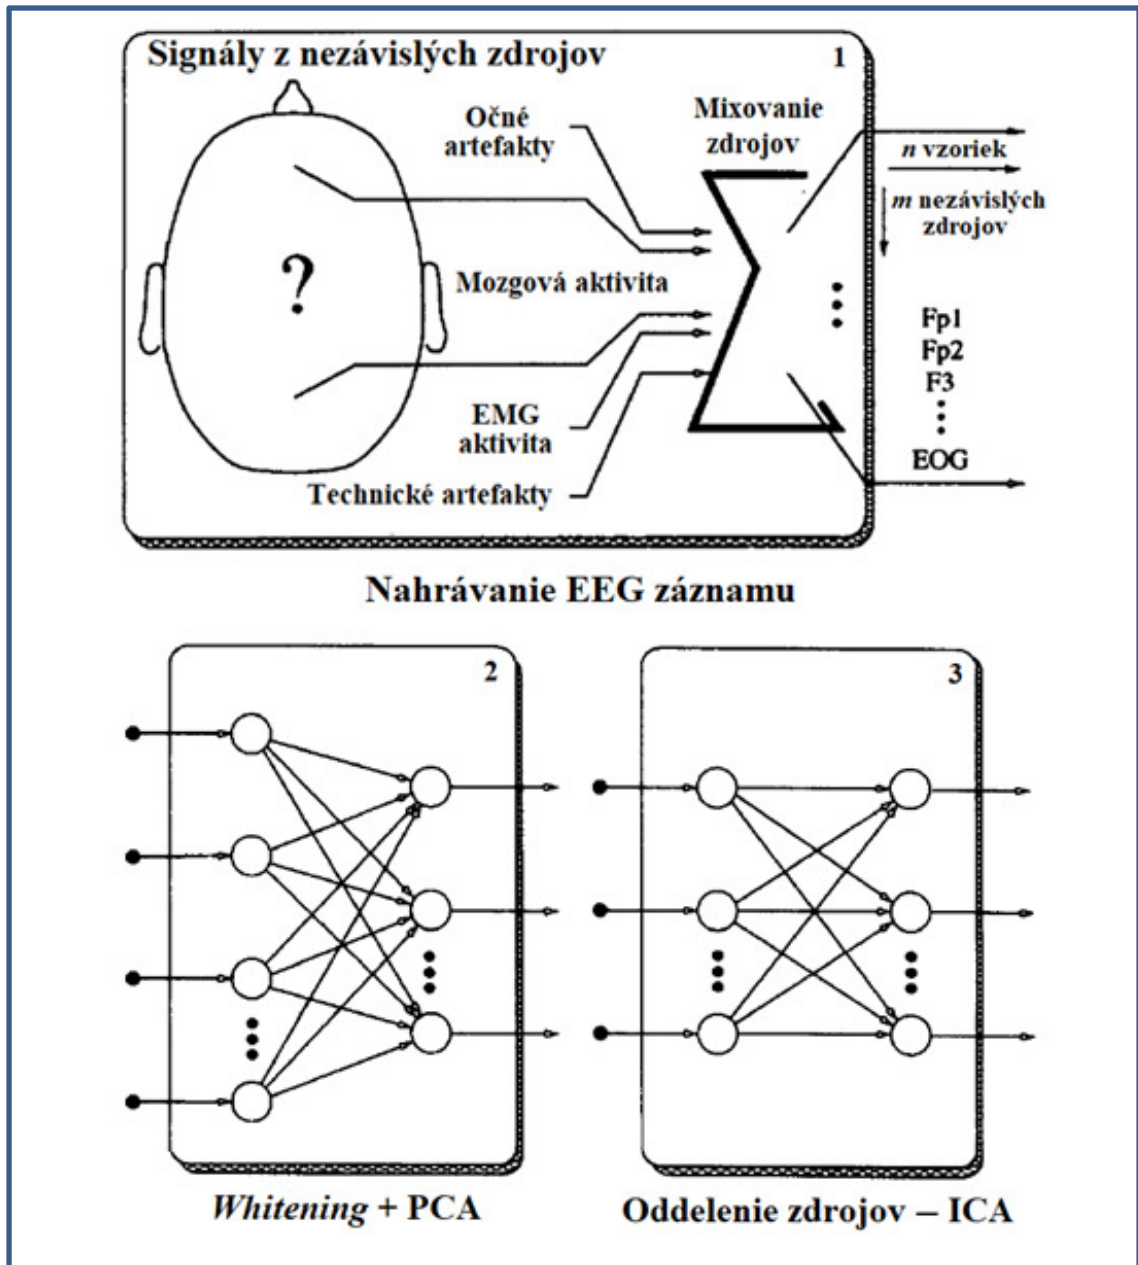




Obrázok 4.3: Ilustrácia metódy PCA. Na vodorovnej osi sú zobrazené jednotlivé hlavné komponenty usporiadané podľa množstva obsiahnutej pôvodnej informácie. Na zvislej osi je percento pôvodnej informácie datasetu. Prevzaté a upravené z [54].

Všetky použité EEG záznamy – implementačný aj validačné boli pred samotnou ICA podrobené každej zo zmiených metód predspracovania. Proces *whiteningu* bol dosiahnutý použitím analýzy hlavných komponentov (PCA), čím zároveň došlo k redukcii dimenzionality dát. Zníženie dimenzionality dát týmto spôsobom bolo v rámci tejto práce žiadúce, keďže spracovávané EEG záznamy boli až z 256 elektród. PCA bola nastavená tak, aby zostalo zachovaných 95 % informácie obsiahnutej v pôvodnom datasete. Výhoda použitia PCA ako formy predspracovania pred ICA je možnosť dopredu nastaviť počet nezávislých komponentov, ktoré algoritmus vypočíta, a tým celý proces zrýchliť.

Nasledovalo použitie metódy ICA na EEG záznamy, pričom bolo sledované, aký rozdiel vo výsledkoch dosiahnu jednotlivé použité algoritmy *Infomax* a *FastICA*. Komponenty obsahujúce akýkoľvek typ očných artefaktov boli v tomto prípade identifikované expertne a zo záznamu manuálne odstránené. Na základe porovnania výsledkov oboch algoritmov bol vybraný jeden, ktorý bol následne rozšírený o automatickú detekciu artefaktových komponentov. Pri porovnávaní výsledkov bol sledovaný počet odstránených komponentov z hľadiska zachovania neurologickej aktivity a na primárnu funkčnosť oboch algoritmov – či v skutočnosti došlo k odstráneniu očných artefaktov. Konkrétne výsledky porovnania sú dostupné v kapitole 5.2 a 5.3.



Obrázok 4.4: Princíp predspracovania EEG signálu potrebného pre následné použitie metódy ICA. V bloku číslo 1 dochádza k nahrávaniu EEG záznamu, do ktorého vstupujú okrem mozgovej aktivity aj iné nezávislé zdroje signálu a dochádza k ich mixovaniu. V bloku č.2 dôjde prostredníctvom PCA k „vybieleniu“ signálu a redukcii jeho dimenzionality – do bloku 2 vstupujú štyri signály a vystupujú z neho tri. V treťom bloku metóda ICA oddelí zo zmiešaných signálov jednotlivé nezávislé zdroje. Prevzaté a upravené z [26].

## 4.5 Automatická detekcia artefaktových komponentov

V tejto kapitole je uvedený detailný popis základnej metódy automatickej identifikácie ICA komponentov, obsahujúcich očné artefakty, vybranej pre túto prácu z odborného článku. Nasledovať bude popis parametrov a postup stanovenia prahových hodnôt, ktoré boli použité na vlastnú úpravu tejto metódy.

### 4.5.1 Základná metóda automatickej detekcie

Ako základná metóda automatickej identifikácie komponentov obsahujúcich očné artefakty, bola vybratá metóda z kapitoly 2.5 *Automatic correction of eye movement artifact* z článku [41] od Tinga a kolektívu. Autori štúdie pri implementácii tejto metódy použili horizontálne a vertikálne EOG kanály, pričom získané EOG dáta neboli použité na regresiu signálu, ale na identifikáciu artefaktových komponentov po použití ICA. Dáta z vertikálnych EOG kanálov boli získané umiestnením elektród nad a pod oči, zatiaľ čo dáta z horizontálnych EOG kanálov sa získali pomocou elektród na vonkajších kútikoch ľavého a pravého oka (*outer canthi*). Záznamy spracovávané v rámci tejto bakalárskej práce síce nemali k dispozícii EOG kanály, ale pri ich nahrávaní bol použitý systém EGI 256 hdEEG, ktorý v sebe zahŕňa aj elektródy umiestnené na miestach EOG elektród. Z tohto dôvodu bolo možné túto metódu implementovať aj pomocou dát získaných bez štandardnej EOG referencie.

Použitá metóda je založená na tom, že jednotlivé zdroje očných artefaktov sú jednoznačne charakterizované ich priestorovým rozložením na povrchu hlavy, viď obrázok 2.6. Tento fakt sa dá využiť pri ich identifikácii, pričom autori na určovanie komponentov použili jeden parameter pre horizontálny pohyb očí, uvedený vo vzťahu (6) a jeden parameter pre vertikálny pohyb očí, vzťah (7). V oboch prípadoch sa hodnota vypočítaných parametrov porovnávala s prahovou hodnotou 0, ktorú autori použili v článku [41].

$$|\mathbf{a}_i(\text{ľavé}) - \mathbf{a}_i(\text{pravé})| - \max|\mathbf{a}_i(\text{zvyšné})| > 0 \quad (6)$$

$$|\mathbf{a}_i(\text{nad}) - \mathbf{a}_i(\text{pod})| - \max(|\mathbf{a}_i(\text{zvyšné})|) > 0 \quad (7)$$

$\mathbf{a}_i(\text{ľavé})$  reprezentuje priemerný výkon ôsmich vybraných kanálov z oblasti ľavého oka,  $\mathbf{a}_i(\text{pravé})$  výkon rovnakého počtu kanálov z oblasti pravého oka.  $\mathbf{a}_i(\text{nad})$  je priemerný výkon dvadsiatich dvoch kanálov umiestnených nad očami a  $\mathbf{a}_i(\text{pod})$  je priemer šiestich kanálov pod očami.  $\mathbf{a}_i(\text{zvyšné})$  je v oboch prípadoch priemer vybraných kanálov z oblasti hlavy, ktorá sa nenachádza v blízkosti očí. Konkrétne použité čísla kanálov sú presne špecifikované v prílohe práce.

Ako bolo uvedené vyššie, zmena pri vlastnej implementácii oproti metóde popísanej v článku [41] bola v tom, že autori v rámci  $\mathbf{a}_i(\text{ľavé})$ ,  $\mathbf{a}_i(\text{pravé})$ ,  $\mathbf{a}_i(\text{nad})$  a  $\mathbf{a}_i(\text{pod})$  používali dáta získané priamo z EOG kanálov, zatiaľ čo v tejto práci bol použitý

priemer výkonu z EEG elektród z oblastí zhodných s oblasťami EOG elektród. Ďalším rozdielom bolo, že pri vlastnej implementácii tejto metódy bola ešte pred výpočtom parametrov vo vzťahoch (6) a (7) použitá normalizácia priestorového rozloženia všetkých komponentov pomocou štandardného skóre (z-skóre). Z-skóre sa v rámci populácie určí tak, že je od pôvodnej hodnoty skóre  $c$  odčítaná stredná hodnota populácie  $\mu$  a výsledok je vydelený smerodajnou odchýlkou populácie  $\sigma$ :

$$z = \frac{c - \mu}{\sigma} \quad (8)$$

Hodnota dát  $z$  po použití vzťahu (8) udáva absolútny rozdiel medzi pôvodným skóre  $c$  a strednou hodnotou populácie  $\mu$  v jednotkách smerodajnej odchýlky  $\sigma$ . V prípade, že stredná hodnota a smerodajná odchýlka populácie sú neznáme, môže byť z-skóre vypočítané približne z hodnôt strednej hodnoty  $\bar{c}$  a smerodajnej odchýlky  $s$  výberu z populácie [55].

Výpočty parametrov (6) a (7) prebehli pre každý normovaný nezávislý komponent určený pomocou ICA. V prípade, že v ktoromkoľvek z komponentov prekonal aspoň jeden parameter prahovú hodnotu, bol komponent automaticky označený ako artefaktový a z výsledného signálu sa odstránil.

#### 4.5.2 Vlastná úprava základnej metódy, horizontálny pohyb očí

Pri použití automatickej klasifikácie komponentov je nutné dbať nielen na to, aby mal algoritmus dostatočnú senzitivitu, ale aj špecificitu. Inými slovami, aby spoločne s artefaktovými komponentami neoznačoval ako artefaktové aj zdroje neurologickej informácie. Špecificita sa v prípade použitej základnej metódy dala zvýšiť počtom parametrov, ktoré musel komponent „splniť“, aby mohol byť klasifikovaný ako artefaktový.

V rámci vlastnej úpravy základnej metódy boli do algoritmu k pôvodným dvom pridané ďalšie štyri parametre: dva pre horizontálny a dva pre vertikálny pohyb očí. V prípade horizontálneho pohybu očí sa v rámci oboch parametrov jednalo o analýzu topografických máp, ktoré boli rovnako ako v základnej metóde normalizované pomocou z-skóre.

**Parameter 1:** Podobne ako v prípade základnej metódy, aj pri výpočte tohto parametru bol vzťahnutý priemerný výkon  $a_i$  z vybraných elektród v oblastiach pravého a ľavého oka voči priemernému výkonu z kanálov nachádzajúcich sa mimo blízkosti očí. Jeho výpočet bol však iný:

$$\frac{\text{mean}(|a_i(\text{ľavé})| + |a_i(\text{pravé})|)}{|a_i(\text{zvyšné})|} > \text{prah} \quad (9)$$

$a_i(\textit{ľavé})$  reprezentuje priemerný výkon ôsmich vybraných kanálov z oblasti ľavého oka,  $a_i(\textit{pravé})$  výkon rovnakého počtu kanálov z oblasti pravého oka.  $a_i(\textit{zvyšné})$  je priemer vybraných kanálov z oblasti hlavy, ktorá sa nenachádza v blízkosti očí. Na výpočet tohto parametru bol použitý výkon z tých istých elektród ako vo vzťahu (6). V rámci vzťahu (9) znamená *mean* priemer výkonov z oblastí ľavého a pravého oka. Komponent splnil klasifikačnú podmienku tohto parametru, ak jeho vypočítaná hodnota bola vyššia ako stanovená prahová hodnota. Postupu stanovenia prahových hodnôt sa bude venovať kapitola 4.5.5.

**Parameter 2:** Charakteristická vlastnosť opačnej polarít výkonu z kanálov v oblastiach pravého a ľavého oka v komponentoch s horizontálnymi očnými pohybmi sa tiež dala využiť pri ich identifikácii. Aby zdroj splnil klasifikačnú podmienku tohto parametru, musel mať priemerný výkon z vybraných elektród z oblasti jedného oka kladnú polaritu, zatiaľ čo priemerný výkon z vybraných elektród z oblasti druhého oka musel mať zápornú polaritu, resp. naopak.

### 4.5.3 Vlastná úprava základnej metódy, vertikálny pohyb očí

Aj pre identifikáciu vertikálneho pohybu očí boli z dôvodu zvýšenia špecificity algoritmu pridané dva parametre. V jednom z nich bolo opäť použité normalizované topografické rozloženie komponentov a v druhom boli analyzované časové priebehy komponentov.

**Parameter 3:** Tu ide o analogický výpočet priemerného výkonu  $a_i$  z rôznych oblastí hlavy, tak ako v prípade parametru číslo jeden. Rozdiel je však vo výbere oblastí hlavy (a tým pádom aj vo výbere kanálov), ktorý je prispôsobený na detekciu komponentov obsahujúcich horizontálne pohyby očí, respektíve žmurkanie. Rovnako ako v predchádzajúcom prípade, klasifikačná podmienka parametru bola splnená, ak jeho hodnota prekročila vopred stanovenú prahovú hodnotu. Výpočet parametru je uvedený v nasledujúcom vzťahu:

$$\frac{|a_i(\textit{oči})|}{|a_i(\textit{zvyšné})|} > \textit{prah} \quad (10)$$

kde  $a_i(\textit{oči})$  je priemerný výkon vybraných elektród z oblasti očí a  $a_i(\textit{zvyšné})$  je priemerný výkon vybraných elektród z oblasti hlavy mimo blízkosti očí. Konkrétne použité elektródy sú uvedené v prílohe práce.

**Parameter 4:** Tento parameter bol zameraný na analýzu časovej zhodnosti napätových špičiek medzi originálnym EEG záznamom a jednotlivými komponentami. Za účelom zvýraznenia špičiek a súčasne potlačenia nízkych amplitúd boli ešte pred ich samotnou detekciou všetky komponenty umocnené na druhú. V rámci originálnych EEG signálov

boli vybrané a spriemerované kanály v oblasti očí, v ktorých boli vertikálne pohyby očí / žmurkanie najvýraznejšie. Spriemerovanie viacerých kanálov bolo pridané preto, aby mohli byť detegované napät'ové špičky aj v prípade, ak by signál z niektorej z frontálnych elektród v zázname z nejakého dôvodu chýbal. Vybrané kanály sú takisto v prílohe.

Na detekciu špičiek bola použitá funkcia *findpeaks* s adaptívnym prahovaním, ktorá v rámci signálu dokázala určiť, v ktorých miestach signál dosahoval vyššie hodnoty ako prah. Prahová hodnota bola pre každý analyzovaný EEG signál aj nezávislý komponent určená samostatne pomocou Tukeyho metódy detekcie odľahlých hodnôt, vid' vzťah (11) [56]. Výrazné napät'ové hroty spôsobené žmurkaním a vertikálnymi pohybmi očí sa v rámci signálu dajú považovať za odľahlé hodnoty, takže použitie tejto metódy bolo opodstatnené. Tukey v tejto metóde používa z informácií o spojitých jednorozmerných dátach dolný ( $Q1$ ) a horný ( $Q3$ ) kvartil. Uvedené kvartily sú vypočítané z časových priebehov jednotlivých kanálov a komponentov, pričom prahovú hodnotu je možné vypočítať nasledovne:

$$\text{prah odľahlých hodnôt} = Q3 + 3 \cdot IQR \quad (11)$$

*IQR* (*Inter Quartile Range* – medzikvartilový rozsah) je vzdialenosť medzi dolným kvartilom  $Q1$  a horným kvartilom  $Q3$ .

Hodnoty presahujúce tento prah sa dajú považovať ako pravdepodobne odľahlé (*probable outliers*). Tukeyho metóda sa rovnako dá použiť aj na detekciu možných odľahlých hodnôt (*possible outliers*), pričom v tomto prípade je použitý jeden a pol násobok medzikvartilového rozsahu [56; 57]. Je nutné dodať, že pri detekcií napät'ových špičiek ide o „horné“ odľahlé hodnoty a preto spodný prah nebolo potrebné riešiť. Ďalším parametrom funkcie *findpeaks* bola minimálna vzdialenosť medzi dvomi špičkami, ktorá bola nastavená na hodnotu 200 ms – približná doba trvania jedného žmurknutia. Túto minimálnu vzdialenosť bolo nutné nastaviť preto, aby algoritmus dvakrát nezaznamenal to isté žmurknutie.

Funkcia *findpeaks* určovala časový okamih, v ktorom nastalo prekonanie prahu presne na tisícinu sekundy. V rámci EEG signálu tak boli v oblastiach týchto okamihov vytvorené intervaly s dĺžkou 40 ms, pričom presný okamih prekonania prahu sa nachádzal v strede každého intervalu. Časová zhodnosť výskytu špičiek bola založená na porovnávaní percentuálneho počtu špičiek v každom z komponentov, ktoré spadali do intervalov definovaných v rámci EEG záznamu. Ak dosiahla táto zhodnosť v niektorom z komponentov určitého prahového percenta, tj. že sa detegované špičky vyskytovali približne v tých istých časových okamihoch ako v EEG zázname, bol aj tento parameter považovaný za splnený. Postup stanovenia prahových hodnôt je aj pre parameter 4 uvedený v kapitole 4.5.5.

#### 4.5.4 Vyhodnotenie vlastnej úpravy metódy

Celkovo tak software vyhodnocoval tri parametre pre každý typ očných pohybov – jeden zo základnej metódy a dva pridané. V prípade, že ľubovoľný komponent splnil podmienky pre všetky tri parametre v rámci jedného alebo druhého typu očných pohybov, bol označený ako artefaktový a zo signálu odstránený. Upravený algoritmus mal aj ďalšiu pridanú hodnotu, ktorá spočívala v detekcii „potenciálnych“ artefaktových komponentov. Ak niektorý z komponentov spĺňoval podmienky v dvoch z troch parametrov, software na túto skutočnosť (spoločne s číslom príslušného komponentu) upozornil obsluhu. Týmto spôsobom zároveň vznikla aj semi-automatická metóda, pri ktorej môže obsluha potenciálne artefaktové komponenty skontrolovať a v prípade potreby odstrániť manuálne. Jej výhodou je, že už stačí kontrola len nízkeho počtu komponentov a nie všetkých.

#### 4.5.5 Stanovenie prahových hodnôt

Táto kapitola sa venuje postupu stanovenia prahov, s ktorými boli porovnávané hodnoty parametrov číslo 1, 3 a 4. Je dôležité zdôrazniť, že sa nejedná o Tukeyho prah odľahlých hodnôt, pomocou ktorého boli detegované vysoké amplitúdové špičky.

Aplikáciou metódy ICA na implementačný záznam boli získané jednotlivé zdroje (komponenty) prispievajúce svojimi dielmi do celkového EEG záznamu. Expertnou analýzou všetkých zdrojov boli určené tie, ktoré boli zodpovedné za vznik očných artefaktov v použítom zázname a boli označené ako skutočne pozitívne (TP – *true positive*). Všetky ostatné komponenty boli tým pádom neartefaktové a boli preto klasifikované ako skutočne negatívne (TN – *true negative*). Toto označenie komponentov platilo, pokiaľ sa algoritmus zhodoval s expertom. Pri nesprávnom nastavení algoritmu sa môže stať, že dôjde k označeniu komponentu s obsahom čisto mozgovej aktivity ako artefaktového a tento komponent sa v tomto prípade stáva falošne pozitívnym (FP – *false positive*). Štvrtou možnosťou je, že algoritmus ako neartefaktový nesprávne označí komponent, ktorý v sebe artefakty zahŕňa a ten sa tak stáva falošne negatívnym (FN – *false negative*).

Informácie o TP, TN, FP a FN sa dajú využiť pre výpočet senzitivity a špecificity diagnostického testu. V tomto prípade sa aj algoritmus môže považovať za test, pretože rôzne komponenty zaraďuje do dvoch skupín: pozitívne (artefaktové) a negatívne (neartefaktové). Senzitivita určuje podiel skutočných prípadov zachytených testom. Vypočíta sa ako podiel skutočne pozitívnych pozorovaní a všetkých pozitívnych prípadov [58]:

$$\text{senzitivita} = \frac{TP}{TP+FN} \quad (12)$$

Špecificita určuje podiel negatívnych výsledkov určených testom. Je určená ako pomer skutočne negatívnych pozorovaní ku všetkým negatívnym prípadom [58]:

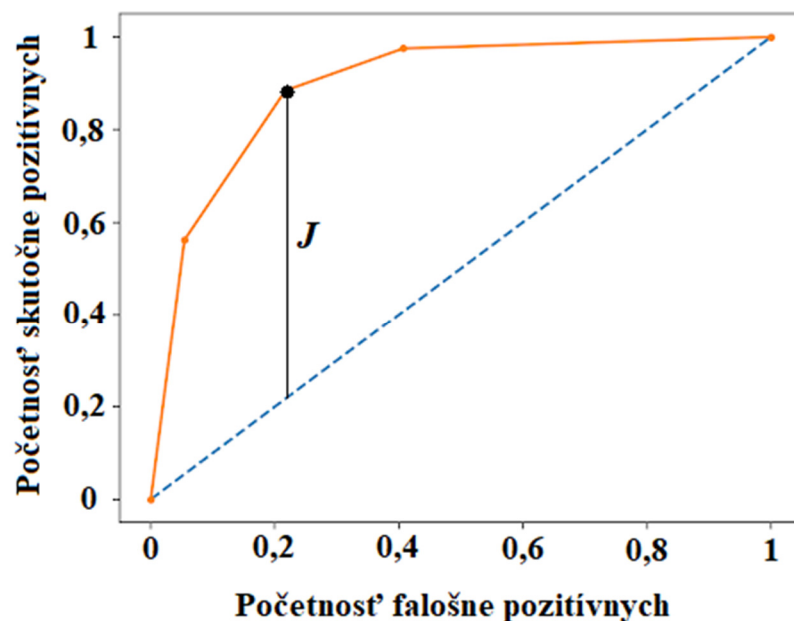
$$\text{špecificita} = \frac{TN}{TN+FP} \quad (13)$$

Senzitivita a špecificita sú dôležitými parametrami klasifikačných vlastností diagnostického testu. Čím je ich hodnota vyššia, tým je test lepší. V reálnych testoch však vždy ide o kompromis medzi týmito dvomi parametrami, teda medzi množstvom falošne pozitívnych a falošne negatívnych pozorovaní [58]. Na hodnotenie a optimalizáciu ich pomeru sa dá použiť ROC krivka (*Receiving Operating Characteristic*), ktorá ukazuje vzťah medzi senzitivitou a špecificitou testu pre všetky prípustné prahové hodnoty. Ideálna hodnota prahu (deliaceho kritéria) sa z ROC krivky dá určiť pomocou Youdenovho indexu  $J$  (viď obrázok 4.5), pre ktorý platí [59]:

$$J = \text{senzitivita} + \text{špecificita} - 1 \quad (14)$$

Hodnota  $J$  sa vypočíta pre každú možnú hodnotu deliaceho kritéria a ako ideálny prah je vybratý ten, pri ktorom je  $J$  najvyššie [59]. Na ROC grafe sa dá Youdenov index zobrazit' ako zvislá čiara medzi diagonálou grafu a samotnou ROC krivkou.

Uvedená ROC analýza prebehla v rámci implementačného záznamu samostatne pre parametre číslo 1, 3 a 4. Deliace kritéria boli pre parametre číslo 1 a 3 skúmané od minimálnej do maximálnej dosiahnutej hodnoty v rámci všetkých komponentov. Pre parameter číslo 4 boli prahové hodnoty v intervale od nula do sto, pretože bol určovaný v percentách. V oboch prípadoch bol použitý jednotkový posun.



Obrázok 4.5: Príklad ROC krivky (oranžová) s vyznačenou polohou Youdenovho indexu  $J$ . Na zvislej osi je početnosť skutočne pozitívnych – senzitivita, na vodorovnej osi je početnosť falošne pozitívnych, matematicky tj.  $1 - \text{špecificita}$ . Modrá prerušovaná priamka je diagonála grafu. Čierny bod na oranžovej krivke zodpovedá hodnote deliaceho kritéria. Prevzaté a upravené z [60].



## 4.6 Vyhodnotenie výsledkov

Ideálnym výsledkom by mal byť algoritmus schopný zbaviť EEG záznam akýchkoľvek artefaktov spôsobených žmurkaním, či inými pohybmi očí subjektu. Pri úprave dát je však nutné dbať na to, aby vo výslednom signáli došlo k zmene iba v súvislosti s potlačením artefaktu a aby zvyšok signálu zostal nezmenený. Štatistická analýza výsledkov sa tak bude týkať troch oblastí:

1. Určenie presnosti, s ktorou algoritmus identifikuje artefaktové komponenty
2. Porovnanie základnej, upravenej a semi-automatickej metódy z hľadiska úspešnosti potlačenia očných artefaktov
3. Porovnanie základnej, upravenej a semi-automatickej metódy z hľadiska zachovania neurologickej aktivity

### 4.6.1 Presnosť algoritmu

V tejto časti bola testovaná presnosť metód automatickej identifikácie komponentov obsahujúcich očné artefakty. Všetkých desať validačných záznamov bolo po rozdelení na nezávislé zdroje odoslaných na expertné ohodnotenie do NÚDZ. Expert v rámci všetkých komponentov určil zdroje očných artefaktov a zdroje mozgovej aktivity, tieto komponenty boli počas vyhodnotenia považované za TP a TN. Z týchto informácií bola následne vyhodnotená presnosť algoritmu z hľadiska identifikácie komponentov. Na základe vzťahov (12) a (13) bola určená senzitivita a špecificita a následne aj celková presnosť algoritmu, ktorá indikuje podiel správne klasifikovaných prípadov. Ide o pomer počtu správne klasifikovaných výsledkov a celkového počtu klasifikácií [21]:

$$presnosť = \frac{TP+TN}{TP+TN+FP+FN} \quad (15)$$

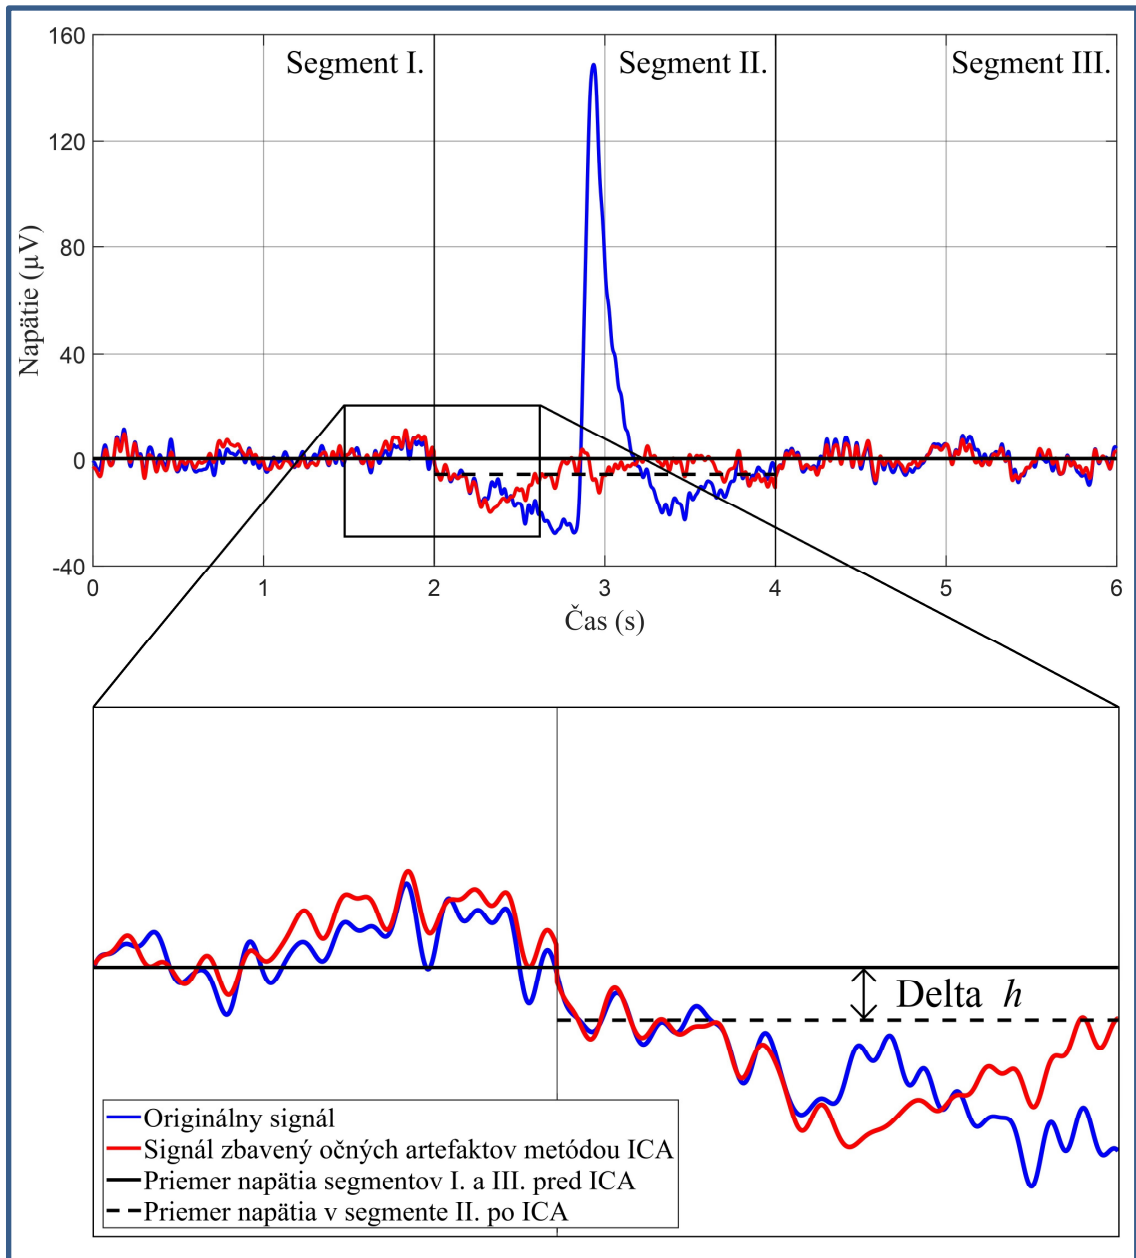
Vo vzťahu (15) sa  $TP$ ,  $TN$ ,  $FP$ ,  $FN$  rovnajú počtu skutočne pozitívnych –  $TP$ , skutočne negatívnych –  $TN$ , falošne pozitívnych –  $FP$  a falošne negatívnych –  $FN$  komponentov. Senzitivita, špecificita aj presnosť bola vypočítaná pre základnú aj pre upravenú metódu automatickej identifikácie komponentov.

### 4.6.2 Úspešnosť potlačenia očných artefaktov

Úspešnosť potlačenia očných artefaktov bola vyhodnocovaná samostatne pre horizontálny a samostatne pre vertikálny pohyb očí / žmurkanie.

Na ilustráciu úspešnosti potlačenia vertikálnych očných pohybov a žmurkania slúži obrázok 4.6. V rámci každého validačného záznamu bolo z kanálu číslo 37 (viď obrázok 4.1) vybratých päť šesťsekundových úsekov (spolu 50), počas ktorých došlo k vertikálnemu pohybu očí subjektov. Tento kanál bol vybratý z dôvodu, že sa nachádzal priamo nad ľavým okom a tak sa predpokladalo, že vertikálne očné pohyby a žmurkanie

v ňom budú najvýraznejšie. Každý z vybratých šesťsekundových úsekov bol následne rozdelený na tri dvojsekundové segmenty tak, aby sa prvý z týchto kratších segmentov nachádzal pred artefaktom, druhý počas a tretí po artefakte. Na rovnaké úseky a segmenty v tých istých časových intervaloch boli rozdelené aj záznamy po redukcii očných artefaktov. Ďalším krokom bolo vypočítanie priemerných hodnôt napätia zo segmentov bez očných artefaktov (I. a III.) zo záznamu pred ICA a tieto dve hodnoty boli následne opäť spriemerované. Výsledkom bola určitá hodnota „izolínie“, ktorú úseky signálu bez artefaktov v originálnom zázname v tej chvíli dosahovali. Táto hodnota bola porovnávaná s priemernou hodnotou signálu v segmente II., ale zo záznamu po aplikácii ICA (jednalo sa teda o úsek, z ktorého bol artefakt odstránený). Ak bola táto hodnota vyššia ako priemer z úsekov I. a III., v zázname pravdepodobne zostalo artefaktové rezíduum, ak bola naopak nižšia, zo záznamu bola spoločne s artefaktom odstránená aj neurologická informácia. V ideálnom prípade by mal algoritmus zo záznamu odstrániť presne toľko informácie, aby bola priemerná hodnota signálu v úsekoch s odstránenými artefaktami zhodná s hodnotou z okolitých úsekov, v ktorých nedošlo k nijakej zmene. V tejto práci bol vyhodnocovaný absolútny rozdiel oboch hodnôt nazvaný Delta  $h$ , ktorý bol vypočítaný pre všetkých 50 vybratých artefaktov naprieč všetkými desiatimi testovanými EEG záznamami pre každú z metód identifikácie komponentov (základná, rozšírená, semi-automatická).



Obrázok 4.6: Ilustrácia metódy, na základe ktorej bolo vyhodnocované potlačenie vertikálnych očných pohybov. V hornej polovici obrázku je šesťsekundový úsek signálu, v ktorom došlo k žmurknutiu subjektu. Tento úsek je rozdelený do troch dvojsekundových segmentov pred – segment I., počas – segment II. a po artefakte – segment III. Modrou farbou je zobrazený originálny signál, červený je signál po použití metódy ICA s potlačeným artefaktom. Na dolnej polovici obrázku je priblížená časť signálu, v ktorej je vidieť hodnotu  $\Delta h$ . Čierna plná čiara je priemerné napätie zo segmentov I. a III. pred aplikáciou ICA, čierna prerušovaná línia je priemerné napätie zo segmentu II. po ICA.  $\Delta h$  je absolútny rozdiel týchto dvoch hodnôt.

Z dôvodu, že sa horizontálne očné pohyby dajú najlepšie zobrazit' pomocou bipolárneho zapojenia, bol pre ich hodnotenie zvolený signál získaný rozdielom potenciálov medzi elektródami číslo 1 a 54, ktoré sa nachádzajú na vonkajších kútikoch pravého a ľavého oka – vid' obrázok 4.1. Pri vyhodnotení bol posudzovaný rozptyl tohto signálu v každom z desiatich validačných záznamov po aplikácii metódy ICA. Úspešnosť bola takisto porovnávaná medzi základnou metódou identifikácie artefaktových komponentov, upravenou metódou s pridanými parametrami a semi-automatickou metódou, pri ktorej boli spoločne s artefaktovými komponentami odstraňované aj všetky potenciálne artefaktové komponenty. Metóda fungovala tým lepšie, čím bol menší rozptyl v rámci signálu po použití ICA – artefakty spôsobujúce tento rozptyl by mali byť potlačené.

### 4.6.3 Zachovanie neurologickej aktivity

Vo fáze predspracovania signálu je okrem odstránenia artefaktov rovnako dôležité dbať na to, aby bolo zo signálu odstránené čo najmenej informácie o aktivite mozgu. Na porovnanie jednotlivých metód z hľadiska zachovania neurologickej aktivity bol použitý výpočet korelačného koeficientu v signáloch pred aplikáciou a po aplikácii metódy ICA. Korelačný koeficient sa dá použiť na určenie miery lineárnej závislosti medzi dvomi signálmi. Jeho hodnota bola počítaná pre všetkých 10 validačných záznamov zo segmentov signálu I. a III. z obrázku 4.6. Tieto segmenty boli vybrané preto, lebo sa v nich nenachádzal nijaký artefakt a tým pádom by použitím metódy ICA nemala nastať žiadna zmena. Teoreticky by v nich mal korelačný koeficient dosahovať hodnotu 1, prakticky by sa jeho hodnoty mali blížiť jednej a platí, že čím vyššiu hodnotu dosiahne, tým menej sa signál odstránením artefaktov pozmenil. S výpočtom korelačného koeficientu bola zároveň otestovaná aj jeho významnosť, ktorá okrem konkrétnej hodnoty berie do úvahy aj celkový počet vzoriek v rámci porovnávaného úseku signálu. V prípade, že sa vypočítaná p-hodnota ukáže byť nižšia ako stanovená hladina významnosti 5 %, je hodnota korelačného koeficientu významná a existuje dostatočné množstvo dôkazov na potvrdenie lineárnej závislosti medzi signálmi.

### 4.6.4 Štatistické testovanie

Štatistické porovnanie jednotlivých metód pomocou výpočtu Dely  $h$ , rozptylu a korelačného koeficientu prebehlo pre každý parameter samostatne nasledujúcim spôsobom: Na zistenie, či medzi metódami existuje štatisticky významný rozdiel bola použitá metóda analýzy rozptylu (ANOVA) s opakovanými meraniami. V prípade, ak dáta nemali normálne rozdelenie a nespĺňovali tak základnú podmienku použitia testu ANOVA, bol ako neparametrická alternatíva zvolený Friedmanov test. Ako nulová hypotéza bola stanovená rovnosť stredných hodnôt skúmaného parametru v rámci všetkých troch porovnávaných metód. Alternatívnou hypotézou bolo, že sa stredná hodnota parametru na hladine významnosti 5 % aspoň v jednej metóde líšila. V prípade,

že bol pomocou testu ANOVA zistený štatisticky významný rozdiel medzi strednými hodnotami ktoréhokolvek parametru, nasledovala analýza jednotlivých metód pomocou tzv. post hoc testu (tj. testu viacnásobných porovnaní – *multiple comparison test*). Post hoc testovanie má za cieľ určiť, v ktorej z troch skúmaných metód bol zistený štatisticky významný rozdiel medzi strednými hodnotami skúmaného parametru. Za účelom minimalizácie chyby I. druhu pri párovom porovnávaní stredných hodnôt z viacerých metód naraz bol na post hoc testovanie použitý Tukeyho HSD test (Honest Significant Difference – test úprimne významného rozdielu).

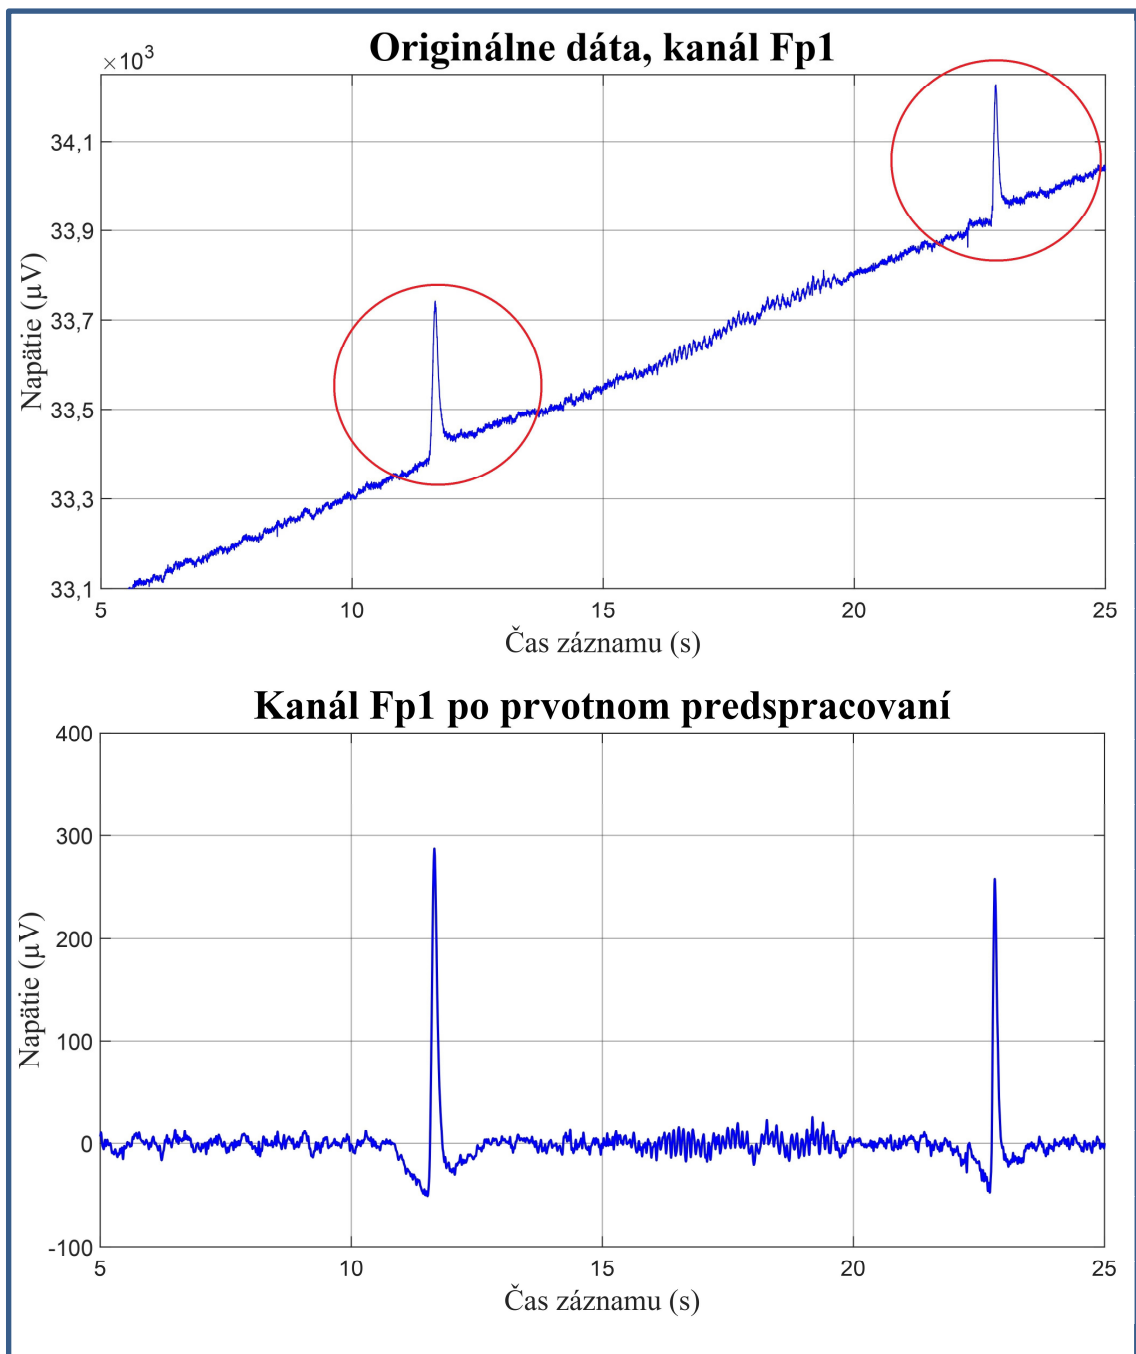
## 5 Výsledky

V tejto kapitole sú uvedené dosiahnuté výsledky práce. Graficky sú zobrazené jednotlivé kroky analýzy signálu od jeho prvotného predspracovania, cez implementovanú metódu ICA, topografické mapy a časové priebehy jednotlivých komponentov až po štatistické vyhodnotenie. Vyhodnocovaný je najprv výber vhodného algoritmu metódy ICA, pri ktorom bola využitá manuálna identifikácia artefaktových komponentov. Následne sú porovnávané jednotlivé metódy automatickej detekcie komponentov s očnými artefaktami, vrátane upravenej metódy vytvorenej v tejto práci. Nakoniec sú štatisticky porovnané jednotlivé metódy automatickej identifikácie komponentov v kombinácii s vhodným ICA algoritmom a ich vplyv na výsledný EEG záznam. Uvedené úpravy signálov boli dosiahnuté vo všetkých desiatich validačných záznamoch a ich výsledné číselné hodnoty boli použité vo vyhodnotení výsledkov. Pre prehľadnosť je graficky zobrazovaný len záznam od subjektu číslo 1.

### 5.1 Predspracovanie dát

V grafoch na obrázku 5.1 je zobrazený rovnaký dvadsaťsekundový úsek EEG záznamu z kanálu Fp1 (elektroda lokalizovaná nad ľavým okom). Tento časový úsek záznamu bol vybratý preto, lebo sú v ňom dobre viditeľné výrazné signálové špičky, počas ktorých došlo k žmurkaniu subjektu. Tieto špičky boli pre ešte lepšiu viditeľnosť v hornom grafe označené červenými krúžkami. Pri porovnaní oboch grafov je možné pozorovať, že špičky z horného aj dolného grafu sú medzi sebou časovo zosynchronizované.

V hornom grafe je zobrazený pôvodný nezmenený úsek záznamu. Je vidieť, že v tomto formáte je signál zarušený rôznymi artefaktami a tým pádom je aj pre skúseného experta ťažko interpretovateľný. Okrem očných artefaktov je v zázname zahrnuté aj výrazné vzdiaľovanie signálu od izolínie – absolútna vzdialenosť od nuly je rádovo až desaťtisíce mikrovoltov. Signál v dolnom grafe bol predspracovaný pomocou metód *demean*, *detrend* a BP filtráciou. Líši sa od prvého v tom, že jeho odchýlka voči izolínii je nulová a pomocou filtrácie došlo aj k odstráneniu nepodstatných frekvenčných pásiem. Výrazné amplitúdové špičky (očné artefakty) sú však prítomné aj v dolnom grafe. Na ich potlačenie boli následne použité dva algoritmy metódy ICA – *Infomax* a *FastICA*.



Obrázok 5.1: Príklad úseku EEG záznamu od dobrovoľníka číslo 1 z kanálu Fp1. V grafe hore je zobrazený úsek originálneho záznamu bez akéhokoľvek predspracovania, v dolnom grafe je ten istý úsek záznamu po prvotnom predspracovaní metódami *demean*, *detrend* a BP filtráciou. Červenými krúžkami sú v hornom grafe vyznačené úseky, v ktorých subjekt žmurkal.

## 5.2 Metóda ICA

Pred samotnou aplikáciou metódy ICA bolo nutné vykonať ešte špecifické kroky predspracovania dát. Jedným z týchto krokov bolo použitie metódy PCA. PCA bola nastavená tak, aby po jej aplikácii zostalo zachovaných 95 % pôvodnej informácie (viď kapitola 4.4.2). Týmto spôsobom bola zredukovaná dimenzionalita dát a zároveň došlo k predspracovaniu potrebnému pred použitím ICA. Počty nezávislých komponentov pre jednotlivé validačné záznamy pri zachovaných 95 % informácie sú uvedené v nasledujúcej tabuľke:

Tabuľka 5.1: Počty zachovaných nezávislých komponentov pre jednotlivé záznamy. Počty boli vybrané tak, aby zostalo zachovaných 95 % informácie pôvodných dát.

Skúmaný EEG záznam	Počet zachovaných komponentov
Subjekt č.1	20
Subjekt č.2	26
Subjekt č.3	25
Subjekt č.4	31
Subjekt č.5	9
Subjekt č.6	11
Subjekt č.7	39
Subjekt č.8	11
Subjekt č.9	29
Subjekt č.10	9

Použitím PCA bola ukončená fáza predspracovania a tak mohlo byť prístupné k oddeleniu signálu na jednotlivé nezávislé zdroje metódou ICA. Pri implementácii metódy ICA boli porovnávané výsledky dvoch rôznych algoritmov, na obrázku 5.2 je zobrazené topografické rozloženie jednotlivých nezávislých zdrojov zo záznamu dobrovoľníka číslo 1 dosiahnuté použitím algoritmu *Infomax*. Ich počet (20) je zhodný s počtom zachovaných komponentov, ktoré boli určené pomocou PCA (viď tabuľka 5.1). V tejto fáze bola zatiaľ využívaná expertná identifikácia artefaktových komponentov, pričom z obrázku 5.2 boli ako zdroje očných artefaktov určené komponenty 4 a 12 – vyznačené žltou farbou. Topografické mapy očných artefaktov sú typické tým, že ich aktivita vychádza primárne z frontálnych oblastí hlavy z blízkosti očí (viď kapitola 2.5), čo je v prípade identifikovaných komponentov z obrázku 5.2 jasne viditeľné.

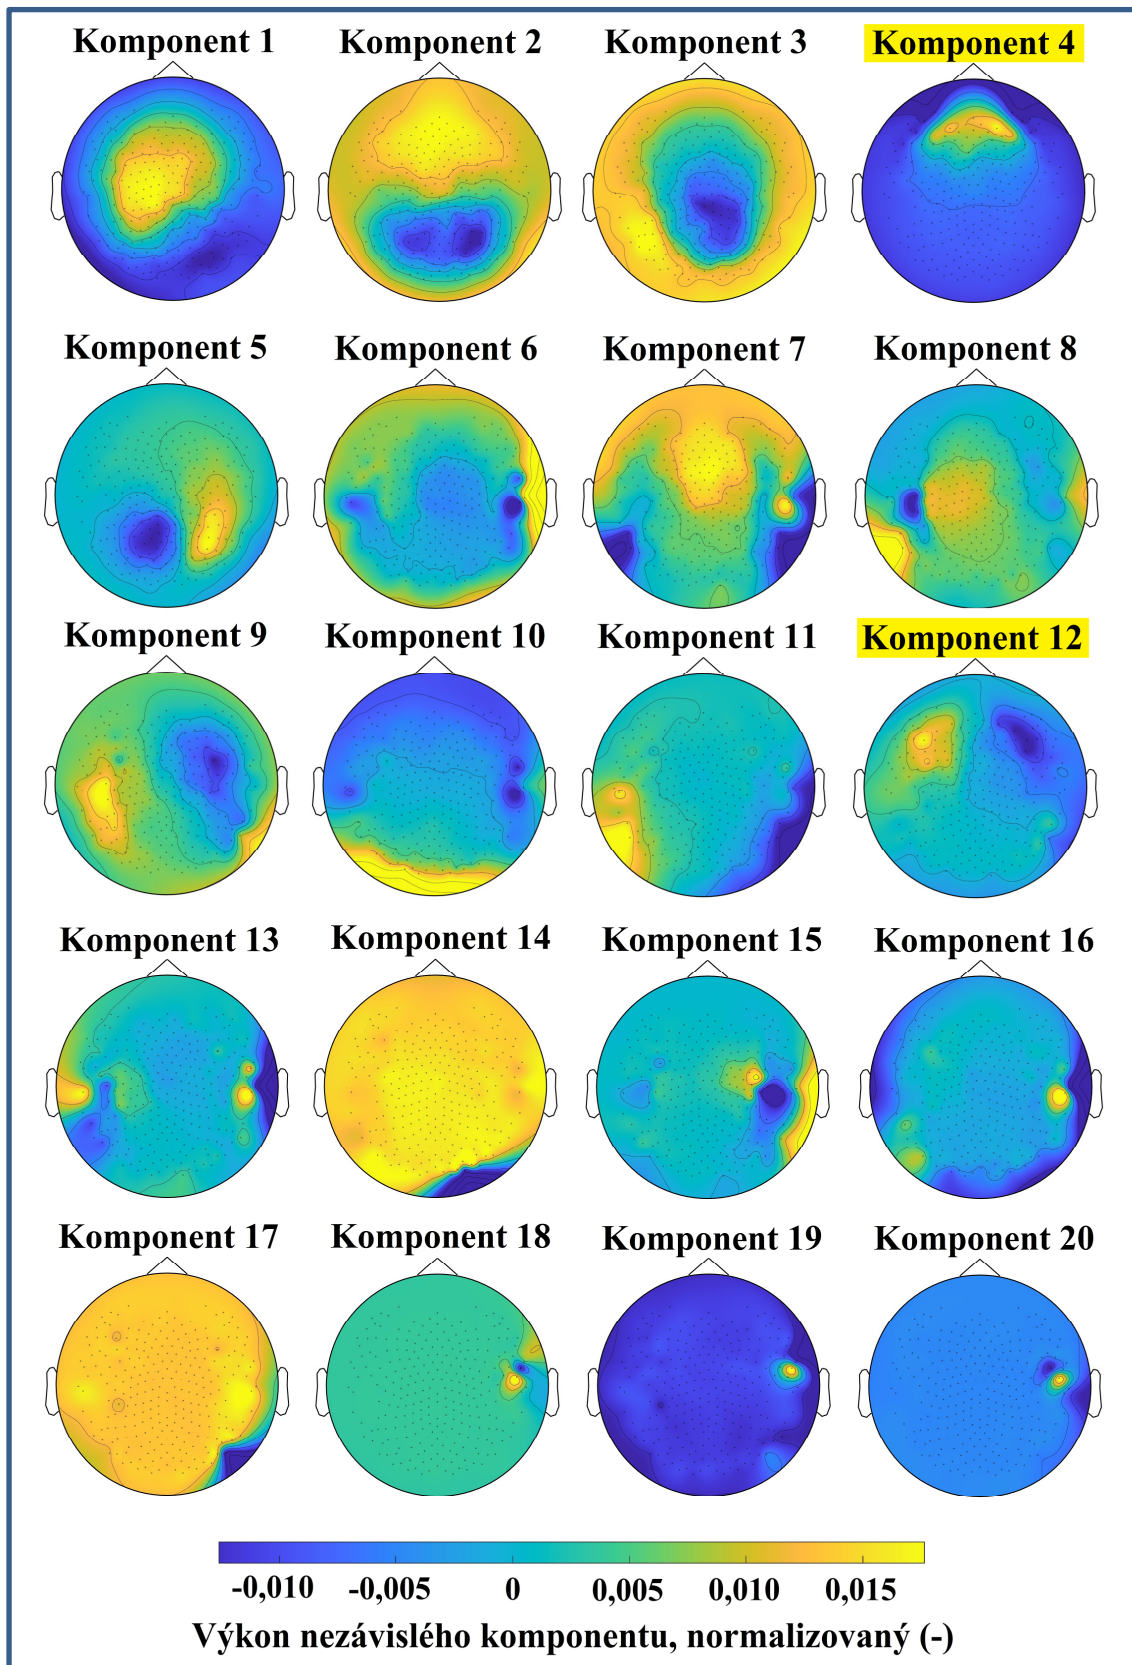
Okrem priestorovej topografie je pri identifikovaní jednotlivých nezávislých komponentov výhodné preskúmať aj ich časové priebehy, ktoré sú zdrojom ďalších informácií o ich pôvode. Na obrázku 5.3 sú zobrazené časové priebehy tých istých



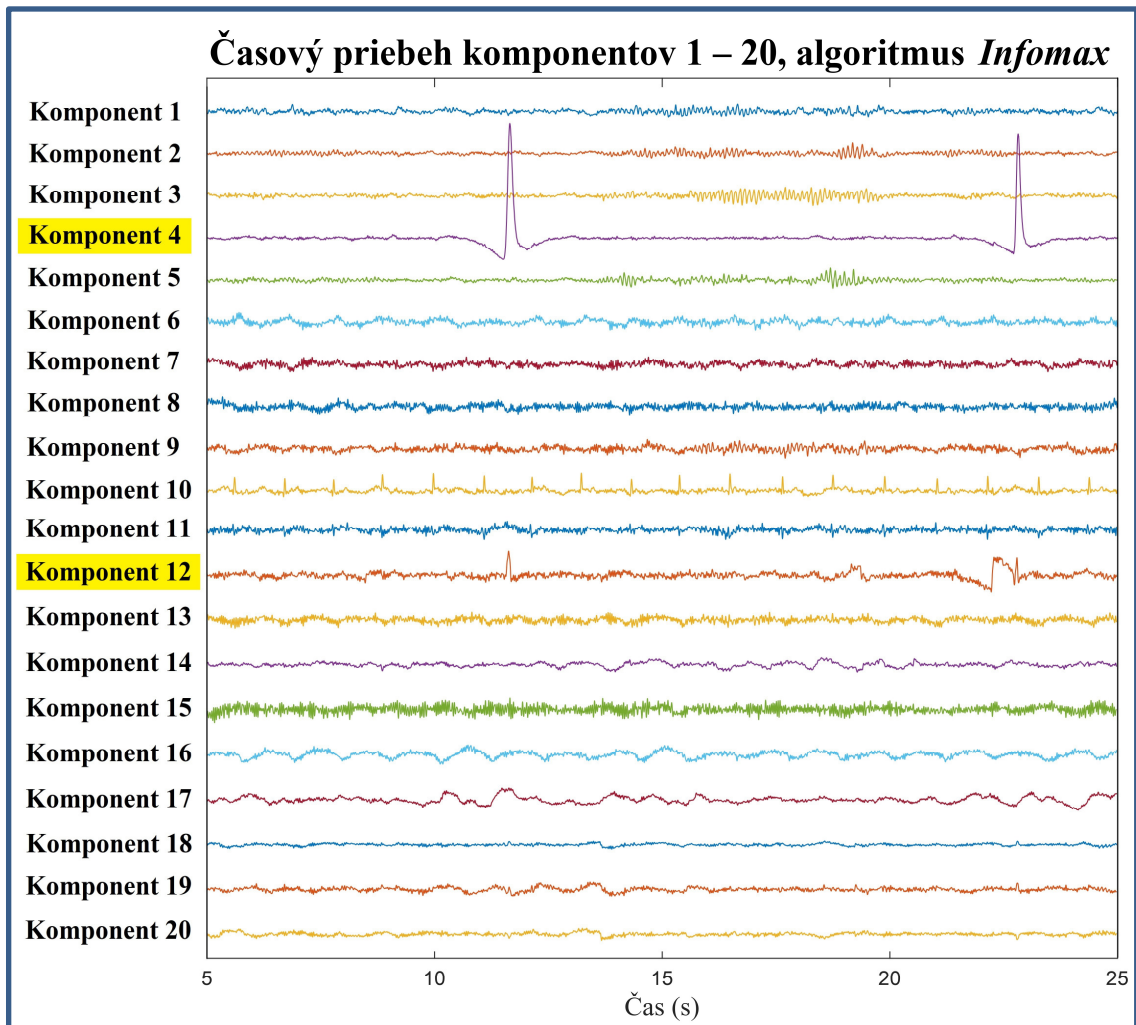
komponentov vypočítaných algoritmom *Infomax*, ktorých priestorová topografia je na obrázku 5.2. Jedná sa o časový úsek od 5. do 25. sekundy, rovnaký ako na obrázku 5.1 s originálnym a predspracovaným záznamom. Artefaktové komponenty 4 a 12 sú opäť vyznačené žltou farbou. Na obrázku je veľmi dobre pozorovateľná prítomnosť výrazných napätových špičiek spôsobených žmurkaním subjektu izolovaných v komponente číslo 2, ktoré sú časovo zosynchronizované so špičkami v originálnom zázname na obrázku 5.1. Zároveň si je možné približne na dvadsiatej druhej sekunde v rámci komponentu 12 všimnúť typický štvorcový tvar signálu, ktorý sa v signáli vyskytuje pri horizontálnom očnom pohybe. Časové priebehy na obrázku 5.3 vlastne slúžia na potvrdenie správnosti identifikácie komponentov z ich priestorového rozloženia.

Obrázky 5.4 a 5.5 ukazujú jednotlivé komponenty vypočítané z toho istého EEG záznamu subjektu číslo 1 vytvorené pomocou algoritmu *FastICA*. V tomto prípade boli ako zdroje očných artefaktov identifikované komponenty 4 a 7 – opäť vyznačené žltou farbou. Na obrázku 5.4 je znázornené priestorové rozloženie jednotlivých komponentov a rovnako ako pri algoritme *Infomax* je vidieť, že aktivita identifikovaných artefaktových zdrojov je primárne lokalizovaná v blízkosti očí. Obrázok 5.5 zobrazuje časový priebeh komponentov a potvrdzuje, že komponenty 4 a 7 obsahujú očné artefakty – v komponente 4 je zachytené žmurkanie a vertikálne očné pohyby subjektu, pričom rovnako ako v predchádzajúcom prípade, tieto úseky časovo korešpondujú so žmurkaním zobrazeným na obrázku 5.1. V komponente číslo 7 sú naopak izolované horizontálne pohyby očí.

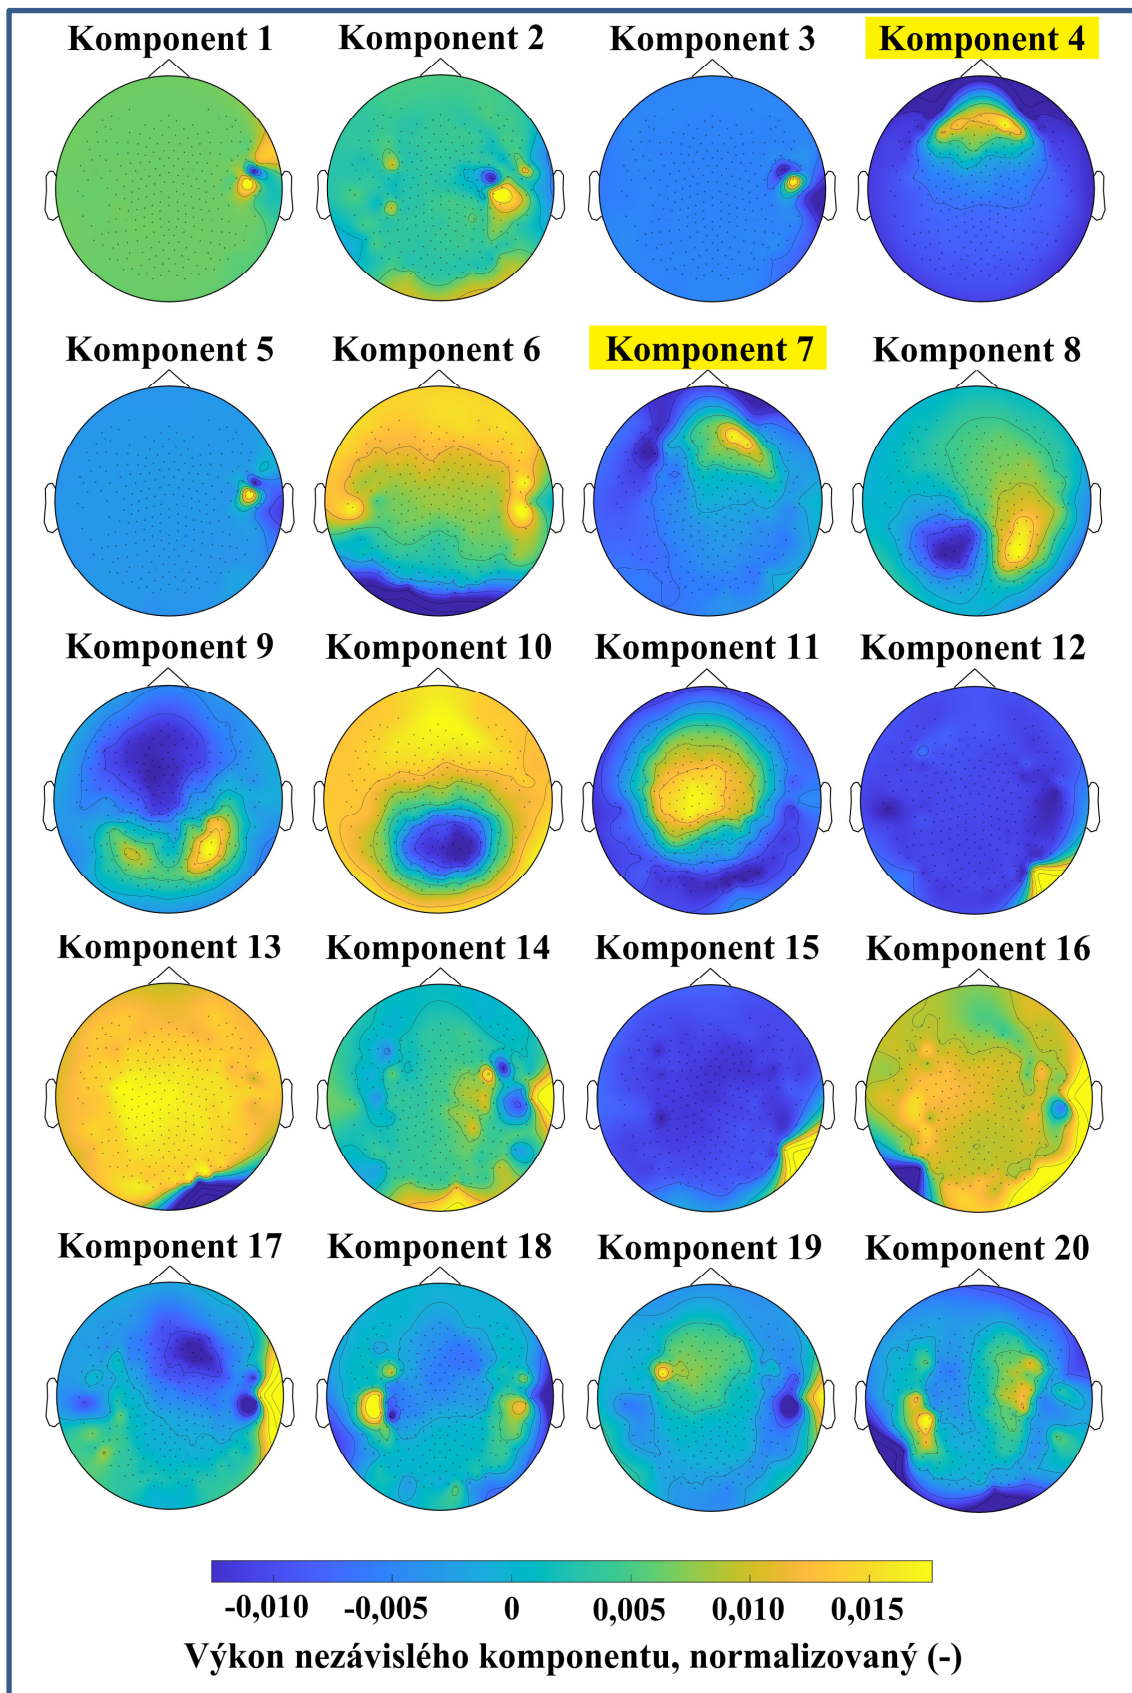
Po správnej identifikácii komponentov, ktoré majú v sebe zahrnuté očné artefakty, nasledovalo ich odstránenie. Zo zostávajúcich komponentov (v prípade EEG záznamu dobrovoľníka číslo 1 ich bolo 18), bol pomocou inverznej ICA spätne zrekonštruovaný záznam, v ktorom boli očné artefakty potlačené.




Obrázok 5.2: Príklad topografického rozloženia 20 nezávislých zdrojov určených pomocou ICA použitím algoritmu *Infomax* zo záznamu od subjektu číslo 1. Z jednotlivých komponentov je možné určiť približne z ktorej oblasti hlavy samostatný „zdroj“ signálu vychádzal. Je možné si všimnúť, že aktivita žltou vyznačených artefaktových komponentov 4 a 12 pochádza z frontálnej oblasti hlavy z blízkosti očí subjektu.



Obrázok 5.3: Vybraný úsek časového priebehu nezávislých komponentov oddelených použitím ICA, algoritmus *Infomax*. Na vertikálnej osi každého z komponentov je amplitúda signálu v  $\mu\text{V}$ . Zobrazený je rovnaký úsek, ako na obr. 5.1. Žltou farbou sú vyznačené artefaktové komponenty 4 a 12. V komponente číslo 4 je možné si všimnúť prítomnosť dvoch výrazných špičiek reprezentujúcich žmurkanie subjektu. Komponent 12 obsahuje typický štvorcový tvar signálu spôsobený horizontálnym pohybom očí.



Obrázok 5.4: Príklad topografického rozloženia 20 nezávislých zdrojov určených pomocou ICA použitím algoritmu *FastICA* zo záznamu od subjektu číslo 1. Z jednotlivých komponentov je možné určiť približne z ktorej oblasti hlavy samostatný „zdroj“ signálu vychádzal. Je možné si všimnúť, že aktivita žltó vyznačených artefaktových komponentov 4 a 7 pochádza z frontálnej oblasti hlavy z blízkosti očí subjektu.

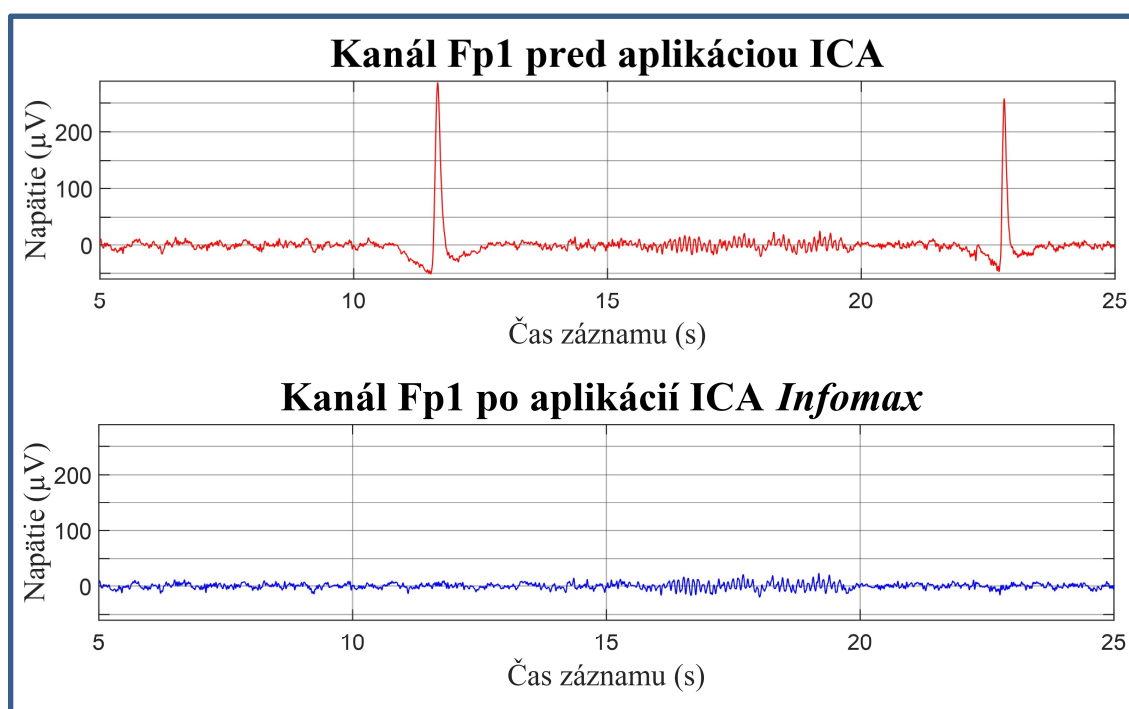


Obrázok 5.5: Vybraný úsek časového priebehu nezávislých komponentov oddelených použitím ICA, algoritmus *FastICA*. Na vertikálnej osi každého z komponentov je amplitúda signálu v  $\mu V$ . Zobrazený je rovnaký úsek, ako na obr. 5.1. Žltou farbou sú vyznačené artefaktové komponenty 4 a 7. V komponente číslo 4 je možné si všimnúť prítomnosť dvoch výrazných špičiek reprezentujúcich žmurkanie subjektu. Komponent 12 obsahuje typický štvorcový tvar signálu spôsobený horizontálnym pohybom očí.


### 5.3 Potlačenie očných artefaktov a výber ICA algoritmu

V tejto kapitole sú zobrazené výsledky dosiahnuté metódou ICA a porovnanie oboch algoritmov z hľadiska potlačenia očných artefaktov. Na obrázku 5.6 je zobrazené porovnanie signálov pred a po aplikovaní ICA algoritmom *Infomax* pri unipolárnom zapojení. V grafoch je znázornený kanál Fp1, pričom časový úsek je rovnaký ako v predchádzajúcich obrázkoch – od 5. do 25. sekundy. Signál na červenom grafe hore je po prvotnom predspracovaní metódami *demean*, *detrend* a filtráciou a je v ňom jasne viditeľné žmurkanie dobrovoľníka v podobe napätových špičiek. Modrý graf dole zobrazuje ten istý úsek záznamu zbavený komponentov 4 a 12 obsahujúcich očné artefakty. V grafe je vidieť, že v tomto konkrétnom úseku signálu došlo k redukcii napätových hrotov, ale zároveň zvyšná časť signálu nebola nijako výrazne pozmenená.

Na obrázku 5.7 je rovnaké porovnanie záznamu od subjektu číslo 1 pred a po ICA algoritmom *Infomax*, ale s využitím bipolárneho zapojenia na zvýraznenie horizontálneho pohybu očí. Zobrazený je rozdiel potenciálov medzi elektródami 54 a 1, ktoré sa nachádzajú na vonkajších kútikoch pravého a ľavého oka. Na červenom grafe hore je možné si približne na 22. sekunde všimnúť typický štvorcový tvar artefaktu spôsobený horizontálnym pohybom očí. Je dôležité zmieniť, že tento artefakt v klasickom unipolárnom zázname nie je výrazný (viď obrázok 5.6), ale napriek tomu sa v zázname nachádza. Na druhej strane, na obrázku 5.3 v časovom priebehu nezávislých komponentov je tento konkrétny artefakt zahrnutý v komponente číslo 12. V modrom grafe dole na obrázku 5.7 je vidieť, že použitím metódy ICA *Infomax* bol artefakt odstránený.




Obrázok 5.6: Príklad porovnania časového úseku EEG záznamu dobrovoľníka číslo 1 pred a po aplikácii ICA algoritmom *Infomax* pri unipolárnom zapojení. Červený graf zobrazuje úsek kanálu Fp1 po prvotnom predspracovaní metódami *demean*, *detrend* a BP filtráciou – tj. pred použitím ICA. V grafe je viditeľné žmurkanie subjektu v podobe dvoch výrazných napätových špičiek. Modrý graf zobrazuje ten istý úsek signálu z kanálu Fp1 po aplikácii ICA, pričom sú napätové špičky v modrom grafe potlačené.



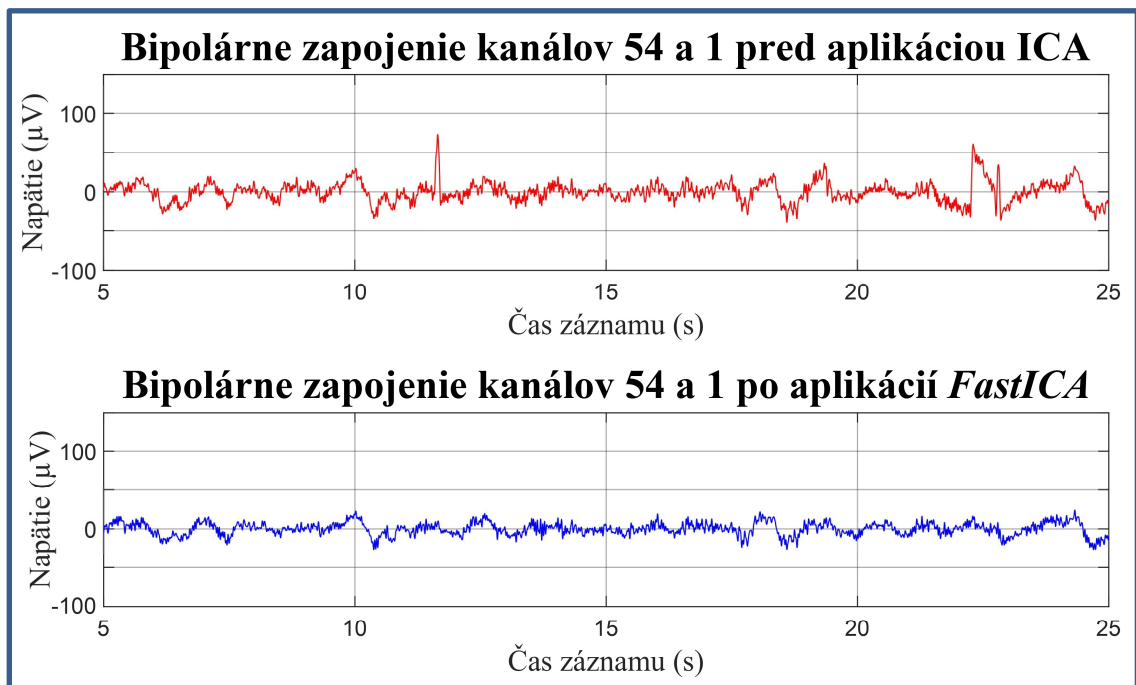
Obrázok 5.7: Príklad bipolárneho zapojenia EEG záznamu subjektu 1 medzi elektródami číslo 54 a 1. Na hornom grafe zobrazený záznam po prvotnom predspracovaní metódami *demean*, *detrend* a BP filtráciou. Približne na 22. sekunde je vidieť typický artefakt spôsobený horizontálnym pohybom očí. Dolný graf znázorňuje ten istý úsek záznamu po použití metódy ICA, algoritmus *Infomax*, z ktorého bol tento artefakt odstránený.

Obrázky 5.8 a 5.9 ukazujú rovnaké porovnanie ako v predchádzajúcom prípade, ale po použití algoritmu *FastICA*. V prípade unipolárneho aj bipolárneho zapojenia sledujú grafy veľmi podobné trendy ako po použití algoritmu *Infomax*. V hornom červenom grafe na obrázku 5.8 je zobrazené unipolárne zapojenie signálu, v ktorom sú zahrnuté napäťové špičky, pričom v dolnom modrom grafe sú tieto artefakty potlačené. Rovnako ako na obrázku 5.6, v modrom signáli zároveň nedošlo k žiadnym ďalším výrazným zmenám a jeho priebeh je veľmi podobný červenému signálu, s výnimkou chýbajúcich špičiek. Obrázok 5.9 zobrazuje bipolárne zapojenie elektród 54 a 1 pred a po ICA. Podobne ako v predchádzajúcom prípade, v hornom červenom grafe je záznam po prvotnom predspracovaní, v ktorom sú stále zahrnuté očné artefakty (22. sekunda). Modrý graf dole ukazuje, že aj použitím algoritmu *FastICA* došlo k redukcii spomínaného artefaktu a zároveň k minimálnej zmene okolitého signálu.

Na základe výsledkov, ktoré v rámci potlačenia očných artefaktov dosiahli obidva algoritmy, bol na ďalšie rozšírenie automatickou identifikáciou komponentov reprezentujúcich očné artefakty vybratý algoritmus *Infomax*. Všetky validačné záznamy boli pomocou tohto algoritmu oddelené na jednotlivé nezávislé zdroje, ktoré boli následne samostatne klasifikované pomocou základnej a upravenej metódy.



Obrázok 5.8: Príklad porovnania časového úseku EEG záznamu dobrovoľníka číslo 1 pred a po aplikácii ICA algoritmom *FastICA* pri unipolárnom zapojení. Červený graf zobrazuje úsek kanálu Fp1 po prvotnom predspracovaní metódami *demean*, *detrend* a BP filtráciou – tj. pred použitím ICA. V grafe je viditeľné žmurkanie subjektu v podobe dvoch výrazných napät'ových špičiek. Modrý graf zobrazuje ten istý úsek signálu z kanálu Fp1 po aplikácii ICA, pričom sú napät'ové špičky v modrom grafe potlačené.



Obrázok 5.9: Príklad bipolárneho zapojenia EEG záznamu subjektu 1 medzi elektródami číslo 54 a 1. Na hornom grafe zobrazený záznam po prvotnom predspracovaní metódami *demean*, *detrend* a BP filtráciou. Približne na 22. sekunde je vidieť typický artefakt spôsobený horizontálnym pohybom očí. Dolný graf znázorňuje ten istý úsek záznamu po použití metódy ICA, algoritmus *FastICA*, z ktorého bol tento artefakt odstránený.




## 5.4 ROC analýza a určovanie prahov

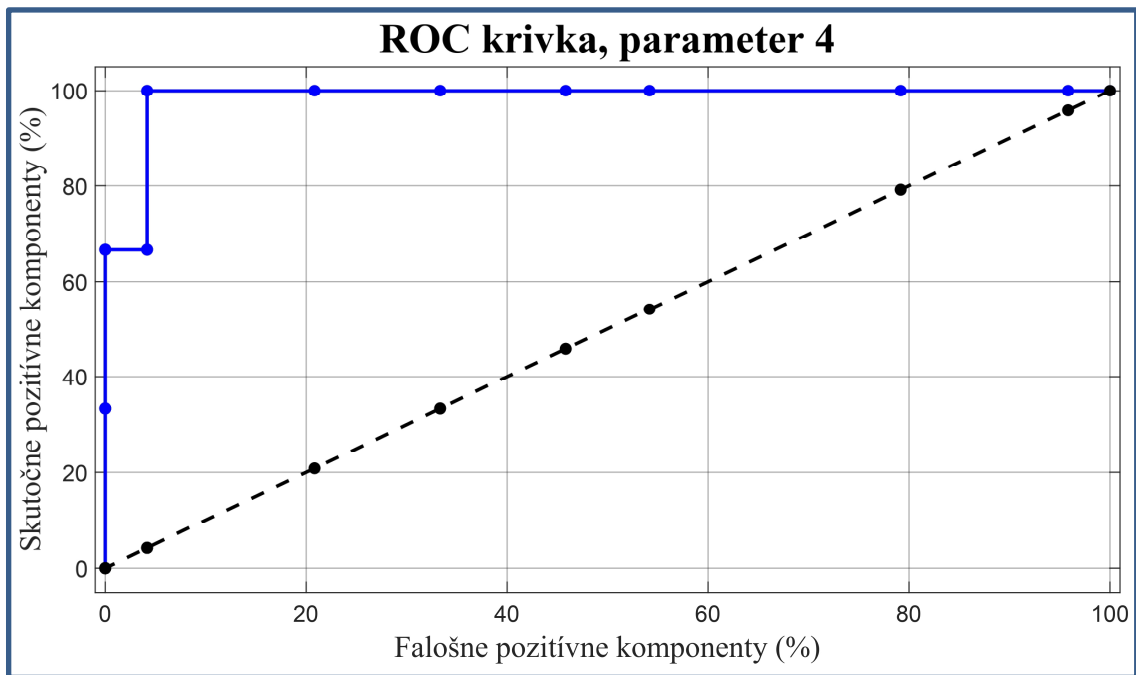
V rámci použitia upravenej metódy automatickej klasifikácie komponentov obsahujúcich očné artefakty bolo potrebné stanoviť prahové hodnoty niektorých parametrov. Jednalo sa konkrétne o určovanie prahov pre klasifikačné parametre 3 a 4 (viď kapitola 4.5.4), ktoré prebehlo pre každý z parametrov samostatne pomocou ROC analýzy. Pre všetky prípustné hodnoty deliaceho kritéria boli vypočítané TP, TN, FP a FN komponenty (správnu klasifikáciu komponentov zabezpečil expert) a na základe ich výsledkov bola pomocou Youdenovho indexu  $J$  určená ideálna prahová hodnota, ktorá zohľadnila najlepší pomer medzi senzitivitou a špecificitou. Prahovú hodnotu bolo nutné stanoviť aj pre parameter číslo 1, ale v implementačnom zázname bol prítomný len jeden komponent, obsahujúci horizontálny pohyb očí, takže ROC analýza v tomto prípade nemala zmysel. Pre prah tohto parametru tak bola použitá rovnaká hodnota ako pre parameter číslo 3. Výsledné prahové hodnoty sú uvedené v tabuľke 5.2, tieto hodnoty boli následne použité v upravenej metóde automatickej identifikácie komponentov.

Tabuľka 5.2: Prahové hodnoty skúmaných parametrov (viď kapitola 4.5.4) určených pomocou ROC analýzy v implementačnom zázname.

Skúmaný parameter	Prahová hodnota
1 a 3	19
4	15



Obrázok 5.10: Výsledná ROC krivka (modrá) pre parametre číslo 1 a 3. Čierna prerušovaná priamka je diagonála grafu. Na zvislej osi sú pre každú prípustnú prahovú hodnotu zobrazené percentá skutočne pozitívnych komponentov – senzitivita, na vodorovnej osi sú percentá falošne pozitívnych komponentov, matematicky tj.  $1 - \text{špecificita}$ .



Obrázok 5.11: Výsledná ROC krivka (modrá) pre parameter číslo 4. Čierna prerušovaná priamka je diagonála grafu. Na zvislej osi sú pre každú prípustnú prahovú hodnotu zobrazené percentá skutočne pozitívnych komponentov – senzitivita, na vodorovnej osi sú percentá falošne pozitívnych komponentov, matematicky tj. 1 – špecificita.

## 5.5 Porovnanie metód automatickej identifikácie artefaktových komponentov

Po úspešnej aplikácii metódy ICA algoritmom *Infomax* na všetky validačné záznamy nasledovala klasifikácia jednotlivých komponentov. Počty a percentuálne zastúpenie komponentov, ktoré jednotlivé metódy identifikovali ako očné artefakty sú uvedené v tabuľkách 5.3 a 5.4. Upravená metóda zároveň upozorňovala aj na potenciálne artefaktové komponenty, ktoré sú v tabuľke uvedené tiež. Automatickým odstránením všetkých artefaktových komponentov, so súčasným manuálnym „doodstraňovaním“ všetkých potenciálnych artefaktových komponentov bola v tejto práci zároveň vytvorená a otestovaná aj semi-automatická metóda. Štatisticky bola porovnávaná presnosť jednotlivých metód v rámci identifikácie komponentov obsahujúcich očné artefakty a ich vplyv na potlačenie horizontálnych a vertikálnych očných artefaktov a zachovanie fyziologickej časti EEG signálu.

Tabuľka 5.3: Počty komponentov identifikovaných ako očné artefakty, ktoré boli klasifikované jednotlivými metódami pre jednotlivé validačné záznamy.

Validačný záznam	Celkový počet komponentov	Základná metóda	Upravená metóda	
		Počet artefaktových komponentov	Počet artefaktových komponentov	Počet potenciálnych artefaktových komponentov
1	20	2	2	0
2	26	3	1	1
3	25	10	2	4
4	31	4	1	2
5	9	4	2	2
6	11	3	1	2
7	39	15	2	7
8	11	2	1	1
9	29	4	2	2
10	9	3	1	1

Tabuľka 5.4: Percentuálne zastúpenie komponentov identifikovaných ako očné artefakty, ktoré boli klasifikované jednotlivými metódami pre jednotlivé validačné záznamy.

Validačný záznam	Základná metóda	Upravená metóda	
	Zastúpenie artefaktových komponentov (%)	Zastúpenie artefaktových komponentov (%)	Zastúpenie potenciálnych artefaktových komponentov (%)
1	10,00	10,00	0,00
2	11,54	3,85	3,85
3	40,00	8,00	16,00
4	12,90	3,23	6,46
5	44,44	22,22	22,22
6	27,27	9,09	18,18
7	38,46	5,12	17,95
8	18,18	9,09	9,09
9	13,80	6,90	6,90
10	33,33	11,11	11,11

### 5.5.1 Vyhodnotenie presnosti určovania komponentov

Úspešnosť metód z hľadiska klasifikácie nezávislých komponentov bola vyhodnocovaná vypočítaním senzitivity, špecificity a celkovej presnosti metód. Ako rozšírenie upravenej metódy bola do porovnania pridaná aj semi-automatická metóda. Skutočné TP a TN komponenty boli v rámci všetkých desiatich validačných záznamov určené expertne. Je vidieť, že v rámci všetkých troch metód bol počet identifikovaných skutočne negatívnych komponentov výrazne najväčší. Výsledky sú k dispozícii v nasledujúcich tabuľkách.

Tabuľka 5.5: Celkové počty TP, TN, FP, FN komponentov identifikované jednotlivými metódami ako očné artefakty.

Metóda	Počet skutočne pozitívnych komponentov (TP)	Počet skutočne negatívnych komponentov (TN)	Počet falošne pozitívnych komponentov (FP)	Počet falošne negatívnych komponentov (FN)
Základná	18	159	32	1
Upravená	10	185	5	10
Semi-automatická	18	172	19	1

Tabuľka 5.6: Senzitivita, špecificita a presnosť identifikácie ICA komponentov dosiahnutá jednotlivými metódami.

Metóda	Senzitivita (%)	Špecificita (%)	Presnosť (%)
Základná	94,74	83,25	84,29
Upravená	50,00	97,37	92,86
Semi-automatická	94,74	90,05	90,48

### 5.5.2 Porovnanie metód z hľadiska potlačenia očných artefaktov

Úspešnosť potlačenia očných artefaktov bola vyhodnocovaná samostatne pre vertikálny typ očných pohybov, resp. žmurkanie a samostatne pre horizontálny typ očných pohybov. Následne bol štatisticky porovnaný rozdiel v úspešnosti jednotlivých metód. Pri vertikálnych očných pohyboch bol sledovaný parameter Delta  $h$  popísaný v kapitole 4.6.2. V rámci každého validačného záznamu bolo vypočítaných päť hodnôt Delty  $h$  pre päť rôznych okamihov vertikálneho pohybu očí. V zázname od dobrovoľníka číslo 4 boli zahrnuté len štyri vertikálne očné artefakty, takže celkový počet vyhodnocovaných hodnôt Delty  $h$  tak bol 49 pre každú z porovnávaných metód (základná, upravená a semi-automatická). Z dôvodu, že v žiadnej z metód nemali hodnoty Delty  $h$  normálne rozdelenie nebola splnená podmienka pre použitie analýzy rozptylu ANOVA s opakovanými meraniami. Porovnanie stredných hodnôt medzi jednotlivými metódami tak prebehlo pomocou Friedmanovho testu. Výsledná p-hodnota tohto testu bola rovná 0,2811 a bola tak vyššia ako 5% hladina významnosti testu. Post

hoc analýza tak v tomto prípade nebola potrebná. V tabuľke 5.7 je zobrazené porovnanie vypočítaných hodnôt Dely  $h$  pre každú z metód.

Tabuľka 5.7: Minimálne, maximálne a priemerné hodnoty Dely  $h$  pre porovnávané metódy získané z 49 úsekov z validačných záznamov. Delta  $h$  (viď kapitola 4.6.2) bola vypočítaná pre porovnanie z hľadiska potlačenia vertikálnych očných pohybov a žmurkania.

Metóda	Minimálna hodnota Dely $h$ ( $\mu\text{V}$ )	Maximálna hodnota Dely $h$ ( $\mu\text{V}$ )	Priemerná hodnota Dely $h$ ( $\mu\text{V}$ )
Základná	0,035	3,100	0,649
Upravená	0,021	3,119	0,736
Semi-automatická	0,035	2,959	0,654

Na vyhodnotenie potlačenia horizontálnych očných pohybov bol využitý rozptyl signálu po aplikácii metódy ICA. V každom z validačných záznamov bola vypočítaná hodnota rozptylu signálu získaného rozdielom potenciálov medzi elektródami 54 a 1, celkovo tak bolo analyzovaných 10 hodnôt pre každú z metód automatickej identifikácie komponentov. Rozptyl bipolárneho zapojenia sa tu berie ako hodnota vyjadrujúca vplyv horizontálnych očných artefaktov na EEG záznamy. V tomto prípade dáta splňovali podmienku normálneho rozdelenia a tak mohli byť jednotlivé metódy porovnané pomocou testu ANOVA s opakovanými meraniami. P-hodnota (0,0028) v rámci tohto testovania dosiahla nižšiu hodnotu ako hladina významnosti 5 % (0,05). Následné post hoc testovanie je zhrnuté v tabuľke 5.8, v ktorej sú uvedené výsledky testu párového porovnania stredných hodnôt rozptylov v rámci jednotlivých metód. Je vidieť, že v prípade samostatného porovnania základnej metódy s upravenou aj so semi-automatickou bola p-hodnota nižšia ako hladina významnosti 5 % (0,05).


Tabuľka 5.8: Výsledky post hoc testu párového porovnania stredných hodnôt rozptylu bipolárneho zapojenia jednotlivých metód. Hodnoty rozptylu boli počítané za účelom porovnania metód z hľadiska potlačenia horizontálnych očných pohybov.

Párové porovnanie metód	P-hodnota
Základná – Upravená	0,0253
Základná – Semi-automatická	0,4218
Upravená – Semi-automatická	0,0498

Tabuľka 5.9 zobrazuje porovnanie vypočítaných hodnôt rozptylu pre každú z metód, na obrázku 5.12 sú pomocou krabicového grafu graficky porovnané aj rozloženia rozptylu.

Tabuľka 5.9: Minimálne, maximálne a priemerné hodnoty rozptylu bipolárneho zapojenia pre porovnávané metódy získané z desiatich validačných záznamov. Hodnoty rozptylu boli počítané za účelom porovnania metód z hľadiska potlačenia horizontálnych očných pohybov.

Metóda	Minimálna hodnota rozptylu	Maximálna hodnota rozptylu	Priemerná hodnota rozptylu
Základná	10,240	51,591	24,739
Upravená	16,140	98,901	49,908
Semi-automatická	10,601	54,814	30,085



Obrázok 5.12: Porovnanie rozloženia hodnôt rozptylu bipolárneho zapojenia medzi základnou, upravenou a semi-automatickou metódou. Z obrázku je možné vidieť, že je hodnota mediánu, dolného aj horného kvartilu rozptylu v rámci upravenej metódy identifikácie artefaktových komponentov najvyššia, čo naznačuje najvýraznejší vplyv prítomnosti reziduí horizontálnych pohybov očí.

### 5.5.3 Porovnanie metód z hľadiska zachovania neurologickej aktivity

Porovnanie metód z hľadiska úspešnosti zachovania neurologickej informácie prebehlo výpočtom korelačného koeficientu pred a po aplikácií metódy ICA. Na jeho určenie boli použité rovnaké úseky signálu ako v prípade vyhodnotenia vertikálnych pohybov očí, pričom ale samotná kalkulácia prebehla len zo segmentov I. a III. (viď obrázok 4.6), v ktorých sa očné artefakty ani v pôvodnom zázname nenachádzali. Celkovo tak bolo vypočítaných 49 hodnôt korelačného koeficientu pre každú z porovnávaných metód a vypočítané hodnoty splňovali podmienku normálneho rozdelenia pre použitie testu ANOVA s opakovanými meraniami. Výsledná p-hodnota ( $1,589 \cdot 10^{-9}$ ) bola nižšia ako 5% hladina významnosti. Výsledky post hoc testu sú

v tabuľke 5.10, v ktorej sú zobrazené p-hodnoty párového porovnania stredných hodnôt korelačného koeficientu v rámci jednotlivých metód.

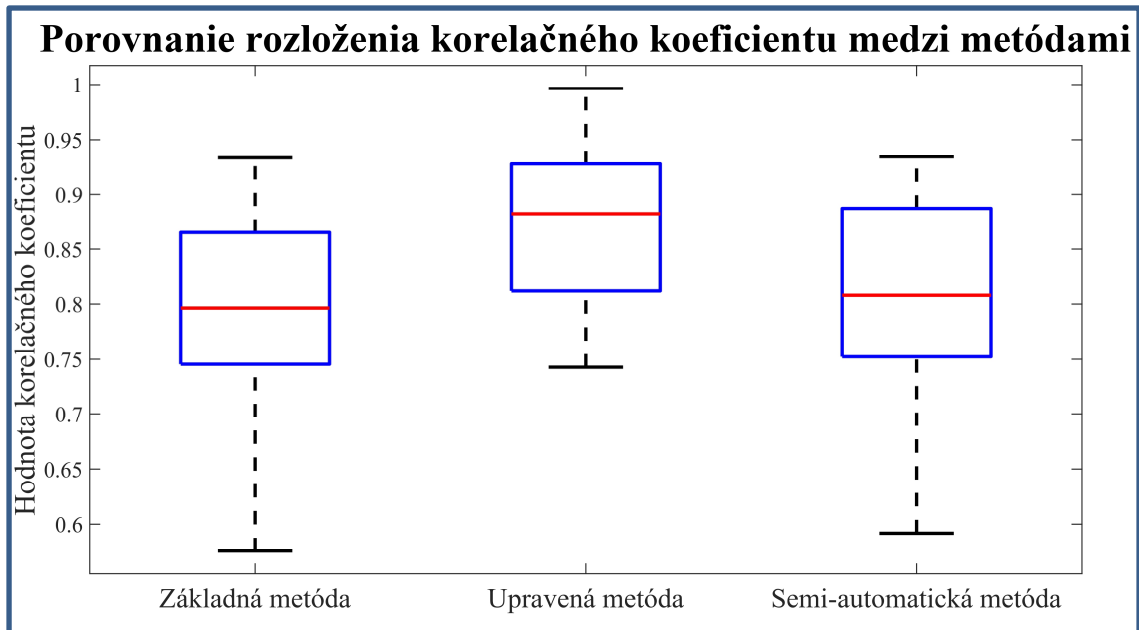
Tabuľka 5.10: Výsledky post hoc testu párového porovnania stredných hodnôt korelačného koeficientu jednotlivých metód. Korelačný koeficient (viď kapitola 4.6.3) bol počítaný za účelom porovnania metód z hľadiska zachovania fyziologickej zložky EEG signálu.

<b>Párové porovnanie metód</b>	<b>P-hodnota</b>
Základná – Upravená	$4,924 \cdot 10^{-6}$
Základná – Semi-automatická	0,0524
Upravená – Semi-automatická	$6,288 \cdot 10^{-5}$

Tabuľka 5.11 zobrazuje porovnanie extrémnych a priemerných hodnôt korelačného koeficientu pre každú z metód, na obrázku 5.13 sú dosiahnuté rozloženia koeficientu aj graficky porovnané. S výpočtom korelačného koeficientu bola zároveň otestovaná aj jeho významnosť, ktorá okrem konkrétnej hodnoty berie do úvahy aj celkový počet vzoriek v rámci porovnávaného úseku signálu. Testovaná dĺžka signálu bola vo všetkých prípadoch spolu štyri sekundy (4000 vzoriek) a aj minimálna dosiahnutá hodnota korelačného koeficientu v rámci základnej metódy identifikácie komponentov (0,576) dosiahla p-hodnotu limitne sa blížiacu nule, čo naznačuje štatistickú významnosť korelačného koeficientu vo všetkých prípadoch.

Tabuľka 5.11: Minimálne, maximálne a priemerné hodnoty korelačného koeficientu pre porovnávané metódy získané z 49 úsekov z validačných záznamov. Korelačný koeficient (viď kapitola 4.6.3) bol počítaný za účelom porovnania metód z hľadiska zachovania fyziologickej zložky EEG signálu.

<b>Metóda</b>	<b>Minimálna hodnota korelačného koeficientu</b>	<b>Maximálna hodnota korelačného koeficientu</b>	<b>Priemerná hodnota korelačného koeficientu</b>
Základná	0,576	0,934	0,801
Upravená	0,743	0,996	0,879
Semi-automatická	0,592	0,934	0,810



Obrázok 5.13: Porovnanie rozloženia hodnôt korelačného koeficientu medzi základnou, upravenou a semi-automatickou metódou. Z obrázku je možné vidieť, že je hodnota mediánu, dolného aj horného kvartilu korelačného koeficientu v rámci upravenej metódy identifikácie artefaktových komponentov najvyššia, čo naznačuje, že má táto metóda najmenší vplyv na obsah neurologickej aktivity v EEG záznamoch.



## 6 Diskusia

Odstránenie artefaktov je pri spracovaní biologických signálov dôležitým predpokladom ich správnej analýzy. V klinickej praxi to platí dvojnásobne, keďže na interpretácii signálu lekárom následne závisí liečba pacienta. Ideálnym stavom by bolo úplne predísť vzniku artefaktov už počas nahrávania, to však bohužiaľ v realite zatiaľ nie je možné. Je pravda, že napríklad pri nahrávaní EEG záznamov počas vyšetrení sú pacienti inštruovaní snažiť sa byť v kľude, vyhýbať sa pohybom hlavy alebo mať pohľad zafixovaný na jedno miesto. Týmto spôsobom dôjde k obmedzeniu vzniku niektorých druhov artefaktov, nie vždy je však možné ich vylúčiť úplne (napríklad aj keď pacient dostal inštrukcie, je náročné počas dlhšieho nahrávania úplne vylúčiť pohyby očí). Zároveň existujú aj iné druhy artefaktov, ktoré pacient jednoducho potlačiť nevie – napríklad žmurkanie.

V rámci tejto práce boli analyzované EEG záznamy od jedenástich dobrovoľníkov, v ktorých boli zahrnuté očné artefakty. Jeden zo záznamov slúžil ako implementačný, zvyšných desať bolo validačných. Použitím metód *demean* a *detrend* bol každý signál zbavený nenulovej jednosmernej zložky a odfiltrovaním frekvencií nižších ako 0,5 Hz a vyšších ako 30 Hz boli odstránené zložky signálu mimo hlavných frekvenčných pásiem delta, theta, alfa a beta – napríklad vysokofrekvenčné EMG artefakty. Výrazné amplitúdové špičky spôsobené žmurkaním, rovnako ako ostatné druhy očných artefaktov ale prvotné predspracovanie potlačiť nedokázalo, vid' obrázok 5.1.

V rôznych štúdiách publikovaných v odbornej literatúre sa používajú na redukcii očných artefaktov metódy slepej separácie zdrojov, napríklad analýza hlavných komponentov (PCA) alebo analýza nezávislých komponentov (ICA) [21; 27; 38; 41]. V tejto práci bola použitá kombinácia oboch uvedených metód. PCA slúžila ako ďalšia forma predspracovania pred ICA. Analýza hlavných komponentov slúžila okrem iného na redukcii dimenzionality pôvodného datasetu, z ktorého boli pomocou matematických algoritmov vylúčené komponenty nesúce malé množstvo informácie. V súčte obsahovali odstránené komponenty v každom zo záznamov menej ako 5 % informácie, pričom konkrétne počty zachovaných komponentov sú uvedené v tabuľke 5.1. Je vidieť, že sa tieto počty pohybovali v intervale od 9 do 39 komponentov. Tým došlo pri strate nepatrného percenta informácie k výraznému ušetreniu časovej a výpočtovej náročnosti pri následnom použití metódy ICA, napríklad v prípade prvého subjektu už nebolo potrebné analyzovať pôvodných 256 komponentov, ale len 20.

Metóda ICA bola v tejto práci implementovaná pomocou dvoch rozšírených algoritmov, *Infomax* a *FastICA*, pričom boli porovnávané výsledky potlačenia očných artefaktov každého z nich. V kapitole 5.2 je na príklade subjektu 1 vidieť, že oba algoritmy úspešne rozdelili dataset na jednotlivé komponenty a že v oboch prípadoch boli očné artefakty izolované do dvoch komponentov, pričom jeden obsahoval vertikálne očné

pohyby / žmurkanie a druhý horizontálne očné pohyby. Na obrázkoch 5.3 a 5.5 je na príklade subjektu 1 zobrazené, že aj časové priebehy artefaktových komponentov sú v rámci oboch algoritmov veľmi podobné. Zo záznamov tak boli v oboch prípadoch odstránené dva zdroje očných artefaktov a na obrázkoch 5.6–5.9 je vidieť, že v prípade dobrovoľníka číslo 1 tak v oboch prípadoch došlo k úspešnému potlačeniu horizontálnych aj vertikálnych očných pohybov.

Napriek tomu, že sa jedná o rovnakú štatistickú metódu ICA, každý z algoritmov pracuje na inom princípe a tak sa medzi dosiahnutými výsledkami dajú pozorovať drobné rozdiely. Pri dôkladnejšom pohľade na jednotlivé topografické mapy (obrázky 5.2 a 5.4) je možné si všimnúť, že niektoré ekvivalentné komponenty majú v jednotlivých algoritmoch opačnú polaritu. Podobné malé rozdiely sa vyskytujú aj v časových priebehoch na obrázkoch 5.3 a 5.5. V konečnom dôsledku však pri potlačení očných artefaktov dospeli obidva algoritmy až na zanedbateľné rozdiely k rovnakému výsledku. Na rozšírenie automatickou detekciou artefaktových komponentov tak bol z dôvodu jednoduchšej implementácie vybraný algoritmus *Infomax*.

Pre správne fungovanie upravenej automatickej metódy identifikácie artefaktových komponentov bolo následne dôležité určiť prahové hodnoty pre parametre 1, 3 a 4. Z hľadiska implementácie automatizovanej metódy nastal najväčší problém pri stanovení prahovej hodnoty parametru číslo 1. V implementačnom zázname sa nachádzal len jeden komponent obsahujúci horizontálne očné pohyby a tak by použitie ROC analýzy na určenie prahu nebolo efektívne. Nakoniec bolo rozhodnuté použiť rovnakú prahovú hodnotu ako pre parameter číslo 3 z dvoch dôvodov: Po prvé, výpočet oboch parametrov bol až na použité signály z rozdielnych elektród takmer rovnaký, a po druhé, komponenty boli v oboch prípadoch vopred normované, takže dosahovali podobné výsledky aj z hľadiska absolútnych hodnôt výkonu. Rovnako aj v prípade určovania prahov pre vertikálne očné pohyby (parametre 3 a 4) bol v rámci implementačného záznamu malý počet komponentov obsahujúcich tento typ artefaktov – len 3, takže výsledné ROC krivky na obrázkoch 5.9 a 5.10 mali skokový tvar. Youdenov index a rozumné prahové hodnoty z nich ale určiť možné bolo, vid' tabuľka 5.2.

Porovnanie základnej, upravenej a semi-automatickej metódy automatickej identifikácie artefaktových komponentov prebehlo viacerými spôsobmi. V tabuľkách 5.3 a 5.4 uvedené počty a percentuálne zastúpenie artefaktových komponentov určených každou z metód. Je vidieť, že základná metóda vo väčšine prípadov identifikovala najviac artefaktových komponentov, z čoho vyplýva, že táto metóda má vysokú senzitivitu. Potvrďuje to aj samotný výpočet senzitivity v tabuľke 5.6, ktorá bola až 94,74 %. Nevýhodou tejto metódy bola jej nízka špecificita (83,25 %), ktorá spôsobovala, že boli zo záznamov odstraňované aj komponenty bez očných artefaktov, ale s obsahom neurologickej aktivity. Špecificitu metódy sa úspešne podarilo zvýšiť vytvorením upravenej metódy, v ktorej boli pridané ďalšie štyri identifikačné parametre. Špecificita tu dosiahla dokonca 97,37 %. Upravená metóda na druhú stranu artefaktových komponentov identifikovala výrazne menej, a tak jej výsledná senzitivita bola len 50 %.

Celková presnosť identifikácie komponentov sa však v rámci všetkých troch metód pohybovala vysoko nad 80 %.

Ďalšia časť vyhodnotenia sa týkala štatistického porovnania metód z hľadiska úspešnosti potlačenia očných artefaktov. Vyhodnotenie prebehlo samostatne pre vertikálne a samostatne pre horizontálne očné pohyby. V prípade vertikálnych očných pohybov / žmurkania bola sledovaný parameter Delta  $h$ , pričom čím menšiu hodnotu dosiahol, tým boli výsledky jednotlivých metód v tejto časti lepšie. V ideálnom prípade by mala byť jeho hodnota nulová. P-hodnota Friedmanovho testu (nebola splnená podmienka normality dát) vyšla 0,2811, čo je viac ako stanovená hladina významnosti testu. Na základe týchto výsledkov tak nebol získaný dostatok štatistických dôkazov na vyvrátenie nulovej hypotézy rovnosti stredných hodnôt Delty  $h$  v rámci jednotlivých metód. Rovnako je v tabuľke 5.7 vidieť, že extrémne a priemerné hodnoty dosahovali relatívne nízkych hodnôt (maximálne jednotky mikrovoltov) a medzi metódami sa nejako značne nelíšili. Všetky tri metódy tak dosiahli z pohľadu odstránenia vertikálnych očných pohybov takmer rovnaké výsledky.

Naopak, výsledky testu ANOVA s opakovanými meraniami pre vyhodnotenie úspešnosti potlačenia horizontálnych očných pohybov ukázali, že stredná hodnota rozptylu medzi metódami bola štatisticky významne rozdielna – p-hodnota bola rovná 0,0028. Čím menšia bola hodnota rozptylu, tým lepšie metóda odstraňovala horizontálne očné pohyby. Následné post hoc testovanie v tabuľke 5.7 a na obrázku 5.12 ukázalo, že rozdiel bol v upravenej metóde identifikácie artefaktových komponentov, pričom jej medián aj horný a dolný kvartil rozptylu dosiahli najvyššie. To naznačuje, že v rámci upravenej metódy zostávali po použití ICA v záznamoch najväčšie artefaktové rezíduá.

Na záver boli vyhodnocované metódy z hľadiska zachovania mozgovej aktivity. Aj v tomto prípade bola výsledná p-hodnota testu ANOVA s opakovanými meraniami nižšia ako 5% hladina významnosti, čo znamená, že medzi jednotlivými metódami bol zistený štatisticky významný rozdiel v stredných hodnotách korelačných koeficientov. Post hoc test v tabuľke 5.10 a na obrázku 5.13 opäť ukázal, že najvyššia hodnota bola dosiahnutá v upravenej metóde identifikácie komponentov, pričom ale v tomto prípade najvyššia stredná hodnota korelačného koeficientu dokazuje najlepšie výsledky z pohľadu zachovania neurologickej informácie. S výpočtom korelačného koeficientu bola zároveň testovaná aj jeho významnosť, ktorá bola preukázaná aj pri jeho najnižšej dosiahnutej hodnote. To je dôkazom, že vo všetkých testovaných metódach bola v úsekoch signálu bez prítomnosti očných artefaktov dosiahnutá signifikantná lineárna závislosť medzi signálmi pred a po použití metódy ICA. Najvyššia stredná hodnota v upravenej metóde však dokazuje, že z pohľadu zachovania neurologickej aktivity dosiahla táto metóda najlepšie výsledky.

Na základe všetkých uvedených zistení je možné tvrdiť, že metóda ICA je vhodná na odstránenie očných artefaktov vzniknutých pri nahrávaní EEG záznamu. Použité algoritmy *Infomax* aj *FastICA* dosiahli z hľadiska primárnej funkčnosti rovnaký výsledok a na potlačenie očných artefaktov sú obidva vhodné. Rozdiely medzi nimi sa mohli

objaviť v ich rýchlosti alebo výpočtovej náročnosti. Hlavnou nevýhodou metódy ICA je potreba identifikácie jednotlivých komponentov, ktorá je v prípade manuálnych metód časovo a personálne náročná a v prípade automatizovaných metód stále nie je stopercentná. V tejto práci bola na základe odbornej literatúry implementovaná jedna z metód automatickej identifikácie komponentov reprezentujúcich očné artefakty. Táto metóda bola na základe dosiahnutých výsledkov na implementačnom zázname upravená, pričom na záver prebehlo ich štatistické porovnanie. Upravená metóda dosiahla v porovnaní so základnou lepšie výsledky z hľadiska špecificity, celkovej presnosti identifikácie artefaktových komponentov a aj po odstránení artefaktových komponentov zachovávala v signáli najviac pôvodnej mozgovej aktivity. Naopak, oproti základnej metóde dosiahla výrazne horšiu senzitivitu a úspešnosť potlačenia horizontálnych očných pohybov. Z hľadiska potlačenia vertikálnych očných pohybov dosiahli obidve metódy porovnateľné výsledky.

Veľkou výhodou upravenej metódy však bolo semi-automatické rozšírenie s identifikáciou potenciálnych artefaktových komponentov, pomocou ktorého sa senzitivita výrazne zvýšila. V rámci tejto práce boli zo všetkých záznamov pri použití semi-automatickej metódy automaticky odstránené artefaktové komponenty, ktoré identifikoval algoritmus a následne manuálne odstránené aj všetky potenciálne artefaktové komponenty. Odstránenie všetkých potenciálnych artefaktových komponentov bol pravdepodobne dôvod určitého zníženia špecificity polo-automatickej metódy oproti upravenej. V tabuľke 5.3 je ale vidieť, že sa ich počty pohybovali v ráde jednotiek. Z tohto dôvodu by tak mohla byť upravená metóda s doplnkovou funkciou identifikácie potenciálne artefaktových komponentov vhodná na semi-automatické určovanie komponentov v EEG záznamoch, pretože po jej aplikácii už nebude potrebné manuálne analyzovať všetky nezávislé komponenty (rádovo desiatky), ale bude stačiť skontrolovať a prípadne odstrániť už len niekoľko vybraných. Tým bude uľahčená práca s manuálnou identifikáciou komponentov pre expertov, pričom ale expertné určovanie potenciálnych komponentov zabezpečí opätovné zvýšenie špecificity upravenej metódy.

## 7 Záver

Táto bakalárska práca sa zaoberala elektroencefalografiou a metódam potlačenia očných artefaktov z EEG záznamov. Na začiatku práce prebehla analýza možností metódy analýzy nezávislých komponentov ICA, ktorá ukázala jej veľký potenciál v oblasti potlačenia očných artefaktov. Z analýzy ďalej vyplynulo, že najväčšou nevýhodou ICA je potreba klasifikácie zdrojov spôsobujúcich v záznamoch artefakty. Na základe týchto informácií bola z odbornej literatúry vybraná jedna z metód automatickej identifikácie komponentov reprezentujúcich očné artefakty, ktorá bola spoločne s ICA implementovaná do programového prostredia MATLAB. Na výpočet ICA komponentov boli použité dva rôzne algoritmy – *Infomax* a *FastICA*, pričom na ďalšie rozšírenie pomocou automatickej identifikácie artefaktových komponentov bol vybratý algoritmus *Infomax*. V ďalšom kroku prebehla vlastná úprava vybratej metódy identifikácie komponentov pomocou pridania ďalších štyroch klasifikačných parametrov. Nastavenie prahových hodnôt v rámci týchto parametrov prebehlo pomocou ROC analýzy. Obe metódy boli následne aplikované na desať validačných EEG záznamov, na ktorých prebehlo pomocou navrhutej štatistickej analýzy porovnanie úspešnosti a vhodnosti použitia oboch metód na potlačenie očných artefaktov.

Posudzovaná bola ich úspešnosť z hľadiska potlačenia očných artefaktov, kde v prípade vertikálnych očných pohybov, respektíve žmurkania ukázali obe metódy porovnateľné výsledky a v prípade horizontálnych očných pohybov sa ukázala byť základná metóda lepšia.

Ďalej bola vyhodnocovaná úspešnosť metód z pohľadu zachovania čo najväčšieho obsahu neurologickej informácie, v ktorej dosiahla naopak upravená metóda lepšie výsledky.

Z hľadiska celkovej presnosti identifikácie artefaktových komponentov sa nakoniec ukázala byť upravená metóda lepšia ako základná, pričom konkrétne hodnoty presnosti boli 84,29 % v prípade základnej metódy a 92,86 % v prípade upravenej metódy. Upravená metóda síce dosiahla relatívne nízku senzitivitu, ale tento problém sa dá vyriešiť pomocou manuálnej analýzy potenciálnych artefaktových komponentov, ktorú je možné v rámci upravenej metódy využiť ako doplnkovú funkciu. Použitie upravenej metódy automatickej identifikácie ICA komponentov reprezentujúcich očné artefakty so semi-automatickým rozšírením sa ukázalo byť vhodné na potlačenie očných artefaktov z EEG záznamov.

## Zoznam použitej literatúry

- [1] NIEDERMEYER, Ernst a Lopes F.H. DA SILVA. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Lippincott Williams & Wilkins, 2004. ISBN 978-0-7817-5126-1.
- [2] BARNETT, Mark W a Phillip R LARKMAN. *The Action Potential*. *Practical Neurology*. 2007, 7(3), 192-7.
- [3] FLETCHER, Allan. *Action potential: generation and propagation* [online]. 2014, 15(6), 287-291 [cit. 2022-09-23]. ISSN 14720299. Dostupné z: doi:10.1016/j.mpaic.2014.03.004
- [4] BECKER, Wayne M., Lewis J. KLEINSMITH, Jeff HARDYN a Gregory P. BERTONI. *The World of the Cell*. 7th. edition. San Francisco: Pearson/Benjamin Cummings, 2008. ISBN 978-0805393934.
- [5] SHNEIDER, M. N. a M. PEKKER. *Correlation of action potentials in adjacent neurons*. *Physical Biology* [online]. 2015, 12(6) [cit. 2023-04-21]. ISSN 1478-3975. Dostupné z: doi:10.1088/1478-3975/12/6/066009
- [6] *How Neurons Communicate: Figure 3* [online]. In: . OpenStax, Cnx Biology, 2012 [cit. 22.09.2022]. Dostupné z: [https://cnx.org/contents/GFy\\_h8cu@9.87:cs\\_Pb-GW@5/How-Neurons-Communicate](https://cnx.org/contents/GFy_h8cu@9.87:cs_Pb-GW@5/How-Neurons-Communicate)
- [7] ST. LOUIS, Erik, Lauren FREY, Jeffrey BRITTON, Jennifer HOPP, Pearce KORB, Mohamad KOUBEISSI, William LIEVENS a Elia PESTANA-KNIGHT. *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants* [online]. American Epilepsy Society, 2016 [cit. 2023-04-21]. ISBN 9780997975604. Dostupné z: doi:10.5698/978-0-9979756-0-4
- [8] KLEIN, S. a B.M. THORNE. *Biological psychology*. New York: N.Y.: Worth, 2006. ISBN 978-0-7167-9922-1.
- [9] TATUM, William O. *Handbook of EEG interpretation*. Demos Medical Publishing, 2014. ISBN 9781617051807.
- [10] CHERNECKY, Cynthia C. a Barbara J. BERGER. *Laboratory tests and diagnostic procedures*. 6th. Edition. St. Louis: Elsevier, 2013. ISBN 9781455706945.

- [11] MCDERMOTT, Barry, Emily PORTER, Diarmaid HUGHES, Brian MCGINLEY, Mark LANG, Martin O'HALLORAN, Marggie JONES a Amy CLEMENTS-CORTES. Gamma Band Neural Stimulation in Humans and the Promise of a New Modality to Prevent and Treat Alzheimer's Disease. *Journal of Alzheimer's Disease* [online]. 2018, **65**(2), 363-392 [cit. 2023-01-13]. ISSN 13872877. Dostupné z: doi:10.3233/JAD-180391
- [12] JING, Wei, Yanran WANG, Guangzhan FANG, Mingming CHEN, Miaomiao XUE, Daqing GUO, Dezhong YAO a Yang XIA. EEG Bands of Wakeful Rest, Slow-Wave and Rapid-Eye-Movement Sleep at Different Brain Areas in Rats. *Frontiers in Computational Neuroscience* [online]. 2016, **10** [cit. 2023-04-21]. ISSN 1662-5188. Dostupné z: doi:10.3389/fncom.2016.00079
- [13] KRAJČA, Vladimír a Jitka MOHYLOVÁ. Číslicové zpracování neurofyziologických signálů. 1. vyd. V Praze: České vysoké učení technické, 2011. ISBN 978-80-01-04721-7.
- [14] CAHN, B. Rael a John POLICH. Meditation states and traits: EEG, ERP, and neuroimaging studies. *Psychological Bulletin* [online]. 2006, **132**(2), 180-211 [cit. 2022-09-24]. ISSN 1939-1455. Dostupné z: doi:10.1037/0033-2909.132.2.180
- [15] JIANG, Xiao, Gui-Bin BIAN a Zean TIAN. Removal of Artifacts from EEG Signals: A Review. *Sensors* [online]. 2019, **19**(5) [cit. 2022-09-24]. ISSN 1424-8220. Dostupné z: doi:10.3390/s19050987
- [16] JURCAK, Valer, Daisuke TSUZUKI a Ippeita DAN. 10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems. *NeuroImage* [online]. 2007, **34**(4), 1600-1611 [cit. 2022-09-25]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2006.09.024
- [17] SPIRANDELI, Amanda Franco, Leonardo Leal Queiroz MARREGA, Ailton Luiz Dias Siqueira JÚNIOR a Alcimar Barbosa SOARES. An Auditory Event-Related Potential Encoder. In: COSTA-FELIX, Rodrigo, João Carlos MACHADO a André Victor ALVARENGA, ed. XXVI Brazilian Congress on Biomedical Engineering [online]. Singapore: Springer Singapore, 2019, s. 525-529 [cit. 2023-04-21]. IFMBE Proceedings. ISBN 978-981-13-2516-8. Dostupné z: doi:10.1007/978-981-13-2517-5\_79
- [18] AURLIEN, H, I.O GJERDE, J.H AARSETH, G ELDØEN, B KARLSEN, H SKEIDSVOLL a N.E GILHUS. EEG background activity described by a large computerized database. *Clinical Neurophysiology* [online]. 2004, **115**(3), 665-673 [cit. 2022-09-25]. ISSN 13882457. Dostupné z: doi:10.1016/j.clinph.2003.10.019

- [19] RADÜNTZ, Thea, Jon SCOUTEN, Olaf HOCHMUTH a Beate MEFFERT. Automated EEG artifact elimination by applying machine learning algorithms to ICA-based features. *Journal of Neural Engineering* [online]. 2017, 14(4) [cit. 2022-09-24]. ISSN 1741-2560. Dostupné z: doi:10.1088/1741-2552/aa69d1
- [20] ROJAS, Gonzalo M., Carolina ALVAREZ, Carlos E. MONTOYA, María DE LA IGLESIA-VAYÁ, Jaime E. CISTERNAS a Marcelo GÁLVEZ. Study of Resting-State Functional Connectivity Networks Using EEG Electrodes Position As Seed. *Frontiers in Neuroscience* [online]. 2018, 12 [cit. 2022-09-29]. ISSN 1662-453X. Dostupné z: doi:10.3389/fnins.2018.00235
- [21] SAI, Chong Yeh, Norrima MOKHTAR, Hamzah AROF, Paul CUMMING a Masahiro IWAHASHI. Automated Classification and Removal of EEG Artifacts With SVM and Wavelet-ICA. *IEEE Journal of Biomedical and Health Informatics* [online]. 2018, 22(3), 664-670 [cit. 2022-09-24]. ISSN 2168-2194. Dostupné z: doi:10.1109/JBHI.2017.2723420
- [22] HUIGEN, E., A. PEPPER a C. A. GRIMBERGEN. Investigation into the origin of the noise of surface electrodes. *Medical & Biological Engineering & Computing* [online]. 2002, 40(3), 332-338 [cit. 2021-03-14]. ISSN 0140-0118. Dostupné z: doi:10.1007/BF02344216
- [23] SCHLÖGL, A., C. KEINRATH, D. ZIMMERMANN, R. SCHERER, R. LEEB a G. PFURTSCHELLER. A fully automated correction method of EOG artifacts in EEG recordings. *Clinical Neurophysiology* [online]. 2007, 118(1), 98-104 [cit. 2022-09-24]. ISSN 13882457. Dostupné z: doi:10.1016/j.clinph.2006.09.003
- [24] DEVUYST, S., T. DUTOIT, P. STENUIT, M. KERKHOFS a E. STANUS. Removal of ECG artifacts from EEG using a modified independent component analysis approach. 2008 30th Annual International Conference of the IEEE Engineering in Medicine and **Biology** Society [online]. IEEE, 2008, 5204-5207 [cit. 2022-09-28]. ISBN 978-1-4244-1814-5. Dostupné z: doi:10.1109/IEMBS.2008.4650387
- [25] RANJAN, Rakesh, Bikash CHANDRA SAHANA a Ashish KUMAR BHANDARI. Ocular artifact elimination from electroencephalography signals: A systematic review. *Biocybernetics and Biomedical Engineering* [online]. 2021, 41(3), 960-996 [cit. 2022-12-24]. ISSN 02085216. Dostupné z: doi:10.1016/j.bbe.2021.06.007



- [26] VIGÁRIO, Ricardo Nuno. Extraction of ocular artefacts from EEG using independent component analysis. *Electroencephalography and Clinical Neurophysiology* [online]. 1997, 103(3), 395-404 [cit. 2022-09-29]. ISSN 00134694. Dostupné z: doi:10.1016/S0013-4694(97)00042-8
- [27] ZHOU, Weidong a Jean GOTMAN. Automatic removal of eye movement artifacts from the EEG using ICA and the dipole model. *Progress in Natural Science* [online]. 2009, 19(9), 1165-1170 [cit. 2022-09-25]. ISSN 10020071. Dostupné z: doi:10.1016/j.pnsc.2008.11.013
- [28] NGUYEN, Hoang-Anh T., John MUSSON, Feng LI et al. EOG artifact removal using a wavelet neural network: A survey. *Neurocomputing* [online]. 2012, 97(3), 374-389 [cit. 2023-01-13]. ISSN 09252312. Dostupné z: doi:10.1016/j.neucom.2012.04.016
- [29] IWASAKI, Masaki, Christoph KELLINGHAUS, Andreas V. ALEXOPOULOS, Richard C. BURGESS, Arun N. KUMAR, Yanning H. HAN, Hans O. LÜDERS a R. John LEIGH. Effects of eyelid closure, blinks, and eye movements on the electroencephalogram. *Clinical Neurophysiology* [online]. 2005, **116**(4), 878-885 [cit. 2023-01-13]. ISSN 13882457. Dostupné z: doi:10.1016/j.clinph.2004.11.001
- [30] DORFER, Thomas A. Artefact Correction with ICA: Illustrated with an example from the neurosciences [online]. In: [cit. 2023-04-23]. Dostupné z: <https://towardsdatascience.com/artefact-correction-with-ica-53afb63ad300>
- [31] DE CHEVEIGNÉ, Alain a Dorothée ARZOUNIAN. Robust detrending, rereferencing, outlier detection, and inpainting for multichannel data. *NeuroImage* [online]. 2018, 172, 903-912 [cit. 2021-03-14]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2018.01.035
- [32] PEDRONI, Andreas, Amirreza BAHREINI a Nicolas LANGER. Automagic: Standardized preprocessing of big EEG data. *NeuroImage* [online]. 2019, 200, 460-473 [cit. 2022-09-28]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2019.06.046
- [33] SUBRAMANIYAM, Narayan P. Pitfalls of Filtering the EEG Signal. In: *Sapien Labs* [online]. [cit. 2022-09-28]. Dostupné z: <https://sapienlabs.org/lab-talk/pitfalls-of-filtering-the-ee-signal/>

- [34] KUSUMANDARI, Dwi Esti, Hanif FAKHRURROJA, Arjon TURNIP, Sutrisno Salomo HUTAGALUNG, Bagus KUMBARA a Janner SIMARMATA. Removal of EOG artifacts: Comparison of ICA algorithm from recording EEG. In: 2014 2nd International Conference on Technology, Informatics, Management, Engineering & Environment [online]. IEEE, 2014, s. 335-339 [cit. 2023-04-21]. ISBN 978-1-4799-4805-5. Dostupné z: doi:10.1109/TIME-E.2014.7011642
- [35] FATOURECHI, Mehrdad, Ali BASHASHATI, Rabab K. WARD a Gary E. BIRCH. EMG and EOG artifacts in brain computer interface systems: A survey. *Clinical Neurophysiology* [online]. 2007, 118(3), 480-494 [cit. 2023-04-21]. ISSN 13882457. Dostupné z: doi:10.1016/j.clinph.2006.10.019
- [36] MAKEIG, S., A. BELL, T.P. JUNG a T.J. SEJNOWSKI. Independent component analysis of electroencephalographic data. *Neural Information Processing Systems 8 (Proc. NIPS'95)* [online]. Cambridge, MA: MIT Press, 1996 [cit. 2023-04-26].
- [37] COMON, Pierre. Independent component analysis, A new concept?. *Signal Processing* [online]. 1994, 36(3), 287-314 [cit. 2022-10-14]. ISSN 01651684. Dostupné z: doi:10.1016/0165-1684(94)90029-9
- [38] JOYCE, Carrie A., Irina F. GORODNITSKY a Marta KUTAS. Automatic removal of eye movement and blink artifacts from EEG data using blind component separation. *Psychophysiology* [online]. 2004, 41(2), 313-325 [cit. 2023-04-26]. ISSN 0048-5772. Dostupné z: doi:10.1111/j.1469-8986.2003.00141.x
- [39] SAHONERO ALVAREZ, Guillermo a Humberto CALDERON. A Comparison of SOBI, FastICA, JADE and Infomax Algorithms. *IMCIC 2017 - 8th International Multi-Conference on Complexity, Informatics and Cybernetics, Proceedings* [online]. [cit. 2022-10-14].
- [40] OOSTENVELD, Robert. Independent component analysis (ICA) to remove EOG artifacts [online]. In: [cit. 2023-04-21]. Dostupné z: [https://www.fieldtriptoolbox.org/example/ic\\_a\\_eog/#ica-decomposition](https://www.fieldtriptoolbox.org/example/ic_a_eog/#ica-decomposition)
- [41] TING, K.H., P.C.W. FUNG, C.Q. CHANG a F.H.Y. CHAN. Automatic correction of artifact from single-trial event-related potentials by blind source separation using second order statistics only. *Medical Engineering & Physics* [online]. 2006, 28(8), 780-794 [cit. 2023-04-26]. ISSN 13504533. Dostupné z: doi:10.1016/j.medengphy.2005.11.006
- [42] HYVÄRINEN, A. a E. OJA. Independent component analysis: algorithms and applications. *Neural Networks* [online]. 2000, 13(4-5), 411-430 [cit. 2022-12-23]. ISSN 08936080. Dostupné z: doi:10.1016/S0893-6080(00)00026-5

- [43] PAULCHAMY, B., I. IAVENNILA, J. JAYA a R. SARAVANAKUMAR. Comparative Evaluation of Various Independent Components (ICA) Tech for the removal of artifacts of EEG Signals. *IJCSNS International Journal of Computer Science and Network Security* [online]. 2010, 10(3) [cit. 2022-12-26].
- [44] SAMADI, Mohammad Reza Haji, Zohreh ZAKERI a Neil COOKE. VOG-enhanced ICA for removing blink and eye-movement artefacts from EEG. In: 2016 IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI) [online]. IEEE, 2016, s. 603-606 [cit. 2023-04-25]. ISBN 978-1-5090-2455-1. Dostupné z: doi:10.1109/BHI.2016.7455970
- [45] DELROME, A., S. MAKEIG a T. SEJNOWSKI. AUTOMATIC ARTIFACT REJECTION FOR EEG DATA USING HIGH-ORDER STATISTICS AND INDEPENDENT COMPONENT ANALYSIS. *Proceedings of the third international ICA conference* [online]. 2001, 9-12 [cit. 2023-04-26].
- [46] DELSANTO, S., F. LAMBERTI a B. MONTRUCCHIO. Automatic ocular artifact rejection based on independent component analysis and eyeblink detection. In: *First International IEEE EMBS Conference on Neural Engineering, 2003. Conference Proceedings* [online]. IEEE, 2003, s. 309-312 [cit. 2023-04-26]. ISBN 0-7803-7579-3. Dostupné z: doi:10.1109/CNE.2003.1196822
- [47] NOLAN, H., R. WHELAN a R.B. REILLY. FASTER: Fully Automated Statistical Thresholding for EEG artifact Rejection. *Journal of Neuroscience Methods* [online]. 2010, **192**(1), 152-162 [cit. 2023-04-26]. ISSN 01650270. Dostupné z: doi:10.1016/j.jneumeth.2010.07.015
- [48] MATLAB. (2020). version 9.8.0.1323502 (R2020a). Natick, Massachusetts: The MathWorks Inc.
- [49] 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* [online]. 2011, 2011, 1-9 [cit. 2021-07-05]. ISSN 1687-5265. Dostupné z: doi:10.1155/2011/156869
- [50] HIRANO, Yoji, Itta NAKAMURA, Shunsuke TAMURA a Toshiaki ONITSUKA. Long-Term Test-Retest Reliability of Auditory Gamma Oscillations Between Different Clinical EEG Systems. *Frontiers in Psychiatry* [online]. 2020, 11 [cit. 2023-01-12]. ISSN 1664-0640. Dostupné z: doi:10.3389/fpsy.2020.00876

- [51] 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* [online]. 2011, **5** [cit. 2023-04-21]. ISSN 1662-5161. Dostupné z: doi:10.3389/fnhum.2011.00159
- [52] TALEBI, Shawhin. Independent Component Analysis (ICA): Finding hidden factors in data [online]. In: [cit. 2022-12-24]. Dostupné z: <https://towardsdatascience.com/independent-component-analysis-ica-a3eba0ccec35>
- [53] LANGLOIS, Dominic, Sylvain CHARTIER a Dominique GOSSELIN. An Introduction to Independent Component Analysis: InfoMax and FastICA algorithms. *Tutorials in Quantitative Methods for Psychology* [online]. 2010, **6**(1), 31-38 [cit. 2022-12-22]. ISSN 1913-4126. Dostupné z: doi:10.20982/tqmp.06.1.p031
- [54] JAADI, Zakaria. A Step-by-Step Explanation of Principal Component Analysis (PCA): Learn how to use a PCA when working with large data sets [online]. In: . [cit. 2022-12-20]. Dostupné z: <https://builtin.com/data-science/step-step-explanation-principal-component-analysis>
- [55] SPIEGEL, Murray R. a Larry J. STEPHENS. *Schaum's Outlines Statistics*. 4th. edition. McGraw Hill, 2008. ISBN 978-0-07-148584-5.
- [56] TUKEY, J. W. *Exploratory Data Analysis*. Reading, MA: Addison-Wesley, 1977.
- [57] SONGWON, Seo. A Review and Comparison of Methods for Detecting Outliers in Univariate Data Sets. 2006. Master's Thesis. University of Pittsburgh.
- [58] FAWCETT, Tom. An introduction to ROC analysis. *Pattern Recognition Letters* [online]. 2006, **27**(8), 861-874 [cit. 2023-05-01]. ISSN 01678655. Dostupné z: doi:10.1016/j.patrec.2005.10.010
- [59] SCHISTERMAN, Enrique F., Neil J. PERKINS, Aiyi LIU a Howard BONDELL. Optimal Cut-point and Its Corresponding Youden Index to Discriminate Individuals Using Pooled Blood Samples. *Epidemiology* [online]. 2005, **16**(1), 73-81 [cit. 2023-05-01]. ISSN 1044-3983. Dostupné z: doi:10.1097/01.ede.0000147512.81966.ba
- [60] VISHWESH, Kumar. How to generate and interpret a ROC curve for binary classification? [online]. In: [cit. 2023-05-01]. Dostupné z: <https://datasciencestunt.com/how-to-generate-and-interpret-a-roc-curve-for-binary-classification/>

# Príloha A: Použité kanály pre výpočet jednotlivých metód a parametrov

## Základná metóda, vzťah (6)

- $a_i$ (*lavé*), kanály číslo: 33, 37, 38, 46, 54, 244, 248, 252
- $a_i$ (*pravé*), kanály číslo: 1, 10, 11, 18, 19, 226, 230, 234
- $a_i$ (*zvyšné*), kanály číslo: 27, 20, 12, 3, 222, 212, 203, 193, 180, 171, 161, 151, 139, 126, 117, 108, 97, 85, 75, 70, 63, 56, 48, 39, 34, 96, 107, 116, 125, 138, 150, 160, 170, 115, 124, 137, 149, 159, 21, 13, 4, 223, 213, 204, 194, 181, 172, 162, 152, 140, 127, 118, 109, 98, 86, 76, 71, 64, 57, 49, 40, 35, 28, 22, 14, 5, 224, 214, 205, 195, 182, 173, 163, 153, 141, 128, 119, 110, 99, 87, 77, 72, 65, 58, 50, 41, 36, 29, 15, 6, 215, 206, 196, 183, 164, 154, 142, 129, 101, 100, 88, 78, 66, 59, 51, 42, 30, 23, 16, 7, 207, 197, 184, 155, 143, 130, 89, 79, 60, 52, 43, 24, 8, 198, 185, 144, 131, 90, 80, 53, 44, 17, 9, 186, 132, 81, 45

## Základná metóda, vzťah (7)

- $a_i$ (*nad*), kanály číslo: 37, 46, 54, 18, 10, 1, 47, 38, 33, 26, 19, 11, 2, 39, 34, 12, 3, 27, 20, 32, 25, 31
- $a_i$ (*pod*), kanály číslo: 244, 241, 242, 238, 234, 239
- $a_i$ (*zvyšné*), kanály číslo: 115, 124, 137, 149, 159, 96, 107, 116, 125, 138, 150, 160, 170, 85, 97, 108, 117, 126, 139, 151, 161, 171, 49, 57, 64, 71, 76, 86, 98, 109, 118, 127, 140, 152, 162, 172, 181, 194, 204, 213, 41, 50, 58, 65, 72, 77, 87, 99, 110, 119, 128, 141, 153, 163, 173, 182, 195, 205, 214, 15, 6, 215, 206, 196, 183, 164, 154, 142, 129, 101, 100, 88, 78, 66, 59, 51, 42, 30, 23, 16, 7, 207, 197, 184, 155, 143, 130, 89, 79, 60, 52, 43, 24, 8, 198, 185, 144, 131, 90, 80, 53, 44, 17, 9, 186, 132, 81, 45

## Upravená metóda, parameter 1, vzťah (9)

- $a_i$ (*lavé*), kanály číslo: 33, 37, 38, 46, 54, 244, 248, 252
- $a_i$ (*pravé*), kanály číslo: 1, 10, 11, 18, 19, 226, 230, 234
- $a_i$ (*zvyšné*), kanály číslo: 27, 20, 12, 3, 222, 212, 203, 193, 180, 171, 161, 151, 139, 126, 117, 108, 97, 85, 75, 70, 63, 56, 48, 39, 34, 96, 107, 116, 125, 138, 150, 160, 170, 115, 124, 137, 149, 159, 21, 13, 4, 223, 213, 204, 194, 181, 172, 162, 152, 140, 127, 118, 109, 98, 86, 76, 71, 64, 57, 49, 40, 35, 28, 22, 14, 5, 224, 214, 205, 195, 182, 173, 163, 153, 141, 128, 119, 110, 99, 87, 77, 72, 65, 58, 50, 41, 36, 29, 15, 6, 215, 206, 196, 183, 164, 154, 142, 129, 101, 100, 88, 78, 66, 59, 51, 42, 30, 23, 16, 7, 207, 197, 184, 155, 143, 130, 89, 79, 60, 52, 43, 24, 8, 198, 185, 144, 131, 90, 80, 53, 44, 17, 9, 186, 132, 81, 45

Upravená metóda, parameter 3, vzťah (10)

- $\mathbf{a}_i$  (oči), kanály číslo: 37, 46, 54, 18, 10, 1, 47, 38, 33, 26, 19, 11, 2, 39, 34, 12, 3, 27, 20, 32, 25, 31
- $\mathbf{a}_i$  (zvyšné), kanály číslo: 115, 124, 137, 149, 159, 96, 107, 116, 125, 138, 150, 160, 170, 85, 97, 108, 117, 126, 139, 151, 161, 171, 49, 57, 64, 71, 76, 86, 98, 109, 118, 127, 140, 152, 162, 172, 181, 194, 204, 213, 41, 50, 58, 65, 72, 77, 87, 99, 110, 119, 128, 141, 153, 163, 173, 182, 195, 205, 214, 15, 6, 215, 206, 196, 183, 164, 154, 142, 129, 101, 100, 88, 78, 66, 59, 51, 42, 30, 23, 16, 7, 207, 197, 184, 155, 143, 130, 89, 79, 60, 52, 43, 24, 8, 198, 185, 144, 131, 90, 80, 53, 44, 17, 9, 186, 132, 81, 45

Upravená metóda, parameter 4, spriemerovanie vybratých kanálov z oblasti očí za účelom detekcie špičiek

- Kanály číslo: 18, 19, 25, 32, 33, 37

## Príloha B: Tabuľky

Tabuľka B.1: Hodnoty Delt  $h$ , korelačného koeficientu a rozptylu bipolárneho zapojenia z validačných záznamov získaných pomocou základnej metódy identifikácie komponentov reprezentujúcich očné artefakty, ktoré boli použité na štatistické porovnanie jednotlivých metód.

Záznam číslo	Artefakt číslo	Delta $h$ ( $\mu\text{V}$ )	Korelačný koeficient	Rozptyl
1	1	0.0500	0.8757	33.43
1	2	0.0899	0.7444	
1	3	0.4596	0.9263	
1	4	0.1684	0.8950	
1	5	0.5371	0.8615	
2	6	0.5080	0.8665	22.97
2	7	0.2883	0.8904	
2	8	0.1271	0.8524	
2	9	0.8704	0.8632	
2	10	0.7580	0.7641	
3	11	3.1003	0.8840	31.78
3	12	1.48170	0.6564	
3	13	0.1970	0.7158	
3	14	0.4513	0.7964	
3	15	0.5039	0.7840	
4	16	0.6558	0.7458	17.57
4	17	0.4954	0.7004	
4	18	0.6817	0.5755	
4	19	0.9027	0.6428	
4	-	-	-	
5	20	0.3425	0.7246	10.24
5	21	0.1283	0.6686	
5	22	0.0394	0.7020	
5	23	0.9756	0.6946	
5	24	1.1639	0.7861	
6	25	1.27950	0.8030	27.50
6	26	0.1244	0.8617	
6	27	0.8498	0.7894	
6	28	0.1680	0.8175	
6	29	0.5252	0.8483	

7	30	1.1538	0.7426	13.91
7	31	0.4089	0.7588	
7	32	0.4219	0.8096	
7	33	0.5852	0.7964	
7	34	0.7957	0.7279	
8	35	0.0347	0.9109	22.26
8	36	0.3818	0.9335	
8	37	0.8351	0.8645	
8	38	0.4990	0.9179	
8	39	0.4983	0.9006	
9	40	1.8565	0.8524	16.13
9	41	0.6155	0.8551	
9	42	0.6142	0.9245	
9	43	0.1230	0.9029	
9	44	0.1828	0.7580	
10	45	0.7155	0.7484	51.59
10	46	0.5829	0.7522	
10	47	0.5638	0.7879	
10	48	1.6331	0.7745	
10	49	1.3854	0.7956	

Pozn. V zázname číslo 4 boli zahrnuté len 4 vertikálne očné artefakty



Tabuľka B.2: Hodnoty Dely  $h$ , korelačného koeficientu a rozptylu bipolárneho zapojenia z validačných záznamov získaných pomocou upravenej metódy identifikácie komponentov reprezentujúcich očné artefakty, ktoré boli použité na štatistické porovnanie jednotlivých metód.

Záznam číslo	Artefakt číslo	Delta $h$ ( $\mu\text{V}$ )	Korelačný koeficient	Rozptyl
1	1	0.0500	0.8757	33.44
1	2	0.0899	0.7444	
1	3	0.4596	0.9263	
1	4	0.1684	0.8950	
1	5	0.5371	0.8615	
2	6	0.2678	0.9231	98.90
2	7	1.0471	0.9198	
2	8	0.0625	0.9211	
2	9	0.5593	0.9069	
2	10	0.8461	0.8703	
3	11	3.1190	0.9497	52.70
3	12	1.3700	0.8717	
3	13	0.1763	0.9518	
3	14	0.6213	0.9444	
3	15	1.0019	0.9130	
4	16	0.1866	0.9954	21.16
4	17	1.42510	0.9949	
4	18	1.0337	0.9962	
4	19	1.6762	0.9964	
4	-	-	-	
5	20	0.4935	0.8024	26.14
5	21	0.0333	0.7591	
5	22	0.0206	0.8056	
5	23	0.8258	0.8139	
5	24	1.3800	0.8737	
6	25	1.3247	0.7993	45.77
6	26	0.1112	0.8613	
6	27	0.8088	0.7900	
6	28	0.2905	0.8150	
6	29	0.5249	0.8505	
7	30	1.2845	0.8786	69.94
7	31	0.6096	0.8785	
7	32	0.8550	0.9005	
7	33	0.8357	0.9116	
7	34	1.1690	0.9267	

8	35	0.4355	0.9472	54.02
8	36	0.2519	0.9634	
8	37	0.3711	0.9181	
8	38	0.5414	0.9553	
8	39	0.7562	0.9467	
9	40	1.8803	0.8545	16.14
9	41	0.5974	0.8823	
9	42	0.5763	0.9313	
9	43	0.0375	0.9089	
9	44	0.1674	0.7617	
10	45	0.5688	0.7427	80.87
10	46	0.8996	0.7650	
10	47	0.5202	0.7864	
10	48	1.67810	0.7845	
10	49	1.50720	0.7769	

Pozn. V zázname číslo 4 boli zahrnuté len 4 vertikálne očné artefakty

Tabuľka B.3: Hodnoty Delt  $h$ , korelačného koeficientu a rozptylu bipolárneho zapojenia z validačných záznamov získaných pomocou semi-automatickej metódy identifikácie komponentov reprezentujúcich očné artefakty, ktoré boli použité na štatistické porovnanie jednotlivých metód.

Záznam číslo	Artefakt číslo	Delta $h$ ( $\mu\text{V}$ )	Korelačný koeficient	Rozptyl
1	1	0.0500	0.8757	33.54
1	2	0.0899	0.7444	
1	3	0.4596	0.9263	
1	4	0.1684	0.8950	
1	5	0.5371	0.8615	
2	6	0.3657	0.9282	22.97
2	7	0.9525	0.9344	
2	8	0.0614	0.9190	
2	9	0.5206	0.9099	
2	10	0.8808	0.8735	
3	11	2.9591	0.8845	41.44
3	12	1.5944	0.6394	
3	13	0.1302	0.7630	
3	14	0.5295	0.7821	
3	15	0.6212	0.8308	
4	16	0.6674	0.7399	18.21
4	17	0.4185	0.7298	
4	18	0.6206	0.5918	
4	19	0.9525	0.6267	
4	-	-	-	
5	20	0.3424	0.7245	10.60
5	21	0.1283	0.6686	
5	22	0.0395	0.7019	
5	23	0.9751	0.6946	
5	24	1.1639	0.7860	
6	25	1.2796	0.8030	27.50
6	26	0.1242	0.8617	
6	27	0.8498	0.7894	
6	28	0.1674	0.8177	
6	29	0.5250	0.8482	
7	30	1.2077	0.7985	54.81
7	31	0.4677	0.7884	
7	32	0.3233	0.8079	
7	33	0.7708	0.8188	
7	34	0.7712	0.6631	

8	35	0.0347	0.9109	22.27
8	36	0.3819	0.9335	
8	37	0.8350	0.8645	
8	38	0.4990	0.9178	
8	39	0.4982	0.9006	
9	40	1.6698	0.8410	15.96
9	41	0.6409	0.8687	
9	42	0.5754	0.9190	
9	43	0.1716	0.8985	
9	44	0.1204	0.7613	
10	45	0.7130	0.7491	53.55
10	46	0.5873	0.7534	
10	47	0.5759	0.7891	
10	48	1.6338	0.7751	
10	49	1.3870	0.7964	

Pozn. V zázname číslo 4 boli zahrnuté len 4 vertikálne očné artefakty

## Príloha C: Obsah priloženého ZIP súboru

- Bakalárska práca
  - 17PBBBP\_491756\_Adam\_Hrabovsky.pdf
- Abstrakt v slovenskom jazyku
  - abstrakt\_sk.pdf
- Abstrakt v anglickom jazyku
  - abstrakt\_en.pdf
- Kľúčové slová v slovenskom jazyku
  - klucove\_slova\_sk.pdf
- Kľúčové slová v anglickom jazyku
  - klucove\_slova\_en.pdf
- Zadanie bakalárskej práce
  - zadanie.pdf
- Skripty pre MATLAB
  - zakladna\_thresholding\_metoda.m
  - upravena\_metoda.m
  - roc\_analyza.m
  - statisticke\_testy.m