

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

---

Fakulta elektrotechnická  
Katedra teorie obvodů

**STUDIUM NEUROSVALOVÉ AKTIVITY  
A SOUVISEJÍCÍCH METOD ZPRACOVÁNÍ  
SIGNÁLŮ**

Disertační práce

Antonín Hlaváček

Školitel: Ing. Václav Hanžl, CSc., školitel specialista : Ing. Jan Havlík, Ph.D.

---

únor 2013

*Název disertační práce:* Studium neurosvalové aktivity a souvisejících metod zpracování signálů

*Autor:* Ing. Antonín Hlaváček

*Doktorský studijní program:* Elektrotechnika a informatika

*Studijní obor:* Teoretická elektrotechnika

*Školitel:* Ing. Václav Hanžl, CSc.

*Školitel specialista:* Ing. Jan Havlík, Ph.D.

Disertační práce byla vypracována v prezenční formě doktorského studia na Katedře teorie obvodů Fakulty elektrotechnické Českého vysokého učení technického v Praze k získání akademického titulu „doktor“, ve zkratce „Ph.D.“.

*Adresa:*

Katedra teorie obvodů

Fakulta elektrotechnická

České vysoké učení technické v Praze

Technická 2

166 27 Praha 6

Praha, únor 2013

V disertační práci použité názvy programových produktů, firem apod. mohou být ochrannými známkami nebo registrovanými ochrannými známkami příslušných vlastníků.

Sazba tohoto dokumentu byla provedena pomocí typografického systému L<sup>A</sup>T<sub>E</sub>X.

# Abstrakt

Předložená práce se zabývá problematikou studia neurosvalové aktivity a souvisejících metod zpracování signálů.

V první části je uvedeno stručné zadání práce a její cíle, dále je shrnut současný stav problematiky.

Ve druhé části jsou popsány metody snímání a zpracování elektroencefalografických signálů.

Ve třetí části je představena teorie Skrytých Markovových modelů.

Ve čtvrté části je popsán samotný experiment, metodika provedení, způsob snímání dat, jejich zpracování. Dále jsou podrobně popsány použité klasifikátory a nastíněna jejich konkrétní implementace v prostředí HTK Toolboxu. V závěru této části je uvedeno srovnání dosažených výsledků v závislosti na klasifikátoru a implementaci.

V závěrečné části jsou shrnuty dosažené výsledky, jejich vyhodnocení a přínos k řešené problematice a nastín možného směru pokračování ve výzkumu.

Tato práce vznikla jako disertační práce oboru Teoretická elektrotechnika na katedře Teorie obvodů Fakulty elektrotechnické Českého vysokého učení technického v Praze.

# Abstract

This paper deals with the topic of neurological and muscle activity and signal processing.

Section one presents a brief layout of the project as well as its goals and summarizes current state of the research.

Section two briefly describes the method of sensing electroencephalographic signals.

The third part presents theory of the Hidden Markov Models.

The fourth part describes the created classifiers in greater detail. The function and particular implementation of the classifiers in the HTK Toolbox environments are defined. The conclusion to this section comprises a brief comparison of the results achieved depending on the classifier and its implementation. End of this part provides a summary and comments on the achieved results.

The final section introduces the intended future treatment of the assigned topic.

This paper has originated as doctoral degree study in the subject Electrical Engineering Theory at the Department of Circuit Theory of the Faculty of Electrical Engineering of the Czech Technical University.

# Poděkování

Děkuji svému školiteli Ing. Václavu Hanzlovi, CSc. a školiteli specialistovi Ing. Janu Havlíkovi, Ph.D. za vedení v průběhu doktorského studia a podporu, které se mi od nich dostalo.

# Prohlášení

Prohlašuji, že jsem disertační práci vypracoval samostatně a že jsem uvedl veškeré použité prameny.

Antonín Hlaváček

Praha, 8. února 2013

# Obsah

<b>1</b>	<b>Úvod</b>	<b>12</b>
1.1	Současný stav . . . . .	13
<b>2</b>	<b>Cíle disertační práce</b>	<b>19</b>
<b>3</b>	<b>EEG signál a jeho zpracování</b>	<b>20</b>
3.1	EEG signál . . . . .	20
3.2	Snímání EEG signálu . . . . .	25
3.2.1	Rozložení elektrod . . . . .	25
3.2.2	Režimy snímání . . . . .	26
3.3	Filtrace . . . . .	28
3.3.1	Independent Component Analysis . . . . .	28
3.4	Extrakce parametrů . . . . .	30
3.4.1	Volba parametrů . . . . .	30
3.4.2	Výpočet parametrů . . . . .	31
<b>4</b>	<b>Skryté Markovovy Modely</b>	<b>34</b>
4.1	Struktura . . . . .	34
4.2	Implementace . . . . .	36
<b>5</b>	<b>Experiment</b>	<b>37</b>
5.1	Technické provedení . . . . .	37
5.2	Měřicí soustava . . . . .	37
5.3	Metoda zpracování dat . . . . .	39
5.3.1	Předzpracování . . . . .	39
5.3.2	Histogram a prahování . . . . .	40
5.3.3	Hledání těžišť . . . . .	42
5.3.4	3D parametrizace . . . . .	43

5.4	Předzpracování dat . . . . .	44
5.5	Filtrace . . . . .	45
5.5.1	Odstranění síťového rušení 50 Hz . . . . .	46
5.5.2	Omezení frekvenčního pásma . . . . .	47
5.5.3	Odstranění kolísání izolinie . . . . .	47
5.5.4	Dekompozice signálu pomocí ICA . . . . .	48
5.6	Segmentace . . . . .	48
5.7	Klasifikace dat . . . . .	49
5.7.1	Klasifikační třídy . . . . .	49
5.7.2	Ruční klasifikace . . . . .	50
5.8	Modely . . . . .	51
5.8.1	Topologie . . . . .	51
5.8.2	Specifika implementace . . . . .	51
5.8.3	Trénování . . . . .	52
5.8.4	Definice úlohy . . . . .	53
5.9	Klasifikace pomocí modelů . . . . .	55
5.9.1	Soubor dat a metriky . . . . .	55
5.9.2	Výsledky klasifikace . . . . .	57
5.10	Zhodnocení výsledků . . . . .	59
<b>6</b>	<b>Výsledky disertační práce</b>	<b>61</b>
6.1	Shrnutí . . . . .	61
6.2	Hlavní výsledky práce . . . . .	62
6.3	Náměty k další práci . . . . .	63
<b>7</b>	<b>Závěr</b>	<b>64</b>
<b>A</b>	<b>Příloha</b>	<b>73</b>

# Seznam tabulek

1.1	Typické parametry současného zařízení pro snímání EEG [57]	18
3.1	Přehled základních rytmů EEG . . . . .	24
5.1	Definice gramatiky . . . . .	54
5.2	Definice slovníku, vlevo název STAVu, vpravo název jevu . . .	54
5.3	Databáze použitá pro trénování a testování modelů . . . . .	56
5.4	Výsledky klasifikace, metrika <i>Correct</i> . . . . .	57
5.5	Výsledky klasifikace, metrika <i>Accuracy</i> . . . . .	57
5.6	Výsledky klasifikace pro osobu O2, trénovací i testovací data stejná osoba. . . . .	58
5.7	Výsledky klasifikace, metrika <i>Correct</i> , bigramové modely. . .	59
5.8	Výsledky klasifikace, metrika <i>Accuracy</i> , bigramové modely. . .	59

# Seznam obrázků

1.1	Zařízení pro měření MEG, vpravo nahoře vizualizace naměřených dat, zdroj obrázku [56] . . . . .	14
1.2	Zařízení pro měření EEG, kompletní 64 kanálový systém připravený k připojení k řídicímu PC, zdroj obrázku [57] . . .	15
1.3	Hans Berger provedl jako první měření elektrických potenciálů lidského mozku, zdroj obrázku [55] . . . . .	16
1.4	Jeden z prvních záznamů EEG z roku 1932, horní signál zaznamenaný pomocí Edelmannova strunového galvanometru, prostřední pomocí dvoucívkového oscilografu Siemens, spodní záznam představuje 10Hz referenci, obrázek získán z [21] . . .	17
1.5	První komerčně dostupný tranzistorový přístroj pro záznam EEG <i>Offner type T</i> [21] . . . . .	18
3.1	EMG artefakty v EEG záznamu . . . . .	21
3.2	EOG artefakty v EEG záznamu . . . . .	22
3.3	ECG artefakty v EEG záznamu, pomalé vlny synchronizované s QRS komplexy viditelné na elektrodách T3-T5 a T4-T6 . . .	22
3.4	Artefakt vyvolaný elektrodou F3 . . . . .	23
3.5	Rozložení elektrod v systému 10/20 . . . . .	25
3.6	Unipolární zapojení elektrod . . . . .	27
3.7	Bipolární zapojení elektrod . . . . .	27
3.8	Zprůměrované zapojení elektrod . . . . .	28
3.9	Záznam EEG s artefakty . . . . .	29
3.10	Vypočtené komponenty, pro odstranění byly zvoleny komponenty č. 1, 2, 4 . . . . .	30
3.11	Výsledný signál po odstranění zvolených komponent . . . . .	31
3.12	Vypočtený spektrogram s frekvenčním rozlišením 1 Hz, časové rozlišení 200 ms . . . . .	32
3.13	Časová a frekvenční forma Hannova okna o délce 256 bodů . .	33

3.14	Derivace spektrogramu . . . . .	33
5.1	Uspořádání měřicího pracoviště . . . . .	38
5.2	Rozmístění videokamer . . . . .	39
5.3	Výřez $30 \times 15$ pixelů . . . . .	40
5.4	Histogram a filtrovaný histogram s vyznačeným trojúhelníkovým algoritmem . . . . .	41
5.5	Ukázka výřezu, na který bylo aplikováno prahování a obsahuje artefakt navíc . . . . .	41
5.6	Ukázka prahovaného výřezu bez rušivých elementů . . . . .	42
5.7	Soustava prst - kamery . . . . .	43
5.8	Lokalizace elektrod C3 a C4 v systému 10/20 . . . . .	45
5.9	Energie ve spektru nefiltrovaného signálu . . . . .	46
5.10	Energie ve spektru po filtraci IIR filtrem s $Fz = 45\text{Hz}$ . . . . .	47
5.11	Identifikační značky v signálu EEG . . . . .	49
5.12	Rozdělení na segmenty . . . . .	50
5.13	Topologie základního modelu . . . . .	51
5.14	Proces trénování modelu . . . . .	52
5.15	Vytvořený klasifikátor = síť + slovník + HMM . . . . .	55

# Kapitola 1

## Úvod

V následující stati se zabývám problémem klasifikace pohybů části lidského těla v korelaci s elektroencefalografickými (dále pouze EEG) signály. EEG je záznamem elektrické aktivity mozku, která je snímána na povrchu skalpu, ve vyjímečných případech i in-vitro. Tato elektrická aktivita je odrazem vniřních procesů probíhajících uvnitř mozku a bylo ukázáno, že vhodným výběrem místa snímání těchto potenciálů je možné odlišit různé druhy aktivity - svalovou aktivitu, duševní činnost atd. [4].

Pokud by bylo možné jednoznačně popsat vztah mezi těmito potenciály a například volnými pohyby těla, otevřel by se nový prostor pro výrobu podpůrných zařízení pro handicapované osoby (protézy), případně pro dálkové ovládání strojů či přístrojů (průzkumné roboty).

Cílem mé práce je vytvořit systém, který umožní klasifikaci EEG signálu odpovídajícího pohybové aktivitě. Vzhledem k velké rozmanitosti pohybů jsem se zaměřil pouze na pohyby prstů ruky.

Dalším postupem disertační práce bude segmentace a klasifikace EEG záznamů pomocí modelů natrénovaných na pohybech prstů.

K dosažení vytyčeného cíle bude nutné v první řadě získat dostatečné množství dat, na kterých by mohla být analýza prováděna. Metodu použitou pro snímání a předzpracování obrazových dat publikoval ve svých článcích Ing. Jan Havlík, PhD. [11], [12], EEG data budou snímána pomocí standardního lékařského vybavení.

Následným krokem bude výběr vhodných kanálů z EEG záznamu [13] a jejich následná parametrizace. Jako vhodné se jeví omezení frekvenčního pásma na cca 8-30 Hz [14], využití energetických a delta parametrů. Bude ověřena i možnost využití algoritmů ICA pro předzpracování signálů [2].

## 1.1 Současný stav

V současné době se problematikou zpracování a analýzy elektroencefalografických signálů (EEG) zabývá po celém světě mnoho výzkumných skupin. Motivací k tomuto výzkumu je mimo jiné identifikace specifických signálů příslušející daným projevům mozkové činnosti - rozpoznání různých druhů volních aktivit, například pohybů. Dalším neméně významným motivem je rozpoznávání patologických stavů u nemocných pacientů, např. predikce epileptických záchvatů. Vzhledem k zaměření této práce se však této oblasti nebudeme hlouběji věnovat. Zaměříme se výhradně na analýzu stavu ohledně rozpoznávání volních pohybů v EEG záznamu.

Výsledky výzkumu na tomto poli nám ukazují, že v současné době je možné odlišit od sebe pohyby různých částí těla, pokud jsou tyto pohyby dostatečně odlišné, respektive prováděny jinou svalovou skupinou, například pohyb pravého ramene vs. pohyb pravého ukazováčku [17] při použití klasifikátoru založeného na Skrytých Markovovských Modelech (HMM). Naproti tomu klasifikace pohybů sobě podobných, například pohyb palce vs. ukazováčku jedné ruky selhává [18].

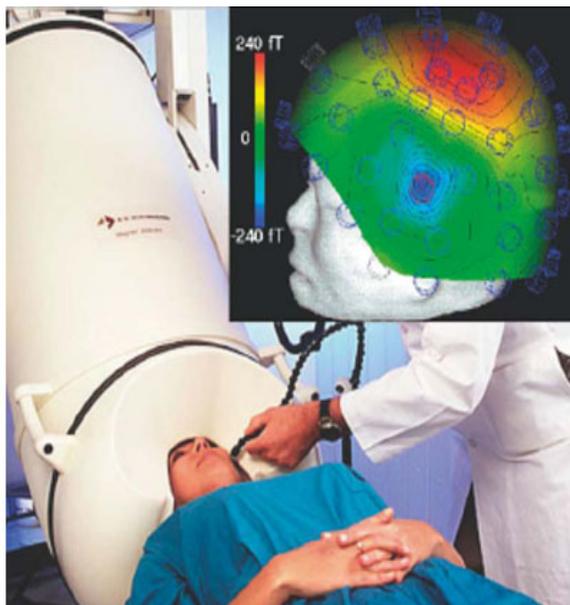
Metody snímání EEG jsou v současné době standarizovány co se týče rozmístění elektrod na skalpu, mezi nejpoužívanější systémy patří mezinárodní systém 10/20 (Jasper, 1958), případně 10/10 [15] pro snímání EEG s vysokým prostorovým rozlišením. Frekvence snímání je používána vzhledem k využitelnému frekvenčnímu rozsahu EEG (0-40Hz) a Nyquistovu teorému 128 až 512 Hz [16].

Podívejme se stručně na metody a vývoj snímání elektrické aktivity mozku. Ponecháme stranou invazivní metody snímání, které se v současné době používají převážně u experimentů s pokusnými zvířaty. V principu existují dvě metody neinvazivního snímání elektrických potenciálů mozku, a to elektroencefalografie (EEG) a magnetoencefalografie (MEG). Tyto metody jsou z hlediska měření osoby bezpečné a poskytují dostatečné časové rozlišení v řádu milisekund. Obě metody mohou být použity pro kontinuální snímání elektrické aktivity, stejně jako pro zaznamenání reakcí na opakované stimuly (u EEG hovoříme o tzv. ERP, event related potential, u EMG jde o ERF, event related fields). Z hlediska prostorového rozlišení jsou metody limitovány měřením signálu na povrchu lebky, která působí výrazné zeslabení signálů a ztěžuje jejich prostorovou lokalizaci.

Zařízení pro snímání MEG jsou velmi nákladná a rozměrná, jejich použití ve vědě a výzkumu je z těchto důvodů poměrně omezené ve srovnání s EEG

aparáty.

Principem činnosti MEG je snímání velmi slabého magnetického pole indukovaného synchronizovanou činností neuronů mozku. Intenzita se pohybuje od 10 femtotesla (fT) pro aktivitu cortexu po  $10^3$  fT odpovídající  $\alpha$  vlnám. Vezmeme-li v úvahu úroveň běžného pozadí  $10^8$  fT je zřejmé, že umístění měřicího zařízení klade vysoké nároky na odstínění a eliminaci veškerých potenciálně rušivých okolních vlivů.



Obrázek 1.1: Zařízení pro měření MEG, vpravo nahoře vizualizace naměřených dat, zdroj obrázku [56]

Oproti tomu, při současném stavu techniky lze zařízení pro snímání EEG realizovat poměrně snadno při zachování nízkých pořizovacích a provozních nákladů. Běžně dostupné komerční systémy umožňují měření s desítkami kanálů (běžně 64) a samotné zařízení lze v případě nutnosti jednoduše transportovat. Na umístění zařízení nejsou kladeny z technického hlediska prakticky žádné omezující podmínky, doporučuje se umístit je v dostatečné vzdálenosti (řádově metry) od ostatních elektrických spotřebičů z důvodu možné indukce rušivých napětí.

První EEG záznam pořídil německý psycholog a psychiatr Hans Berger (1873 - 1941) [20] v roce 1924.



Obrázek 1.2: Zařízení pro měření EEG, kompletní 64 kanálový systém připravený k připojení k řídicímu PC, zdroj obrázku [57]

Jako první popsal mozkové vlny včetně  $\alpha$  a  $\beta$  vln a zavedl termín elektroencefalografie. Jeho článek *Über das Elektrenkephalogramm des Menschen*<sup>1</sup> publikovaný v roce 1929 v *Archive für Psychiatrie und Nervenkrankheiten* byl prvním z 23 publikací týkajících se tohoto tématu.

Popsal mnoho jevů týkajících se jak normálního, tak abnormálního EEG, kupříkladu změny související s pozorností, mentálním úsilím či poraněním mozku. Jeho výzkumy potvrdili jako první britští vědci Adrian a Matthews v roce 1934.

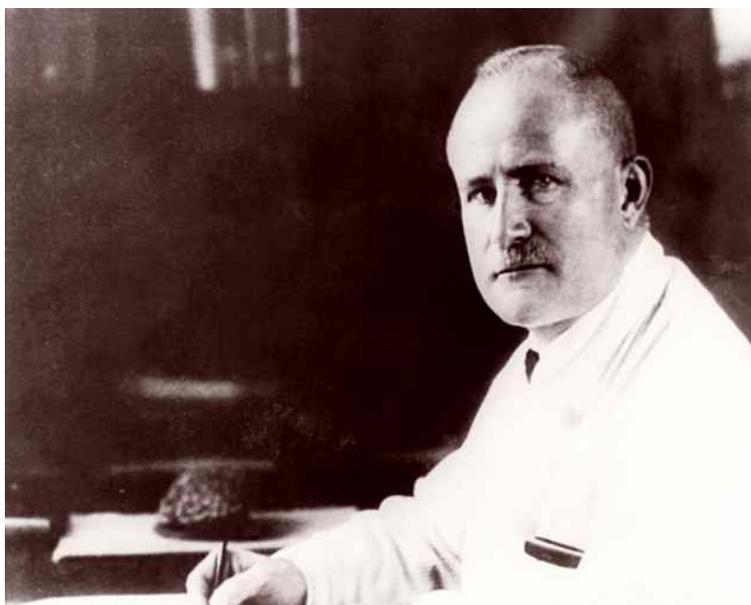
Berger ve své práci navazoval na předchozí výzkumy Cantona, který prováděl pokusy na zvířatech a již v roce 1875 prezentoval výsledky svého výzkumu ohledně elektrické aktivity zvířecího mozku, kterou snímal pomocí zrcátkového galvanometru.

S rozšiřujícím se využitím elektronek docházelo ke zlepšování parametrů zařízení, např. vstupní impedance<sup>2</sup> vzrostl z 3 kOhm u strunového galvano-

---

<sup>1</sup>*O lidském elektroencefalogramu*

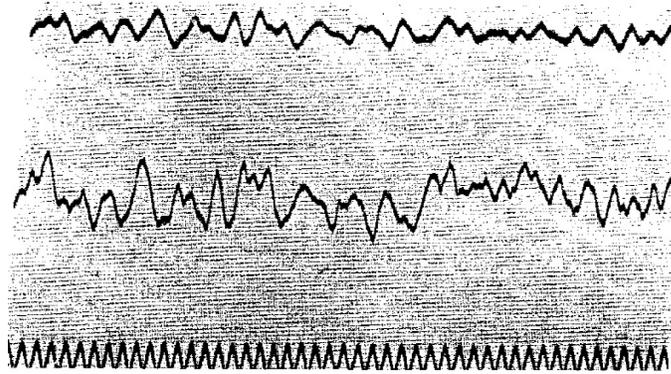
<sup>2</sup>Máme na mysli obecně vstupní impedanci zesilovače, nicméně u strunového galvanometru nelze o zesilovači hovořit



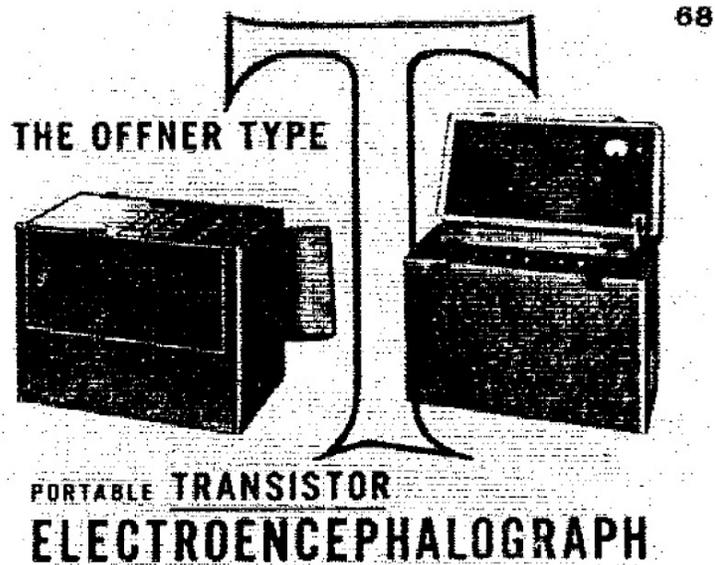
Obrázek 1.3: Hans Berger provedl jako první měření elektrických potenciálů lidského mozku, zdroj obrázku [55]

metru v roce 1929 na 200 kOhm u elektronkového diferenciálního zesilovače Matthewa z roku 1934. První přenosné systémy pro měření EEG byly na trh uvedeny na přelomu čtyřicátých a padesátých let, šlo již o plně tranzistorová zařízení. Tato zařízení používala záznam na roli papíru, dosahovala citlivosti až  $2\mu\text{V}/\text{mm}$  a byla vybavena osmi diferenciálními vstupy s potlačením souhlasného rušení 10000:1.

Nástup počítačové techniky v osmdesátých letech přinesl zejména změnu ve způsobu sběru a uchovávání dat. Dostatečná kapacita záznamových médií umožnila dlouhodobé monitorování pacientů. Digitální uchovávání dat dovoluje jejich snadné sdílení po celém světě a tím zpřístupňuje lékařskou péči na místa dříve nedostupná, kde postačuje kvalifikovaná obsluha pro zapojení přístroje a internetové připojení pro přenos nasnímaných dat. V současné době jsou standardem systémy umožňující současné snímání v 64 nebo 128 kanálech při vzorkovací frekvenci až 512 Hz.



Obrázek 1.4: Jeden z prvních záznamů EEG z roku 1932, horní signál zaznamenaný pomocí Edelmannova strunového galvanometru, prostřední pomocí dvoucívkového oscilografu Siemens, spodní záznam představuje 10Hz referenci, obrázek získán z [21]



Obrázek 1.5: První komerčně dostupný tranzistorový přístroj pro záznam EEG *Offner type T* [21]

Připojení k PC	USB/HDMI
Počet kanálů	32/64/128
A/D převodník	24bit
Vzorkovací frekvence	128, 256, 512 Hz
Vstupní impedance	$\geq 10$ MOhm
CMRR	$\geq 100$ dB
Šum	$\leq 0,5\mu$ VRMS

Tabulka 1.1: Typické parametry současného zařízení pro snímání EEG [57]

# Kapitola 2

## Cíle disertační práce

S ohledem na analýzu současného stavu problematiky byly stanoveny následující cíle práce:

1. Pořízení EEG záznamu v objemu dostačujícím pro statistické zpracování signálů.
2. Zpracování a ruční klasifikace pořízených signálů.
3. Návrh klasifikátorů umožňujících rozlišení mezi jednotlivými pohyby prstu.
4. Ověření klasifikátorů na reálných datech a zhodnocení jejich praktické použitelnosti.

# Kapitola 3

## EEG signál a jeho zpracování

### 3.1 EEG signál

Elektroencefalografický signál (EEG) je záznamem elektrických projevů mozkové činnosti. Snímání EEG se provádí neinvazivní metodou, při které jsou na povrch skalpu připevněny elektrody, jenž snímají sumační elektrickou aktivitu z povrchu lebky. Z principu snímání je zřejmé, že prostorová rozlišitelnost zdrojů aktivity bude vzhledem k počtu elektrod (řádově desítky) vs. počet zdrojů nízká, stejně tak jako amplituda signálu, která se pohybuje v řádu nejvýše desítek mikrovolt.

Zdrojem EEG signálu je elektrická aktivita neuronů mozku. Vzhledem k nízké intenzitě signálu jednotlivých neuronů je detekována pouze synchronní aktivita tisíců až milionů neuronů s podobnou prostorovou orientací. V případě rozdílné orientace nedojde k excitaci okolních neuronů a nevznikne detekovatelná vlna.

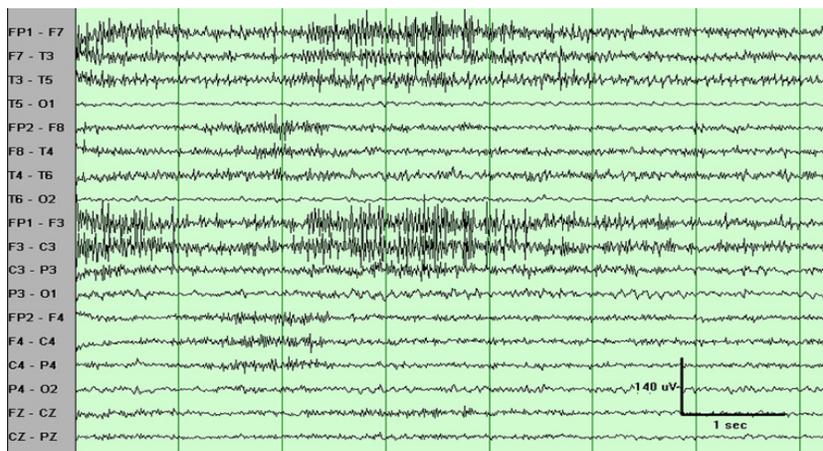
Mimo užitečného signálu se v EEG záznamu objevují i signály nesouvisející s neurální aktivitou mozku, tyto signály nazýváme artefakty a můžeme je rozdělit do dvou základních skupin - fyziologické a extrafyziologické. Fyziologické artefakty souvisejí s dalšími procesy v těle měřené osoby, extrafyziologické či technické artefakty jsou způsobeny vnějšími vlivy jako je prostředí, měřicí vybavení atp.

Mezi základní fyziologické artefakty patří:

1. Svalová aktivita

Potenciály generované svaly (EMG) jsou nejběžnějším typem artefaktů.

Tyto signály mají ve většině případů kratší délku<sup>1</sup> než EEG a jsou detekovatelné na základě této délky, morfologie a frekvence, typicky 20 - 100 Hz.



Obrázek 3.1: EMG artefakty v EEG záznamu

## 2. Pohyby očí

Pohyby očí jsou detekovatelné v EEG záznamu a mohou být použity například pro detekci spánkových stavů (REM, Non-REM). Mrkání je v záznamu EEG pozorovatelné jako výrazné vlny s vysokou amplitudou na elektrodách s frontální lokací.

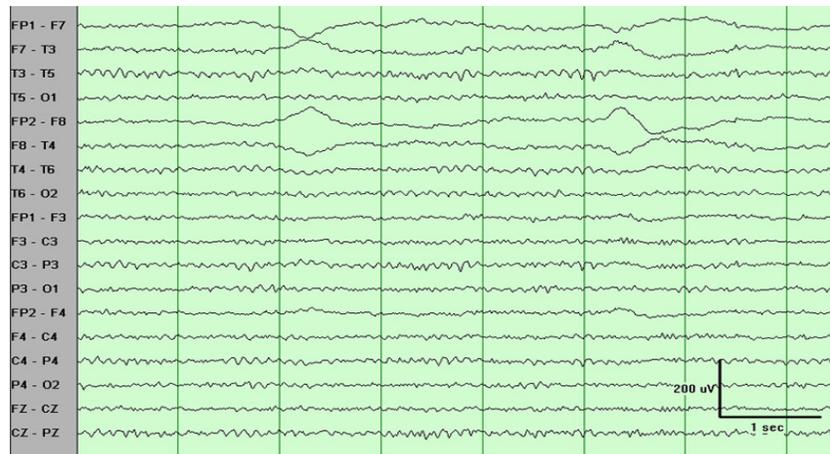
## 3. Srdeční aktivita

Záznam srdeční aktivity (ECG) je rozpoznatelný díky své periodicitě odpovídající frekvenci srdečního rytmu, artefakty jsou synchronizovány s QRS komplexy. Pro usnadnění odstranění těchto artefaktů se při snímání EEG připojují další elektrody pro záznam ECG.

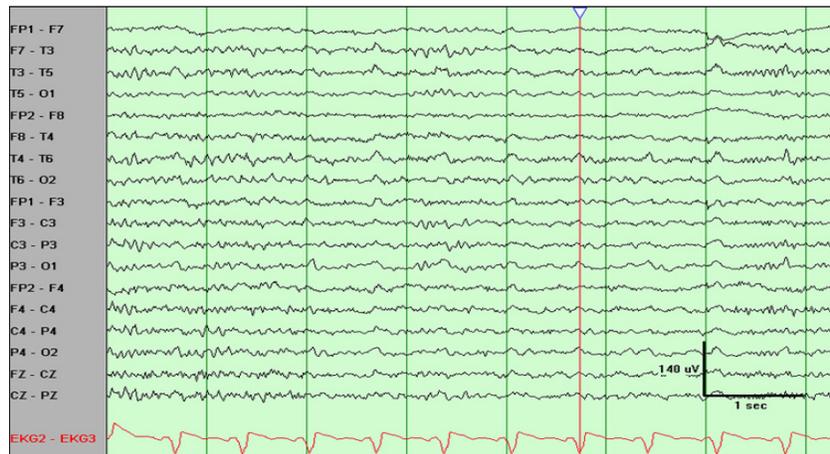
## 4. Puls

Tyto artefakty se objeví v případě umístění snímací elektrody nad pulsuující žílu ve skalpu. Pulsace se projeví v záznamu jako pomalé vlny podobné mozkové aktivitě. Existuje zde přímá souvislost mezi ECG a

<sup>1</sup>Záznam EEG signálu může probíhat až hodiny, EMG signály trvají řádově sekundy



Obrázek 3.2: EOG artefakty v EEG záznamu



Obrázek 3.3: ECG artefakty v EEG záznamu, pomalé vlny synchronizované s QRS komplexy viditelné na elektrodách T3-T5 a T4-T6

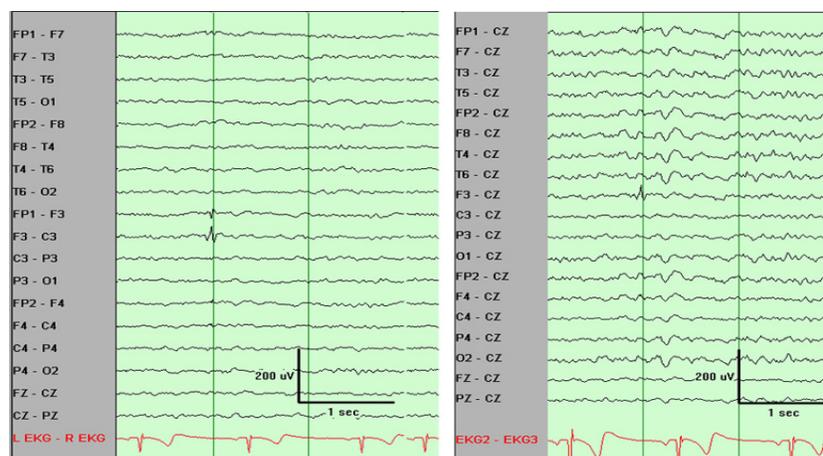
pulsními vlnami, QRS komplex vždy předchází pulsním vlnám o 200 - 300 ms.

Mezi další fyziologické artefakty ovlivňující záznam EEG patří například dýchání či pocení, které ovlivňuje impedanci připojených elektrod.

K extrafyziologickým, či technickým artefaktům zejména náleží:

## 1. Elektrody

Nejběžnějším artefaktem pocházejícím z elektrod je praskání. Morfologicky se jeví jako jedna nebo více ostrých křivek v důsledku náhlé změny impedance. Tyto křivky jsou identifikovatelné svým charakteristickým vzhledem (náhlé vertikální přechody bez změny aktivity pozadí) a lokalizací, jenž je omezena na jedinou elektrodu. Obecně lze říci, že veškeré ostré přechody lokalizované v jediné elektrodě by měly být považovány za artefakty, pokud nelze dokázat opak.



Obrázek 3.4: Artefakt vyvolaný elektrodou F3

## 2. Rušení z elektrorozvodné sítě (50 Hz)

Tento typ artefaktů lze velmi dobře eliminovat kvalitním uzemněním měřené osoby. Artefakt představuje přesně frekvenci střídavého napětí z napájení snímacího zařízení, tedy 50 Hz. Tento typ rušení lze z EEG záznamu snadno odstranit pomocí filtrace, například filtrem typu dolní propust.

## 3. Vliv prostředí

S ohledem na citlivost snímacího zařízení je nutné, aby osoba, na níž se měření provádí, byla maximálně v klidu a nebyla vyrušována okolními vlivy. Pohyb osob na pracovišti může způsobit vznik kapacitních či elektrostatických artefaktů v záznamu. Rušení vysokofrekvenčními signály

rytmus	fr. [Hz]	amp. [ $\mu$ V]	lokalizace	stav
delta ( $\delta$ )	0.3 - 3.5	100 - 150	difuzní	spánek
theta ( $\theta$ )	4.0 - 7.0	70 - 100	frontálně, centrálně	usínání
alfa ( $\alpha$ )	8.0 - 13.0	20 - 50	okcipitálně	relaxované bdění
beta ( $\beta$ )	14.0 - 30.0	5 - 10	frontálně	duševní aktivita
gama ( $\gamma$ )	38.0 - 40.0	3 - 5	centrálně, okcipitálně	volní pohyb, myšlení
mí ( $\mu$ )	8.0 - 10.0	20 - 50	centrálně	zvýšená pozornost

Tabulka 3.1: Přehled základních rytmů EEG

z rádia, televize či informačních systémů lze eliminovat například umístěním měřené osoby do faradayovy klece.

Z pohledu frekvencí lze rozdělit EEG signál do několika pásem (rytmů). Tyto rytmy se vzájemně liší amplitudou, lokalizací na povrchu lebky a vztahem k definovaným fyziologickým stavům.

Delta rytmus je vždy patologickým projevem v EEG dospělého bdělého člověka. Vlny delta se vyskytují hlavně v hlubokém spánku (non REM III,IV), ale i v transu a hypnóze.

Theta rytmus se u zdravých lidí objevuje v centrální, temporální (spánkové) a parietální (temenní) oblasti. Patologický stav indikují theta vlny, jestliže je jejich amplituda alespoň dvakrát vyšší než aktivita alfa REM fáze spánku.

Alfa rytmus je vlastností mozku, který je zdravý (při organické lézi se alfa mění nebo ztrácí). V bdělém stavu je maximum nad zadními oblastmi mozkových hemisfér a to v klidu (bez duševní činnosti) a při fyzické relaxaci. Alfa vlny jsou charakteristické pro stadium těsně před usnutím. Nejlépe je alfa aktivita vyjádřena při zavřených očích, tlumí se právě otevřením a duševní činností. Alfa rytmus je především aktivitou optického analyzátoru – lidé od narození slepí nemají vytvořenou alfa aktivitu.

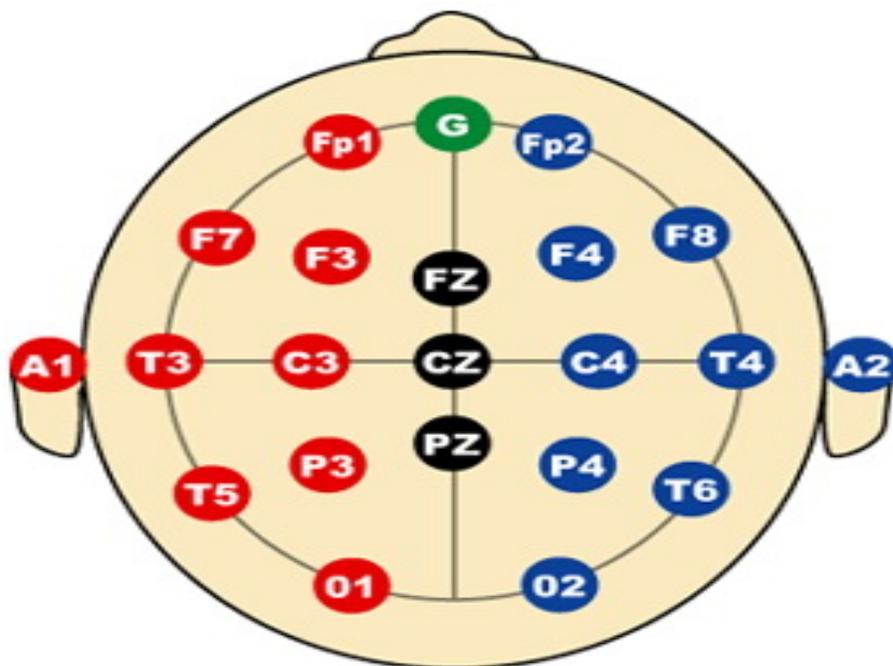
Beta rytmus je z hlediska lokalizace symetrický. Maximum je nejčastěji nad předními částmi lebky, hlavně frontálně. Směrem dozadu ubývá. Beta vlny jsou typické pro soustředění na vnější podněty, pro logicko-analytické myšlení, ale i pro pocity neklidu, hněvu a strachu. Obvykle se netlumí pozorností či zrakovým vjemem.

## 3.2 Snímání EEG signálu

### 3.2.1 Rozložení elektrod

V současné době je rozložení snímacích elektrod na skalpu standarizováno na základě systému navrženého J. Jasperem, jednotlivé systémy se od sebe odlišují zejména počtem elektrod, jejich rozmístění je dáno danými pravidly popsanými níže.

10-20 systém je mezinárodně uznávanou metodou popisující umístění elektrod na skalpu. Tato metoda byla vyvinuta pro zajištění reprodukovatelnosti tak, aby byla zajištěna opakovatelnost a reprodukovatelnost měření mezi subjekty nezávisle na čase. Tento systém je založen na vztahu mezi umístěním elektrod a základními oblastmi mozkové kůry. "10" a "20" se vztahují na skutečnosti, že skutečné vzdálenosti mezi sousedními elektrodami jsou buď 10% nebo 20% z celkové předozadní a pravo-levé vzdálenosti na lebce.



Obrázek 3.5: Rozložení elektrod v systému 10/20

Každý bod (umístění elektrody) je popsán tak, aby mohl být identifikován mozkový lalok (značeno písmenem) a hemisféra (číslo). Písmena F, T, C, P a O označují frontální, temporální, centrální, parietální a okcipitální laloky. Všimněme si, že neexistuje žádný centrální lalok, "C" popis slouží pouze k identifikačním účelům. "Z" (nula) odkazuje na elektrody umístěné na středové linii. Sudá čísla (2, 4, 6, 8) se vztahují k elektrodám na pravé hemisféře, zatímco lichá čísla (1, 3, 5, 7) se vztahují k těm na levé hemisféře.

Dva anatomické orientační body jsou použity pro základní polohování EEG elektrod: za prvé, nasion, který je bodem mezi čelem a nosem, za druhé inion, což je nejnižší bod lebky od zadní části hlavy, je indikován výstupkem na týlní kosti.

Při nahrávání podrobnějšího EEG s více elektrodami se další elektrody přidávají do mezer mezi stávající elektrody systému 10/20. Pro popis těchto nových elektrod byla vyvinuta tzv. modifikovaná kombinatorní nomenklatura, viz. například [15].

### **3.2.2 Režimy snímání**

#### **Unipolární režim**

Tento režim používá společnou referenční elektrodu, která je nejčastěji umístěna na ušním lalůčku, případně lze spojit oba ušní lalůčky dohromady. V tomto režimu lze získat vyšší úroveň EEG, umožňuje lépe pozorovat velikost a tvar vln, nicméně lokalizační výsledky mají větší chyby než u často používaného bipolárního režimu.

#### **Bipolární režim**

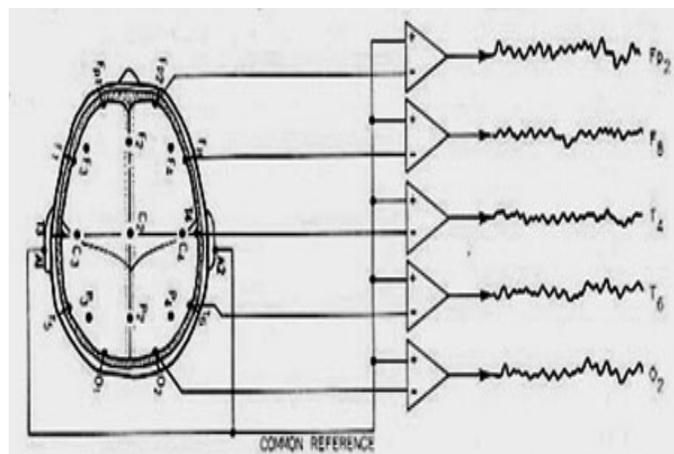
V tomto režimu se nepoužívá společná referenční elektroda, nýbrž se pro každou elektrodu použije signál z elektrody sousední jako referenční, pracujeme tedy s rozdílovými signály, viz. obr. 3.7.

#### **Zprůměrovaný režim**

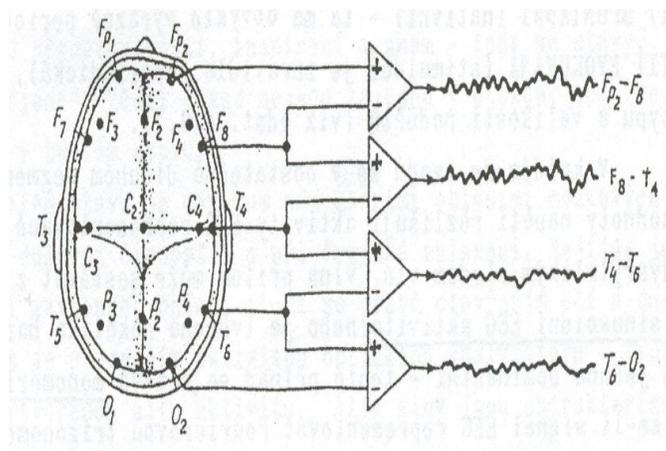
V tomto režimu se používá společná indiferentní elektroda, obvykle vytvořená v zapojení podle Goldmana.

Další systémy uvedeme heslovitě

- **Věncový bipolární režim**



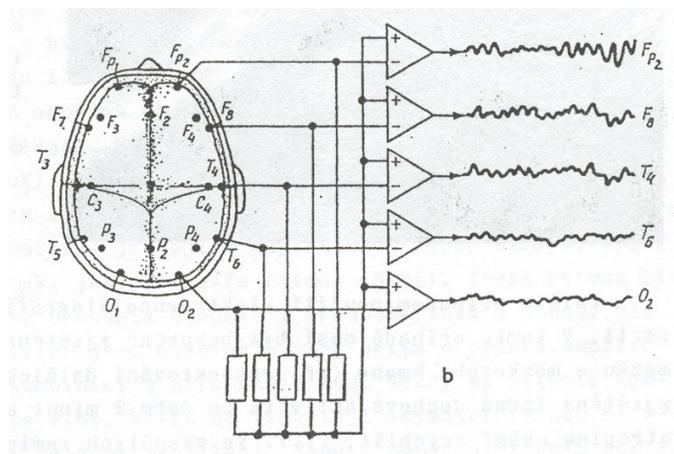
Obrázek 3.6: Unipolární zapojení elektrod



Obrázek 3.7: Bipolární zapojení elektrod

Zde jsou elektrody zapojeny v příčných řadách.

- **Uzavřený bipolární režim**  
Páry elektrod tvoří uzavřený kruh.
- **Referenční bipolární režim**  
Používá systém referenčních svodů.



Obrázek 3.8: Zprůměrované zapojení elektrod

- **Trojúhelníkový režim**

Jde o speciální variantu využívající tři párů bipolárních svodů.

### 3.3 Filtrace

V této části budou stručně popsány metody filtrace signálu, které byly použity při zpracování EEG. Níže uvedené metody byly zvoleny na základě rešerše dostupných publikací a jejich funkčnost a vhodnost pro danou aplikaci byla experimentálně ověřena na reálných datech.

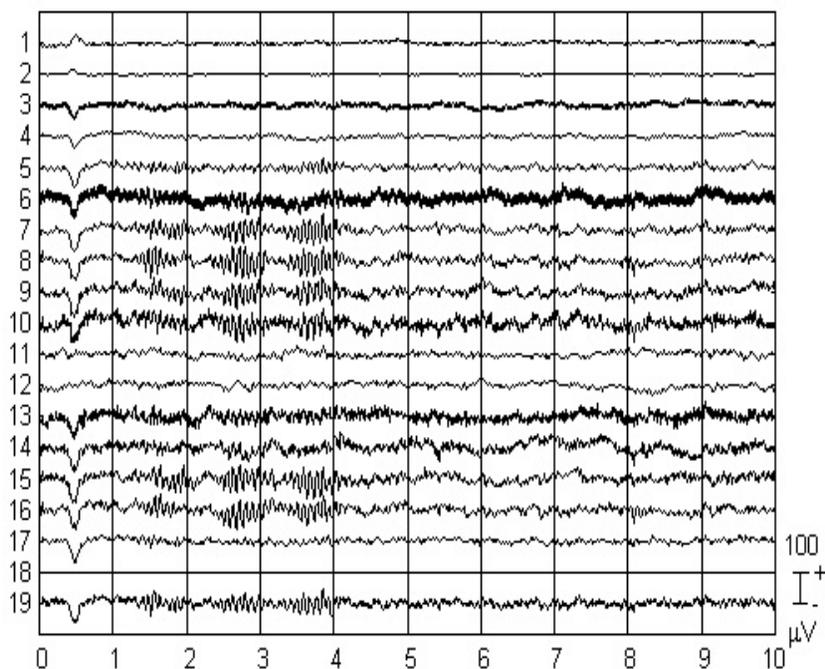
#### 3.3.1 Independent Component Analysis

Independent Component Analysis (ICA), analýza nezávislých komponent, patří ke skupině metod číslicového zpracování signálů, jejichž cílem je obnovení zdrojových signálů na základě znalosti signálu smíšeného.

Mějme skupinu realizací náhodných proměnných  $(x_1(t), x_2(t), \dots, x_n(t))$ , kde  $t$  je čas, případně číslo vzorku a předpokládejme, že tyto realizace jsou generovány jako lineární kompozice nezávislých proměnných:

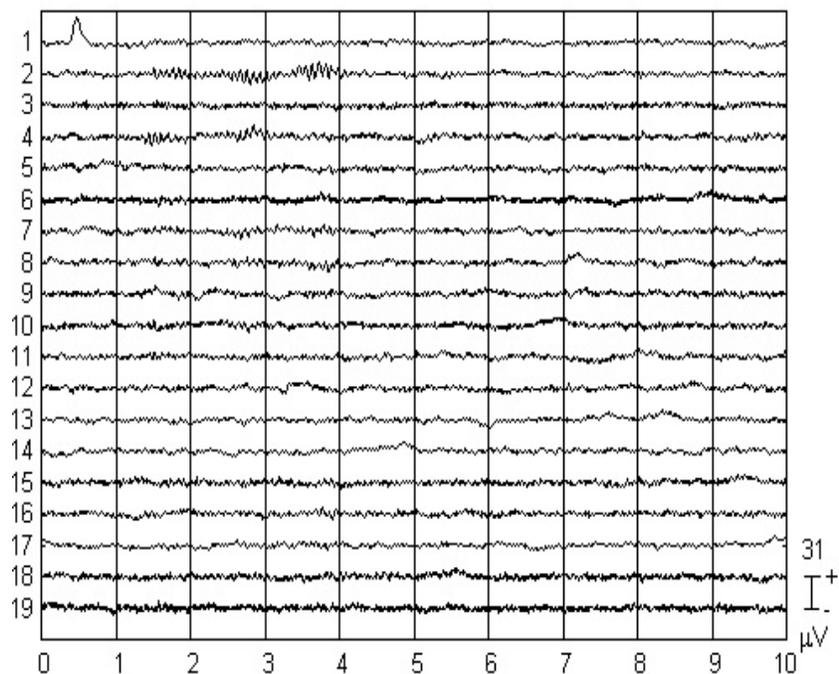
$$\begin{pmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_n(t) \end{pmatrix} = \mathbf{A} \begin{pmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_n(t) \end{pmatrix} \quad (3.1)$$

kde  $\mathbf{A}$  je neznámá matice. ICA spočívá v nalezení jak matice  $\mathbf{A}$ , tak signálů  $s_i(t)$  ze znalosti realizací  $x_i(t)$ . Pro zjednodušení předpokládejme, že počet nezávislých komponent  $s_i$  je stejný jako počet pozorovaných proměnných. Základní podmínkou pro ICA je nutnost, aby nezávislé komponenty  $s_i$  neměly normální (Gaussovské) rozložení.



Obrázek 3.9: Záznam EEG s artefakty

Při rekonstrukci původního signálu  $x_i$  lze vynechat komponenty  $s_n$  jenž považujeme za nežádoucí (artefakty, šum), čímž dosáhneme jejich odstranění bez zásahu do užitečné složky signálu.



Obrázek 3.10: Vypočtené komponenty, pro odstranění byly zvoleny komponenty č. 1, 2, 4

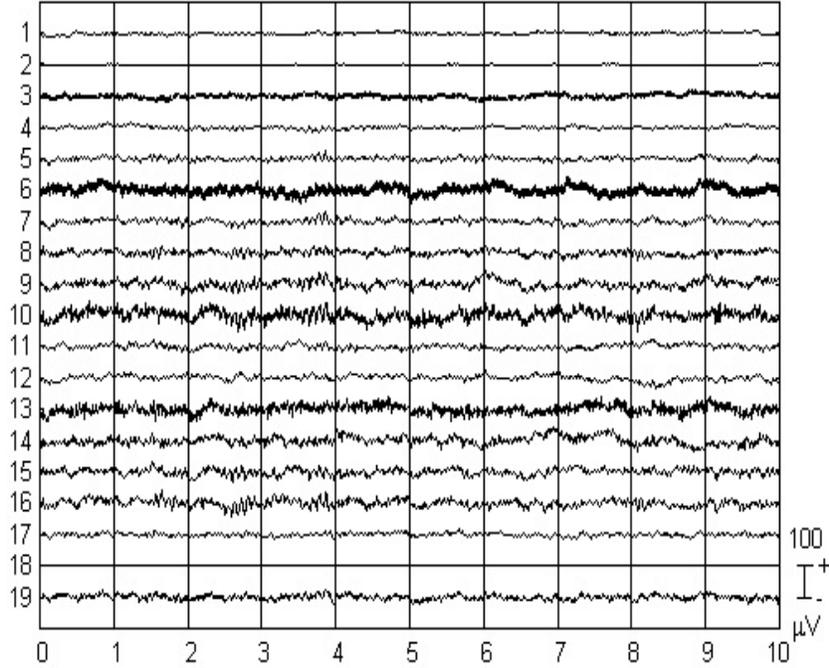
## 3.4 Extrakce parametrů

### 3.4.1 Volba parametrů

Analýzu signálů je možno provádět buďto v časové, nebo frekvenční oblasti. S ohledem na dosavadní výzkumy se pro analýzu EEG preferuje frekvenční oblast, která na rozdíl od časové umožňuje sledovat souběžně probíhající děje o různých frekvencích (viz. kapitola o frekvenčním rozdělení EEG signálu).

Jako první sada parametrů byly zvoleny amplitudy spektrálních čar v rozmezí 1 - 40 Hz s časovým rozlišením cca 200ms a spektrálním 1 Hz. Dané parametry byly určeny s ohledem na předchozí výzkumy [13] a ověřeny při ruční analýze signálů.

Jako druhá sada parametrů byly vypočteny derivace prvního řádu z dříve



Obrázek 3.11: Výsledný signál po odstranění zvolených komponent

získaných spektrogramů,

$$D(n) = D(n) - D(n + 1), n \in \langle 1, m - 1 \rangle, \quad (3.2)$$

kde  $m$  je délka spektrogramu.

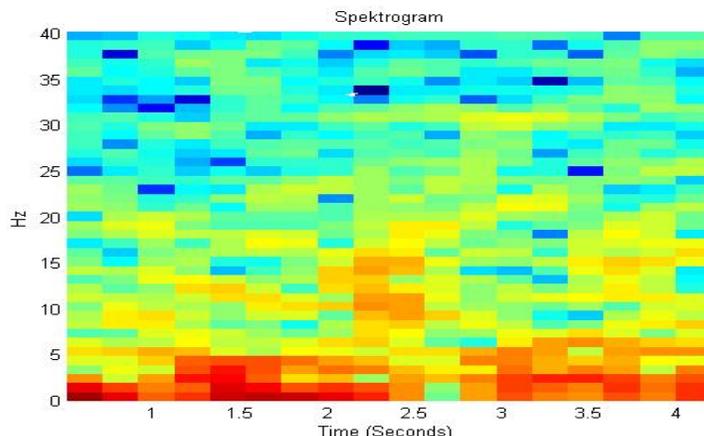
### 3.4.2 Výpočet parametrů

Parametry spektrogramu byly vypočteny pomocí funkce Matlabu *spectrogram*, kde výstupem je matice obsahující výkonovou spektrální hustotu (PSD) vstupních dat v definovaných úsecích. Každý bod PSD je definován jako

$$P(i, j) = k|S(i, j)|^2, \quad (3.3)$$

kde  $k$  je vektor

$$k = \frac{2}{Fs \sum_{n=1}^L |w(n)|^2} \quad (3.4)$$



Obrázek 3.12: Vypočtený spektrogram s frekvenčním rozlišením 1 Hz, časové rozlišení 200 ms

a  $S$  je matice obsahující body rychlé fourierovy transformace.

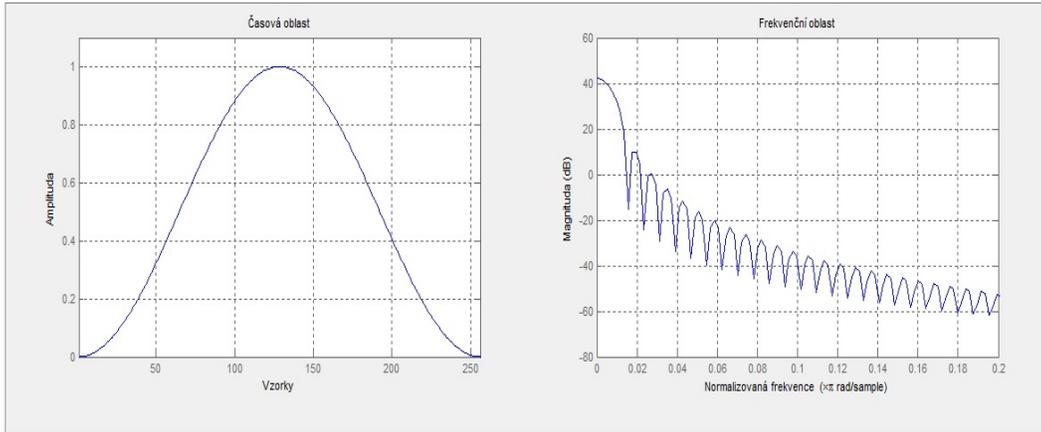
Pro výpočet spektrogramu o požadovaných parametrech (frekvenční a časové rozlišení) byly zvoleny následující parametry: Délka okna pro výpočet DFT byla zvolena jako nejbližší mocnina dvou vzorkovací frekvence, pro  $F_s = 250$  Hz je to 256 bodů. Jako váhovací okno bylo využito Hannovo okno

$$w(n) = 0.5 \left( 1 - \cos \left( 2\pi \frac{n}{N} \right) \right), 0 \leq n \leq N \quad (3.5)$$

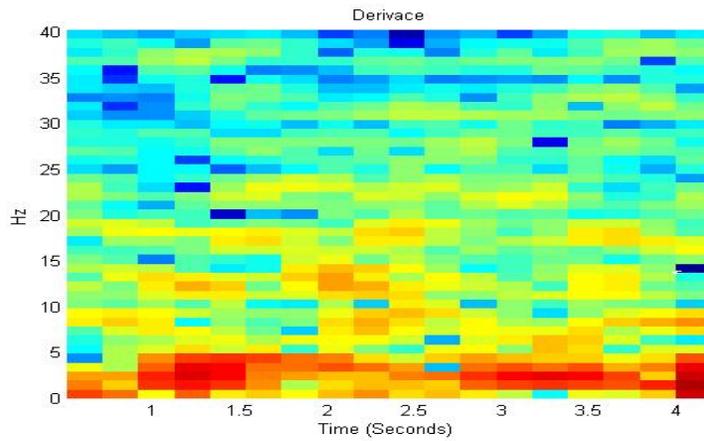
o identické délce, tzn. 256 bodů. Tímto způsobem získáme okno o délce cca 1 s. Pro získání časového rozlišení 200 ms je nutné, aby se okna z 80 % překrývala, parametr overlap určující překryv oken je tímto určen na 205 bodů.

Jak plyne z výše uvedeného vztahu pro derivaci, je zřejmé, že derivační parametry budou kratší o jeden bod, což při daném časovém rozlišení znamená zkrácení pozorovaného úseku o 200 ms. Aby mohla být data analyzována za pomoci všech vypočtených parametrů, bylo rozhodnuto vypustit i poslední bod spektrogramu.

Vzhledem k překryvu oken při výpočtu jednotlivých spektrogramů a faktu, že délka okna byla zvolena s ohledem na výše uvedené, nedojde k významné ztrátě dat, bude nevyužito jen posledních 200 ms záznamu.



Obrázek 3.13: Časová a frekvenční forma Hannova okna o délce 256 bodů



Obrázek 3.14: Derivace spektrogramu

# Kapitola 4

## Skryté Markovovy Modely

### 4.1 Struktura

#### Markovovy procesy

Nechť  $X(t) : t \geq 0$  je náhodný proces se spojitým časem a diskrétní množinou stavů  $I = \{0, 1, 2, \dots\}$ . Náhodný proces se nazývá *Markovův proces*, jestliže platí

$$\begin{aligned} P(X(t_{n+1}) = j | X(t_n) = i, X(t_{n-1}) = i_{n-1}, \dots, X(t_0) = i_0) = \\ = P(X(t_{n+1}) = j | X(t_n) = i) \end{aligned} \quad (4.1)$$

pro libovolné  $0 \leq t_0 \leq \dots \leq t_n \leq t_{n+1}$  a  $i_0, \dots, i_{n-1}, i, j \in I$ . Pravděpodobnosti typu (4.1) se nazývají *pravděpodobnosti přechodu*. Pokud nezávisejí na hodnotách  $t_n$  a  $t_{n+1}$ , ale pouze na jejich rozdílu, pak se jedná o *homogenní* Markovův proces a označujeme je

$$a_{ij}(t_{n+1} - t_n) = P(X(t_{n+1}) = j | X(t_n) = i). \quad (4.2)$$

Označuje-li  $t_n$  přítomný časový okamžik, pak podle Markovovské vlastnosti pravděpodobnostního chování Markovova procesu v libovolném budoucím okamžiku závisí pouze na přítomném čase a nezávisí na stavech minulých.

#### Markovovy řetězce

Jsou analogií Markovových procesů v diskrétním čase. Náhodná posloupnost  $\{X_n : n = 0, 1, \dots\}$  se nazývá *Markovův řetězec*, jestliže platí

$$P(X_{n+1} = j | X_n = i, X_{n-1} = i_{n-1}, \dots, X_0 = i_0) = P(X_{n+1} = j | X_n = i) \quad (4.3)$$

pro libovolná  $i_0, \dots, i_{n-1}, i, j \in I$ . Pokud pravděpodobnosti přechodu nezávisí na  $n$ , pak se Markovův řetězec nazývá homogenní a pravděpodobnosti přechodu se označují jako

$$a_{ij} = P(X_{n+1} = j | X_n = i). \quad (4.4)$$

Pravděpodobnosti přechodů vyšších řádů značíme

$$a_{ij}(k) = P(X_{n+k} = j | X_n = i) \quad k = 0, 1, \dots \quad (4.5)$$

Pravděpodobnosti přechodů je zvykem uspořádat do matice přechodů  $A = [a_{ij}]$  a  $A(k) = [a_{ij}(k)]$

Dále zavedeme tato značení:

- Pozorovaná sekvence  $\mathbf{O} = \{\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_n\}$ , kde  $\mathbf{o}_1, \mathbf{o}_2, \dots$  jsou pozorované znaky
- $N$  počet stavů modelu
- Funkce  $b_j(\mathbf{o})$ , které přísluší každému emitujícímu stavu  $j$ , tyto funkce jsou Gaussovská rozložení určená středy  $\mu$  a variacemi  $\mathbf{r}$  v prostoru.
- Pravděpodobnost počátečního stavu  $\pi_i = P(q_1 = i) \quad 1 \leq i \leq N$

### Skryté Markovovy modely

Skrytý Markovův model se skládá z matice přechodů  $A$  a z funkcí  $b_j(\mathbf{o})$ , které přísluší každému emitujícímu stavu  $j$ . Vytvoření modelu spočívá v určení matice  $A$  a parametrů funkcí  $b_j(\mathbf{o})$ . Výstupem modelu je matice  $\alpha$

$$\alpha_n^i = [\alpha_{n-1}^i * A * b_n] \quad (4.6)$$

kde

$$\alpha^i = [\alpha_1^i \quad \alpha_2^i \quad \dots \quad \alpha_N^i] \quad (4.7)$$

a

$$b_n = [b_1(\mathbf{o}_n) \quad b_2(\mathbf{o}_n) \quad \dots \quad b_N(\mathbf{o}_n)] \quad (4.8)$$

$N$  je počet stavů modelu a  $n$  délka  $\mathbf{O}$ ,  $\alpha_0$  zvolíme na základě znalosti počátečních podmínek  $\pi$ . Řádky matice  $\alpha$  obsahují pravděpodobnosti, s jakými daný pozorovaný znak  $\mathbf{o}$  přísluší do které třídy.

Část matice  $\alpha$  pro třístavový model:

řádky matice $\alpha$ / stavy	s1	s2	s3
$\alpha_1$	0,1	0,1	0,8
$\alpha_2$	0,08	0,12	0,8
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$\alpha_n$	0,7	0,22	0,08

Lze vyčíst, že například znak  $\mathbf{o}_2$ , kterému odpovídá druhý řádek matice, s 80% pravděpodobností náleží do třetí třídy, která odpovídá stavu  $s_3$ .

## 4.2 Implementace

Skryté Markovovy modely v HTK Toolboxu jsou definovány v prostém textovém souboru s určenou strukturou. Tato implementace umožňuje jejich snadnou změnu a přenositelnost mezi platformami, nicméně systém jako takový nedovoluje náhled do vnitřní funkce modelu na rozdíl od modelů v MATLABu.

HTK Toolbox také na rozdíl od MATLABu umožňuje definovat parametry<sup>1</sup>, které jsou vypočítány ze vstupních dat a použity při trénování modelu.

Dále bylo nutno přeformátovat použitá data tak, aby byla zpracovatelná v HTK Toolboxu.

---

<sup>1</sup>energie, spektrální hustota, delta parametry atd.

# Kapitola 5

## Experiment

### 5.1 Technické provedení

Pro potřeby snímání EEG a souvisejících signálů bylo použito zařízení BrainScope. Impuls pro změnu polohy prstu měřené osoby byl dáván opticky pomocí LED diody připojené do snímacího zařízení, informace o časech impulsů byly ukládány přímo v záznamu signálu jako události. Elektronický systém pro signalizaci vyvinul Ing. Jan Havlík, PhD. v rámci své disertační práce [11].

### 5.2 Měřicí soustava

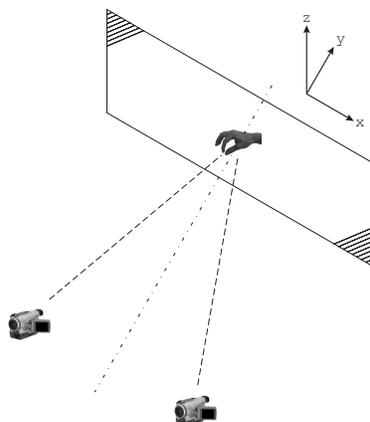
Data, na kterých je prováděna klasifikace, jsou záznamem pohybu palce ruky v prostoru. Tyto pohyby jsou snímány dvojicí běžně dostupných digitálních videokamer (DV). Tyto kamery jsou vzájemně umístěny tak, aby bylo možno z jejich záznamů rekonstruovat trojrozměrnou trajektorii pohybu. Na každém videozáznamu je nejdříve pomocí hranové detekce nalezen terčík, který slouží jako orientační značka. Střed tohoto terčíku je považován za polohu palce.

Měřená osoba je usazena do předem definované polohy s podepřenou hlavou. Poloha těla je důležitá z toho důvodu, aby bylo měření opakovatelné a v EEG záznamu bylo co nejméně rušivých signálů. Po nasazení EEG čepice se snímacími elektrodami je na palec pravé ruky nalepen terčík, jehož polohu budeme ve videozáznamu hledat. Ruka je podepřena, aby se palec při pohybu nedostal mimo zorné pole videokamer.



Obrázek 5.1: Uspořádání měřicího pracoviště

Celé měřicí pracoviště je na obrázku 5.1, poloha snímacích kamer na obrázku 5.2 . Snímání se provádí za takových světelných podmínek, které umožňují co nejsnazší zpracování videozáznamu.



Obrázek 5.2: Rozmístění videokamer

## 5.3 Metoda zpracování dat

Videozáznamy jsou zpracovávány offline, tzn. po pořízení jsou nahrány do počítače a vyhodnoceny. Cílem je nalézt trajektorii pohybu terčíku, který měla měřená osoba nalepen na palci.

Použitou metodu lze rozdělit do několika kroků.

- Předzpracování videozáznamu
- Výpočet těžiště
- Parametrizace pohybu

### 5.3.1 Předzpracování

Při předzpracování jsou barevné snímky převedeny na černobílé, které mají bílé pozadí - dochází k inverzi bílé na černou. Hledaný terčík tedy bude černý kruh s bílým mezikružím.

#### Hranová detekce

Celý obrázek je převeden na černobílý obrázek. Tím je zbaven nepodstatné barevné informace a je možno se soustředit na další zpracování, kterým

je hranová detekce terčíku. Pro hranovou detekci je použit Robertsův algoritmus, který je založen na dvourozměrné konvoluci obrázku  $f(i, j)$  s Robertsovými gradientními operátory  $h(m, n)$

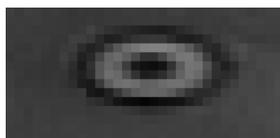
$$\mathbf{g}(i, j) = \sum_m \sum_n h(m, n) * f(i - m, j - n) \quad (5.1)$$

Robertsovy gradientní operátory pro konvoluční masku 2x2:

$$\mathbf{h1} = \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix} \quad \mathbf{h2} = \begin{pmatrix} 0 & 1 \\ -1 & 0 \end{pmatrix}$$

Použití těchto operátorů je výhodné, jelikož mimo diferenciaci provádějí i mírné vyhlazení obrázku.

V následujícím kroku je pro každý snímek spočtena mapa hustoty hran. V malém okně, např.  $15 \times 15$ , které je posouváno přes celý obrázek, jsou sečteny body náležející hranám. Tyto součty jsou uloženy do hustotní mapy. Z této mapy jsou určeno globální maximum. Souřadnice tohoto maxima jsou přepočteny na souřadnice v původním obrázku a z něj je vyříznuto okolí o velikosti  $30 \times 15$  pixelů. Výřez odpovídá části obrazu, kterou považujeme za terčík. Tuto získanou oblast dále separátně zpracováváme.

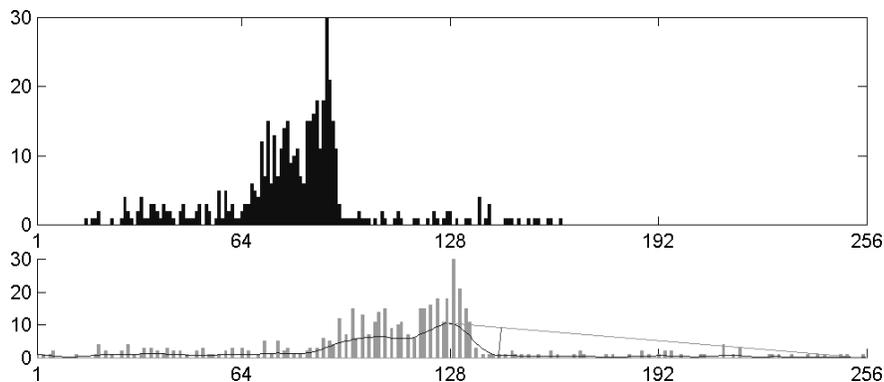


Obrázek 5.3: Výřez  $30 \times 15$  pixelů

### 5.3.2 Histogram a prahování

Nejprve je upraven dynamický rozsah histogramu vyříznuté oblasti jeho maximálním roztažením, při kterém ještě nedojde ke ztrátě informace.

V upraveném histogramu je zvolen práh a celý obraz převeden na dvě barvy, černou a bílou. Prah je určen pomocí trojúhelníkového algoritmu. Trojúhelníkový algoritmus je přesný a citlivý postup zvláště vhodný k prahování signálů, jejichž histogram neobsahuje výrazná maxima. Princip trojúhelníkového algoritmu je následující:



Obrázek 5.4: Histogram a filtrovaný histogram s vyznačeným trojúhelníkovým algoritmem

- spoj úsečkou maximum signálu s krajním bodem, který odpovídá nejsvětlejšímu bodu (nejsvětlejší šedé)
- najdi bod, ve kterém je úsečka nejvzdálenější obalu histogramu, neboli najdi bod, ve kterém je vzdálenost mezi úsečkou a signálem největší
- tento bod určí za práh (tato úroveň šedi je prahová)

Na histogram je nejprve aplikován FIR filtr klouzavých průměrů 9. řádu. Až na takto odfiltrovaný signál je použit trojúhelníkový algoritmus na určení prahové hodnoty, která je použita pro prahování výřezu. Takto je získán černobílý obraz.



Obrázek 5.5: Ukázka výřezu, na který bylo aplikováno prahování a obsahuje artefakt navíc

Prahaný obraz má bílé pozadí a jednu nebo více černých oblastí, ležící v místě bílého mezikruží. Ne všechny obrázky obsahují po prahování pouze jednu černou oblast. Proto je nutné přebytečné oblasti odstranit. Ze znalosti

tvaru a barevnosti hledaného terčíku lze určit následující podmínky, jejichž splnění je nutné, abychom mohli obrázek považovat za terčík:

- Víme, v jakém intervalu by se měl pohybovat počet černých pixelů v oblasti
- Víme, že oblast má být spojitě černé mezikružím, tedy těžiště černé oblasti musí být bílé.

S využitím těchto podmínek již dokážeme eliminovat oblasti, které nejsou terčíky. Dále je složen prahovaný obrázek ze separátně zpracovaných oblastí.



Obrázek 5.6: Ukázka prahovaného výřezu bez rušivých elementů

### 5.3.3 Hledání těžišť

Dalším krokem je nalezení těžišť černého mezikružím ve všech snímcích předzpracované videosekvence. Ve všech snímcích bude lokalizována černá oblast, všechny pixely v této oblasti opatřeny indexem a souřadnice všech černých pixelů z celé videosekvence budou uloženy do matice  $R_{ij}[n]$ , kde

$i \in \{1, 2\}$	souřadnice černého bodu ve snímku, {řádek, sloupec}
$j \in \{1, 2, \dots, J\}$	index pixelu ve spojitě oblasti { J ... počet pixelů ve spojitě oblasti }
$n \in \{1, 2, \dots, N\}$	index snímku ve videosekvenci { N ... počet snímku ve videosekvenci }

Následuje výpočet těžiště pomocí (5.2).

$$C_i = \frac{\sum_{j=1}^J R_{ij}[n]}{J} \quad (5.2)$$

Převedení posloupnosti matic na jednu matici podle vztahu:

$$C_{in} = C_i[n]. \quad (5.3)$$

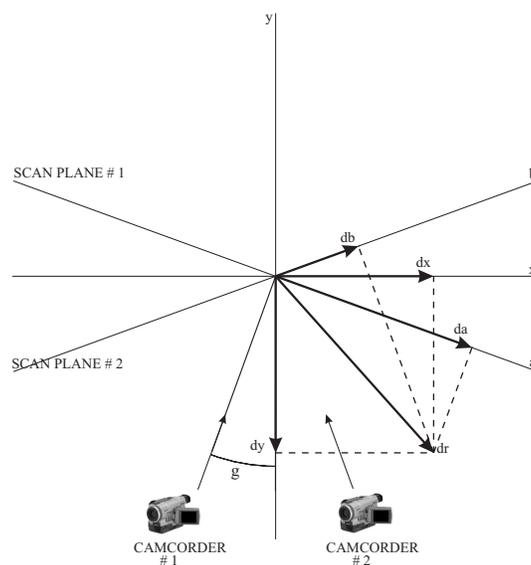
Touto úpravou byla získána matice obsahující všechny polohy palce v celém záznamu. Aplikací výše uvedeného postupu na oba videozáznamy jsou získány dva lineárně nezávislé popisy pohybu palce ve dvojrozměrném prostoru. Pomocí trojrozměrné parametrizace lze z těchto dvou popisů získat trojrozměrnou trajektorii pohybu palce.

### 5.3.4 3D parametrizace

Vstupem jsou dvě matice souřadnic popisující polohu terčičku z různých směrů.

Souřadnice z první kamery jsou označeny  $az$  a z druhé kamery  $bz$ . Cílem 3D parametrizace je spočítat souřadnice  $[x,y,z]$  polohy značky, potažmo tedy palce, v trojrozměrném prostoru.

Mějme vektor  $\mathbf{dr}$ , který reprezentuje pohyb značky mezi dvěma po sobě následujícími snímky. Potom tomu odpovídající pohyb zaznamenaný první kamerou je  $\mathbf{da}$  a druhou  $\mathbf{db}$ , viz obrázek 5.7.



Obrázek 5.7: Soustava prst - kamery

Velikost vektorů  $\mathbf{dx}$  a  $\mathbf{dy}$  lze spočítat jako průměty vektoru  $\mathbf{dr}$  na osy  $x$  a  $y$ , jak je naznačeno na obrázku 5.7. Matematický zápis průmětů je následující:

$$dy = \tan\left(\frac{\pi}{2} + \gamma\right)dx - \frac{da}{\sin \gamma} \quad (5.4)$$

$$dy = \tan\left(\frac{\pi}{2} - \gamma\right)dx + \frac{db}{\sin \gamma} \quad (5.5)$$

Přepisem rovnic 5.4 a 5.5 je ekvivalentní zápis

$$\tan\left(\frac{\pi}{2} + \gamma\right)dx - \frac{da}{\sin \gamma} = \tan\left(\frac{\pi}{2} - \gamma\right)dx + \frac{db}{\sin \gamma} \quad (5.6)$$

Výsledkem úpravy 5.6 je rovnice pro výpočet velikosti  $dx$

$$dx = \frac{1}{2} \frac{da + db}{\cos \gamma} \quad (5.7)$$

Po dosazení 5.7 do rovnic 5.4 a 5.5 a úpravách je získán vztah pro výpočet velikosti  $dy$

$$dy = -\frac{1}{2} \frac{da - db}{\sin \gamma} \quad (5.8)$$

Velikost vektoru  $\mathbf{dz}$  je shodná s projekcí osy  $z$  vektorů  $\mathbf{da}$  a  $\mathbf{db}$  a lze ji spočítat například jako průměr

$$dz = \frac{z_{\mathbf{da}} + z_{\mathbf{db}}}{2} \quad (5.9)$$

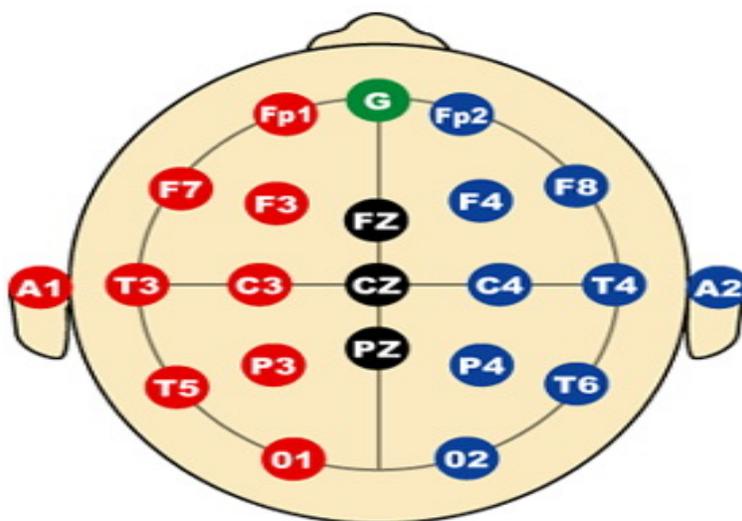
Výsledky rovnic 5.7, 5.8, 5.9 po zapsání jako souřadnice  $[x, y, z]$  představují popis pohybu značky v prostoru.

Tyto souřadnice jsou uloženy do matice  $C_i[n]$ , kde  $i \in \{1, 2, 3\}$  odpovídají souřadnicím  $x, y, z$  a  $n$  odpovídá číslu snímku ve videosekvenci.

## 5.4 Předzpracování dat

Nasnímaná data (EEG signály) je třeba upravit tak, aby byly odstraněny nežádoucí artefakty a ponecháno maximum užitečného signálu. Podrobný popis nejčastěji se vyskytujících artefaktů byl uveden v předchozí části práce, zde se zaměříme na konkrétní realizaci způsobu jejich odstranění a výběr relevantních dat. Pro zpracování dat byl použit EEGLab v11.0.0.0b.

S ohledem na to, že u měřených subjektů byly snímány pohyby levé nebo pravé ruky, byl prvním krokem výběr vhodných svodů EEG. Senzomotorická oblast mozku se nachází v místech, kde jsou lokalizovány elektrody C3 pro pohyby realizované pravou polovinou těla, resp. C4 pro levou polovinu těla.



Obrázek 5.8: Lokalizace elektrod C3 a C4 v systému 10/20

Dalším krokem byla ruční inspekce dat sloužící k odebrání úseků, jenž jsou pro analýzu nepoužitelné, resp. obsahují příliš mnoho rušivých artefaktů způsobených např. pohyby měřené osoby a úseky na začátku měření a konci měření.

Vybrané úseky byly označeny a po segmentaci signálu byly segmenty obsahující předmětné úseky odstraněny z dalšího zpracování.

## 5.5 Filtrace

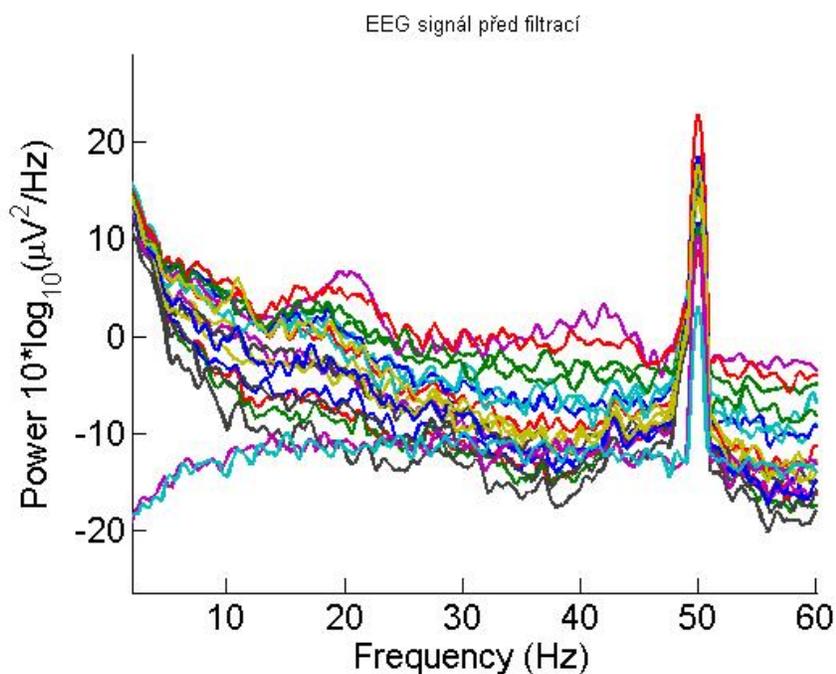
Účelem filtrace dat je odstranění rušivých artefaktů a nepotřebných složek signálu. Použitý postup byl následující:

1. Odstranění síťového rušení 50 Hz
2. Omezení frekvenčního pásma

3. Odstranění kolísání izolinie
4. Dekompozice signálu pomocí ICA

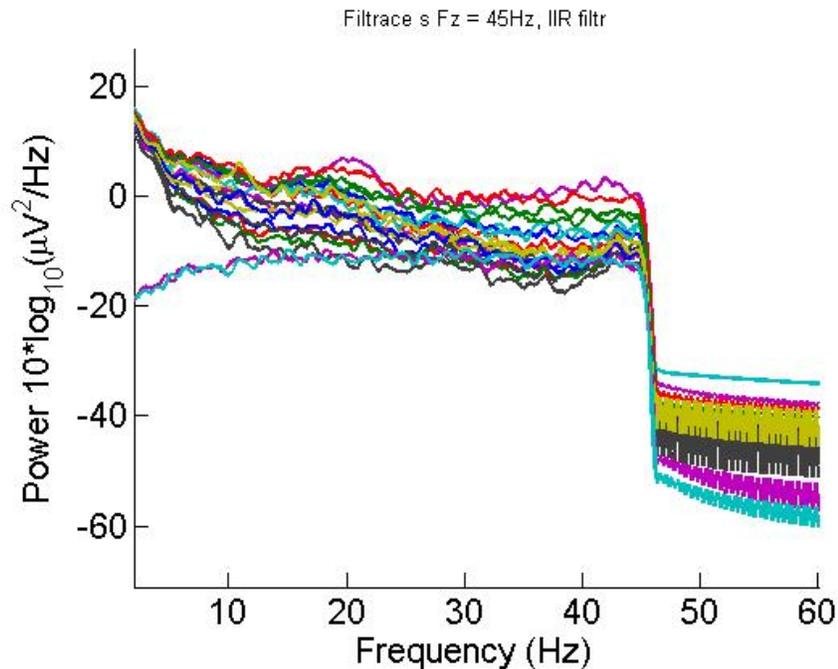
### 5.5.1 Odstranění síťového rušení 50 Hz

Síťové rušení v signálu lze odstranit filtrem typu dolní propust se zlomovou frekvencí nižší než 50Hz. Pro filtraci byl použit IIR filtr z EE-GLABu. Podívejme se na energii ve spektru původního signálu. Je jasně viditelný nárůst energie při frekvenci 50Hz, odpovídající pronikajícímu síťovému rušení.



Obrázek 5.9: Energie ve spektru nefiltrovaného signálu

S ohledem na výše uvedené byly parametry filtru nastaveny tak, že zlomová frekvence byla stanovena na 45 Hz. Tímto způsobem dojde k úplnému odstranění síťového rušení a zároveň není narušeno spektrum užitečného signálu, viz. obr. 5.10.



Obrázek 5.10: Energie ve spektru po filtraci IIR filtrem s Fz = 45Hz

### 5.5.2 Omezení frekvenčního pásma

Vzhledem k tomu, že tato práce je zaměřena na klasifikaci volných pohybů, lze predikovat, že relevantní frekvenční pásmo se bude nacházet v okolí  $\beta$  a  $\gamma$  rytmů EEG. S ohledem na současný stav znalostí dané problematiky a výsledky výzkumů bylo zvoleno frekvenční pásmo 5 - 40 Hz. V tomto frekvenčním pásmu se nacházejí události související s volným pohybem, zejména Event Related Synchronization ERS, a Event Related Desynchronization ERD.

### 5.5.3 Odstranění kolísání izolinie

V průběhu snímání, zejména u dlouhodobějších záznamů, může docházet a také dochází ke kolísání izolinie signálu. Tento artefakt lze odstranit průměrováním signálu. V této práci byla použita funkce Remove baseline z EEGLABu, která provede odečet průměrné hodnoty signálu.

### 5.5.4 Dekompozice signálu pomocí ICA

Pro každou sadu dat byla provedena jejich dekompozice pomocí funkce Run ICA v EEGLABu. Po dekompozici byly komponenty ručně analyzovány a vybrány ty, které reprezentovaly rušivé artefakty signálu, jako je mrkání či s měřením nesouvisející pohyby měřené osoby. Při trénování modelů byla použita jak data s odstraněnými komponentami, tzn. ručně očištěná, tak data, u kterých byla provedena pouze automatická filtrace podle předchozích odstavců.

## 5.6 Segmentace

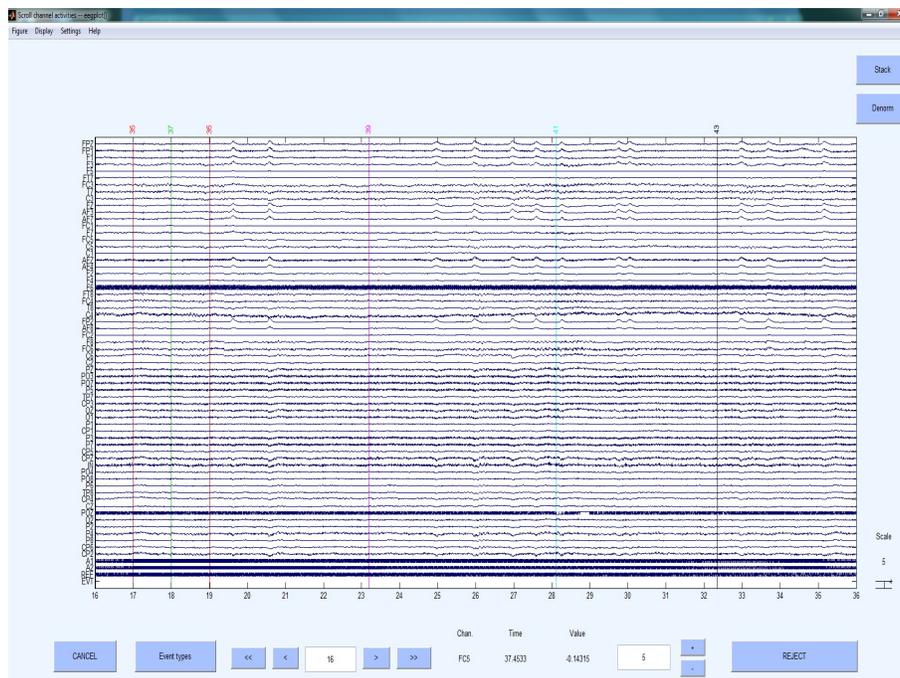
Záznam EEG obsahuje časové značky (viz. obr. 5.11), pomocí kterých jsou určeny začátky pohybů. Tyto značky jsou generovány v pseudonáhodném intervalu 5 sekund  $\pm 1$  s. Pseudonáhodný interval byl zvolen proto, aby měřený subjekt po čase nesklouzl k automatickému provádění pohybů bez ohledu na to, zda přišel signál k provedení tohoto pohybu. Měřená osoba sleduje obrazovku PC, na které se zobrazí pokyn k provedení pohybu, ve stejnou chvíli je do EEG záznamu vložena časová značka a do zvláštního souboru uložen čas od začátku měření, ve kterém byla značka vygenerována. Směr pohybu není indikován, záleží na měřené osobě jaký pohyb provede (v kontextu předem dohodnutých parametrů). Počátek měření je identifikován pomocí tří značek označených 35, 37, 35<sup>1</sup>, následujících po sobě v jednovteřinových intervalech, od třetí značky se začíná měřit čas.

Záznam je rozdělen na segmenty tak, že úsek začíná 2 s před značkou a končí 3 s po značce, tzn. délka segmentu je 5 s, viz. obr. 5.12. Vzhledem k tomu, že vzdálenost mezi značkami může být menší než 5 s může dojít k překryvu mezi jednotlivými segmenty. Nicméně tato skutečnost nemá vliv na vyhodnocení, neboť překryv je maximálně 1 s a obsahuje pouze klidové EEG.

Jednotlivé segmenty jsou označeny jako epochy v EEGLABu a uloženy pro další zpracování.

---

<sup>1</sup>Značky slouží pouze pro orientaci v záznamu, jejich číselná hodnota je irelevantní, byla zvolena s ohledem na technické omezení snímacího zařízení. Pro orientaci slouží pouze časové umístění značek v záznamu.



Obrázek 5.11: Identifikační značky v signálu EEG

## 5.7 Klasifikace dat

Veškerá data jsou po nasnímání předzpracována a filtrována viz předchozí kapitoly. Poté následuje extrakce a selekce vhodných příznaků. V tento okamžik přichází na řadu ruční označení zbylých dat tak, aby je bylo možno použít pro trénování modelů a kontrolu jejich funkčnosti.

### 5.7.1 Klasifikační třídy

Snímaný pohyb probíhá mezi třemi definovanými koncovými stavy. Tyto stavy a přechody mezi nimi byly číselně označeny z důvodu jejich jednoznačné identifikace. Mohou nastat následující možnosti - buď dojde k pohybu prstu mezi stacionárními stavy, nebo setrvání prstu v současném stavu.

Pro jednoznačnou identifikaci bylo využito následující značení:  $sXY$  kde  $s$  je obecný identifikátor označující stav,  $X$  označuje výchozí stav,  $Y$  konečný stav. Pohyb mezi stavy 1 a 2 označíme  $s12$ , ostatní analogicky. Základní



Obrázek 5.12: Rozdělení na segmenty

stacionární stavy, mezi kterými se pohybujeme jsou definovány následovně:

- s1 Palec je rovnoběžně s ostatními prsty ruky, v rovině dlaně.
- s2 Palec je v jedné rovině s ukazováčkem, ukazuje směrem dolů, kolmo k dlani.
- s3 Palec je v jedné rovině s dlaní, kolmo k ukazováčku.

### 5.7.2 Ruční klasifikace

Veškeré úseky dat určené k dalšímu zpracování (tzn. trénování modelů a ověřování jejich funkčnosti) byly ručně označeny příznakem odpovídajícím pohybu v daném úseku. Výstupem klasifikace jsou jednak označené úseky v souboru dat pro matlab, jednak textový soubor pro HTK Toolbox ve formátu *ZKS*, kde

*Z* označuje čas, ve kterém daný úsek začíná,

$K$  označuje čas, ve kterém daný úsek končí,

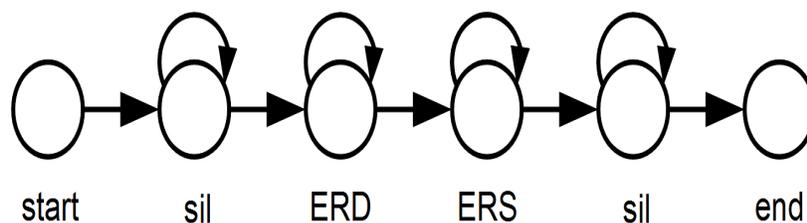
$S$  označuje druh pohybu v daném úseku.

## 5.8 Modely

### 5.8.1 Topologie

Z hlediska topologie byl zvolen levo-pravý model. Tato topologie je vhodná vzhledem k charakteru vstupního signálu. Jak je známo, při volných pohybech dochází v EEG signálu k předvídatelným jevům v určeném pořadí, tímto máme na mysli ERD a ERS fáze, kterým předchází, resp. následuje klidový stav.

Vzhledem k fyziologické podstatě těchto jevů nelze předpokládat, že by došlo ke změně v jejich časové souslednosti, proto model neobsahuje zpětné kroky. Analogicky nelze předpokládat, že by došlo k vynechání některého z uvedených jevů, proto jsou přeskoky vpřed ob jeden nebo více stavů vynechány. Topologie základního modelu je uvedena na obrázku 5.13.



Obrázek 5.13: Topologie základního modelu

Každý ze stavů  $sXY$  je popsán jedním modelem s výše uvedenou topologií, pro kompletní klasifikaci je tedy třeba 9 modelů ( $s11, s12, \dots$ ).

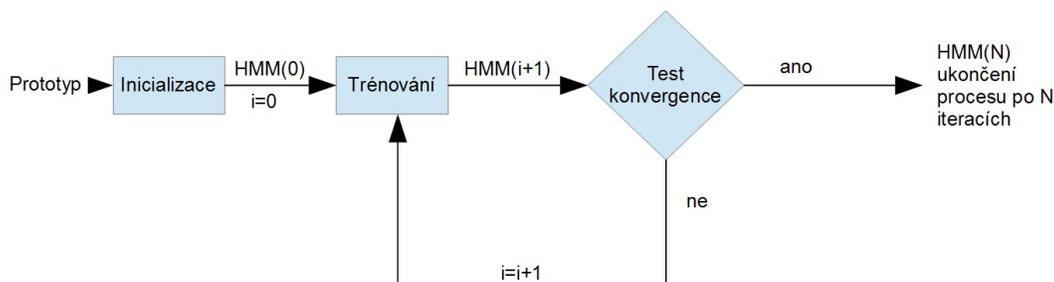
### 5.8.2 Specifika implementace

Obecně, pro použití HTK Toolboxu jako klasifikátoru je nutné provést následující kroky:

1. Vytvoření trénovací databáze obsahující dostatečný počet realizací každého jevu, který chceme klasifikovat. Všechny jevy musí být v databázi označeny. Způsob značení byl popsán v předcházející kapitole.
2. Výpočet parametrů ze vstupních dat vhodných pro klasifikaci, pokud to charakter vstupních dat vyžaduje<sup>2</sup>.
3. Definice modelů - jejich topologie, počet vstupních proměnných podle charakteru dat.
4. Trénování modelů pomocí dříve ručně označených trénovacích dat.
5. Výběr jevů - jaké jevy mají být rozpoznány ve vstupních neznámých datech.
6. Rozpoznání neznámých dat.
7. Vyhodnocení úspěšnosti klasifikátoru.

### 5.8.3 Trénování

Podívejme se blíže na to, jak vypadá proces trénování modelu v HTK Toolboxu.



Obrázek 5.14: Proces trénování modelu

Jako první je nutno vytvořit prázdný model, který bude vstupem pro následně použité estimativní algoritmy. V tomto prázdném modelu musí být definována topologie pomocí matice přechodů  $A$  a základní parametry

<sup>2</sup>Například převod z časové do frekvenční oblasti

každého emitujícího<sup>3</sup> stavu jimiž jsou v případě, že uvažujeme Gaussovské rozdělení pozorovaných dat, střední hodnota (*Mean*) a rozptyl (*Variance*). Pro účely inicializace je vhodné zvolit střední hodnotu nulovou a rozptyl jednotkový [54].

Pro prvotní inicializaci byl použit nástroj HInit. Tento nástroj pomocí Viterbiho algoritmu a ručně označených vstupních dat nastaví počáteční parametry modelu. Nulové prvky matice  $A$  zůstanou nulovými<sup>4</sup>, ostatní jsou nastaveny podle charakteru trénovacích dat.

V dalším kroku proběhne iterativní zpřesnění parametrů modelu pomocí opakovaného použití nástroje HRest. HRest provádí přepočítání modelu podle Baum-Welchova reestimačního algoritmu. Při každé iteraci je vypočtena míra změny mezi novým a původním modelem, jakmile je tato změna limitně blízká nule, můžeme prohlásit, že modely jsou již dostatečně natrénovány.

Tímto způsobem jsou postupně trénovány všechny modely.

#### 5.8.4 Definice úlohy

HTKToolbox je primárně určen pro zpracování a klasifikaci řečových záznamů. Z tohoto důvodu jsou zde jistá specifika co se týče obecného použití pro zpracování jiných signálů. Aby mohla být provedna klasifikace je nutné systému sdělit, jaké jevy a v jakých sekvencích jsou hledány. Při zpracování řeči se jedná o slovník (seznam jevů) a gramatiku (v jakém pořadí a četnosti se jevy mohou vyskytovat).

Mějme seznam jevů  $s_{11}, s_{12}, s_{13}, \dots, s_{33}$ , které tvoří slovník. Vzhledem k tomu, že pohyby mohou probíhat libovolně na vůli měřené osoby je pozorovaná sekvence (v řeči by šlo například větu) náhodnou posloupností výše uvedených jevů o délce  $n$ .

Definice gramatiky je uvedena v tabulce 5.1. STAV může nabývat hodnot  $s_{11}$  až  $s_{33}$ , závorky  $\{ \}$  označují nula nebo více výskytů STAVu.

Analogicky je třeba definovat slovník, který určuje, kterému stavu odpovídá který model.

Jak je vidět v tabulce 5.2, názvy modelů byly zvoleny analogicky k názvům jednotlivých jevů, resp STAVů.

Výše vytvořenou gramatiku a slovník je třeba nástrojem HParse přetvořit v síť modelů, která bude použita při samotné klasifikaci.

---

<sup>3</sup>Emitujícím stavem rozumíme stav, který není počátečním ani koncovým stavem.

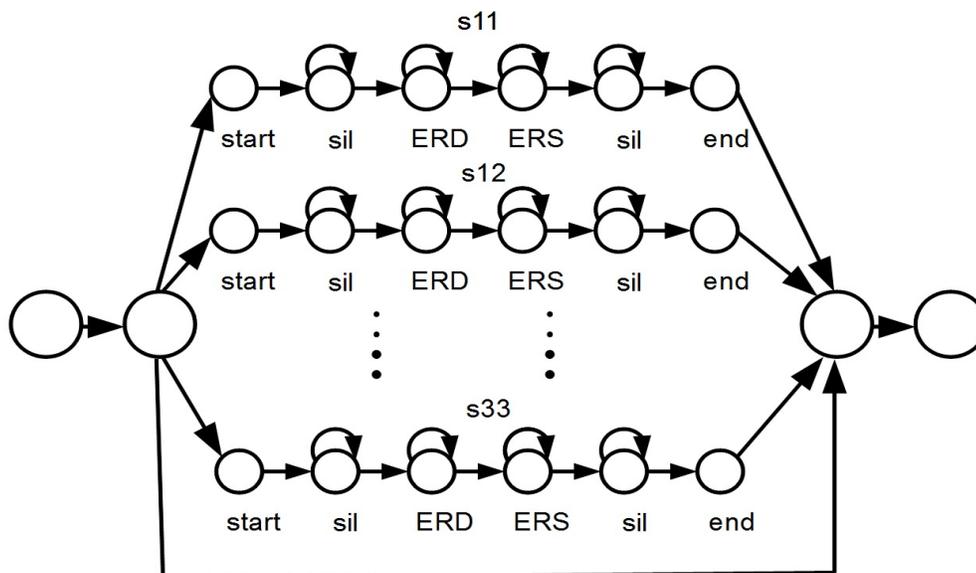
<sup>4</sup>Topologie modelu se nezmění.

$\$STAV = s11 \mid s12 \mid s13 \mid s21 \mid s22 \mid s23 \mid s31 \mid s32 \mid s33$ $( \{ \$STAV \} )$
--

Tabulka 5.1: Definice gramatiky

s11	s11
s12	s12
s13	s13
s21	s21
s22	s22
s23	s23
s31	s31
s32	s32
s33	s33

Tabulka 5.2: Definice slovníku, vlevo název STAVu, vpravo název jevu



Obrázek 5.15: Vytvořený klasifikátor = síť + slovník + HMM

## 5.9 Klasifikace pomocí modelů

### 5.9.1 Soubor dat a metriky

Mějme k dispozici následující soubor dat (viz. tabulka 5.3), jak vidíme, byly měřeny tři subjekty<sup>5</sup>, u subjektů číslo jedna a dvě byly snímány pohyby pravé ruky, u subjektu číslo tři pouze pohyb pravé ruky, u subjektu číslo dvě postupně pohyby obou rukou. Označme si tyto subjekty jako O1, O2, O2L a O3L.

Záznamy byly pořizovány v tiché částečně zatemněné místnosti aby byly maximálně eliminovány vnější rušivé vlivy, každý záznam trval 20 min, což odpovídá cca 100 pohybům. Po snímání následovala půlhodinová pauza a další snímání. Vzhledem k náročnosti měření byl daný subjekt během jednoho dne měřen nejvýše dvakrát.

Pro vyhodnocení kvality klasifikace použijeme následující parametry:

<sup>5</sup>Muži ve věku 26-36 let, praváci, mimo číslo dvě, který je levák.

Měřený subjekt	Pohyb	Realizací
1/2/2L/3L	s11	10/2/2/1
1/2/2L/3L	s12	130/38/41/31
1/2/2L/3L	s13	110/24/35/27
1/2/2L/3L	s21	105/20/30/20
1/2/2L/3L	s22	22/4/1/1
1/2/2L/3L	s23	104/40/35/26
1/2/2L/3L	s31	110/43/22/12
1/2/2L/3L	s32	102/22/22/12
1/2/2L/3L	s33	9/4/2/1

Tabulka 5.3: Databáze použitá pro trénování a testování modelů

$$Correct = \frac{H}{N} \times 100[\%] \quad (5.10)$$

a

$$Accuracy = \frac{H - I}{N} \times 100[\%], \quad (5.11)$$

kde  $H$  je počet správně klasifikovaných jevů,  $N$  celkový počet jevů a  $I$  počet jevů vložených. Tyto metriky umožňují pouze pohled na celkový stav klasifikace pro daný datový soubor, pro podrobný pohled na výsledky uvedeme i kompletní matici, kde jsou zřetelné výsledky pro jednotlivé jevy. Sloupec Del uvádí počet neklasifikovaných (přeskočených) jevů, řádek Ins naproti tomu uvádí počet jevů chybně vložených.

Parametry % c a % e reprezentují procentuální přesnost klasifikace přes celý řádek, respektive procentuální nepřesnost klasifikace v řádku vztáženou k celkovému počtu klasifikovaných jevů.

Vzhledem k objemu dat byla pro trénování a kontrolu kvality klasifikátorů zvolena následující metoda:

- Rozdělení dat podle subjektů, resp. měřených rukou. Tímto způsobem získáme čtyři soubory dat.
- Každý soubor je náhodně rozdělen na dvě stejně velké disjunktní množiny, z nichž jedna slouží jako trénovací a druhá jako testovací.

	O1	O2	O2L	O3L
O1	<10%	<10%	<10%	<10%
O2	<10%	62%	33%	55%
O2L	<10%	25%	75%	55%
O3L	<10%	50%	38%	77%

Tabulka 5.4: Výsledky klasifikace, metrika *Correct*

	O1	O2	O2L	O3L
O1	<10%	<10%	<10%	<10%
O2	<10%	-8%	30%	-55%
O2L	<10%	25%	57%	32%
O3L	<10%	32%	31%	50%

Tabulka 5.5: Výsledky klasifikace, metrika *Accuracy*

Toto rozdělení je provedeno desetkrát<sup>6</sup>, pro každé rozdělení jsou klasifikátory natrénovány a otestovány. Uvedeny jsou průměrné výsledky.

- Testování interpersonální klasifikace. Z klasifikátorů uvedených v předchozím bodě je pro každý soubor dat vybrán náhodně jeden klasifikátor, který je použit pro klasifikaci souboru dat získaných od jiného subjektu. V této části očekáváme ověření míry interpersonální variability v závislosti na typu pohybu (jednoduchá extenze, flexe versus složitější pohyby).

## 5.9.2 Výsledky klasifikace

Podívejme se na souhrnné výsledky klasifikace představené v níže uvedených tabulkách 5.4 a 5.5.

Řádky tabulky odpovídají trénovacím souborům, sloupce testovacím.

Klasifikace zcela selhala u osoby O1, získaná data byla snímána v roce 2004, kdy byl celý experiment v počátcích a hledalo se vhodné uspořádání systému. V tomto případě byl nevhodně zvolen interval mezi jednotlivými pohyby, a to na 2 s. Takto krátký interval neumožňuje data klasifikovat

<sup>6</sup>Pro získání dostatečného počtu výsledků pro statistické zpracování.

	s12	s13	s21	s23	s31	s32	s11	s22	s33	Del	% c	% e
s12	24	0	0	0	0	0	0	0	0	0	-	-
s13	4	26	0	3	3	0	0	0	0	2	72.5	5.2
s21	2	0	18	3	4	0	0	0	0	1	66.7	4.7
s23	0	0	0	25	0	0	0	0	0	3	-	-
s31	0	0	1	0	32	0	0	0	0	1	97.0	0.5
s32	6	0	0	1	4	19	0	0	0	2	63.3	5.7
s11	0	0	0	0	1	0	1	0	0	0	50.0	0.5
s22	0	0	0	0	0	0	0	2	0	2	-	-
s33	1	0	0	0	0	0	0	0	1	0	50.0	0.5
Ins	18	2	0	13	7	3	0	0	0			

Tabulka 5.6: Výsledky klasifikace pro osobu O2, trénovací i testovací data stejná osoba.

pomocí vytvořených klasifikátorů, které vyžadují pro svou činnost nejméně 4 s interval mezi jednotlivými pohyby, jinak dochází k překrývání událostí týkajících se sousedních jevů. Do hodnocení výsledků nejsou zahrnuty jevy s11, s22 a s33 neb jde o stacionární stavy, jež nejsou z hlediska klasifikace důležité - nejde o pohyby, nýbrž o setrvání v dané poloze.

HTK Toolbox dovoluje i konstrukci sofistikovanějších klasifikátorů, než výše představený typ, jež je v podstatě rozpoznávačem jednotlivých jevů bez jakéhokoliv kontextu.

Pokud známe závislost mezi jednotlivými jevy, například co se týče jejich výskytu v návaznosti na jiné jevy, jsme schopni tyto závislosti do klasifikátoru zapracovat. V tomto případě byla využita metoda bigramového modelování. Podstatu této metody lze vyjádřit následujícím vztahem:

$$p(i, j) = \begin{cases} N(i, j) - D / N(i) & \text{if } N(i, j) \leq t \\ b(i)p(j) & \text{jinak} \end{cases}, \quad (5.12)$$

kde  $N(i, j)$  je četnost výskytu jevu  $j$  po jevu  $i$  a  $N(i)$  je počet výskytů jevu  $i$ . Část pravděpodobnosti výskytu frekventovaných bigramů<sup>7</sup> je distribuována mezi méně četné bigramy. Tento proces se nazývá *discounting* a jeho míra je určena konstantou  $D$ , která je ve výchozím nastavení modelů rovna 0,5.

<sup>7</sup>Dvou po sobě následujících jevů.

	O1	O2	O2L	O3L
O1	<10%	<10%	<10%	<10%
O2	<10%	81%	35%	61%
O2L	<10%	63%	75%	55%
O3L	<10%	46%	44%	86%

Tabulka 5.7: Výsledky klasifikace, metrika *Correct*, bigramové modely.

	O1	O2	O2L	O3L
O1	<10%	<10%	<10%	<10%
O2	<10%	11%	35%	46%
O2L	<10%	33%	57%	32%
O3L	<10%	43%	44%	65%

Tabulka 5.8: Výsledky klasifikace, metrika *Accuracy*, bigramové modely.

Původně vytvořené modely byly modifikovány na modely bigramové, modifikace spočívá ve vypočtení pravděpodobností podle vztahu 5.12 a použití těchto pravděpodobností pro vytvoření sítě analogicky jako u předchozí sady modelů. Pro výpočet pravděpodobností obsahuje HTK Toolbox nástroj HL-Stats, resp. HBuild pro vytvoření sítě. Data byla zpracována a klasifikována stejným způsobem. Souhrnné výsledky pro klasifikaci pomocí bigramových modelů vidíme v tabulkách 5.7 a 5.8.

## 5.10 Zhodnocení výsledků

Podle očekávání jsou nejlepší výsledky klasifikace v případech, kdy testovací i trénovací data pocházejí od jedné osoby. Co se týče interpersonální klasifikace, zde klasifikátory nepodávají na první pohled jednoznačné výsledky.

Signifikantně lepších výsledků dosahují bigramové modely, u nichž zavedení další znalosti vstupních dat (kontext) vedlo ke zlepšení zejména co se týče metriky *Accuracy*, tedy odstranění vložených jevů.

Podrobnějším zkoumáním výstupů klasifikátorů pomocí nástroje HResults a plných konfusních matic (podrobné výsledky jsou uvedeny v příloze) pro jednotlivé případy a modely lze dospět k těmto závěrům:

- První sada modelů dosahuje poměrně nízkého klasifikačního skóre,

zejména pro vysoký počet vložených jevů. Vzhledem k zamýšlenému účelu využití výsledků jsou vložené jevy nežádoucí, jevy vynechané nemusí představovat takový problém v případě, že je dostatek vstupních dat.

- Obecně vyšší klasifikační skóre dosahují jevy představující čistě extenzní či flexní pohyby (jevy s13, s31). U jevů, představujících pohyby, při nichž je zapojeno více svalových skupin a jejichž provedení závisí výrazně na měřené osobě, je skóre v průměru více než o třetinu nižší.
- Testování interpersonální prokázalo, že EEG data jsou silně individuálně závislá a klasifikátory natrénované na jedné osobě nelze s úspěchem využít pro klasifikaci pohybů jiné osoby. Nicméně i zde se ukázalo, že čistě extenzní/flexní pohyby jsou výrazně lépe klasifikovány a s jistým omezením by bylo možno klasifikátor ke klasifikaci těchto pohybů použít.
- Bigramové modely přinesly zlepšení co se týče redukce počtu vložených a vynechaných jevů a zpřesnění klasifikace - díky informacím o kontextu se snížila chyba klasifikátoru.

# Kapitola 6

## Výsledky disertační práce

V předložené disertační práci byla představena problematika klasifikace EEG signálů s podporou obrazového záznamu. Cílem práce bylo navrhnout klasifikátory umožňující klasifikovat EEG záznamy vztahující se k volným pohybům. Ověření klasifikátorů bylo provedeno pomocí obrazových dat....

### 6.1 Shrnutí

S přihlédnutím k dosavadním výzkumům je zřejmé, že problematika rozpoznávání pohybů ze záznamů EEG signálů je velmi rozsáhlá a na tomto poli je stále mnoho neprobádaných oblastí. Z tohoto důvodu se lze domnívat, že každý nový způsob uchopení této problematiky může být dalším krokem k cíli, jímž je prohloubení pochopení funkce lidského mozku.

V předložené disertační práci (zejména v kapitole 3) byl uveden teoretický rozbor řešené problematiky. Je zde uveden způsob snímání a řešení pracoviště pro snímání obrazových dat a EEG signálů. Vzhledem k zadání práce byl kladen důraz na zpracování EEG signálů a jejich klasifikaci, způsob zpracování obrazového záznamu byl uveden pro úplnost, neboť byl součástí celého experimentu, nicméně není těžištěm předložené práce.

V práci byly popsány techniky a nástroje použité pro zpracování získaných dat. Z rozsáhlého matematického aparátu využitelného pro filtraci a zpracování digitálních dat byly stručně představeny pouze ty metody, jenž byly použity v této práci. Jedná se zejména o analýzu nezávislých komponent (ICA), filtry s nekonečnou impulsní odezvou (IIR filtry) a rychlou fourierovu transformaci.

Jako klasifikátory byly zvoleny Skryté Markovovy Modely. Tyto modely byly již ověřeny v předchozích pracích při klasifikaci pohybů z obrazového záznamu [19]. Pro realizaci těchto modelů byl zvolen HTK Toolbox, jde o robustní nástroj pro práci s HMM, původně vyvinutý pro klasifikaci řečových dat. Nicméně vzhledem ke své univerzálnosti bylo rozhodnuto o pokusu jej využít i při klasifikaci EEG. S přihlédnutím k uvedeným výsledkům se lze domnívat, že tento pokus byl úspěšný.

V části zabývající se použitými modely jsou podrobně rozebrány jejich vlastnosti, zejména co se týče zvolené topologie a specifik implementace v HTK Toolboxu. Topologie modelů byla zvolena s ohledem na znalost vstupního signálu, jenž je charakterizován sousledností jevů typických pro EEG záznam pohybů. Implementační specifikata HTK Toolboxu jsou uvedena proto, aby bylo zřejmé, jakým způsobem systém s modely pracuje a jaké má uživatel možnosti ovlivnění činnosti klasifikátoru<sup>1</sup>.

Pomocí HTK Toolboxu lze velmi snadno z jednoduchých modelů vytvořit specificky definovanou síť modelů pouhou změnou několika málo parametrů, aniž bychom se dotkli definice samotných modelů. Definice této sítě má strukturálně odpovídat klasifikovaným datům, což přispívá ke zlepšení kvality klasifikace.

Na základě dosažených výsledků se lze domnívat, že volba HMM jako klasifikátorů a nástroje HTK Toolbox pro realizaci těchto klasifikátorů byla vhodná pro zamýšlené využití. Klasifikátor vykazuje uspokojivé výsledky při klasifikaci a odlišení extenzních a flexních pohybů, pro pohyby jenž nejsou čistě extenzní/flexní je však úroveň přesnosti klasifikace signifikantně nižší. Lze se domnívat že je tomu tak z důvodu zapojení více svalových skupin, kde se signály pro jejich aktivaci překrývají a nelze je od sebe dostatečně rozlišit.

## 6.2 Hlavní výsledky práce

Za hlavní výsledky práce lze považovat:

- opakované provedení experimentu zahrnující simultánní snímání obrazových záznamů a EEG signálu,
- vytvoření databáze označených EEG signálů vhodných pro trénování a ověřování klasifikátorů,

---

<sup>1</sup>Nemáme na mysli změnu topologie modelu.

- návrh a realizaci klasifikátorů založených na HMM,
- ověření možnosti použití HTK Toolboxu pro klasifikaci EEG záznamů,
- ověření funkčnosti a kvality navržených klasifikátorů.

### 6.3 Náměty k další práci

S přihlédnutím k dosaženým výsledkům uvedeným v této disertační práci se jako vhodné náměty k další práci jeví zejména:

- další rozšíření databáze signálů a standardizace rozhraní této databáze,
- nalezení způsobu pro zlepšení úspěšnosti klasifikace, zejména v případech, kdy se nejedná o čistě extenzní či flexní pohyb,
- návrh a implementace systému umožňujícího současnou klasifikaci obrazových záznamů a EEG signálu včetně uživatelského rozhraní,
- automatizace výše uvedeného systému pro možnost širšího využití bez nutnosti hlubší znalosti problematiky klasifikace a zpracování signálů.

# Kapitola 7

## Závěr

V předložené disertační práci byly představeny způsoby zpracování EEG signálu a klasifikátory EEG signálu založené na Skrytých Markovových Modelech implementovaných v HTK Toolboxu.

S ohledem na obtížnost a časovou náročnost při provádění popsaného experimentu byly zvoleny takové metody pro trénování a vyhodnocování klasifikátorů, které nevyžadují rozsáhlé soubory dat.

Výsledky získané z naměřených dat ukazují, že navržené klasifikátory jsou funkční a lze pomocí nich získat relevantní údaje.

Motivací pro vznik této práce byl požadavek ze strany lékaře na zařízení, jenž by snadno umožnilo sledovat mozkovou aktivitu pacienta v korelaci s jeho pohybovou aktivitou. Takovéto zařízení by mohlo pomoci při rekonvalescenci po úrazech, případně při jiných poruchách motoriky, případně umožnit lékařům hlubší studium vztahu mezi neurologickou a svalovou aktivitou.

Pochopení vztahu mezi mozkovou a pohybovou aktivitou by také jistě přineslo nové možnosti při vývoji systémů pro komunikaci mezi člověkem a strojem, kupříkladu systémy pro dálkové ovládání bez nutnosti přítomnosti obsluhy na místě (nebezpečné podmínky, radiace, atp.).

Experiment byl navržen za účelem možnosti sledovat korelaci mezi volní pohybovou aktivitou a činností mozku. Vzhledem k tomu, o jak univerzální experiment ve své podstatě jde, se lze domnívat, že navržené řešení je použitelné i pro snímání jiných pohybů (např. celá ruka, noha, atp.). Z hlediska zpracování EEG signálu se jedná pouze o výběr jiných svodů a upravení sítě modelův HTK Toolboxu.

Další rozvoj představeného systému by mohl z hlediska biomedicínského

inženýrství přinést nové poznatky o činnosti lidského těla a přispět tak k rozšíření obzorů lidského poznání.

## Vlastní publikace

- Hlaváček A., Stohr J.: *Graphical User Interface for Testing Methods of Human Body Movements Classification*, POSTER, 2005
- Havlík J., Stöhr J., Hlaváček A.: *Recursive clustering algorithm for thumb motion classification*, In 3rd European Medical and Biomedical Engineering Conference EMBEC'05 [CD-ROM]. Společnost biomedicínského inženýrství a lékařské informatiky ČLS JEP, Prague, 2005
- Hlaváček, A., Hanžl. V., Havlík, J.: *Using Hidden Markov Models for Movement Classification*, Lékař a technika, červen, s. 121-123, 2006
- Hlaváček, A., Hanžl. V., Havlík, J.: *Human Body Movements Classification*, Proceedings of the Fifth IASTED International Conference on Biomedical Engineering, Calgary, pp. 326-329, 2006
- Hlaváček, A.: *Implementace skrytých Markovových modelů*, Technical Computing Prague 2006 - Sborník příspěvků 14. ročníku konference, Humusoft, Praha, s. 44, 2006
- Hlaváček, A.: *Klasifikace pohybů lidského těla pomocí markovových modelů implementovaných v HTK Toolboxu a MATLABu*, sborník konference Trendy v biomedicínském inženýrství, vydavatelství ČVUT v Praze, Fakulta biomedicínského inženýrství, Praha, s. 259-261, 2007
- Hlaváček, A.: *Přístrojové vybavení diagnostických laboratoří*, Vyzvaná přednáška, Fakulta Informatiky VUT Brno, 2008
- Hlaváček, A.: *Přístrojové vybavení diagnostických laboratoří*, Vyzvaná přednáška, Fakulta Informatiky VUT Brno, 2009
- Hlaváček, A.: *Přístrojové vybavení diagnostických laboratoří*, Vyzvaná přednáška, Fakulta Elektrotechnická ČVUT Praha, 2010

# Literatura

- [1] N. Firat Ince, Ahmed Tewfik, Sami Arica, Suha Yagcioglu: *Analysis and Visualization of Movement related EEG activities using Local Discriminant Bases*, The 2nd International IEEE EMBS Conference on Neural Engineering, Washington, DC, USA, 2005
- [2] Boscolo, R.: *Independent component analysis*, Wiley, New York, 2006
- [3] Fazel, A.: *EEG Signal Classification by Feed Forward Neural Network*, ECE 501NN - Neural and Adaptive Systems, Project Report, 2006
- [4] Blinkowska, K., Durka, P.: *Electroencephalography*, Wiley, New York, 2006
- [5] Lugger K, Flotzinger D, Schlögl A, Pregenzer M, Pfurtscheller G.: *Feature extraction for on-line EEG classification using principal components and linear discriminants*, Medical Biological Engineering Computing, 1998, pp. 309-314
- [6] Maria L. Stavrinou, Liviu Moraru, Polyxeni Pelekouda, Vasileios Kokkinos, Anastasios Bezerianos: *A Wavelet Tool to Discriminate Imagery Versus Actual Finger Movements Towards a Brain-Computer Interface*, Biological and Medical Data Analysis, ISBN 978-3-540-68063-5, 2006, pp. 323-333
- [7] S. C. Johnson: *Hierarchical Clustering Schemes Psychometrika*, 2:241-254
- [8] R. O. Duda, P. E. Hart, D. G. Stork: *Pattern Classification*, Wiley, New York, second edition, 2001
- [9] L. Rabiner, B. H. Juang: *Fundamentals of Speech Recognition*, Chapter 6, Prentice Hall PTR, New Jersey, 1993

- [10] V. Hlaváč, M. Sedláček: *Zpracování signálů a obrazů*, Vydavatelství ČVUT, 2001
- [11] J. Havlík: *Klasifikace pohybů části lidského těla v prostoru*, Disertační práce, Fakulta elektrotechnická ČVUT 2008
- [12] J.Havlík, J. Horčík: *Finger motion parametrization based on image processing* (in press), In Biosignal 2004, 2004.
- [13] Šťastný, J., Sovka, P., Stančák, A.: *EEG Signal Classification Introduction to the Problem*, In Radioengineering
- [14] Ranaweera, R. D., Talavage, T. M., Krishnan, A.: *Time-frequency Features Differentiate Direction of Finger Movement in Cued and Self-paced Tasks*, In Proceedings of the 2nd IEEE EMBS Conference on Neural Engineering, Arlington, Virginia, 2005
- [15] Oostenveld Robert, Praamstra Peter: *The five percent electrode system for high-resolution EEG and ERP measurements*, In Clinical Neurophysiology 112, 713-719, 2001
- [16] Srinivasan, R., Tucker, D.M: *Estimating the spatial Nyquist of the human EEG*, In Behavior Research Methods, Instruments, & Computers 30(1), 8-19, 1998
- [17] Šťastný, J., Sovka, P., Stančák, A.: *EEG Signal Classification*, In Radi-engineering
- [18] Šťastný, J., Sovka, P.: *High-Resolution EEG Classification*, In Hindawi Publishing Corporation, Computational Intelligence and Neuroscience, Volume 2007, Article ID 54925, 2007
- [19] Hlaváček, A.: *Klasifikace pohybů ve videozáznamu*, Diplomová práce, Fakulta Elektrotechnická ČVUT, 2006
- [20] Haas, L.F.: *Hans Berger (1873 - 1941), Richard Canton (1842 - 1926) and electroencephalography*, Journal of Neurology, Neurosurgery & Psychiatry 74 (1):9
- [21] Collura, T. F.: *History and Evolution of Electroencephalographic Instruments and Techniques*, Journal of Clinical Neurophysiology 10(4):476-504, Raven Press, Ltd., New York

- [22] Savoy, R. L.: *History and future directions of human brain mapping and functional neuroimaging*, Acta Psychologica 107 (2001) 9-42, Elsevier
- [23] Ranaweera R. D., Talavage T. M., Krishnan A.: *Time-frequency Features Differentiate Direction Finger Movement in Cued and Self-paced Tasks*, Proceedings of the second international IEEE EMBS Conference on Neural Engineering, Arlington, Virginia, March 16-19, 2005
- [24] Bicego M., Murino V., Figueiredo M. A. T.: *A sequential pruning strategy for the selection of the number of states in the hidden Markov models*, Pattern Recognition Letters 24 (2003) 1395-1407, Elsevier
- [25] Eksler V.: *Analýza hlavních komponent v problematice separace naslepo*, Elektrorevue 2005/29
- [26] Horniak R.: *Analýza EEG signálu*, Diplomová práce, Fakulta elektrotechnická ČVUT, 2010
- [27] Knight J.N.: *Signal fraction analysis and artifact removal in EEG*, Thesis, Colorado State University Fort Collins, Colorado, 2003
- [28] Cernea D., Olech P.-S., Ebert A., Kerren A.: *EEG-based Measurement of Subjective Parameters in Evaluations*, Proceedings of the 14th International Conference on Human-Computer Interaction, pp 279-283, volume 174 of CCIS, Orlando, Florida, USA, 2011, Springer
- [29] Pfurtcheller G., Graimann B., Neuper Ch.: *EEG-based Brain-computer interface system*, Wiley Encyclopedia of Biomedical Engineering, 2006, John Wiley & Sons, Inc.
- [30] Blinowska K., Durka P.: *Electroencephalography (EEG)*, Wiley Encyclopedia of Biomedical Engineering, 2006, John Wiley & Sons, Inc.
- [31] Bočková M., Rektor I.: *Desynchronizace a synchronizace EEG rytmu*, Neurologia pre prax 10(4), 2009
- [32] Valentová H.: *Návrh metod zpracování EEG signálu za účelem studie vztahu svalové a mozkové aktivity*, Diplomová práce, Fakulta elektrotechnická ČVUT, 2010
- [33] Ručkay L.: *Předzpracování pohybového EEG pomocí ICA a klasifikace nezávislých komponent*, Fakulta elektrotechnická ČVUT

- [34] Park I., Wankhede M., Zaveri T., Winters J.: *A Simple Approach to EEG-based Control*, Biomedical Engineering, University of Florida, USA
- [35] Jung T.P. et al: *Extended ICA Removes Artifacts from Electroencephalographic Recordings*, in *Advances in Neural Information Processing Systems* 10:894-900, 1998
- [36] Fazel A.: *EEG Signal Classification by Feed Forward Neural Network*, Neural and Adaptive Systems, Project Report, 2006
- [37] Dymarski P.: *HIDDEN MARKOV MODELS, THEORY AND APPLICATIONS*, InTech 2010
- [38] Fine S., Singer Y., Tishby N.: *The Hierarchical Hidden Markov Model: Analysis and Applications*, in *Machine Learning*, 32, 41–62, 1998
- [39] Boscolo R.: *INDEPENDENT COMPONENT ANALYSIS*, Wiley Encyclopedia of Biomedical Engineering, 2006 John Wiley & Sons, Inc.
- [40] Konopka O.: *Analýza nezávislých komponent*, Fakulta elektrotechnická ČVUT
- [41] Kamousi B., Liu Z., He B.: *An EEG Inverse Solution based Brain-Computer Interface*, IJBEM Vol. 7, No. 2, 2005
- [42] Liu J. Z. et al: *Linear correlation between fractal dimension of EEG signal and handgrip force*, Biol Cybern 93: 131–140, 2005
- [43] Yom-Tov E., Grossman A., Inbar G. F.: *Movement-related potentials during the performance of a motor task I: The effect of learning and force*, Biological Cybernetics, Springer-Verlag, 2001
- [44] Obrenović Ž., Starčević D., Jovanov E.: *MULTIMODAL PRESENTATION OF BIOMEDICAL DATA*, Wiley Encyclopedia of Biomedical Engineering, 2006 John Wiley & Sons, Inc.
- [45] Seiss E. et al: *Proprioception-Related Evoked Potentials: Origin and Sensitivity to Movement Parameters*, NeuroImage 17, 461–468, 2002
- [46] Baldi P., Chauvin Y.: *Smooth On-Line Learning Algorithms for Hidden Markov Models*, Neural Computation 6, 307-318, 1994

- [47] Novák R.: *Hodnocení EEG signálu v reálném čase*, Diplomová práce, Fakulta elektrotechnická ČVUT, 2011
- [48] Stančák A. jr., Wackermann J.: *Spatial EEG Synchronisation Over Sensorimotor Hand Areas in Brisk and Slow Self-Paced Index Finger Movements*, Brain Topography, Volume 11, Number 1, 1998
- [49] Novák J.: *Vliv očních pohybů na EEG signál*, Bakalářská práce, Fakulta elektrotechnická ČVUT, 2012
- [50] Novák D.: *Electrocardiogram Signal Processing using Hidden Markov Models*, Disertační práce, Fakulta elektrotechnická ČVUT, 2009
- [51] Laan C. L., Pace D. F., Shatkay H.: *Initial model selection for the Baum-Welch algorithm as applied to HMMs of DNA sequences.*, First Canadian Student Conference on Biomedical Computing, 2005
- [52] Cincotti F. et al: *Comparison of Different Feature Classifiers for Brain Computer Interfaces*, Proceedings of the 1st International IEEE EMBS Conference on Neural Engineering, Capri Island, Italy March 20-22, 2003
- [53] Li Y. et al: *Single trial EEG classification during finger movement task by using hidden Markov models*, Proceedings of the 2 International IEEE EMBS Conference on Neural Engineering, Arlington, Virginia · March 16 - 19, 2005
- [54] Moreau, N.: *HTK(v.3.1) Basic Tutorial*, URL: [www.read.pudn.com](http://www.read.pudn.com), 2.2.2013
- [55] <http://www.psychiatrie.uk-j.de/Geschichte.html> *Klinik für Psychiatrie und Psychotherapie, Geschichte*, Universitätsklinik Jena
- [56] <http://www.thinkneuro.de>
- [57] <http://cncnation.en.made-in-china.com/product/tMiJjUybEFhL/>
- [58] Akrami A. et al: *EEG-Based Mental Task Classification: Linear and Nonlinear Classification of Movement Imagery*, Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference Shanghai, China, September 1-4, 2005

- [59] Yan T.et al: *Classifying EEG signals based HMM-AR*,E-ISBN 978-1-4244-1748-3, IEEE 2008
- [60] Congedo M.: *Tomographic Neurofeedback; a new Technique for the Self-Regulation of Brain Electrical Activity*, Dissertation, University of Tennessee, Knoxville 2003

# Příloha A

## Příloha

V této příloze jsou uvedeny kompletní konfusní matice. Jsou použity následující identifikátory:

- TR: Soubor dat použitý pro trénování klasifikátoru
- TE: Soubor dat použitý pro testování klasifikátoru











