

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

FAKULTA ELEKTROTECHNICKÁ



## BAKALÁŘSKÁ PRÁCE

**Analýza rozdílů EEG signálu nadaných  
a průměrně nadaných adolescentů**

**Praha, 2015**

**Autor:** Petr Bukovský  
**Vedoucí práce:** Mgr. Karla Štěpánová



## Prohlášení autora práce

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze dne \_\_\_\_\_

\_\_\_\_\_ podpis

## **Poděkování**

Děkuji především Mgr. Karle Štěpánové za vstřícnost a trpělivost, kterou projevila při vedení bakalářské práce. Dále bych chtěl poděkovat MUDr. Ladislavu Reznerovi za jeho odborné konzultace a poskytnuté materiály. Mé poděkování patří také rodině a všem, co mě podporovali ať už psychicky, finančně nebo i jinak.

## Abstrakt

Tato bakalářská práce si klade za cíl určit rozdíly v zapojení různých částí mozku u nadaných adolescentů oproti průměrně nadaným v průběhu řešení úlohy mentální rotace. Vybraným jedincům bylo během řešení úlohy snímáno EEG, z jehož výsledků se bude pro porovnání vycházet.

V první části práce proběhlo předzpracování EEG a výpočet příznaků. Pro porovnání rozdílů v zapojení různých částí mozku byla provedena selekce příznaků, různé metody klasifikace a vizualizace dat.

Kvůli špatnému EEG záznamu byly z experimentu vyřazeny některé subjekty. Selektce a klasifikace prokázaly rozdíly zejména v zapojení mediální oblasti mozku. To potvrdila i vizualizace, která navíc prokázala zvýšenou aktivitu v temporálních lalocích u nadaných adolescentů.

Nadaní při řešení úloh logického charakteru zapojují části mozku, kde se nacházejí asociální centra. Na základě výsledků může být nadaným a průměrně nadaným adolescentům přizpůsobena výuka podle dovedností.

## Klíčová slova

Mozek, EEG, mentální rotace, artefakty, segmentace, dopředná selekce, zpětná eliminace, klasifikace, naivní Bayesovský klasifikátor, vícevrstvý perceptron, rozhodovací strom.

## **Abstract**

The purpose of this bachelor thesis is to determine differences in the brain activity of gifted and average adolescents during the mental rotation task. The experiment is based on EEG results, which were measured during this task.

After signal preprocessing frequency and statistical features were calculated. To compare the brain activity was performed selection, classification and visualization of EEG results.

Some subjects were excluded because of bad EEG signals. Selection and classification proved different brain activity especially on electrodes Fz and Cz. This results was confirmed by visualization, which also showed increased activity of gifted adolescents in the temporal lobe.

## **Keywords**

Brain, EEG, mental rotation, artifacts, segmentation, forward selection, backward elimination, classification, naive Bayesian classifier, Multilayer Perceptron, decision tree.

## ZADÁNÍ BAKALÁŘSKÉ PRÁCE

**Student:** Petr B u k o v s k ý

**Studijní program:** Kybernetika a robotika (bakalářský)

**Obor:** Robotika

**Název tématu:** Analýza rozdílů EEG signálu nadaných a průměrně nadaných adolescentů

### Pokyny pro vypracování:

Cílem bakalářské práce je pomocí analýzy EEG signálu identifikovat mozkové struktury, které dobře klasifikují mezi nadanými a průměrně nadanými adolescenty v průběhu řešení úlohy mentální rotace (2D a 3D). Student se seznámí s měřením EEG signálu, jeho zpracováním, selekcí a klasifikací příznaků a provede vizualizaci výsledků. Zároveň bude provedeno zpracování behaviorálních dat (reakční časy a chybovost). Jednotlivé kroky práce jsou následující:

1. Seznamte se s průběhem psychologického experimentu, konkrétně s úlohou mentální rotace a dosavadním výzkumem měření mozkové aktivity v průběhu řešení kognitivních úloh.
2. Samostatné měření EEG signálu.
3. Proveďte automatické zpracování EEG záznamů naměřených v průběhu úlohy mentální rotace na nadaných i průměrně nadaných adolescentech (data jsou připravena) s příslušným předzpracováním (detekce artefaktů, segmentace signálu, extrakce příznaků, normalizace...).
4. Na základě extrahovaných příznaků proveďte selekci příznaků, které nejlépe budou klasifikovat mezi nadanými a průměrně nadanými jedinci. Porovnejte výstupy dopředné a zpětné selekce a jednotlivých klasifikátorů (naive Bayes, neuronové sítě, rozhodovací stromy).
5. Vizualizujte naměřená data i výsledky klasifikace.

### Seznam odborné literatury:

- [1] S. Tong, N. V. Thakor - Quantitative EEG Analysis Methods and Clinical Applications. - Artech House, 2009.
- [2] Stenberg Robert J. – Kognitivní psychologie - Portál, 2002.
- [3] O'Boyle, Michael W., et al. - Mathematically gifted male adolescents activate a unique brain network during mental rotation. - Cognitive Brain Research 25.2 (2005), strana 583-587.
- [4] Petr Volf - Analýza EEG záznamu mentálně nadaných dětí – Praha, 2013 (diplomová práce).

**Vedoucí bakalářské práce:** Mgr. Karla Štěpánová

**Platnost zadání:** do konce letního semestru 2015/2016

L.S.

doc. Dr. Ing. Jan Kybic  
vedoucí katedry

prof. Ing. Pavel Ripka, CSc.  
Děkan

V Praze dne 27. 1. 2015





# Obsah

Seznam obrázků	xi
Seznam tabulek	xiii
<b>1 Úvod</b>	<b>1</b>
<b>2 Mozek</b>	<b>3</b>
2.1 Neuron . . . . .	3
2.2 Hemisféry . . . . .	4
2.3 Laloky . . . . .	4
2.3.1 Čelní lalok . . . . .	5
2.3.2 Temenní lalok . . . . .	5
2.3.3 Spánkový lalok . . . . .	5
2.3.4 Týlní lalok . . . . .	5
<b>3 EEG</b>	<b>7</b>
3.1 Vlny . . . . .	7
3.1.1 Delta . . . . .	8
3.1.2 Theta . . . . .	8
3.1.3 Alfa . . . . .	8
3.1.4 Beta . . . . .	8
3.1.5 Gama . . . . .	8
3.2 Elektroencefalograf . . . . .	9
3.2.1 Elektrody . . . . .	10
3.2.1.1 Systém 10-20 . . . . .	10
3.2.2 Hlavice . . . . .	11
3.2.3 Vlastní EEG aparát . . . . .	11
3.3 Vyšetření . . . . .	12

<b>4</b>	<b>Mentální rotace</b>	<b>13</b>
4.1	Úloha mentální rotace . . . . .	13
4.1.1	Experiment podle R. Sheparda a J. Metzlerové . . . . .	14
4.2	Rozdíl mezi nadanými a průměrně nadanými dětmi . . . . .	14
<b>5</b>	<b>Předzpracování signálu</b>	<b>17</b>
5.1	Převzorkování . . . . .	17
5.2	Filtrace 50 Hz . . . . .	18
5.3	Artefakty . . . . .	18
5.3.1	Technické artefakty . . . . .	19
5.3.2	Biologické artefakty . . . . .	19
5.4	Segmentace . . . . .	20
5.4.1	Konstantní segmentace . . . . .	20
5.4.2	Adaptivní segmentace . . . . .	21
5.4.2.1	Míra difference ve dvou spojených oknech . . . . .	21
5.5	Příznaky . . . . .	21
<b>6</b>	<b>Selekce</b>	<b>23</b>
6.1	Dopředná selekce . . . . .	23
6.2	Zpětná eliminace . . . . .	24
6.3	Algoritmus plus p - minus q . . . . .	24
<b>7</b>	<b>Klasifikace</b>	<b>25</b>
7.1	Trénovací a testovací množina . . . . .	25
7.1.1	Hold-out . . . . .	26
7.1.2	Krosvalidace . . . . .	26
7.1.2.1	Leave-one-out . . . . .	26
7.2	Klasifikátory . . . . .	27
7.2.1	Naivní Bayesovský klasifikátor . . . . .	27
7.2.2	Neuronová síť . . . . .	28
7.2.2.1	Perceptron . . . . .	28
7.2.2.2	Vícevrstvý perceptron . . . . .	29
7.2.3	Rozhodovací strom . . . . .	29
7.2.3.1	Vytváření rozhodovacích stromů . . . . .	30
7.2.3.2	Rozhodovací strom C4.5 . . . . .	30

<b>8 Experiment</b>	<b>31</b>
8.1 Seznam měřených subjektů . . . . .	31
8.2 Měření . . . . .	31
8.2.1 Průběh experimentu . . . . .	31
8.2.2 Elektroencefalograf . . . . .	32
8.3 Předzpracování dat . . . . .	33
8.3.1 Artefakty . . . . .	33
8.3.2 Segmenty . . . . .	33
8.3.3 Příznaky . . . . .	34
<b>9 Výsledky</b>	<b>37</b>
9.1 Selekcce . . . . .	37
9.2 Klasifikace . . . . .	39
9.2.1 Porovnání klasifikátorů . . . . .	39
9.2.2 Leave-one-out . . . . .	40
9.2.3 Klasifikace v jednotlivých částech mozku . . . . .	42
9.2.3.1 Klasifikace podle hemisfér . . . . .	42
9.2.3.2 Klasifikace podle laloků . . . . .	43
9.3 EEG . . . . .	44
9.3.1 Alfa . . . . .	44
9.3.2 Beta . . . . .	45
9.3.3 Gama . . . . .	47
<b>10 Diskuse a závěr</b>	<b>49</b>
<b>A Seznam zkratk</b>	<b>I</b>
<b>B Obrázky</b>	<b>III</b>
<b>C Tabulky</b>	<b>VII</b>
<b>D Obsah příloženého CD</b>	<b>XI</b>



# Seznam obrázků

2.1	Stavba neuronu . . . . .	4
2.2	Mozkové laloky . . . . .	6
3.1	Porovnání jednotlivých vln . . . . .	9
3.2	Porovnání jednotlivých spekter . . . . .	9
3.3	Systém 10-20 . . . . .	10
3.4	Rozmístění elektrod - systém 10-20 . . . . .	11
4.1	Příklady jednotlivých 2D a 3D stimulů. . . . .	14
4.2	Aktivnější oblasti mozku u nadaných chlapců oproti průměrně nadaným. . . . .	15
5.1	Porovnání průběhu signálu před filtrací a po filtraci 50 Hz . . . . .	18
5.2	Porovnání spektra signálu před filtrací a po filtraci 50 Hz . . . . .	18
5.3	Artefakt - vypadlá elektroda . . . . .	19
5.4	Artefakt - mrkání . . . . .	20
5.5	Konstantní segmentace o délce segmentu 1 sekunda . . . . .	20
5.6	Míra difference ve dvou spojených oknech . . . . .	21
7.1	Krosvalidace . . . . .	26
7.2	Leave-one-out . . . . .	27
7.3	Schéma perceptronu . . . . .	28
7.4	Schéma vícevrstvého perceptronu . . . . .	29
8.1	2D stimulus - identický . . . . .	32
8.2	2D stimulus - zrcadlený . . . . .	32
8.3	3D stimulus - identický . . . . .	32
8.4	3D stimulus - zrcadlený . . . . .	32
9.1	Závislost přesnosti klasifikace na počtu příznaků - beta 2D . . . . .	40
9.2	Alfa aktivita 2D . . . . .	44

9.3	Alfa aktivita 3D . . . . .	44
9.4	Aktivnější oblasti u nadaných oproti průměrně nadaným - alfa aktivita .	45
9.5	Beta aktivita 2D . . . . .	45
9.6	Beta aktivita 3D . . . . .	46
9.7	Aktivnější oblasti u nadaných oproti průměrně nadaným - beta aktivita .	46
9.8	Gama aktivita 2D . . . . .	47
9.9	Gama aktivita 3D . . . . .	47
9.10	Aktivnější oblasti u nadaných oproti průměrně nadaným - gama aktivita	47
B.1	Záznam EEG signálu při zavřených očích . . . . .	III
B.2	Příklad rozhodovacího stromu . . . . .	IV
B.3	Histogram selektovaných frekvenčních příznaků pro 2D stimuly . . . . .	V

# Seznam tabulek

2.1	Funkce hemisfér . . . . .	4
8.1	Rozdělení segmentů . . . . .	34
8.2	Frekvenční příznaky . . . . .	34
8.3	Statistické příznaky . . . . .	35
9.1	Selekce příznaků 2D . . . . .	38
9.2	Selekce příznaků 3D . . . . .	38
9.3	Porovnání klasifikátorů - 2D stimuly . . . . .	39
9.4	Leave-one-out . . . . .	41
9.5	Klasifikace podle hemisfér - 2D . . . . .	42
9.6	Klasifikace podle hemisfér - 3D . . . . .	42
9.7	Klasifikace v jednotlivých lalocích - 2D . . . . .	43
9.8	Klasifikace v jednotlivých lalocích - 3D . . . . .	43
C.1	Seznam měřených subjektů . . . . .	VIII
C.2	Výskyt artefaktů . . . . .	IX





# Kapitola 1

## Úvod

Lidé úspěšní v různých oblastech mohou části svého mozku zapojovat jinak. Kreativní jedinci zapojují více pravou hemisféru mozku, zatímco matematicky nadaní jedinci mají aktivnější levou hemisféru. Géniové jako byl např. Albert Einstein mohou mít rozšířené různé části mozku, čímž se pak můžou odlišovat od ostatních lidí. Albert Einstein měl rozšířený temenní lalok, což mohlo mít za následek lepší logické uvažování a díky tomu mohl formulovat např. obecnou teorii relativity. Cílem této práce je ověřit rozdílné zapojení různých částí mozku v průběhu řešení kognitivních úloh u nadaných a průměrně nadaných adolescentů.

Pro posuzování zapojení mozku nadaných a průměrně nadaných adolescentů bylo subjektům snímáno EEG v průběhu řešení úlohy mentální rotace. Mentální rotace je jednou ze základních kognitivních úloh, kde má subjekt za úkol co nejdříve a nejpresněji rozhodnout, zda dva rotované obrázky jsou vůči sobě identické nebo zrcadlené. V průběhu úlohy si každý jedinec vybuduje strategii, na základě které volí svoji odpověď.

V předchozích experimentech bylo prokázáno rozdílné zapojení mozku u nadaných adolescentů oproti průměrně nadaným při řešení úlohy mentální rotace. Například studie funkční magnetické rezonance (fMRI), kterou v roce 2005 provedl M. W. O'Boyle, ukázala, že nadaní chlapci zapojují v průběhu řešení úlohy levou i pravou hemisféru a že se nejvyšší aktivita oproti průměrně nadaným chlapcům projevuje především ve střední části čelního laloku a v temenním laloku. Podobné výsledky se očekávají i z výsledků EEG. Bude porovnáváno, jak dobře lze klasifikovat podle různých částí mozku mezi skupinou nadaných a skupinou průměrně nadaných adolescentů. Dále proběhne vizualizace EEG, ze které budou názorně patrné aktivní oblasti u obou skupin. Dosažené výsledky budou porovnány s výše zmíněnou studií fMRI.



# Kapitola 2

## Mozek


Mozek je nejsložitější strukturou živé hmoty. Je analytickým, syntetickým a koordinačním orgánem a regulátorem životních funkcí se schopností učit se, pamatovat si a přizpůsobit činnost měnícím se životním podmínkám. V průběhu života se dynamicky vyvíjí. Obsahuje 10 miliard až 1 bilion neuronů<sup>1</sup>. Mozek sestává ze dvou hemisfér a čtyř základních laloků. [2, 9]

### 2.1 Neuron

Neuron je základní stavební jednotkou nervového systému. Neurony mají různou velikost, tvar a funkci. Jejich společnou vlastností je dráždivost. Neuron je sám o sobě nefunkční, funguje jen ve spojení s dalšími nervovými nebo jinými strukturami. Spojení mezi neurony vytváří dendrity společně s axonem. Dendrity mezi sebou tvoří bohaté sítě a přivádějí do neuronu vzruchy z jiných struktur. Axon je v neuronu jen jeden a vede vzruch, který neuron vytvořil, do cílového místa. Pro zrychlení přenosu signálu je axon obalen myelinovou pochvou. Shluky neuronů vytvářejí v mozku a míše šedou hmotu, která je lokalizována v mozkové kůře a v hlubokých částech mozku. [9]

---

<sup>1</sup>Odhad počtu neuronů v mozku se v literaturách výrazně liší.



Obrázek 2.1: Stavba neuronu

Zdroj: [https://cs.wikibooks.org/wiki/Soubor:Neuron\\_\(cesky\)-1.svg](https://cs.wikibooks.org/wiki/Soubor:Neuron_(cesky)-1.svg)

## 2.2 Hemisféry

V mozku se rozlišuje levá a pravá hemisféra. Mezi hemisférami se nachází tzv. mediální oblast. Levá hemisféra ovládá pravou část těla a ve většině případů dominuje u vyhraněných praváků. Pravá hemisféra řídí levou část těla a bývá dominantní u vyhraněných leváků. Funkce obou hemisfér se liší. Levá hemisféra se podílí na úkolech logického charakteru, zatímco pravá hemisféra má funkci spíše duševní. [9]

Tabulka 2.1: Funkce hemisfér

Hemisféra	Funkce
Levá	Řeč, logické uvažování, psaní, čtení
Pravá	Orientace v prostoru, představivost, vnímání barev a zvuků

## 2.3 Laloky

Každá hemisféra se skládá z čelního (frontálního), spánkového (temporálního), temenního (parietálního) a týlního (okcipitálního) laloku (obr. 2.2). Jednotlivé laloky jsou od sebe odděleny brázdami a mají odlišnou funkci.

### 2.3.1 Čelní lalok

Přední část čelního laloku má nejvyšší analytické, syntetické a asociační funkce a řídí vůlí vyvolávané činnosti. Zadní (precentrální) část čelního laloku nacházející se před centrální brázdou má motorické funkce. Ve spodní části čelního laloku se nacházejí čichová centra. [9, 21]

### 2.3.2 Temenní lalok


Temenní lalok je oddělen od centrálního laloku centrální brázdou. Za centrální brázdou se nachází somatosenzorické centrum, do kterého přicházejí vlákna z celého těla vedoucí citlivost. V další části temenního laloku se nachází gyrus angularis. Gyrus angularis spojuje zrakové, sluchové a řečové funkce na malém prostoru mozkové kůry. Jeho poškozením dochází k různým poruchám řeči, čtení, psaní a poznávání. [9, 21]

### 2.3.3 Spánkový lalok

Spánkový lalok je oddělen od čelního a temenního laloku boční brázdou. Nachází se zde sluchové centrum, které má za úkol rozbor složitějších zvukových signálů (např. řeč). [9, 21]

### 2.3.4 Týlní lalok

Týlní lalok je oddělen od temenního temenotýlní brázdou. V zadní části týlního laloku se nachází zraková oblast sloužící k vnímání barvy, tvaru a orientace obrazu. [9, 21]



Obrázek 2.2: Mozkové laloky

Zdroj: <http://pfyziol1fup.upol.cz/castwiki/?p=3265>

# Kapitola 3

## EEG

Elektroencefalogram (EEG) zaznamenává elektrickou aktivitu mozku. Výsledkem miliard výbojů v mozkové kůře je neustále se měnící elektrické pole, které proniká přes lebku. Elektrické pole se dá detekovat elektrodami, které jsou přiložené na hlavě. Vhodnou citlivostí, filtrací a zapojením elektrod lze dostat signál podobající se lehkému vlnění mořské hladiny. [21]

### 3.1 Vlny

Existuje pět hlavních mozkových vln, které se liší rozdílným kmitočtovým pásmem<sup>1</sup> (obr. 3.2). Charakteristika vln se mění podle činnosti, kterou člověk dělá. Při spánku se projevují pomalé frekvence a při logickém přemýšlení naopak rychlé frekvence. Charakteristika vln se mění také s věkem. [22]

---

<sup>1</sup>Hranice jednotlivých pásem se liší v závislosti na literatuře.

### 3.1.1 Delta

Delta vlny jsou vlny s nejpomalejší frekvencí, které se u člověka zkoumají. Jejich frekvence leží v rozmezí 0.5 až 4 Hz. Vyskytují se především při hlubokém spánku. Často mohou být zaměněny s artefakty, které vznikají činností svalů v krku a čelistech. [22]

### 3.1.2 Theta

Frekvence theta vln se nachází v pásmu od 4 do 7.5 Hz. Objevují se u člověka, který je ospalý nebo se nachází v hluboké meditaci. Jsou také spojeny s tvůrčí činností. Theta vlny jsou dominantní v kojeneckém věku dítěte. U dospělých jedinců je výskyt theta vln v bdělém stavu známkou patologického problému. [22]

### 3.1.3 Alfa

Alfa vlny vznikají v zadní polovině hlavy v týlní oblasti. Jejich frekvence leží v pásmu 8 až 13 Hz. Průběh alfa vln má podobný tvar jako sinusoida. Objevují se u člověka, který má zavřené oči, je uvolněný a bez jakékoliv koncentrace a napětí. Alfa aktivita se potlačuje otevřením očí. [22]


### 3.1.4 Beta

Beta vlny vznikají v přední a centrální části mozku. Frekvence beta vln se nachází v rozmezí od 14 do 26 Hz. Jsou spojené s aktivním myšlením a řešením konkrétních problémů. Vyskytují se u člověka v emočním neklidu. [22]


### 3.1.5 Gama

Gama vlny mají frekvenci vyšší než 30 Hz. Jejich amplituda je velmi nízká oproti vlnám s pomalejší frekvencí a objevují se poměrně vzácně. Vyskytují se například v situacích extrémní koncentrace. Detekce těchto rytmů lze použít pro potvrzení některých onemocnění mozku. [22]





Obrázek 3.1: Porovnání jednotlivých vln



Obrázek 3.2: Porovnání jednotlivých spekter

## 3.2 Elektroencefalograf

Elektroencefalograf je přístroj sloužící k snímání EEG. Skládá ze tří základních částí: elektrod, hlavice a vlastního EEG aparátu. [27]


### 3.2.1 Elektrody

Snímací elektrody slouží k přenosu elektrických potenciálů z hlavy snímaného subjektu do EEG přístroje. Pro kvalitní záznam musí být elektrody vyrobeny z vodivého materiálu, který nereaguje s elektrolyty na skalpu. Nejčastěji se používají kovové elektrody potažené zlatem, platinou nebo chloridem stříbrným. [27]

Rozlišují se 3 základní typy elektrod: neinvazivní (skalповé), semiinvazivní a invazivní. Pro základní snímání EEG se používají elektrody skalповé. Skalповá elektroda je tvořena kovovou miskou o průměru 4-10 mm, ke které je připojen izolovaný flexibilní vodič sloužící k propojení elektrody se vstupem elektroencefalografu. Elektrody se vyplňují vodivou pastou nebo gelem mající charakter elektrolytu, který slouží jako vodivé médium a minimalizuje výskyt pohybových artefaktů. [27]

#### 3.2.1.1 Systém 10-20


Mezinárodní systém rozmístění elektrod 10-20 pokrývá skalp soustavou elektrod. Univerzální systém umožňuje stejné snímání pacientů a porovnávání jejich výsledků nezávisle na tom, kde byl záznam pořízen. Poloha elektrod vychází z linií, které vedenou mezi kostěnými výstupky na hlavě. Elektrody jsou umístěny tak, že dělí linie na 10% a 20% úseky celé její délky (obr. 3.3). [27]



Obrázek 3.3: Systém 10-20

Zdroj: [http://www.diytdcs.com/media/010\\_EEG\\_standard.gif](http://www.diytdcs.com/media/010_EEG_standard.gif)

Metoda 10-20 standardně zahrnuje 21 elektrod sloužící k snímání a jednu elektrodu zemnicí. Název elektrody se skládá z písmene, který odpovídá názvu snímaného laloku<sup>2</sup>, a indexu (obr. 3.4). Číselný index označuje laterální polohu snímání<sup>3</sup>, index *z* označuje snímání mediální oblasti. [27]



Obrázek 3.4: Rozmístění elektrod - systém 10-20

Zdroj: <http://brain.fuw.edu.pl/edu/Plik:10-20.png>

### 3.2.2 Hlavice

Konektor na konci vodiče elektrod se zapojuje do zdírek v hlavici EEG přístroje. Při skalpovém snímání jsou zdířky označeny symboly umístění elektrod na skalpu. Kvůli bezpečnosti pacientů musí být hlavice a její spojení s vlastním EEG přístrojem konstruovány tak, aby jimi mohl procházet proud maximálně 20 A. [27]

### 3.2.3 Vlastní EEG aparát

Nedílnou součástí vlastního elektroencefalografu je zesilovač. Na vstup zesilovače jsou zapojeny elektrody mezi nimiž se snímá rozdíl elektrických potenciálů. Úkolem zesilovače je zesílit tento rozdíl. Zesílené rozdíly je dále nutné filtrovat. U moderních elektroencefalografů se filtrace obvykle provádí až po skončení vyšetření pomocí digitálních filtrů. [27]

<sup>2</sup>Fp - frontopolární, F - frontální, C - centrální, P - parietální, O - okcipitální, A - ušní lalůčky

<sup>3</sup>lichý index - levá hemisféra, sudý index - pravá hemisféra

### 3.3 Vyšetření

Standardní EEG vyšetření trvá cca 20 minut. Při vyšetření pacient leží nebo sedí, musí se nacházet v klidu a být uvolněný. V první části měření pacient postupně zavře, otevře a znovu zavře oči. V okamžiku otevření očí se eliminuje alfa aktivita a můžou se objevit beta vlny, v momentu zavření očí se opět objeví alfa aktivita (obr. B.1). Ve chvíli, kdy pacient zavře resp. otevře oči, se mohou na záznamu objevit oční artefakty. Toto měření se několikrát opakuje, přičemž pacient na pokyny lékaře střídá dýchání ústy a nosem. Dýchání nosem aktivuje čichová centra a spánkovou oblast. Dýcháním ústy je aktivován thalamus a rozsáhlé oblasti mozkové kůry. [21]

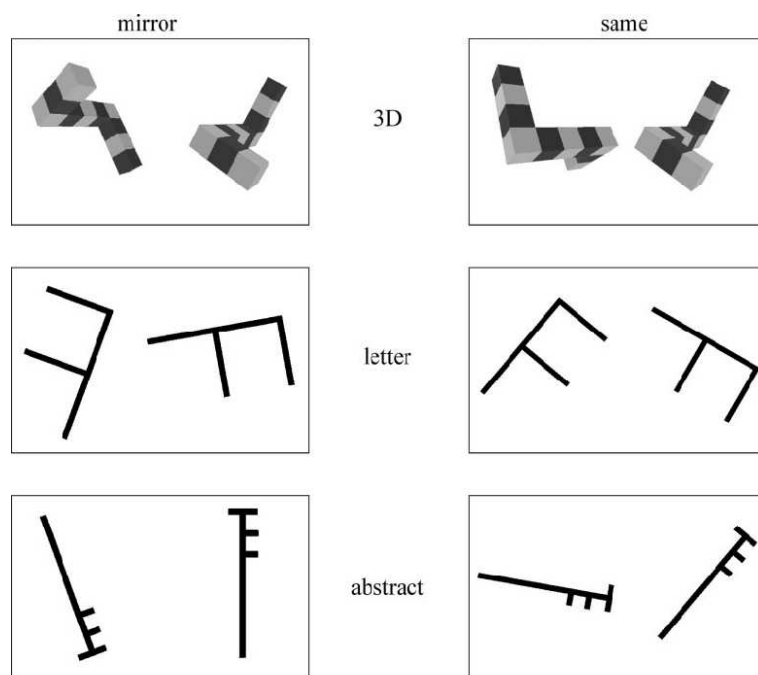
V druhé části vyšetření probíhá fotostimulace pomocí stroboskopu. Pacient má zavřené oči a přes oční víčka vnímá blikání stroboskopu. Frekvence blikání se postupně mění ze 3 na 30 Hz a zpět na 3 Hz. Z výsledného signálu se následně dají určit případné patologické příznaky. [21]

# Kapitola 4

## Mentální rotace

### 4.1 Úloha mentální rotace

Úloha mentální rotace je typická úloha z kognitivní psychologie, která zkoumá přesnost a rychlost odpovědí a rozdílný způsob přemýšlení u subjektů lišící se např. národností, pohlavím, profesí nebo IQ. Mentální rotaci vizuálních objektů lze provádět s řadou obrázků, a to jak s dvourozměrnými, tak s trojrozměrnými (obr. 4.1). Dvourozměrné podněty, jako jsou například písmena nebo obrázky různých složitostí, mohou být otáčeny pouze v rovině obrázku narozdíl od trojrozměrných obrázků, které mohou být otáčeny i do hloubky. V modelu podle R. Sheparda a J. Metzlerové jsou měřeným subjektům prezentovány páry obrázků. Jeden obrázek je vzhledem k druhému pootočený a může být buď identický nebo zrcadlený. Úkolem měřeného subjektu je rozhodnout, zda jsou obrázky stejné nebo různé co nejrychleji a nejpresněji. Velká část výzkumu založená na práci Sheparda a Metzlerové zkoumala, jakým způsobem měřené subjekty otáčejí obrázky v jejich mysli. [4, 18, 24]



Obrázek 4.1: Příklady jednotlivých 2D a 3D stimulů.

[8]


#### 4.1.1 Experiment podle R. Sheparda a J. Metzlerové

V experimentu podle R. Sheparda a J. Metzlerové bylo každému z osmi měřených subjektů prezentováno 1600 párů obrázků. Měřený subjekt měl pro každý pár co nejrychleji rozhodnout, zda jsou obrázky vůči sobě stejné či zrcadlené. Experiment dokázal, že doba k rozpoznání zda jsou obrázky stejné či nikoliv je lineárně závislou funkcí na úhlovém rozdílu otočení mezi oběma obrázky. [24]

## 4.2 Rozdíl mezi nadanými a průměrně nadanými dětmi

Výzkum v oblasti kognitivní neurovědy naznačuje, že mozky matematicky nadaných dětí jsou kvantitativně a kvalitativně odlišné od těch, které mají průměrné matematické schopnosti. Matematicky nadané děti vykazují známky zvýšeného vývoje v pravé části hemisféry a při přemýšlení mají tendenci se spoléhat na mentální představivost. [15]

Pro měření mozkové aktivity u matematicky nadaných a průměrně nadaných chlapců byla použita fMRI. Výsledky ukázaly rozdíly ve využití různých částí mozku při řešení úlohy mentální rotace (obr. 4.2). Mozková aktivita u nadaných se projevila v obou hemisférách a to zejména v parietálním laloku, který byl doplňován zapojováním frontálního laloku, zatímco průměrně nadaní zapojovali pouze pravou část mozku. [16]



Obrázek 4.2: Aktivnější oblasti mozku u nadaných chlapců oproti průměrně nadaným.

[16]





# Kapitola 5

## Předzpracování signálu

Předzpracování EEG signálu probíhá v několika krocích. První fáze spočívá v převzorkování signálu a filtraci 50 Hz. Dále se v záznamu detekují artefakty a nakonec se signál segmentuje. Pro přehlednější průběh se dají ze signálu vyfiltrovat i velmi nízké nebo naopak velmi vysoké frekvence.


### 5.1 Převzorkování

Elektroencefalograf v praxi zaznamenává signál se vzorkovací frekvencí 200, 250 nebo 500 Hz. Pro zjištění frekvenčního spektra signálu pomocí rychlé Fourierovy transformace (FFT) je vhodné tento signál převzorkovat na vzorkovací frekvenci, která je rovna mocnině dvou. Při dlouhém záznamu je možné signál podvzorkovat, čímž se zmenší celkový počet dat a algoritmy se budou provádět kratší dobu. Musí se však dodržet Shannonův-Kotělnikovův teorém (5.1). Vzorkovaný signál o nejvyšší mezní frekvenci  $f_M$  musí být vzorkován vzorkovací frekvencí  $f_S$  dvakrát větší než  $f_M$ , aby se dal signál rekonstruovat beze ztráty informace. [6, 23]


$$f_S \geq 2f_M \tag{5.1}$$

## 5.2 Filtrace 50 Hz

Síťový šum je artefakt, který pochází z přístrojů napájených ze sítě vyskytujících se v okolí měření, tedy i ze samotného elektroencefalografu. V záznamu se tento artefakt objevuje v podobě frekvence 50 Hz a jejich násobků (obr. 5.1). Rušivé frekvence se odstraní ve frekvenčním spektru signálu (obr. 5.2) pomocí filtru s pásmovou zádrží.



Obrázek 5.1: Porovnání průběhu signálu před filtrací a po filtraci 50 Hz




Obrázek 5.2: Porovnání spektra signálu před filtrací a po filtraci 50 Hz

## 5.3 Artefakty

Artefakty jsou nežádoucí části signálu vyskytující se v EEG záznamu, tedy každý signál, který nevzniká elektrickou činností mozku měřeného subjektu. Podle vzniku se dělí na artefakty technické a artefakty biologické. [27]

### 5.3.1 Technické artefakty


Technické artefakty jsou snáze detekovatelné a lépe se s nimi pracuje. Do skupiny technických artefaktů patří kromě síťového šumu např. artefakt vzniklý výpadkem nebo špatným kontaktem elektrody (obr. 5.3) a artefakt způsobený chybou samotného EEG přístroje. Artefakt z elektrody se v daném okamžiku projevuje zpravidla jen na jedné elektrodě. Je-li tedy vypadlá elektroda z hlediska měření nepodstatná, výsledek měření to nijak neovlivní. [27]



Obrázek 5.3: Artefakt - vypadlá elektroda

### 5.3.2 Biologické artefakty

Biologické artefakty se rozpoznávají obtížněji a prakticky se nedají odstranit. Dají se snadno zaměnit za patologický příznak. Projevují se zpravidla na větší skupině elektrod, proto je signál v době trvání artefaktu téměř nepoužitelný. Do této skupiny artefaktů řadíme nežádoucí části signálu, které jsou způsobeny měřeným subjektem. Patří sem oční artefakty (např. mrkání (obr. 5.4)), které se projevují zejména na elektrodách Fp1 a Fp2, svalová činnost subjektu, pocení a artefakty způsobené srdeční činností. V záznamu se může projevit i artefakt způsobený dýcháním, ale má výrazně pomalejší frekvenci než ta, která je zpravidla zkoumána, a lehce se odstraní filtrováním pomalých frekvencí. [27]




Obrázek 5.4: Artefakt - mrkání

## 5.4 Segmentace

Segmentace je rozdělení signálu na části podle určitého pravidla. Rozlišují se dvě skupiny segmentace: konstantní a adaptivní.

### 5.4.1 Konstantní segmentace

Konstantní segmentace je nejjednodušší způsob, jak rozdělit signál. Není to nic jiného, než rozdělení signálu na časově konstantní úseky (obr. 5.5). Takto rozdělené úseky nemají mezi sebou žádný vztah.



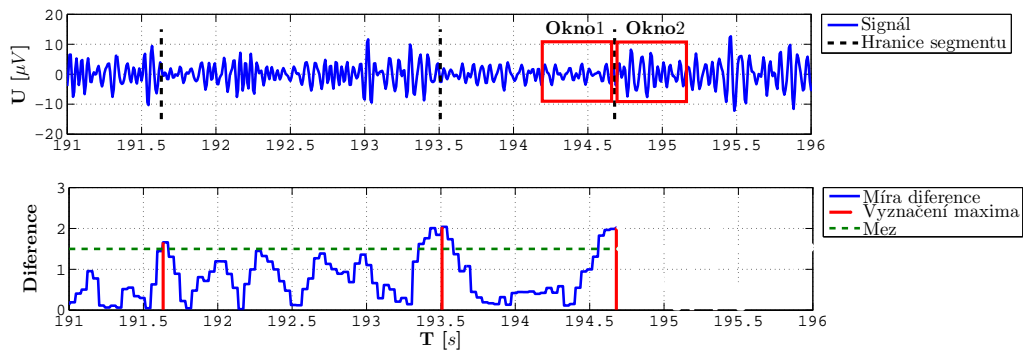
Obrázek 5.5: Konstantní segmentace o délce segmentu 1 sekunda

## 5.4.2 Adaptivní segmentace

Adaptivní segmentace je rozdělení signálu na části lišící se určitými vlastnostmi. Existuje řada algoritmů, které se liší výpočetní náročností, možností pracování v reálném čase nebo obtížností implementace. Příkladem adaptivní segmentace je segmentace na základě jednoduché míry diference ve dvou spojených oknech. [17]

### 5.4.2.1 Míra diference ve dvou spojených oknech

Tento způsob adaptivní segmentace je snadný na implementaci a může pracovat s malým zpožděním v reálném čase. Princip spočívá v klouzání dvou spojených oken, ve kterých se počítají zadané parametry, po signálu. V každém kroku se spočítá míra diference mezi parametry, ve které se pak hledají lokální maxima nacházející se nad zvolenou mezí (obr. 5.6). Maxima představují hranici segmentu. [17]



Obrázek 5.6: Míra diference ve dvou spojených oknech

## 5.5 Příznaky

Každý segment se dá popsat pomocí charakteristických příznaků. Základní způsob, jak popsat segmenty, je pomocí statistických (tab. 8.3) a frekvenčních (tab. 8.2) příznaků. Frekvenční příznaky udávají informaci o výkonech frekvenčního spektra. Intervaly jednotlivých spekter odpovídají kmitočtovému rozmezí příslušných vln.



# Kapitola 6

## Selekce

Ne všechny vypočtené příznaky jsou důležité pro další výpočty nebo klasifikaci. Některé příznaky mohou být přebytečné a některé irelevantní. Účelem selekce je vybrat takové příznaky, které přináší největší informační zisk a eliminovat tak jejich celkové množství. Zkoušet všechny možnosti, jak optimálně poskládat množinu příznaků, je výpočetně velice náročné. Pro selekci příznaků se proto používají různé heuristiky, které mohou pracovat na principu dopředné selekce nebo zpětné eliminace. Často se používají i genetické algoritmy, které jsou inspirovány přírodou.

### 6.1 Dopředná selekce

Dopředná selekce spočívá v přidávání příznaků do prázdné množiny. Do množiny se postupně přidávají odpovídající příznaky takové, aby množina příznaků měla co nejmenší chybu klasifikace. Selekcce končí v případě, že neexistuje další příznak, který by mohl snížit chybu klasifikace nebo v případě splnění předem dané podmínky (např. přesnost klasifikace je vyšší než požadovaná přesnost nebo počet selektovaných příznaků by přesáhl požadované maximum). [13]

Nalezené řešení je pouze suboptimální. Přidané příznaky se z množiny neodebírají. Může se tedy stát, že příznak bude nadbytečný po přidání dalších příznaků. [7]

## 6.2 Zpětná eliminace

Ve zpětné eliminaci se začíná s množinou obsahující všechny příznaky, ze které se postupně odebírají ty nejhorší. Eliminace pokračuje, dokud existuje příznak, který by nezměnil přesnost klasifikace nebo dokud není splněna předem daná podmínka (např. přesnost klasifikace po odebrání dalšího příznaku by klesla pod požadovanou přesnost). [13]

Stejně jako princip dopředné selekce najde i zpětná eliminace suboptimální řešení, protože po neoptimálním odebrání příznaku se již daný příznak nemůže do množiny přidat. [7]

## 6.3 Algoritmus plus $p$ - minus $q$

Pomocí algoritmu *plus  $p$  - minus  $q$*  lze částečně optimalizovat metody *dopředné selekce* i *zpětné eliminace*. Algoritmus spočívá v přidávání  $p$  příznaků a následném odebrání  $q$  příznaků. Proces končí v případě, kdy se dosáhne požadovaného počtu příznaků. Dopředná selekce probíhá v případě  $p > q$  a zpětná eliminace v případě  $p < q$ . [7]



# Kapitola 7

## Klasifikace

Klasifikací se rozumí rozdělení objektů, které jsou charakterizovány určitými příznaky, do jednotlivých skupin (tříd). V třídách se nachází objekty se stejnými nebo podobnými vlastnostmi. Klasifikace probíhá pomocí algoritmů tzv. klasifikátorů. [7]

Klasifikátor je algoritmus, který dokáže pomocí určitých pravidel rozhodnout, do které skupiny pravděpodobně daný objekt patří. Rozhodovací pravidla se klasifikátor naučí na trénovací množině dat. Jedná se o tzv. učení s učitelem. Trénovací množina obsahuje příznaky objektů s identifikátorem třídy, do které objekt patří. Na testovací množině se pak může klasifikátor otestovat, jak přesně dokáže klasifikovat. Není-li k dispozici trénovací množina, probíhá určování pravidel až při samotné klasifikaci. Tento způsob se nazývá učení bez učitele a je typický pro shlukování. [7]

### 7.1 Trénovací a testovací množina

Není vhodné použít množinu všech dat zároveň na trénování a testování klasifikátoru, protože hrozí tzv. přetrénování<sup>1</sup>. Množina všech dat se proto dělí na trénovací a testovací množinu. Na trénovací množině se klasifikátor naučí a na testovací vyzkouší, jak přesně dokáže klasifikovat. Existují různé způsoby, jak z celé množiny dat vybrat data na trénování a data na testování. [12]

---

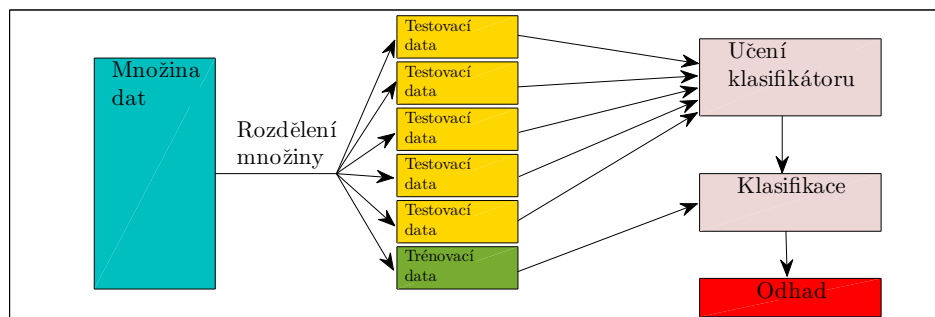
<sup>1</sup>Klasifikátor dobře klasifikuje na trénovací množině dat, ale má vysokou chybovost na datech, která mu nebyla v průběhu učení předložena.

### 7.1.1 Hold-out

Metoda *Hold-out* se zakládá na rozdělení množiny dat  $D$  na dvě stejně velké podmnožiny  $D_1$  a  $D_2$ . V první části se klasifikátor naučí na množině  $D_1$  a testuje na množině  $D_2$ . V druhé části se klasifikátor naučí na množině  $D_2$  a otestuje na  $D_1$ . Oba výsledky se zprůměrují. [12]

### 7.1.2 Krosvalidace

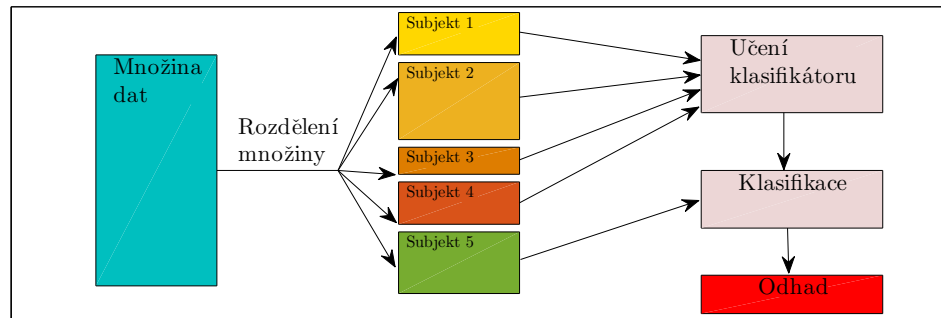
Křížová validace (*krosvalidace*) spočívá v rozdělení dat na  $k$  stejně velkých množin. Postupně se vždy jedna množina bere jako testovací množina a zbytek jako trénovací množina. Na trénovací množině se klasifikátor naučí klasifikovat a na testovací otestuje přesnost klasifikace. Z celkových  $k$  výsledků se vypočítá aritmetický průměr. [12]



Obrázek 7.1: Krosvalidace

#### 7.1.2.1 Leave-one-out

Jedna z variant krosvalidace je metoda *Leave-one-out*. Postupně se příznaky naměřené u jednoho konkrétního subjektu určí pro testování a na zbytku dat se klasifikátor naučí. Testování probíhá tolikrát, kolik je k dispozici naměřených subjektů. Výhodou je věrohodný odhad o tom, jak by byl klasifikován neznámý subjekt. [12]



Obrázek 7.2: Leave-one-out

## 7.2 Klasifikátory

### 7.2.1 Naivní Bayesovský klasifikátor

Bayesovský klasifikátor (NB) je základním statistickým klasifikátorem a vychází z Bayesova vztahu (7.1). Bayesův vztah vyjadřuje pravděpodobnost jevu  $\omega_j$  za splnění podmínky jevu  $x$ . [5, 12]

$$P(\omega_j|x) = \frac{P(x|\omega_j)P(\omega_j)}{P(x)} \quad (7.1)$$

Naivní Bayesovský klasifikátor předpokládá, že všechny jevy  $x_1, \dots, x_N$  jsou podmíněně nezávislé, platí-li jev  $\omega_j$ . To umožňuje vyjádřit pravděpodobnost  $P(\omega_j|x)$  pomocí součinů jednotlivých podmíněných pravděpodobností  $P(x_i|\omega_j)$  (7.2). [10]

$$P(\omega_j|x_1, \dots, x_N) = \frac{P(\omega_j)}{P(x_1, \dots, x_N)} \times \prod_{i=1}^N P(x_i|\omega_j) \quad (7.2)$$

Hodnoty  $P(\omega_j)$  a  $P(x_i|\omega_j)$  se určí při učení klasifikátoru. Klasifikace probíhá na základě přiřazení nejpravděpodobnější cílové hodnoty vzhledem k hodnotám příznaků  $x_1, \dots, x_N$ , kde  $\omega_{NB}$  označuje výstup klasifikátoru (7.3). [10]

$$\omega_{NB} = \arg \max_{\omega_j \in \Omega} P(\omega_j|x_1, \dots, x_N) \quad (7.3)$$

## 7.2.2 Neuronová síť

Neuronová síť je síť mnoha jednoduchých procesorů, které jsou mezi sebou vzájemně propojeny. Jednotlivé procesory se nazývají neurony, protože zjednodušeně modelují skutečné neurony nervové soustavy. Jedním z modelů neuronové sítě je vícevrstvý perceptron. [5,14]


### 7.2.2.1 Perceptron

Nejjednodušší model neuronové sítě je perceptron, který sestává z jednoho neuronu. Do neuronu vstupuje vektor  $x = [x_1, \dots, x_n]$ , který reprezentuje výstupy jiných neuronů nebo podněty z vnějšího okolí. Každý vstup  $x_i$  má příslušnou váhu  $w_i$ . Další vstupní veličinou do neuronu je tzv. práh  $\theta$ . [5,14]

Vážený součet (7.4) udává celkový podnět, tzv. potenciál neuronu. Na potenciál reaguje neuron výstupní odezvou  $z = S(\xi)$ , kde  $S$  je předepsaná nelineární přenosová funkce, obvykle tvaru sigmoidy (7.5). [14]

$$\xi = \sum_{i=1}^n w_i x_i - \theta \quad (7.4)$$

$$S(\xi) = \frac{1}{1 + \exp(-\lambda\xi)} \quad (7.5)$$




Obrázek 7.3: Schéma perceptronu

Zdroj: <http://cs.wikipedia.org/wiki/Perceptron#/media/File:Perceptron.png>

### 7.2.2.2 Vícevrstvý perceptron

Vícevrstvý perceptron (MLP) je složen z jednoduchých perceptronů. Jedná se o neuronovou síť s dopřednými vazbami. Skládá se ze tří částí: vstupní vrstvy, skryté vrstvy a výstupní vrstvy. Vstupní vrstva slouží k distribuci vstupních hodnot do sítě. Výstupy neuronů z jedné vrstvy jsou zároveň vstupy do neuronů následující vrstvy. Vazby mezi neurony se nacházejí pouze u neuronů ze sousedních vrstev, u neuronů ze vzdálenějších vrstev nebo ze stejné vrstvy nejsou žádné přímé vazby. Každý neuron má tedy tolik vstupů kolik je neuronů v nižší vrstvě. [5, 14]



Obrázek 7.4: Schéma vícevrstvého perceptronu

Zdroj: [http://is.mendelu.cz/eknihovna/opory/index.pl?fit\\_window=1;cast=21471](http://is.mendelu.cz/eknihovna/opory/index.pl?fit_window=1;cast=21471)

### 7.2.3 Rozhodovací strom

Rozhodovací strom reprezentuje sekvenci otázek. Bývá užitečný pro data nečíslného typu, protože na otázky týkající se stromů existuje odpověď typu „pravda/nepravda“, „ano/ne“ apod. Na vrcholu stromu se zobrazuje kořenový uzel (kořen), z kterého vede odkaz v závislosti na odpovědi do dalšího uzlu. Podobně jsou připojeny další uzly, které vedou až do koncových uzlů (listů). List nese označení kategorie, do které budou zařazeny testovaná data. Výhodou stromů je jednoduchá a přehledná interpretace. [5, 14]

### 7.2.3.1 Vytváření rozhodovacích stromů

Nejprve se vyhledá kořen tedy takový atribut, který nese největší množství informace. Dále se rozdělí množina příkladů na podmnožiny, kterých je tolik jako hodnot kořenového atributu. Každá podmnožina obsahuje příklady s právě jednou hodnotou tohoto atributu. V každé z podmnožin se vyhledá další atribut nesoucí největší množství informace. Rekurzivně se pokračuje dokud nebudou vyčerpány atributy, příklady nebo nebude splněna předem daná podmínka. [5, 14]

Množství informace se nejčastěji počítá pomocí entropie (7.6). Váženým součtem entropií jednotlivých podmnožin je dána celková entropie (7.7). [14]

$$H_j = -p_1 \log_2 p_1 - p_2 \log_2 p_2 \quad (7.6)$$

$p_1$  - poměr pozitivních příznaků v  $j$ -té podmnožině k celkovému počtu prvků v podmnožině

$p_2$  - poměr negativních příznaků v  $j$ -té podmnožině k celkovému počtu prvků v podmnožině

$$H = \sum_{j=1}^K P_j H_j \quad (7.7)$$

$K$  - počet podmnožin vycházející z jednoho atributu

$P_j$  - poměr velikosti  $j$ -té podmnožiny k množině všech příkladů

$H_j$  - entropie  $j$ -té podmnožiny

### 7.2.3.2 Rozhodovací strom C4.5

Rozhodovací strom *C4.5* používá k vybrání nejlepšího příznaku a rozdělení množin *gain ratio*. Narozdíl od informačního zisku (*info gain*), který upřednostňuje vybírání atributů, jenž mají velký počet hodnot, používá *gain ratio* informaci o poměru a tím tuto zaujatost eliminuje. [11]

Dalším rozdílem oproti běžným rozhodovacím stromům je, že *C4.5* dokáže pracovat s chybějícími daty. V uzlu, který byl dotázán na chybějící příznak, jsou následovány všechny potomky uzlu. [5]

# Kapitola 8

## Experiment

### 8.1 Seznam měřených subjektů

Pro experiment byla poskytnuta data (tab. C.1) z měření EEG v průběhu mentální rotace u 26-ti adolescentů. Věk adolescentů se pohyboval v rozmezí 15 až 20 let. Měření se zúčastnilo 10 žen a 16 mužů. Mezi měřenými subjekty byli tři leváci. Všichni měli normální nebo korigovaný zrak. Žádný z měřených subjektů nebral léky, které by mohly mít vliv na záznam EEG. Adolescenti byli podle IQ rozděleni do dvou skupin na nadané<sup>1</sup> a průměrně nadané.

### 8.2 Měření

Úkolem subjektů bylo v průběhu řešení stimulů co nejrychleji a nejpresněji určit, zda se jedná stimuly identické nebo zrcadlené. Správnost odpovědí a reakční časy byly měřeny zároveň s EEG. Měření EEG trvalo cca 25 minut.

#### 8.2.1 Průběh experimentu


- Seznámení subjektu s experimentem
- Měření EEG

1. Měření klidové aktivity - zavřené oči


---

<sup>1</sup>Do skupiny mezi nadané se řadí subjekty s IQ vyšším než 130.


2. Měření klidové aktivity - otevřené oči
  3. Ukázka vzorových stimulů
  4. Řešení 2D stimulů s různou složitostí (obr. 8.1, obr. 8.2)
  5. Řešení 3D stimulů s různou složitostí (obr. 8.3, obr. 8.4)
- Vyplnění osobního dotazníku (věk, pohlaví, lateralita,...)
  - Vyplnění dotazníku týkajícího se způsobu řešení
  - Ravenův IQ test
  - Psychologický dotazník<sup>2</sup> - AQ, EQ, SQ




Obrázek 8.1: 2D stimulus - identický



Obrázek 8.2: 2D stimulus - zrcadlený



Obrázek 8.3: 3D stimulus - identický



Obrázek 8.4: 3D stimulus - zrcadlený

### 8.2.2 Elektroencefalograf

Měření EEG probíhalo elektroencefalografem o vzorkovací frekvenci 250 Hz. K dispozici byly povrchové AgCl elektrody ve standardním zapojení 10-20. Pro kontakt elektrody s pokožkou hlavy byl použit gel. Zapojení elektrod bylo unipolární s referenční elektrodou v oblasti FCz.

<sup>2</sup>Psychologický dotazník pro zpracování behaviorálních dat. AQ - kvocient autistického spektra, EQ - emoční kvocient, SQ - spirituální kvocient.



## 8.3 Předzpracování dat

Práce se signálem a výpočet příznaků probíhal v softwarovém prostředí Matlab<sup>3</sup>. Byl použit toolbox PSGlab<sup>4</sup> doplněný o vlastní funkce.

Z toolboxu PSGlab byly použity funkce: *options.run\_load\_dfile* pro načtení D souborů (\*.d) do formátu pro práci v Matlabu, *options.run\_data\_resampling* pro převzorkování signálu z 250 Hz na 128 Hz, *options.run\_data\_filtering\_50hz* pro filtrování frekvence 50 Hz a *options.run\_data\_new\_excl* pro konverzi starých časových údajů (např. hranice segmentů) na nové.

### 8.3.1 Artefakty

Detekce artefaktů probíhala manuálně pomocí funkce *artefakty\_vizualne*. V signálu se často objevovaly artefakty vzniklé výpadkem elektrody, svalové artefakty a oční artefakty (tab. C.2). Měřené signály u tří subjektů musely být v důsledku velkého rušení a častého výskytu artefaktů z experimentu odstraněny. Dále byly odstraněny jednotlivé elektrody, kde signál podléhal velkému rušení nebo kde se objevovaly časté výpadky elektrod.

### 8.3.2 Segmenty

Segmenty byly rozděleny podle odpovědí měřených subjektů. Každá odpověď zahrnovala informaci o tom, zda porovnávané obrázky byly posouzeny subjektem jako identické nebo jako zrcadlené. V závislosti na dimenzi obrázku obsahovala odpověď ještě informaci o tom, jestli se jednalo o 2D nebo 3D stimulus.

---

<sup>3</sup>Vysokoúrovňový programovací jazyk. [www.mathworks.com/products/matlab/](http://www.mathworks.com/products/matlab/)

<sup>4</sup><http://bio.felk.cvut.cz/psglab/>

Tabulka 8.1: Rozdělení segmentů

Segment	Označení	Komentář
Zavřené oči	1	Měření klidové aktivity zavřených očí, doba trvání 30 sekund
Otevřené oči	2	Měření klidové aktivity otevřených očí, doba trvání 60 sekund
2D stejné	21	2D stimulus označen subjektem jako identický
2D zrcadlené	22	2D stimulus označen subjektem jako zrcadlený
3D stejné	31	3D stimulus označen subjektem jako identický
3D zrcadlené	32	3D stimulus označen subjektem jako zrcadlený

### 8.3.3 Příznaky

Frekvenční (tab. 8.2) a statistické (tab. 8.3) příznaky byly spočítány pro každý segment pomocí funkce z toolboxu PSGlab *options.run\_feature\_extraction\_default*. Jednotlivé segmenty byly přiřazeny k příslušným příznakům pomocí funkce *konecne\_segmenty*. Pro export příznaků do programu *Weka*<sup>5</sup> byly použity funkce *to\_weka*<sup>6</sup>, *to\_weka\_l1o*<sup>7</sup> a *to\_weka\_l1o\_best*<sup>8</sup>.

Tabulka 8.2: Frekvenční příznaky

Příznak	Jednotka	Interval
Alfa	$\mu V^2/Hz$	$\langle 7; 12 \rangle$ Hz
Beta	$\mu V^2/Hz$	$\langle 12; 30 \rangle$ Hz
Gama	$\mu V^2/Hz$	$\langle 30; 40 \rangle$ Hz

<sup>5</sup>Program, který obsahuje nástroje pro předzpracování dat, klasifikaci, regresi, shlukování a vizualizaci výsledků. <http://www.cs.waikato.ac.nz/ml/weka/>

<sup>6</sup>Export zadaných příznaků ze všech elektrod do formátu pro použití krosvalidace

<sup>7</sup>Export zadaných příznaků ze všech elektrod do formátu pro použití leave one out

<sup>8</sup>Export nejlepších příznaků do formátu pro použití leave one out

Tabulka 8.3: Statistické příznaky

Příznak	Označení	Vzorec
Minimum	minvalue	-
Maximum	maxvalue	-
Střední hodnota	mean	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$
Směrodatná odchylka	std	$s_x = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
Koeficient šikmosti	skewness	$\alpha = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{s_x^3}$
Koeficient špičatosti	kurtosis	$\beta = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{s_x^4} - 3$
Medián	median	$\tilde{x}_{0.5} = \begin{cases} x_{([0.5n]+1)}, & 0.5n \neq [0.5n] \\ \frac{x_{(0.5n)} + x_{(0.5n+1)}}{2}, & 0.5n = [0.5n] \end{cases}$



# Kapitola 9

## Výsledky

Selekce a klasifikace výsledků probíhala v programu *Weka* pro příznaky naměřené zvlášť při 2D stimulech a při 3D stimulech. Z výsledků selekce a klasifikace by měly být patrné rozdíly v zapojení různých částí mozku pro řešení 2D a 3D stimulů. Rozdíly by se měly projevit i ve vizualizaci výkonového spektra.

### 9.1 Selekcce

Pro selekci příznaků byla použita funkce *GreedyStepwise*, která má jako parametr volbu mezi dopřednou selekcí a zpětnou eliminací. Selekcce probíhala na frekvenčních přízracích (tab. 8.2), statistických přízracích (tab. 8.3) a dále zvlášť na přízracích alfa, beta a gama.

Tabulka 9.1: Selekcce příznaků 2D

<b>Příznaky</b>	<b>Dopředná selekce</b>	<b>Zpětná selekce</b>
Frekvenční	F4-gama,O1-gama, T4-gama,Fz-alfa, Fz-beta,Fz-gama, Cz-alfa,Cz-beta	F4-gama,O1-gama, T4-gama,Fz-alfa, Fz-beta,Fz-gama, Cz-alfa,Cz-beta
Statistické	F4-skewness,F7-std, F8-kurtosis,F8-std, Fz-minvalue,Fz-std, Fz-maxvalue,Cz-std, Cz-kurtosis	F4-skewness,F7-std, F8-kurtosis,F8-std, Fz-minvalue,Fz-std, Fz-maxvalue,Cz-std, Cz-kurtosis
Alfa	Fz,Cz	Fz,Cz
Beta	T4,Fz,Cz	T4,Fz,Cz
Gama	F4,O1,T4,Fz	F4,O1,T4,Fz

Tabulka 9.2: Selekcce příznaků 3D

<b>Příznaky</b>	<b>Dopředná selekce</b>	<b>Zpětná selekce</b>
Frekvenční	Fz-alfa,Fz-beta, Fz-gama,Cz-alfa	Fz-alfa,Fz-beta, Fz-gama,Cz-alfa
Statistické	F7-kurtosis,F7-std, Fz-minvalue,Fz-median, Fz-maxvalue,Fz-std, Cz-kurtosis,Cz-std	F7-kurtosis,F7-std, Fz-minvalue,Fz-median, Fz-maxvalue,Fz-std, Cz-kurtosis,Cz-std
Alfa	Fz,Cz	Fz,Cz
Beta	Fz,Cz	Fz,Cz
Gama	O1,T4,Fz,Cz	O1,T4,Fz,Cz

Dopředná selekce i zpětná eliminace vykazují stejné výsledky. Nejčastější zastoupení ve vybraných příznacích mají příznaky z elektrod Fz a Cz. To naznačuje rozdílnou mozkovou činnost mezi hemisférami ve frontální a centrální části. Největší zastoupení u statistických příznaků má směrodatná odchylka. Naopak žádné z vybraných příznaků nepochází z parietálních a frontopolárních elektrod. U frontopolárních elektrod se často projevují oční artefakty, proto zde nemusí být žádný rozdíl mezi oběma skupinami.

## 9.2 Klasifikace

Pro klasifikaci byly použity funkce *NaiveBayes*, *MultilayerPerceptron* a *J48*<sup>1</sup> implementovány v programu *Weka*. Nejdříve byly porovnány klasifikátory a vybral se nejvhodnější z nich. Dále se provedla klasifikace *Leave-one-out*, kde byly vyřazeny subjekty, které nebyly správně klasifikovány. Nakonec byly subjekty klasifikovány podle hemisfér a jednotlivých laloků, kde byly patrné rozdíly v zapojování různých částí mozku u nadaných oproti průměrně nadaným adolescentům.

### 9.2.1 Porovnání klasifikátorů

Klasifikátory byly porovnány na výsledcích naměřených při 2D stimulech. Byla použita krosvalidace, kde množina příznaků byla rozdělena na 10 podmnožin. Klasifikace proběhla na všech příznacích dané skupiny příznaků i na příznacích selektovaných (tab. 9.1).

Tabulka 9.3: Porovnání klasifikátorů - 2D stimuly

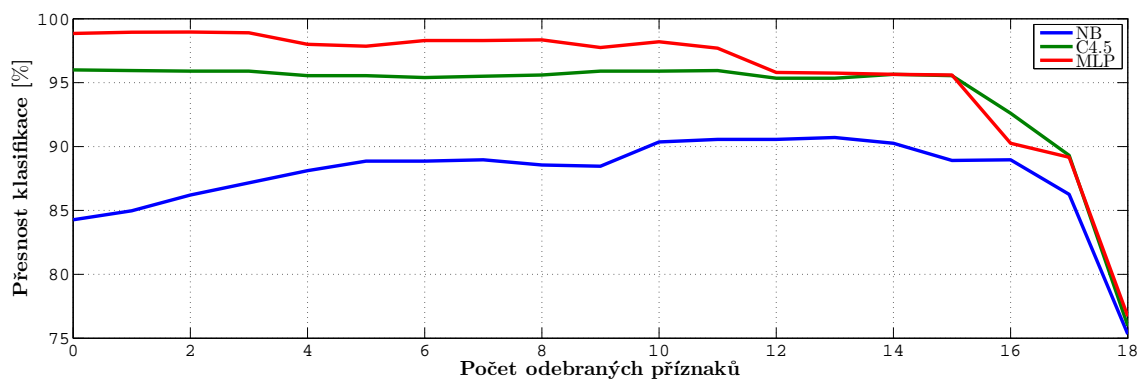
Klasifikátor	C4.5		NB		MLP	
	Všechny příznaky	Selektované příznaky	Všechny příznaky	Selektované příznaky	Všechny příznaky	Selektované příznaky
Frekvenční	96.80	97.20	92.41	92.81	99.30	97.50
Statistické	93.01	92.71	82.72	81.02	97.75	95.01
Alfa	93.01	90.41	91.31	90.91	95.45	90.41
Beta	96.30	95.85	89.26	92.56	99.10	95.65
Gama	93.26	88.36	84.87	84.12	97.75	88.41

Největší chybu klasifikace na celé množině příznaků vykazuje NB, naopak nejlépe klasifikuje MLP. Rozhodovací strom C4.5 má srovnatelnou přesnost klasifikace na množině selektovaných příznaků jako MLP a o cca 3 % horší na celé množině daných příznaků.

Přesnost klasifikace selektovaných příznaků u klasifikátoru C4.5 a NB je ve většině případech podobná jako jejich klasifikace na celé množině příznaků. U MLP se zhoršila přesnost klasifikace na množině selektovaných příznaků oproti klasifikaci na množině všech příznaků průměrně o 4.5 %.

<sup>1</sup>Funkce s implementací rozhodovacího stromu C4.5

Další způsob porovnání klasifikátorů byl proveden pomocí zpětné eliminace, kde byly postupně z celé množiny daných příznaků odebírány nejhorší příznaky. V každém kroku byly testovány jednotlivé klasifikátory. Testování proběhlo na beta příznacích naměřených při 2D stimulech.



Obrázek 9.1: Závislost přesnosti klasifikace na počtu příznaků - beta 2D

S odebíráním nejhorších příznaků postupně roste přesnost NB, ale i v nejlepším případě je o cca 5 % horší než u MLP a C4.5. Přesnost C4.5 se téměř vůbec nemění až do odebrání 15. příznaku. Díky vnitřní selekci rozhodovacích stromů může C4.5 celou dobu pracovat jen s těmi nejlepšími příznaky. MLP je až do odebrání 11. příznaku lepší o 2 až 3 % než C4.5 a v další části jsou oba klasifikátory srovnatelné.

Jako klasifikátor se nejlépe jeví C4.5. Má lepší klasifikační schopnost než NB a na menší množině příznaků je srovnatelný i s MLP. Jeho časová náročnost je značně nižší než u MLP<sup>2</sup> a výsledky rozhodovacího stromu se dají snadno interpretovat (obr. B.2).

## 9.2.2 Leave-one-out

Příznaky pro každý subjekt byly postupně brány jako testovací množina a příznaky ostatních tvořily trénovací množinu. Pro klasifikaci byla použita funkce *J48*.

<sup>2</sup>Klasifikace příznaků beta trvala funkcí *MultilayerPerceptron* přes 1 minutu. Klasifikace pomocí funkce *J48* proběhla za cca 4 sekundy.



Tabulka 9.4: Leave-one-out

<b>Jméno</b>	<b>Frekvenční 2D</b>	<b>Frekvenční 3D</b>	<b>Statistické 2D</b>	<b>Statistické 3D</b>
1313	100	98.28	100	100
2332	85.11	94.55	80.85	83.64
42292	97.78	100	88.89	77.55
elmo2	96.00	100	100	96.00
nuzky	100	100	100	100
tarzan	96.88	96.55	95.83	98.28
will	98.94	100	97.87	100
delizrout	100	100	100	97.96
jedle	100	98.11	84.27	86.79
klara	96.88	94.83	94.79	91.38
mcslunicko	98.95	82.14	100	94.64
objekt14	98.80	100	96.39	100
peta	72.92	31.03	54.17	87.93
tomas	97.65	56.00	77.65	78.00
Johny	100	100	98.82	98.25
Ludek	100	100	100	100
Najanaa	98.92	100	95.70	98.25
Michal5	96.88	100	86.46	74.14
Mikro97	100	100	92.86	94.64
Yuillya	98.94	100	100	100
zanet	52.87	4.88	33.33	19.51
tadeas	3.26	1.75	78.26	56.14
tucnak2	50.00	73.68	11.46	14.04
<b>Průměr</b>	88.73	84.00	85.55	84.66

Špatná klasifikace proběhla celkem v 8 případech a projevila se u 4 subjektů. Z experimentu byly vyřazeny subjekty, které byly klasifikovány špatně více než jednou, tedy zanet, tadeas, tucnak2. Nejvyšší přesnost klasifikace se projevila u subjektů Nuzky a Ludek.

### 9.2.3 Klasifikace v jednotlivých částech mozku

Pro zjištění rozdílů v zapojení různých částí mozku nadaných a průměrně nadaných byla provedena klasifikace, která zahrnovala příznaky alfa, beta a gama z jednotlivých laloků a hemisfér. Pro klasifikaci byla použita funkce  $J_48$ .

#### 9.2.3.1 Klasifikace podle hemisfér

Tabulka 9.5: Klasifikace podle hemisfér - 2D

Část mozku	Alfa	Beta	Gama	Průměr
Pravá hemisféra	77.59	89.35	84.19	83.71
Levá hemisféra	82.98	91.49	90.21	88.23
Mediální oblast	99.77	99.71	97.97	99.15
<b>Průměr</b>	86.78	93.52	90.79	-

Tabulka 9.6: Klasifikace podle hemisfér - 3D

Část mozku	Alfa	Beta	Gama	Průměr
Pravá hemisféra	76.74	88.89	86.72	84.12
Levá hemisféra	81.36	92.00	86.53	86.63
Mediální oblast	99.53	99.81	97.83	99.06
<b>Průměr</b>	85.88	93.57	90.36	-

Mezi klasifikacemi pro 2D a 3D stimulus nejsou výrazné rozdíly. Jediný větší rozdíl se týká klasifikace příznaku gama podle levé hemisféry. Nejlepší klasifikaci vykazuje mediální oblast (elektrody Fz, Cz, Pz), kde je průměrná přesnost klasifikace téměř 100 %. Klasifikace podle levé hemisféry vychází ve většině případů lépe než podle pravé hemisféry. Nejlepší příznak beta dosahuje průměrné přesnosti klasifikace přes 93 %. Nejhorším z frekvenčních příznaků je alfa.

## 9.2.3.2 Klasifikace podle laloků

Tabulka 9.7: Klasifikace v jednotlivých lalocích - 2D

Část mozku	Alfa	Beta	Gama	Průměr
Frontopolární	76.61	79.91	78.34	78.29
Frontální	97.28	98.67	91.89	95.95
Parietální	74.81	76.38	75.85	75.68
Temporální	72.43	78.40	75.91	75.58
Okcipitální	74.00	84.89	84.95	81.28
Centrální	97.92	95.66	82.74	92.11
<b>Průměr</b>	82.18	85.65	81.61	-

Tabulka 9.8: Klasifikace v jednotlivých lalocích - 3D


Část mozku	Alfa	Beta	Gama	Průměr
Frontopolární	72.69	84.09	79.76	78.85
Frontální	97.27	98.78	92.56	96.20
Parietální	69.40	72.32	68.46	70.06
Temporální	69.11	74.48	73.73	72.44
Okcipitální	71.19	79.38	79.47	76.68
Centrální	96.99	95.76	82.02	91.59
<b>Průměr</b>	79.44	84.14	79.33	-

Největším rozdílem mezi 2D a 3D stimulem je přesnost klasifikace podle parietálního a okcipitálního laloku, kde je v obou případech průměrná přesnost klasifikace větší o cca 5 % u 2D stimulu než u 3D stimulu. Nejlepší klasifikaci vykazuje frontální lalok s průměrnou přesností klasifikace kolem 96 % a dále centrální lalok s průměrnou přesností klasifikace 92 %. Naopak nejhorší klasifikace je podle parietálního a temporálního laloku.


## 9.3 EEG

Pro vykreslení výkonů frekvenčního spektra byla použita funkce *topoplot* z toolboxu EEGLab<sup>3</sup>. Byla vykreslena výkonová spektra alfa, beta a gama vln pro 2D i 3D stimuly u nadaných a průměrně nadaných adolescentů. Dále byla provedena vizualizace aktivnějších oblastí nadaných oproti průměrně nadaným.

### 9.3.1 Alfa




Obrázek 9.2: Alfa aktivita 2D



Obrázek 9.3: Alfa aktivita 3D

<sup>3</sup><http://scn.ucsd.edu/eeglab/>




Obrázek 9.4: Aktivnější oblasti u nadaných oproti průměrně nadaným - alfa aktivita


Alfa aktivita u obou skupin je výrazná zejména v okcipitálním laloku a dále v parietálním a temporálních lalocích (obr. 9.2, obr. 9.3). Mezi aktivitou při řešení 2D a 3D stimulů není u obou skupin téměř žádný rozdíl.

Největší rozdíl mezi nadanými a průměrně nadanými adolescenty je patrný v zapojení částí, které jsou snímány elektrodami Fz a Cz (obr. 9.4), což potvrzuje i selekce příznaků alfa (tab. 9.1, tab. 9.2).


### 9.3.2 Beta



Obrázek 9.5: Beta aktivita 2D



Obrázek 9.6: Beta aktivita 3D




Obrázek 9.7: Aktivnější oblasti u nadaných oproti průměrně nadaným - beta aktivita


Beta aktivita u průměrně nadaných se projevuje zejména v okcipitální části mozku a směrem k frontopolárnímu laloku je vidět postupný pokles aktivity (obr. 9.5, obr. 9.6). Jak u nadaných tak i u průměrně nadaných pracují obě hemisféry téměř identicky.

V porovnání nadaných a průměrně nadaných adolescentů jsou patrné (stejně jako u alfa aktivity) rozdíly především v aktivitě snímané elektrodami Fz a Cz. Dále je patrný rozdíl v zapojení temporálních laloků, který se projevuje především při řešení 3D stimulů (obr. 9.7).


## 9.3.3 Gama



Obrázek 9.8: Gama aktivita 2D



Obrázek 9.9: Gama aktivita 3D

Obrázek 9.10: Aktivnější oblasti u nadaných oproti průměrně nadaným -  
gama aktivita

Stejně jako beta i gama aktivita vykazuje nejvyšší činnost v okcipitálním laloku. Nadaní zapojují především levou hemisféru mozku, zatímco u průměrně nadaných není patrná zvýšená aktivita nikde, kromě okcipitálního a části parietálního laloku (obr. 9.8, obr. 9.9). U průměrně nadaných je vidět částečný pokles v aktivitě v řešení 3D stimulů oproti 2D stimulům.

Nadaní oproti průměrně nadaným mají v průběhu řešení 2D stimulů zvýšenou aktivitu na elektrodě Fz. V průběhu 3D stimulů jsou rozdíly ještě výraznější. Vyšší aktivita se projevuje zejména v levém temporálním laloku a v přední části pravé hemisféry (obr. 9.10).



# Kapitola 10

## Diskuse a závěr

Celkem 26 jedinců ve věku 15-20 let se zúčastnilo experimentu, ve kterém jim bylo v průběhu řešení úlohy mentální rotace snímáno EEG. Každému ze subjektů bylo promítnuto 96 2D a 58 3D párů obrázků. Úkolem bylo co nejrychleji a nejpřesněji určit zda jsou obrázky identické nebo zrcadlené. Po naměření EEG každý ze subjektů vyplnil osobní dotazník a dotazník týkající se postupu řešení. Dále se každý subjekt zúčastnil psychologických testů pro zjištění AQ, EQ a SQ a Ravenova IQ testu, podle kterého byly rozděleny do dvou skupin na nadané a průměrně nadané.

Z naměřeného EEG bylo potřeba vyfiltrovat frekvenci 50 Hz vzniklou síťovým rušením a detekovat artefakty. Nejčastěji se v signálech vyskytovaly svalové a oční artefakty a artefakty vzniklé špatným kontaktem elektrody. U subjektů byly vyřazeny segmenty s výskytem artefaktů a ve zbylých segmentech byly spočítány frekvenční a statistické příznaky.

Pomocí selekce bylo snahou určit, které příznaky od sebe nejlépe oddělují obě skupiny. Nejlepší frekvenční příznaky byly příznaky z elektrod Fz a Cz a dále z elektrod O1 a T4 u příznaku gama. Mezi statistickými příznaky figurovaly příznaky naměřené ve frontálním a centrálním laloku.

Pro klasifikaci bylo nejprve nutné vybrat vhodný klasifikátor. Otestovány byly 3 klasifikátory: *naivní Bayesovský klasifikátor*, *vícevrstvý perceptron* a *rozhodovací strom C4.5*. Porovnávána byla jejich schopnost přesně klasifikovat na všech a na selektovaných příznacích dané skupiny. Nejhorší klasifikační schopnost se projevila u *NB*. Nejlepší schopnost klasifikovat na všech příznacích měl *MLP*. Na množině selektovaných příznaků byly klasifikátory *MLP* a *C4.5* srovnatelné. Kvůli výpočetní náročnosti *MLP* a dobré

interpretovatelnosti rozhodovacího stromu byl nakonec pro další klasifikaci vybrán klasifikátor *C4.5*.

Pro vyloučení špatně klasifikovaných subjektů byla použita metoda *Leave-one-out*. Příznaky jednoho subjektu byly určeny na testování, zatímco příznaky ostatních subjektů tvořily trénovací množinu, na které se klasifikátor naučil. Klasifikace proběhla na frekvenčních a statistických příznacích naměřených při řešení 2D i 3D stimulů. Z experimentu byly vyřazeny subjekty, které byly chybně klasifikovány více než jednou.

Pro zjištění, jak dobře lze obě skupiny klasifikovat podle různých částí mozku, byla provedena klasifikace podle hemisfér a podle laloků na frekvenčních příznacích. Nejlépe šlo klasifikovat podle mediální oblasti. Z obou hemisfér bylo dosaženo lepších výsledků pomocí příznaků z levé hemisféry. Jako nejlepší příznak se projevil příznak beta a nejhorším příznakem byl příznak alfa. Z laloků klasifikoval nejlépe frontální a centrální lalok. Z příznaků opět klasifikoval nejlépe příznak beta a přesnost klasifikace u příznaků alfa a gama byla srovnatelná.

Z vykreslení výkonu frekvenčního spektra se projeví rozdíly na elektrodách Fz a Cz. Na elektrodě Fz měli nadaní zvýšenou aktivitu oproti průměrně nadaným, zatímco na Cz ji měli nižší. U beta aktivity nadaných adolescentů se projevila zvýšená činnost obou hemisfér a to hlavně u 3D stimulů, kde byl zapojen především levý temporální lalok. Stejně jako u beta i u gama aktivity se projevila zvýšená aktivita u nadaných v levém temporálním laloku a s ním i vyšší aktivita v pravé části frontálního laloku.

Zapojení frontálního laloku společně s vyšší aktivitou v levé hemisféře se shoduje s fMRI studií, kterou provedl M. W. O'Boyle [16]. Zvýšená aktivita střední části frontálního laloku u nadaných může být způsobena zapojením asociačních center v průběhu řešení úlohy. Zapojováním těchto center v průběhu řešení úloh logického charakteru může pomoci k dosažení lepších výsledků.

# Literatura

- [1] ALIVISATOS, Bessie; PETRIDES, Michael: Functional activation of the human brain during mental rotation. *Neuropsychologia*, ročník 35, č. 2, 1997, s. 111–118.
- [2] ATKINSON, Rita L.: *Psychologie*. Praha: Victoria Publishing, 1995, ISBN 808560535x.
- [3] BERKA, Petr. *Bayesovská klasifikace* [online]. 3.10.2009 [cit. 2015-04-14]. Dostupné z: [http://sorry.vse.cz/~berka/docs/izi456/kap\\_5.6.pdf](http://sorry.vse.cz/~berka/docs/izi456/kap_5.6.pdf)
- [4] COOPER, Lynn A.: Mental rotation of random two-dimensional shapes. *Cognitive psychology*, ročník 7, č. 1, 1975, s. 20–43.
- [5] DUDA, Richard; HART, Peter E.; STORK, David G.: *Pattern classification*. New York: J. Wiley, druhé vydání, 2001, ISBN 0471056693.
- [6] HAASZ, Vladimír; SEDLÁČEK, Miloš: *Elektrická měření: přístroje a metody*. Praha: Vydavatelství ČVUT, 2003, ISBN 8001027317.
- [7] HOLČÍK, Jiří: *Analýza a klasifikace dat*. Brno: Akademické nakladatelství CERM, 2012, ISBN 9788072047932.
- [8] JORDAN, K.; HEINZE, H.-J.; LUTZ, K.; aj.: Cortical Activations during the Mental Rotation of Different Visual Objects. *NeuroImage*, ročník 13, č. 1, 2001, s. 143–152.
- [9] Kandel, Eric R.; Schwartz, James H.; Jessell, Thomas M.; aj.: *Principles of neural science*, ročník 4. New York: McGraw-Hill, 2000.
- [10] KANTARCIOGLU, M.; VAIDYA, J.; CLIFTON, C.: Privacy preserving naive bayes classifier for horizontally partitioned data. *IEEE ICDM workshop on privacy preserving data mining*[online], 2003, s. 3–9. Dostupné z: <http://www.cis.syr.edu/~wedu/ppdm2003/papers/1.pdf>

- [11] Karegowda, A. G.; Manjunath, A. S.; Jayaram, M. A.: Comparative study of attribute selection using gain ratio and correlation based feature selection. *International Journal of Information Technology and Knowledge Management*, ročník 2, č. 2, 2010, s. 271–277.
- [12] KUNCHEVA, Ludmila I.: *Combining pattern classifiers: methods and algorithms*. John Wiley & Sons, 2004, ISBN 9780471210788.
- [13] LIU, Huan; MOTODA, Hiroshi: *Computational methods of feature selection*. Boca Raton: Chapman & Hall/CRC, c2008, ISBN 9781584888789.
- [14] MAŘÍK, Vladimír; ŠTĚPÁNKOVÁ, Olga; LAŽANSKÝ, Jiří; aj.: *Umělá inteligence*. Praha: Academia, první vydání, 1993, ISBN 8020004963.
- [15] O'BOYLE, Michael W.: Mathematically Gifted Children: Developmental Brain Characteristics and Their Prognosis for Well-Being. *Roeper Review*, ročník 30, č. 3, 2008, s. 181–186.
- [16] O'BOYLE, Michael W.; CUNNINGTON, R.; SILK, T. J.; aj.: Mathematically gifted male adolescents activate a unique brain network during mental rotation. *Cognitive Brain Research*, ročník 25, č. 2, 2005, s. 253–257.
- [17] OSTRÁ, Anežka: *Adaptivní segmentace EEG signálu*. Brno, 2012. Bakalářská práce. VUT v Brně, Fakulta elektrotechniky a komunikačních technologií.
- [18] PETERS, Michael; BATTISTA, C.: Applications of mental rotation figures of the Shepard and Metzler type and description of a mental rotation stimulus library. *Brain and cognition*, ročník 66, č. 3, 2008, s. 260–264.
- [19] PETERS, M.; LAENG, B.; LATHAM, K.; aj.: A Redrawn Vandenberg and Kuse Mental Rotations Test - Different Versions and Factors That Affect Performance. *Brain and Cognition*, ročník 28, č. 1, 1995, s. 39–58.
- [20] *Popisná statistika* [online]. 17.12.2009 [cit. 2015-03-29].  
Dostupné z: <http://mant.upol.cz/soubory/MC/p13.pdf>
- [21] Rozhovory s MUDr. Ladislavem REZNEREM, neurologem v nemocnici Boskovice. Brno, 10.–29.4.2015.
- [22] SANEI, Saeid; CHAMBERS, Jonathon A.: *EEG signal processing*. NJ: John Wiley & Sons, 2007, ISBN 0470025816.

- [23] SHANNON, Claude E.: Communication in the Presence of Noise. *PROCEEDINGS OF THE IEEE*, ročník 86, č. 2, 1998.
- [24] SHEPARD, R. N.; METZLER, J.: Mental rotation of three-dimensional objects. *Science*, ročník 171, č. 3972, únor 1971, s. 701–703.
- [25] STERNBERG, Robert J.: Kognitivní psychologie. Praha: Portál, 2002, ISBN 8071783765
- [26] TONG, Shanbao; THAKOR, Nitish Vyomesh: *Quantitative EEG analysis methods and clinical applications*. Boston: Artech House, 2009.
- [27] VOJTĚCH, Zdeněk.: *EEG v epileptologii dospělých*. Praha: Grada, 2005, ISBN 8024706903.
- [28] VOLF, Petr: *EEG signal analysis of mentally gifted children*. Praha, 2013. Diplomová práce. ČVUT v Praze, Fakulta elektrotechnická.



# Příloha A

## Seznam zkratk


<b>AQ</b>	Kvociet autistického spektra
<b>C</b>	Centralní
<b>EEG</b>	Elektroencefalograf
<b>EQ</b>	Emoční kvociet
<b>F</b>	Frontální
<b>FFT</b>	Rychlá Fourierova transformace (Fast Fourier transform)
<b>fMRI</b>	Funkční magnetická rezonance
<b>Fp</b>	Frontopolární
<b>IQ</b>	Intelligenční kvociet
<b>MLP</b>	Vícevrstvý perceptron (Multilayer perceptron)
<b>NB</b>	Naivní Bayesovský klasifikátor (Naive Bayes)
<b>O</b>	Okcipitální
<b>P</b>	Parietální
<b>SQ</b>	Spirituální kvociet



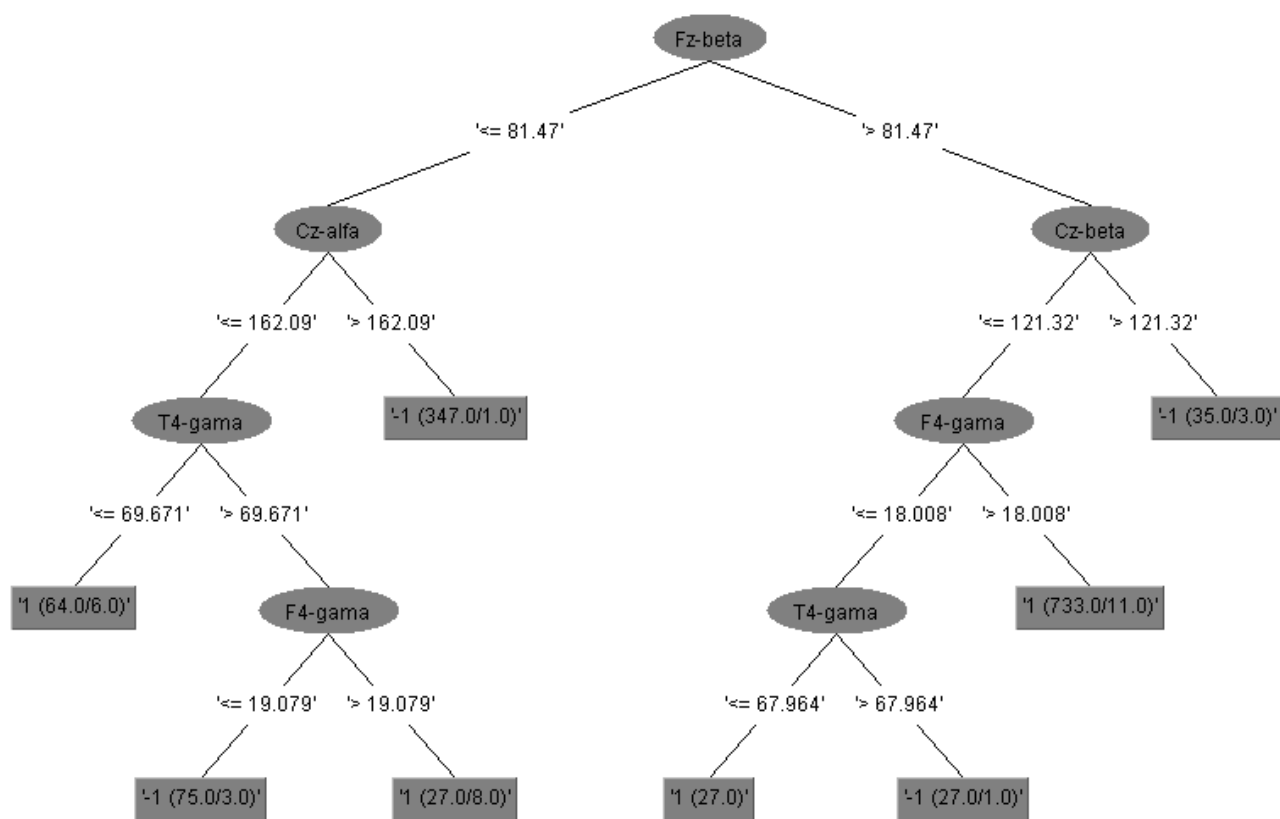


# Příloha B

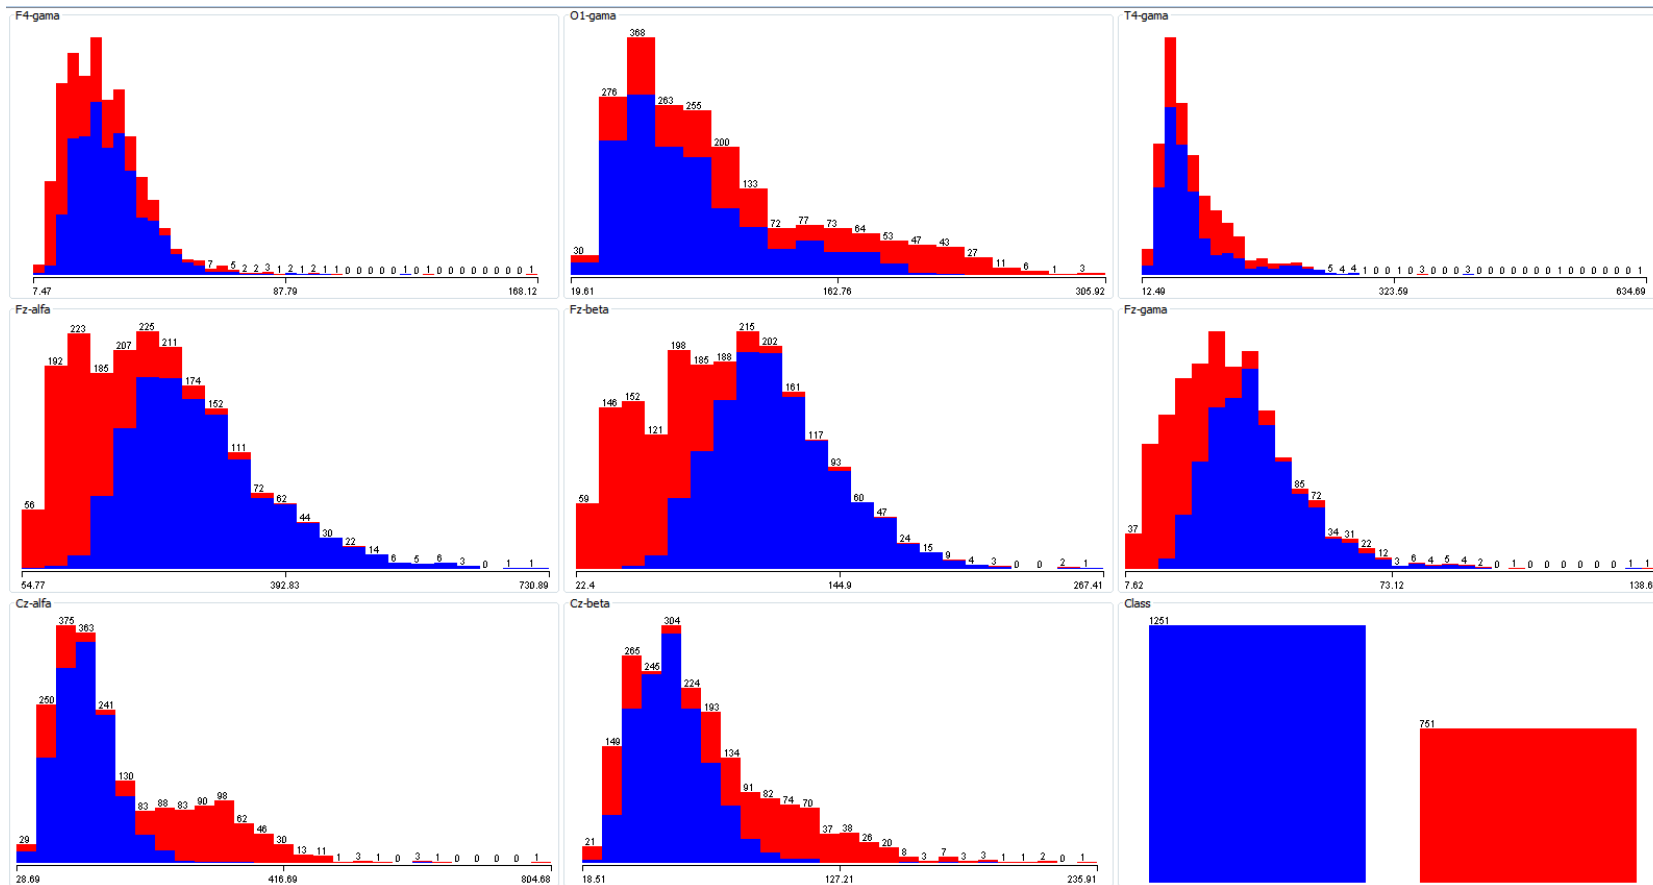
## Obrázky



Obrázek B.1: Záznam EEG signálu při zavřených očích  
Zdroj: Nemocnice Boskovice, duben 2015



Obrázek B.2: Příklad rozhodovacího stromu



Obrázek B.3: Histogram selektovaných frekvenčních příznaků pro 2D stimuly



# Příloha C

## Tabulky

Jméno	Pohlaví	Věk	Lateralita	IQ
333	Ž	16	P	> 130
1313	Ž	17	P	> 130
2332	M	16	P	> 130
42292	Ž	16	P	> 130
elmo2	M	16	P	> 130
nuzky	M	16	P	> 130
tarzan	Ž	16	P	> 130
will	M	16	P	> 130
delizrout	Ž	15	P	> 130
jedle	M	15	P	> 130
klara	Ž	15	P	> 130
mcslunicko	M	15	P	> 130
objekt14	M	15	L	> 130
peta	M	15	P	> 130
tomas	M	15	P	> 130
Johny	M	17	L	⟨90, 110⟩
Ludek	M	16	P	⟨90, 110⟩
Najanaa	Ž	17	L	⟨90, 110⟩
Michal5	M	15	P	⟨90, 110⟩
Mikro97	M	15	P	⟨90, 110⟩
Yuillya	Ž	15	P	⟨90, 110⟩

zanet	Ž	?	P	$\langle 90, 110 \rangle$
tadeas	M	?	P	$\langle 90, 110 \rangle$
tucnak2	M	20	P	$\langle 90, 110 \rangle$
arina	Ž	19	P	$\langle 90, 110 \rangle$
dick	M	20	P	$\langle 90, 110 \rangle$

Tabulka C.1: Seznam měřených subjektů

Jméno	Procento artefaktů	Komentář
333	100	Vysoká úroveň očních artefaktů, výpadky elektrody O1, vysoká úroveň špiček - nepoužitelný signál
1313	0.73	Žádné svalové artefakty, střední úroveň očních artefaktů
2332	1.29	Střední úroveň rušení, malé svalové artefakty, výpadky elektrod
42292	4.68	Střední úroveň rušení, výskyt drobných artefaktů
elmo2	35.07	Vysoká úroveň rušení, výskyt svalových a očních artefaktů, konec signálu nepoužitelný
nuzky	12.39	Výskyt velkých svalových artefaktů, oční artefakty, výpadky elektrod
tarzan	2.20	Výpadek signálu, hodně očních artefaktů (neodstraněno), bez svalových artefaktů
will	2.06	Malá úroveň rušení, mírné artefakty
delizrout	4.42	Střední úroveň rušení, výpadky elektrod
jedle	7.98	Střední úroveň rušení, výskyt velkých svalových artefaktů
klara	0	Signál téměř bez rušení, bez artefaktů
mcslnicko	0.89	Mírné rušení, téměř bez artefaktů
objekt14	9.19	Velké rušení, hodně výpadků elektrod

peta	0	Mírné rušení, bez artefaktů
tomas	8.77	Velké rušení na všech elektrodách, výpadky elektrod, nepoužitelné signály z elektrod T5 a C3
Johny	11.71	Nízká úroveň rušení, velké svalové artefakty
Ludek	1.14	Nízká úroveň rušení, výskyt svalových artefaktů
Najanaa	1.13	Nízká úroveň rušení, malé artefakty
Michal5	0	Vysoké rušení, nepoužitelný signál na elektrodách Fp1, F3, C3, C4, P3, O1, F7
Mikro97	50.32	Začátek signálu velice rušený s výskytem velkých svalových artefaktů, druhá půlka lepší, výskyt menších svalových artefaktů
Yuillya	1.86	Malá úroveň rušení, výpadky elektrody, bez svalových artefaktů
zanet	8.65	Výskyt svalových a očních artefaktů
tadeas	3.46	Čistý signál, výskyt malých svalových artefaktů
tucnak2	2.42	Vysoká úroveň rušení, drobné svalové artefakty
arina	100	Vysoká úroveň rušení, výskyt artefaktů po celém úseku - nepoužitelný signál
dick	100	Vysoká úroveň rušení, výskyt artefaktů po celém úseku - nepoužitelný signál

Tabulka C.2: Výskyt artefaktů





# Příloha D

## Obsah přiloženého CD

K této práci je přiloženo CD, na kterém je uložena práce ve formátu PDF a zdrojové kódy.