

**Univerzita Palackého v Olomouci**  
**Přírodovědecká fakulta**  
**Katedra geoinformatiky**

**ANALÝZA EMOCÍ PŘI ČTENÍ MAPY A ŘEŠENÍ  
PROSTOROVÝCH ÚLOH**

**Diplomová práce**

**Bc. Adam PÁTEK**

**Vedoucí práce Mgr. Stanislav Popelka, Ph.D.**

**Olomouc 2017**  
**Geoinformatika**

## **ANOTACE**

Cílem předkládané diplomové práce je přijít s postupem, jakým způsobem analyzovat EEG data, aby z nich byly patrné emoce. Práce detailně popisuje headset Emotiv EPOC+, jenž byl použit pro měření EEG dat, možnosti předzpracování dat v toolboxu EEGlab, úpravu dat do konečné vhodné podoby pro klasifikaci v aplikaci Matlab. Navržený postup prací byl aplikován při kombinovaném eye-tracking a EEG experimentu. Pro experiment byla použita sada obrázků z databáze IAPS (International Affective Picture System). Tyto obrázky sloužily v experimentu jako referenční data, na kterých byla trénována schopnost úspěšně klasifikovat emoce. Do experimentu vstupovaly ještě snímky, které obsahovaly mapy. U těchto snímků bylo cílem zjistit, zda osoba, která je pozoruje, pociťuje nějaké emoce. Druhou částí experimentu byl dotazník SAM (The Self-Assessment Manikin). Při tomto dotazníku účastníci sebehodnotili, jak na ně obrázky působily, formou piktografického přiřazování emocí k jednotlivým obrázkům. Výstupem práce je detailní popis postupu a porovnání obou výstupů experimentu, tedy klasifikace EEG dat a výsledky dotazníku SAM. Součástí práce je i manuál podrobně popisující veškeré úkony potřebné při zpracování EEG dat. Tento manuál figuruje jako volná příloha předkládané práce.

## **KLÍČOVÁ SLOVA**

Emoce, EEG, IAPS, kartografie, Emotiv EPOC

Počet stran práce: 52

Počet příloh: 6 (z toho 2 volná a 1 elektronická)

## **ANOTATION**

Main aim of this theses is to come with workflow describing how to analyze EEG data in a way that it is possible to gain information of emotions from them. In the thesis there is very thorough description of EEG headset Emotiv EPOC+ which was used for EEG data measurements. Also there is description of possibilities of preprocessing the data in EEGLab toolbox, than adjustments of data into their final form which is suitable for final step which is classification in Matlab software. Designed workflow was than applied on combined eye-tracking and EEG experiment. For the experiment there was used a set of pictures from IAPS database (International Affective Picture System). These pictures featured in the experiment as referential data because on data from these pictures was trained an ability to succesfully classify emotions from EEG data. Next to IAPS pictures, there was also pictures containig maps in the experiment. On the pictures with maps, the main goal was to find out if person who is looking at them is experiencing any emotion. Second part of the experiment was the SAM questionnaire (The Self-Assessment Manikin). In this questionnaire participants of the experiment self-evaluated how the pictures had effected them. Output of the thesis is detailed description of the workflow and comparision of both parts of the experiment and their results. Part of the thesis is also a manual with description of every steps during the EEG data analyze. This manual is attached as an appendix.

## **KEYWORDS**

Emotion, EEG, IAPS, cartography, Emotiv EPOC

Number of pages: 52

Number of appendixes: 6

**Prohlašuji, že**

- bakalářskou/diplomovou práci včetně příloh, jsem vypracoval(a) samostatně a uvedl(a) jsem všechny použité podklady a literaturu.

- jsem si vědom(a), že na moji bakalářskou/diplomovou práci se plně vztahuje zákon č.121/2000 Sb. - autorský zákon, zejména § 35 – využití díla v rámci občanských a náboženských obřadů, v rámci školních představení a využití díla školního a § 60 – školní dílo,

- beru na vědomí, že Univerzita Palackého v Olomouci (dále UP Olomouc) má právo nevýdělečně, ke své vnitřní potřebě, bakalářskou/diplomovou práci užívat (§ 35 odst. 3),

- souhlasím, aby jeden výtisk bakalářské/diplomové práce byl uložen v Knihovně UP k prezenčnímu nahlédnutí,

- souhlasím, že údaje o mé bakalářské/diplomové práci budou zveřejněny ve Studijním informačním systému UP,

- v případě zájmu UP Olomouc uzavřu licenční smlouvu s oprávněním užít výsledky a výstupy mé bakalářské/diplomové práce v rozsahu § 12 odst. 4 autorského zákona,

- použít výsledky a výstupy mé bakalářské/diplomové práce nebo poskytnout licenci k jejímu využití mohu jen se souhlasem UP Olomouc, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly UP Olomouc na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Olomouci dne

Bc. Adam Pátek

Děkuji vedoucímu práce Mgr. Stanislavu Popelkovi, Ph.D. za podněty a připomínky při vypracování práce. Mé poděkování patří i všem účastníkům provedeného experimentu, bez kterých by diplomová práce nemohla vzniknout.

## ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Adam PÁTEK**  
Osobní číslo: **R150069**  
Studijní program: **N1301 Geografie**  
Studijní obor: **Geoinformatika**  
Název tématu: **Analýza emocí při čtení mapy a řešení prostorových úloh**  
Zadávající katedra: **Katedra geoinformatiky**

### Z á s a d y p r o v y p r a c o v á n í :

Cílem práce je využití zařízení EEG Emotiv EPOC propojeného s eye-trackerem SMI RED 250 při kartografickém experimentu.

V teoretické části si student nastuduje možnosti analýzy EEG dat (například s využitím nástroje EEGLab tool for Matlab). Analyzovány budou jak přístrojem definované emoce (stres, frustrace), tak i raw data z jednotlivých elektrod. Student následně ověří správnost postupu na stimulech z datové sady IAPS (International Affective Picture System) a poté tyto znalosti aplikuje na vzorovém příkladu s kartografickou tematikou.

Student vyplní údaje o všech datových sadách, které vytvořil nebo získal v rámci práce, do Metainformačního systému katedry geoinformatiky a současně vytvoří zálohu údajů ve formě validovaného XML souboru. Celá práce (text, přílohy, výstupy, zdrojová a vytvořená data, XML soubor) se odevzdá v digitální podobě na CD (DVD) a text práce s vybranými přílohami bude odevzdán ve dvou svázaných výtiscích na sekretariát katedry. O diplomové práci student vytvoří webovou stránku v souladu s pravidly dostupnými na stránkách katedry. Práce bude zpracována podle zásad dle Voženílek (2002) a závazné šablony pro diplomové práce na KGI. Povinnou přílohou práce bude poster formátu A2.

Rozsah grafických prací: **dle potřeby**  
Rozsah pracovní zprávy: **max. 50 stran**  
Forma zpracování diplomové práce: **tištěná**

Seznam odborné literatury:

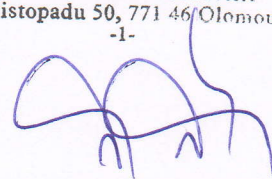
- DIMIGEN, O. (2014). Co-registration of eye movements and EEG during active vision. Humboldt-Universität zu Berlin, Mathematisch-Naturwissenschaftliche Fakultät II.
- GEDMINAS, L. (2014) Evaluating hurricane advisories using eye-tracking and biometric data. Dissertation, East Carolina University, 2011.
- GÖRGEN, K. (2010) Combining Eyetracking and EEG. Publications of the Institute of Cognitive Science, 15.
- HARRISON, T. The Emotiv mind: Investigating the accuracy of the Emotiv EPOC in identifying emotions and its use in an Intelligent Tutoring System.
- HOLMQVIST, K., NYSTRÖM, M., ANDERSSON, R., DEWHURST, R., JARODZKA, H., & VAN DE WEIJER, J. (2011). Eye tracking: A comprehensive guide to methods and measures: Oxford University Press.
- VOŽENÍLEK, V. (2002): Diplomové práce z geoinformatiky. Vydavatelství Univerzity Palackého, Olomouc, UP, 31 s.

Vedoucí diplomové práce: **Mgr. Stanislav Popelka, Ph.D.**  
Katedra geoinformatiky

Datum zadání diplomové práce: **1. října 2015**

Termín odevzdání diplomové práce: **5. května 2017**

UNIVERZITA PALACKÉHO V OLOMOUCI  
PŘÍRODOVĚDECKÁ FAKULTA  
KATEDRA GEOINFORMATIKY  
17. listopadu 50, 771 46 Olomouc  
-1-



prof. RNDr. Vít Voženílek, CSc.  
vedoucí katedry

L.S.

prof. RNDr. Ivo Frébort, CSc., Ph.D.  
děkan

V Olomouci dne 1. října 2015

# OBSAH

SEZNAM POUŽITÝCH ZKRATEK .....	9
ÚVOD .....	10
<b>1 CÍLE PRÁCE.....</b>	<b>11</b>
<b>2 METODY A POSTUPY ZPRACOVÁNÍ .....</b>	<b>12</b>
<b>3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY .....</b>	<b>15</b>
3.1 Elektroencefalografie .....	15
3.2 Emoce.....	17
3.2.1 Vybrané metody klasifikace emocí .....	17
3.2.2 Emoce v kartografii .....	19
3.3 Práce a studie zabývající se aplikačním užitím EEG .....	20
<b>4 VLASTNÍ ŘEŠENÍ .....</b>	<b>24</b>
4.1 Emotiv EPOC+.....	24
4.2 Metodika práce s EEG daty.....	26
4.2.1 Měření dat .....	27
4.2.2 Předzpracování dat.....	29
4.2.3 Extrakce charakteristických rysů .....	32
4.2.4 Klasifikace dat .....	34
4.3 Experiment se stimuly IAPS .....	35
<b>5 VÝSLEDKY .....</b>	<b>40</b>
5.1 Metodika měření a zpracování EEG dat .....	40
5.2 Výsledky experimentu se stimuly IAPS .....	40
5.3 Kartografický experiment .....	46
5.4 Manuál.....	46
5.4.1 Obsah manuálu .....	47
<b>6 DISKUZE .....</b>	<b>48</b>
<b>7 ZÁVĚR.....</b>	<b>51</b>
<b>POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE</b>	
<b>PŘÍLOHY</b>	



## **SEZNAM POUŽITÝCH ZKRATEK**

<b>Zkratka</b>	<b>Význam</b>
BCI	Brain-computer interface
DEAP	A Dataset for Emotion Analysis using Physiological Signals
DVD	Digital Versatile Disc
EEG	Elektroencefalografie, elektroencefalograf, elektroencefalogram
EDF	European Data Format
EKG	elektrokardiografie
EMG	elektromyografie
E-T	Eye-tracking
FFT	Fast Fourier Transformation
GUI	Graphical User Interface
IADS	The International Affective Digitized Sounds
IAPS	The International Affective Picture System
ICA	Independent Component Analysis
KGI	Katedra geoinformatiky
PSD	Power Spectrum Density
SAM	The Self-Assessment Manikin
SVM	Support Vector Machine
USB	Universal Serial Bus

## ÚVOD

Studium emocí zůstávalo dlouho doménou psychologických oborů. S rozvojem technologií a zvýšením jejich dostupnosti se rozšířilo i portfolio vědeckých oborů, ve kterém pojem „emoce“ začíná rezonovat.

Spojení emocí a kartografie zůstávalo dlouho mimo oblast výzkumu. Až v posledních deseti letech se začínají objevovat první studie, které pracují s emocemi. V kartografii je možný dvojitý přístup k emocím. První přístup – a častěji využívaný – se snaží zmapovat emoce. Výsledkem tohoto přístupu jsou mapy, které zobrazují, jaké emoce a pocity mají lidé v určitých částech mapované oblasti. Druhý přístup se pak snaží řešit problematiku toho, jaké emoce mají lidé, kteří se dívají na mapu, či s ní pracují. A právě tento druhý přístup se stal tématem předkládané práce, ačkoliv se jedná zejména o přístup designový a umělecký.

Jak již bylo řečeno, technologie se stávají dostupnější. Katedra geoinformatiky disponuje low-cost brain-computer interface přístrojem, který dovede zaznamenávat EEG vlny. Za pomoci tohoto přístroje byl proveden experiment, při kterém byla EEG data měřena na účastnících, kterým byly mj. promítány snímky s mapami. Práce si klade za cíl zjistit, zda takové snímky u pozorovatelů vyvolávají emoce a zda jsou tyto emoce detekovatelné v jejich EEG vlnách. Ambicí práce není detailní popis emocí z hlediska medicínského, není v ní popsána fyziologie emocí. Stejně tak není ambicí práce matematicky zdůvodňovat jednotlivé kroky při analýze dat.

Jedná se o první využití přístroje EEG Emotiv EPOC+ na katedře geoinformatiky. Doposud nebyl přístroj využíván a nebyla ustavena metodika práce s přístrojem včetně následné úpravy a zpracování EEG dat. Výstupem práce je tedy detailní postup prací při zpracování dat, včetně popisu přístroje Emotiv EPOC+ a jeho údržby.

Tato práce byla podpořena studentským projektem IGA\_PrF\_2017\_024 Univerzity Palackého v Olomouci.

# 1 CÍLE PRÁCE

Cílem práce je využití zařízení EEG Emotiv EPOC+ propojeného s eye-trackerem SMI RED 250 při kartografickém experimentu. Výsledkem experimentu se v případě předkládané diplomové práce rozumí zejména metodika přípravy a realizace experimentu včetně použitého hardwaru a softwaru, přičemž není kladen důraz na samotné kvalitativní či kvantitativní hodnoty vycházející z experimentu. Dalšími cíli práce jsou zhodnocení věrohodnosti dat, jež jsou produkovány zařízením EEG Emotiv EPOC+ a následné navrhnutí možností analýzy těchto dat. Pro naplnění hlavního cíle práce byly rozpracovány dílčí, postupné cíle.

V první řadě se jedná o nastudování problematiky diplomové práce z důvodu korektního užívání terminologie a všeobecného pochopení tématu týkajícího se EEG (elektroencefalografie), E-T (eye trackingu) a konceptu emocí. Součástí tohoto cíle je zejména ustanovení metodiky pro měření a následné zpracování EEG dat včetně výběru softwarů vhodných pro naplnění cílů práce.

Druhým dílčím cílem se stala příprava a realizace eye-tracking a EEG experimentu s vybranými obrázky pocházejícími z IAPS (International Affective Picture System) databáze. Výstupem z tohoto experimentu byla verifikace zařízení EEG Emotiv EPOC+ a také ověření navrhované metodiky pro určování emocí z EEG.

Závěrečným cílem práce se pak stala příprava a realizace kartografického eye tracking a EEG experimentu, při kterém budou testované subjekty plnit jednoduché prostorové úkoly.

Výsledky práce umožní používání zařízení EEG Emotiv EPOC+ pro další potřeby katedry geoinformatiky. Práce navrhuje a ustanovuje základní metodiku získání a zpracování EEG dat při kombinovaných eye tracking experimentech.

## 2 METODY A POSTUPY ZPRACOVÁNÍ

V této kapitole jsou popsány použité metody, data a programy, které vedly k vytvoření diplomové práce. Vše je seřazeno v logické časové posloupnosti (obr 1).

### Rešerše odborné literatury

Primární a nezbytnou částí diplomové práce byla rešerše odborné literatury, při které došlo k prvotnímu seznámení s řešenými tématy. Pro téma týkající se elektroencefalografie byly použity zejména publikace od Syslové a kol. (2010), Moráně (1995) a Mišurce a Chmelaře (1990). Provádění eye tracking experimentů společně s EEG se věnuje celá řada zejména zahraničních autorů. Výčet článků s experimenty je uveden v seznamu použité literatury. Vzhledem k faktu, že zkoumaná témata práce, jako jsou emoce a EEG, zažívají v posledních letech rozvoj, objevilo se v nedávné době několik vysokoškolských kvalifikačních prací, které se problematikou zabývají. Za všechny mohou být jmenovány např. práce Strakoše (2016), Hudy (2014) nebo Schaaff (2008). K rešeršní části práce bylo přistupováno opakovaně vzhledem k šířce studované problematiky.

### Návrh metodiky zpracování EEG dat

Část, která následovala po rešerši odborných zdrojů, se zabývala návrhem metodiky zpracování EEG dat. Navrhovaná metodika kombinuje postupy z několika obdobných experimentů prováděných zejména v zahraničí. Stručně by se dal postup charakterizovat následující posloupností:

- naměření dat,
- preprocessing dat,
- extrakce charakteristických rysů dat,
- klasifikace dat.

### Vybavení pro kombinovaný eye tracking a EEG experiment

Nejdůležitější součástí praktické stránky práce bylo provedení kombinovaného eye tracking a EEG experimentu. Před začátkem přípravy experimentu bylo nutné nastudování používaného hardwaru a softwaru. Experiment se konal v eye-tracking laboratoři na katedře geoinformatiky (KGI) v Olomouci. Ta je vybavená statickým eye trackerem SMI RED 250 a zařízením EEG Emotiv EPOC+. Jedná se o EEG headset od společnosti Emotiv, který je navržen pro „kontextuální výzkum a pokročilé brain-computer interface (BCI) aplikace“ (Emotiv EPOC, 2017). Pomocí 14 senzorů, kterými headset disponuje, byla sbírána data pro potřeby diplomové práce.

Spolu s výše jmenovaným hardwarem je dodáván i software, který je potřebný pro samotnou přípravu experimentu a sběr dat. Pro přípravu a průběh experimentu byly nutné následující softwary:

- SMI Experiment Center™ Software,
- SMI BeGaze™ Eye Tracking Analysis Software,

- Emotiv TestBench™,
- EPOC Control Panel™.

První dva jmenované softwary byly použity pro přípravu a spuštění experimentu, získání dat (jak E-T tak EEG) a export dat. Druhé dva softwary pak sloužily pro kontrolu a kalibraci headsetu a pro vizuální kontrolu EEG dat během experimentu.

### **První kombinovaný eye tracking a EEG experiment**

V prvním experimentu účastníci pouze sledovali obrazovku monitoru, na které se postupně zobrazovaly obrázky z databáze IAPS. Tuto databázi bylo nutné získat od majitele, jmenovitě od The Center for the Study of Emotion and Attention (Centra pro studium emocí a pozornosti) spadající pod University of Florida. Mezi obrázky z databáze IAPS byly v experimentu účastníkům promítány i různé snímky map. Kromě pohybu očí byla účastníkům zaznamenávána i EEG aktivita. Dále byla součástí experimentu metoda sebehodnocení pocitů z pozorování obrázků, tzv. Self Assessment Manikin (SAM). Podklady pro ni byly také získány od vlastníka – The Center for the Study of Emotion and Attention.

### **Druhý kombinovaný eye tracking a EEG experiment**

Plánovaný druhý experiment se měl od prvního lišit formou působení účastníků. Zatímco u prvního experimentu jde pouze o pozorování obrazovky, na které se promítají stimuly, při druhém experimentu mělo jít o plnění jednoduchých prostorových úloh nad mapami. Opět měly být účastníkům zaznamenávány pohyb očí a EEG aktivita. Vzhledem k výsledkům v kapitole 5.2 nebyl tento experiment proveden. Odůvodnění je v kapitole 5.3.

### **Zpracování získaných dat**

Naměřená primární (raw) EEG data bylo nutné zpracovat a analyzovat. Prvním krokem ve zpracování dat je tzv. fáze preprocessingu (předzpracování), při které docházelo k filtraci dat, odstranění artefaktů a k analýze nezávislých komponent (ICA). Pro tuto část práce byl použit Microsoft Excel a Matlab toolbox s grafickým uživatelským rozhraním:

- EEGLAB 13.6.5b.

Předzpracovaná data byla poté dále zpracovávána za účelem extrakce charakteristických rysů. Z tohoto důvodu byla na datech vypočítávána výkonová spektrální hustota za pomoci rychlé Fourierovy transformace (FFT). K výpočtům docházelo v softwaru:

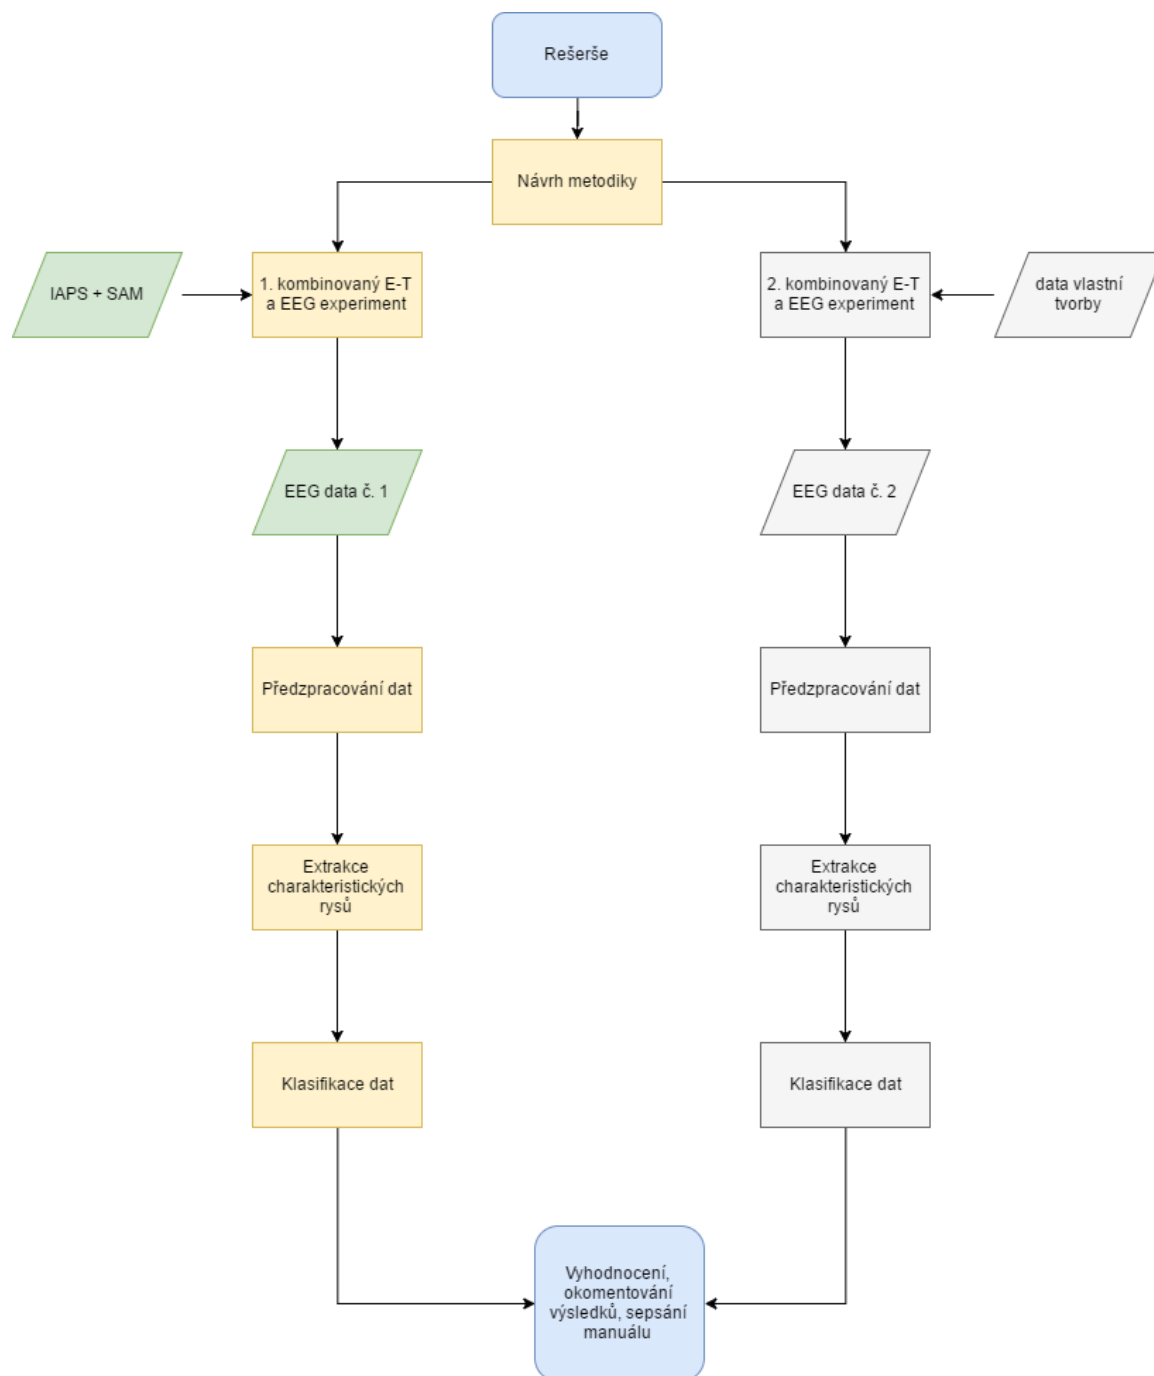
- MATLAB R2016b,

který sloužil i pro toolbox EEGLAB. Při práci byla používána 30denní trialová verze softwaru MATLAB, u které je možnost opakované instalace i přes skončení platnosti licence.

### **Klasifikace dat**

Závěrečnou částí, která následovala po zpracování dat, se stala klasifikace dat. Vzhledem k rešerši se velmi vhodným klasifikátorem stala metoda Support Vector

Machines (SVM) (Liu a kol., 2010; Lahane a kol., 2015; Schaaff, 2008; Aguiñaga a kol, 2015). Jedná se o metodu strojového učení s učitelem. Klasifikace probíhala v aplikaci Classification Learner, která je součástí softwaru MATLAB.




Obr. 1: Vývojový diagram průběhu prací, šedě znázorněné plánované, ale neuskutečněné kroky (zdroj: vlastní zpracování autora, 2017).

### 3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

S rozvojem technologií se na trhu začala v posledních letech objevovat stále nová zařízení. Dříve striktně jednooborové přístroje se začaly postupně implementovat i v dalších vědních oborech. Jednou skupinou těchto přístrojů jsou i tzv. BCI (Brain Computer Interface). Ramadan a Vasilakos (2016) definují BCI jako komplexní systém zahrnující jak hardware, tak software, který umožňuje pomocí mozkových vln ovládat počítač či jiné komunikační zařízení. Původ BCI může být nalezen v lékařském prostředí. Schwartz (2004) definuje BCI jako zařízení propojující mozek s okolním světem pomocí počítače, který zpracovává neurální signál za účelem ovládnutí externího zařízení. Takové zařízení, sloužící jako neurální protéza, může umožnit nepohyblivým lidem jak komunikaci, tak pohyb. V poslední době se právě výzkum v oblasti BCI nabývá na objemu. Vzhledem k tomu, že EEG je dostupné jako low-cost zařízení s možností připojení k počítači, roste tak jeho použití v mnoha vědeckých oborech mimo lékařské kliniky (Mavros a kol., 2012). Za příklad mohou být uvedeny ovládnutí dronu pomocí BCI (Kosmyňa a kol., 2015) či výzkum lidských emocí. Právě výzkum lidských emocí je hlavní doménou této práce.

#### 3.1 Elektroencefalografie

První zprávy o tom, že živá tkáň produkuje elektrické jevy, pocházejí z druhé poloviny 18. století od L. Galvaniho a A. Volty. V polovině 19. století vyvinul Du Bois Reymond nepolarizovatelnou elektrodu, s jejíž pomocí registroval aktivitu žabího mozku (Mišurec a Chmelař, 1990). Elektroencefalografie je základní elektrofyziologickou metodou pro vyšetření mozkové aktivity. Jedná se o neinvazivní metodu, při které se aktivita snímá pomocí povrchových elektrod. Principem elektroencefalografie je zaznamenávání časové změny elektrického potenciálu, který vzniká aktivitou membrán na synapsích neuronů. Grafický záznam změny mozkové aktivity se nazývá elektroencefalogram (obr. 2). Přístroj, který měří mozkovou aktivitu a zaznamenává ji, se



Obr. 2: Příklad elektroencefalogramu (zdroj: vlastní zpracování autora, 2017).

nazývá elektroencefalograf. Použití elektroencefalografie se nejčastěji vyskytuje v neurologii a psychiatrii a to zejména při klinických vyšetření epilepsie či poruch centrální nervové soustavy.

EEG jako trvalý šum mozku obsahuje široké frekvenční spektrum. Frekvenční rozmezí má fuzzy horní i dolní hranici (Moráň, 1995). Zaznamenané signály na elektroencefalogramu jsou kombinací několika typů mozkových vln, které se od sebe vzájemně liší frekvencí a amplitudou. Jednotlivé vlny se dominantně projevují v různých částech mozku a za různých podmínek (např. bdělost, relaxace očí, motorický klid). Základní rozdělení typů vln je uvedeno v tab. 1. Řada publikací uvádí rozdílné hodnoty frekvence u jednotlivých typů vln. V tab. 1 je uvedeno dělení dle Moráně (1995). Kromě uvedených typů vln se dále můžeme setkat s vlnami kapa ( $\kappa$ ), lambda ( $\lambda$ ), sigma ( $\sigma$ ) nebo mí ( $\mu$ ).

Tab. 1: Typy mozkových vln (zdroj: Moráň, 1995).

Typ vln	Frekvence [Hz]
Delta ( $\delta$ )	0,5–4
Theta ( $\theta$ )	5–8
Alfa ( $\alpha$ )	9–13
Beta ( $\beta$ )	13–30
Gamma ( $\gamma$ )	31–50

Snímání EEG probíhá pomocí povrchových elektrod, které mohou být buď samostatně, skryté v elektrodové čepici nebo jsou ve formě tzv. headsetu. Tento způsob se objevuje zejména u low-costových EEG zařízení. Každá elektroda má své kódové označení, které určuje pozici umístění elektrody na lebce. Kód se skládá z písmena a čísla, přičemž písmeno určuje pozici v pomyslné rovině lebky mezi kořenem nosu a kostním hrbolkem na týlní kosti a číslo určuje pozici v pomyslné rovině lebky mezi dvěma body těsně před ušním boltcem na obou stranách.

Význam písmen je následující:

- A = aurikulární (ušní),
- Fp = frontopolární,
- F = frontální (čelní),
- C = centrální (střední),
- T = temporální (spánkový),
- P = parietální (temenní),
- O = okcipitální (týlní).

Význam čísel je následující:

- sudá čísla = pozice nad pravou hemisférou mozku,
- lichá čísla = pozice nad levou hemisférou mozku,



- písmeno „Z“ = označení pro elektrody v centrální linii.

Umístění elektrod se řídí mezinárodně uznávaným tzv. 10-20 systémem. Pro tento systém platí, že veškeré elektrody jsou v každé pomyslné linii rozloženy takovým způsobem, že mezi dvěma sousedními elektrodami je vždy 10 nebo 20 % délky obou rovin lebky, přičemž součet v každé linii dává 100 % (Mišurec a Chmelař, 1990).

### 3.2 Emoce

Emoce – běžně používané slovo v každodenním životě. Emoce jsou studovány v mnoha vědních oborech – biologii, psychologii, neurovědě, antropologii či sociologii. Každý vědní obor na problematiku emocí nahlíží z jiného úhlu. Kvůli tomu se však nemohou shodnout na definici tohoto pojmu či dokonce nějakou z definic preferovat (Cabanac, 2002). Kleinginna a Kleinginna v roce 1981 dokonce sepsali 92 definicí emoce. Již Aristoteles se zabýval emocemi. Popsal je jako: „*pocity, které mění lidi, ovlivňují jejich úsudky, a také jsou často doprovázeny bolestí nebo rozkoší*“ (Encyclopaedia Britannica, 2017). Zakladatel empirické psychologie, američan William James přišel v roce 1884 s teorií, kdy emoce je výsledkem fyziologických změn v lidském těle, které se udály kvůli vnějšímu podnětu. Celou myšlenku uvádí James ve své práci na příkladu setkání člověka a medvěda: „*Selský rozum nám říká, že pokud se setkáme s medvědem, dostaneme strach a utečeme. Já zde naopak obhajuji domněnku, že takové pořadí stavů je chybné. Správné pořadí je následující. Vidíme medvěda, usoudíme, že nejlepším řešením je před ním utéct a kvůli útěku dostaneme strach*“ (James, 1884). Schachter a Singer (1962) definují emoce jako stav fyziologického vzrušení a stav vědomí odpovídající míře vzrušení. S postupným rostoucím poznáním a vývoji nových vědeckých oborů se začaly objevovat i nové definice. Cabanac (2002) přijímá emoce, stejně jako ostatní psychické prožitky, za výsledky nervové aktivity odehrávající se v mozku. Současné definice se také liší, ale velmi často se v nich opakují výrazy jako „pocit“, „mentální stav“ apod. Encyklopedie Britannica (2017) definuje emoci jako komplexní prožitek vědomí, fyzického vjemu a chování, který odráží osobní důležitost konkrétní věci, události nebo situace. Oxford Dictionaries (2017) pak emoci definuje jako silný pocit odvozený od nálady osoby, vztahu s ostatními nebo jinými okolnostmi. Školní slovník současné češtiny (2012) pak o emoci hovoří jako o psychologickém procesu, zahrnujícím subjektivní zážitky, libosti a nelibosti, provázeném fyziologickými a jinými změnami.

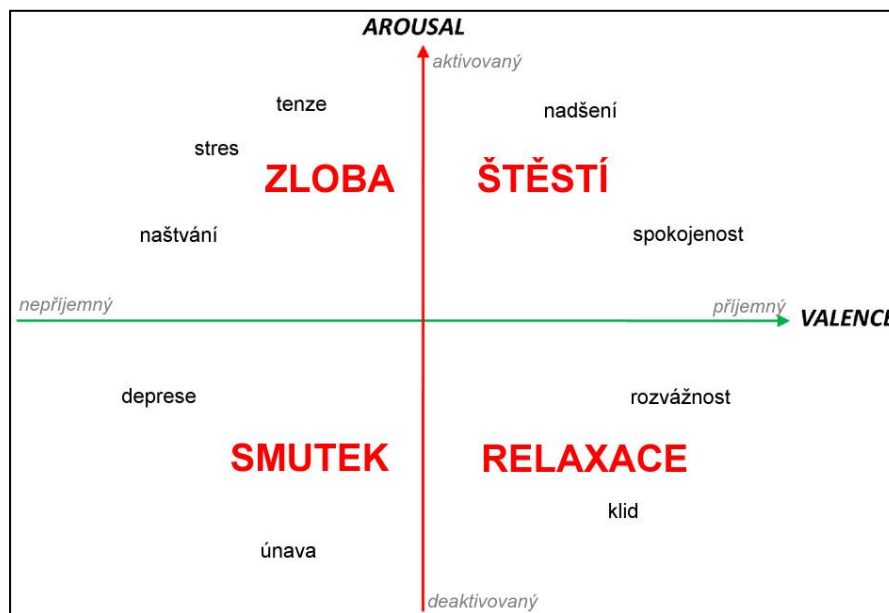
#### 3.2.1 Vybrané metody klasifikace emocí

Radost, strach, hněv, pýcha, důvěra – to jsou pouze příklady z celé řady různých emocí. Každá emoce má unikátní charakteristické stránky – signál, fyziologii a událost, která emoci předcházela (Ekman, 1992). Díky tomu, že emoce mají tyto charakteristiky, je možno je klasifikovat, o což se vědci snažili od začátků moderní psychologie. Wilhelm Wundt v roce 1896 klasifikoval emoce ve třech bipolárních dimenzích. První dimenze obsahovala hodnoty libost a nelibost, druhá obsahovala hodnoty nadšení a klid a třetí

obsahovala hodnoty napětí a klid (Reisenzein, 1992). Tato teorie pak dala základy i dalším teoriím o klasifikaci emocí.

### Kruhový model Jamese Russella

Jednou z teorií klasifikace emocí je Kruhový model Jamese Russella. Psychologové v době před ním uvažovali o emocích jako o diskrétních jevech. Russell (1980) naopak říká, že emoční stavy nejsou navzájem nezávislé, ale mají mezi sebou velmi systematické vazby. Russell tedy navrhl model, ve kterém jsou emoce zobrazeny jako kruh ve dvoudimenzionálním bipolárním prostoru (obr. 3).



Obr. 3: Kruhový model Jamese Russella (zdroj: Candra a kol., 2015).<sup>1</sup>

Prostor je definován dvěma veličinami. Horizontální veličinou je valence, tedy míra přitažlivosti či averze osoby vůči nějaké věci či události. Zjednodušeně může být řečeno, zda na osobu něco působí pozitivně nebo negativně. Pojem valence je odvozen od slova ambivalence, které znamená současné působení zcela protichůdných citových postojů osoby. Vertikální veličinou v Kruhovém modelu Jamese Russella je míra vzrušení, míra zaujetí, míra aktivity (angl. arousal). Z obr. 3 je patrné, že pokud jsou emoce děleny dle výše jmenovaných veličin, mohou být seskupeny do obecnějších skupin emocí. Pokud má osoba vysokou míru valence a zároveň vysokou míru aktivity a zaujetí, mohou se její emoce označit jako šťastné, pokud má osoba nízkou míru valence a vysokou míru aktivity a zaujetí mohou se její emoce označit za naštvané apod. Vzhledem k obtížné přeložitelnosti výrazů arousal a valence do češtiny budou dále v práci pro jednotlivé dimenze používány pouze anglické výrazy.

### PAD Emotional State Model


Na práci Russella navázal Albert Mehrabian, který doplnil Kruhový model Jamese Russella o třetí dimenzi. Tento emoční model nese název PAD Emotional State Model (P = pleasure, A = arousal, D = dominance). Osa dominance v modelu určuje pocity

<sup>1</sup> upraveno

osoby z hlediska dominance a kontroly nebo submisivity v opačném případě. Jako příklad mohou posloužit emoce hněv a strach. Obě emoce jsou negativní a vysoce vzrušivé, ale zatímco hněv je dominantní, strach je submisivní (Mehrabian, 1996).

### Plutchikovo kolo emocí

V roce 1980 přišel americký psycholog Robert Plutchik s třídimenzionálním kruhovým modelem, který popisuje vztahy mezi emocemi. Model může být zobrazen buď jako rovinný, nebo jako prostorový (obr. 4).



Obr. 4: Plutchikovo kolo emocí (zdroj: Wikimedia Commons, 2017).<sup>2</sup>

Barevné sektory v Plutchikově kole emocí vyznačují osm primárních emočních směrů tak, jak je Plutchik definoval. Směry jsou srovnány způsobem, že leží naproti sobě a zároveň jsou znázorněny vzájemně doplňkovými barvami. S postupujícím směrem od středu kruhu klesá intenzita barev a s tím i intenzita emocí v daném emočním směru. Emoce, které jsou v prázdných prostorech, se označují jako primární dyády a vznikly kombinací dvou sousedních emocí nacházejících se v druhém kruhu od středu (Plutchik, 2001). Například emoce láska vznikla kombinací emocí radost a důvěra.

### 3.2.2 Emoce v kartografii

Studium emocí v oboru kartografie zůstávalo dlouho nedotčeným. Teprve v posledních 10 letech se toto téma začalo více probírat. O tom, že téma map a emocí nabývá na významu, svědčí i workshop Mezinárodní kartografické asociace s názvem Maps & Emotions, který se bude konat v návaznosti na 28. Mezinárodní kartografickou

<sup>2</sup> upraveno

konferencií pořádanou v červenci 2017 ve Washingtonu. V kartografii se na problematiku emocí dá nahlížet ze dvou směrů, přičemž jeden směr je spíše vědecký, zatímco druhý umělecký. První směr se zabývá studiem lidských emocí generovaných různým kartografickým designem. Druhý směr se snaží zachytit a kartograficky vyjádřit emoce spojené s určitým prostředím (ICA, 2016). Prvním směrem se zabývali například Fabrikant a kol. (2012), kdy testovali jak rozdílný kartografický styl působí na čtenáře mapy. Nicméně stav výzkumu, jak mapy emočně působí na jejich čtenáře, je stále pouze v plenkách a studie na toto téma se objevují velmi sporadicky. Výjimku tvoří samostatné studie, které zkoumají vliv barev na čtenáře.

Druhý směr, při kterém se „mapují“ emoce v prostoru, je mnohem častější, ať už se jedná o získávání dat pomocí Bio Mappingu či crowdsourcingové zdroje. Mezi jeden z neznámějších projektů v České republice, při kterém se získávají emoční data metodou crowdsourcingu, patří Pocitové mapy (pocitovemapy.cz), za kterým stojí Mgr. Jiří Pánek, Ph.D. z katedry rozvojových studií na Univerzitě Palackého v Olomouci.

Mapování emocí stále zůstává zcela neprozkoumané, neboť se jedná o mapování neviditelného jevu. Směr, kterým se nyní toto téma ubírá, je zjišťování a hledání způsobu, jak nejlépe vizualizovat emoce v mapě. Nicméně mapování emocí je součástí konceptu deep mapping, který je založen na ideji, že člověk může opravdu poznat místo, pouze pokud vezme v potaz i vzpomínky a emoce vztahující se k tomu místu (ICA, 2016).

### **3.3 Práce a studie zabývající se aplikačním užitím EEG**

Rešeršované práce by mohly být rozděleny do dvou kategorií. Jednou z nich jsou vědecké studie zabývající se jednak rozeznáváním emocí z EEG, ale také aplikačním užitím technologií BCI. Druhou kategorií jsou pak kvalifikační práce, jejichž cíl byl až na některé drobné odlišnosti velmi podobný cíli předkládané práce. Velká část vědeckých studií pochází z území mimo severoatlantický prostor, konkrétně se jedná o studie z Mexika, Austrálie, Singapuru, Indie, Číny nebo Malajsie. Oddělení a instituty, které studie publikují, jsou ve většině případů technologického charakteru, např. katedry výpočetní techniky, technické univerzity, katedra mechatroniky, v menší míře pak biomedicínské instituty či ústavy neuropsychologie.

Tematicky i postupem nejvíce podobná předkládané práci je studie od Lahane a kol. (2015). Cílem studie je analýza emocí z EEG, přičemž při zpracování používají FFT a pro klasifikaci klasifikátory typu SVM. Bohužel autoři neuvádějí, jaký typ elektroencefalografu pro svoji práci použili. Cílem Murugappan a kol. (2010) bylo také pomocí EEG klasifikovat emoce. Postup prací v jejich studii je srovnatelný s postupem prací v předkládané diplomové práci, nicméně rozdíly se nacházejí v provedení některých částí. Autoři používali pro měření 64senzorové EEG, nepoužili FFT ale vlnkovou transformaci signálu a pro klasifikaci použili metody K-nejbližšího souseda a diskriminační analýzu. Stejným problémem se zabývali Candra a kol. (2015), kteří se snažili klasifikovat EEG vlny do čtyř emocí. Data získali z experimentu, při kterém účastníci pozorovali několik minutových hudebních videí. Pro klasifikaci použili

klasifikátor typu SVM, přičemž dosáhli úspěšnosti klasifikace kolem 70 %. Nicméně oproti navrhovanému postupu v této práci použili pro extrakci charakteristických rysů signálu vlnkovou transformaci. Otázkou také zůstává, proč autoři studie použili pro trénování dat a následnou klasifikaci pouze data od pěti účastníků, ačkoliv se jich tohoto experimentu zúčastnilo celkem 32.

Rozdílný přístup k získání emocí z EEG dat provedl Bos (2006). Pro získání hodnot emocí používal pouze data z tří EEG senzorů, kdy vypočítával poměry vlnových pásem  $\alpha$  a  $\beta$ , čímž získával hodnoty dimenzí arousal a valence. Pro klasifikaci autor použil binární lineární Fischerovu diskriminační analýzu. Klasifikace dosáhla úspěšnosti přes 90 %, nicméně problematicky se jeví fakt, že experimentu se zúčastnilo pouze pět účastníků, na které působilo celkem pouze 39 stimulů různých typů, jak vizuálních tak poslechových. Sreeshakthy a Preethi (2016) se také zabývali získáváním emocí z EEG dat, nicméně hlavní rozdíl v postupu prací oproti této diplomové práci je v klasifikaci. Autoři nepoužili klasifikátor typu SVM, ale použili tři různé umělé neuronové sítě. První z nich byla založená na algoritmu optimalizace hejnem částic, druhá byla probabilistická neuronová síť a třetí založena na kukaččím algoritmu. Výsledky klasifikace u všech tří neuronových sítí dosahovaly hodnot přes 90 % a to i přes fakt, že se experimentu zúčastnilo 32 subjektů. Khosrowabadi a kol. (2010) pro klasifikaci emocí z EEG použili osm elektroencefalografických senzorů. Experimentu se zúčastnilo 26 osob, přičemž jim byly promítány stimuly z databáze IAPS. Stejně tak účastníci hodnotili stimuly pomocí dotazníku SAM, totožně jako je to provedeno v této práci. Rozdíly jsou pak při extrakci charakteristických rysů signálu, kdy autoři použili koherenční funkce, a při klasifikaci, kdy byla použita samoorganizační mapa. Úspěšnost klasifikace se pohybuje v hodnotách přes 84 %. Aguiñaga a Ramírez (2015) ve své studii navrhují postup, jak získat emoce z EEG dat. Autoři při experimentu použili elektroencefalograf s 36 senzory, nicméně použili pouze data z vybraných senzorů na základě Brodmannovy analýzy, která přiřazuje pouze některé oblasti mozku k emočním projevům. Celkem 32 účastníkům experimentu byly promítány audiovizuální stimuly z databáze DEAP<sup>3</sup> (A Dataset for Emotion Analysis using Physiological Signals). Pro extrakci charakteristických rysů signálu použili autoři vlnkovou transformaci a pro klasifikaci použili SVM klasifikátory. Celková úspěšnost klasifikace se pohybovala v hodnotách přes 80 %. Studie autorů Hidalgo-Muñoz a kol. (2013) se odlišuje od ostatních svým původem, neboť pochází z katedry experimentální psychologie. Cíl autorů ovšem zůstává stejný – analyzovat EEG data a klasifikovat je do emočních kategorií. V experimentu, jehož se účastnilo 26 žen, byl použit elektroencefalograf s 21 senzory a jako stimuly sloužily obrázky z databáze IAPS. Jako charakteristický rys signálu autoři používají hodnotu global field power, což je směrodatná odchylka potenciálů naměřených na EEG senzorech. Pro klasifikaci použili klasifikátor SVM-RFE, který klasifikuje data v iteracích, přičemž s každou iterací je z klasifikace odstraněna část dat. Úspěšnost klasifikace se s přibývajícím iteracemi přibližovala hodnotě 100 %. Aydin a kol. (2016) ve své práci přistupují k hodnocení

---

<sup>3</sup> <http://www.eecs.qmul.ac.uk/mmv/datasets/deap/>

emocí z EEG odlišným způsobem. Data neměřili, pouze je převzali z databáze DEAP a to v rozsahu pouhých čtyř audiovizuálních stimulů a čtyř účastníků. U těchto dat pak pouze hodnotili velikost amplitudy výkonového spektra signálů ve vybraných vlnových pásmech. Autoři prezentovali závěry, které je ovšem nutno, s ohledem na malou objemnost zkoumaných dat, brát s rezervou. Liu a kol. (2010) ve své práci představují proces, kterým docílili rozpoznávání emocí z EEG v reálném čase. Z experimentu, při kterém účastníci poslouchali zvukové stimuly z databáze IADS (The International Affective Digitized Sounds), autoři studie rozeznávali šest emocí. Pro měření dat byl použit přístroj Emotiv EPOC, ovšem zpracována byla data pouze ze tří senzorů. Jako charakteristický rys signálu autoři vypočítali fraktální dimenzi signálu pomocí Higuchiho algoritmu. Vypočítaná emoce pak byla převedena na monitor, kde se zobrazil avatar vyjadřující příslušnou emoci. Bohužel autoři neuvádějí úspěšnost klasifikace emocí.

Na českém území se téma emocí a EEG ve většině případů řeší ve formě diplomových prací. Bakalářská práce Vaněčkové (2014) z Ústavu biomedicínského inženýrství na Vysokém učení technickém v Brně se zabývá emocemi a jejich vlivem na signál EEG. Za pomoci přístroje Emotiv EPOC, obrázkových sad z databází GAPED<sup>4</sup> (Geneva Affective PicturE Database) a IAPS a dotazníků SAM byl proveden experiment, který obsahoval 30 stimulů a jehož se zúčastnilo 10 osob. Pro zjištění hodnot dimenzí arousal a valence z EEG dat autorka používala obdobného postupu jako Bos (2006). Strakoš (2016), který svoji magisterskou práci vypracovával na stejném ústavu jako Vaněčková (2014), testoval při experimentu emoční reakci osob při reklamních spotech. Pro měření dat používal jak přístroj Emotiv EPOC+ tak laboratorní EGI GES 400 MR, což je EEG čepice s 256 senzory. Po analýze dat autor přešel ke klasifikaci, kterou prováděl jak pomocí klasifikátoru SVM, tak pomocí umělé neuronové sítě a to pro data z různých počtů senzorů. V prvním kroku klasifikoval data do čtyř kategorií, nicméně úspěšnost klasifikace se pohybovala v rozmezí 20–30 %. Po redukci na dvě kategorie se úspěšnost klasifikace pohybovala pro rozdílné přístroje a rozdílný počet elektrod vstupujících do trénování dat v hodnotách mezi 56 a 64 %. Magisterská práce Hudy (2014) z katedry informatiky a výpočetní techniky Západočeské univerzity v Plzni se zabývá měřením emocí z EEG podněcených vizuálními stimuly. Při experimentu byly účastníkům promítány obrázky z databáze IAPS a také stimuly zobrazující pivo. Myšlenka magisterské práce se totiž zabývá měřitelností pitelnosti piva. Naměřená data autor nijak neklasifikuje, nýbrž pouze zkoumá průběh vln v čase a velikost jejich amplitud v různých lebečních oblastech. Kromě elektroencefalografu využíval autor také měření elektrodermální aktivity. Údaje získané ze zkoumání amplitud vln pak porovnával s dotazníkem SAM, na který účastníci experimentu také odpovídali. Magisterská práce autorky Schaaff (2008) z Universität Karlsruhe navrhuje řešení jak klasifikovat emoce ze signálů EEG do tří kategorií (pozitivní, neutrální a negativní). Experimentu se zúčastnilo 23 osob, kterým byly promítány stimuly z databáze IAPS. Měření probíhalo pomocí EEG čepice s 19 senzory, z které byla ale data ze tří senzorů vypuštěna pro další zpracování.

---

<sup>4</sup> <http://www.affective-sciences.org/en/>

Pro klasifikaci použila autorka klasifikátor typu SVM a také skrytý Markovův model, přičemž úspěšnost klasifikace dosahovala u SVM hodnoty 62 % a u skrytého Markovova modelu 45 %.

Kromě studia emocí slouží přístroje BCI i k dalším, rekreačním aktivitám. Kosmyna a kol. (2015) použili 16-senzorový elektroencefalograf pro pilotování dronu pomocí EEG vln. Princip zpracování vln je identický s postupem prací navrženým v diplomové práci. Rozdíl je v experimentu, při kterém účastníci opakovaně pomocí myšlenek trénovali pohyb dronu. Skupina účastníků experimentu byla rozdělena do tří částí, dle délky trénování pohybů dronu – jeden den, jeden týden a jeden měsíc. Úspěšnost pohybu dronu se pak pohyboval od 60 % při jednodenním trénování po 87 % při měsíčním trénování. Reuderink a kol. (2013) ve své práci zkoumají hodnoty dimenzí arousal, valence a dominance během hraní počítačových her. Hra byla naprogramovaná takovým způsobem, aby ztěžovala hráči hraní, např. nefunkčnost ovládní, vypnutí monitoru apod. Takto naplánovaný experiment trval 30 minut, přičemž každé dvě minuty byl účastník experimentu požádán o vyplnění dotazníku SAM, aby byl zaznamenán jeho emoční stav. Vyplněné dotazníky poté autoři porovnávali s naměřeným EEG, přičemž potvrdili korelaci mezi dimenzemi arousal a valence ve vlnových pásmech alfa, delta a theta.

S kombinací EEG, eye-trackingu a dalších biometrických dat pracuje ve své diplomové práci Gedminas (2010). Při experimentu, který měl za cíl otestovat, jak jsou vnímány geovizualizace zobrazující hurikány, bylo kromě EEG účastníkům zaznamenáváno i EKG (elektrokardiografie) a EMG (elektromyografie). Při záznamu EMG autor sledoval výskyt svalových záškubů asociovaných s nepříjemnými stimuly. Data z EEG sloužila pro podporu evaluace experimentu. Hodnocení dat EEG vycházelo z premisy, že při pozitivní stimulaci je zvýšená mozková aktivita v levé hemisféře. Slanzi a kol. (2016) ve své studii využili BCI přístroje v kombinaci s eye-trackingem pro predikci kliknutí myši na webu uživatelem. Na pěti existujících webových stránkách autoři provedli experiment, při kterém 21 osobám bylo zaznamenáváno EEG a také pohyb a poloha očí pomocí eye-trackeru. Autoři použili Higuchiho algoritmus pro výpočet fraktální dimenze signálu, přičemž potom v kombinaci s eye-tracking daty navrhli sedm klasifikačních modelů. Nejúspěšnější model dosáhl přesnosti klasifikace dosahující hodnoty přes 70 %.

Jak již bylo řečeno v kapitole 3.2.2 výzkum emocí v oboru kartografie je stále z velké části neprobádané území. Vědecké studie, při kterých by bylo použito BCI zařízení v souvislosti s mapami, nejsou dohledatelné. Nejbližší k použití EEG při výzkumu kartografického tématu měl již zmíněný Gedminas (2010). V případě jeho práce ovšem EEG sloužilo jako podpůrná metoda, větší důraz byl kladen na eye-tracking a EMG.


## 4 VLASTNÍ ŘEŠENÍ

V následujících podkapitolách bude detailně popsáno řešení předkládané diplomové práce. Nejdříve bude popsáno zařízení Emotiv EPOC+, následovat bude obecný popis všech kroků potřebných k dosažení výsledků. V závěru této kapitoly pak budou popsány výsledky experimentů, na kterých byl postup prací ověřován.

### 4.1 Emotiv EPOC+

Leitmotivem diplomové práce je evaluace emocí z naměřeného EEG. Pro měření EEG katedra geoinformatiky disponuje zařízením EPOC+, které bylo vytvořeno a je prodáváno společností Emotiv Inc. sídlící v San Franciscu.

EPOC+ je bezdrátový 14kanálový EEG neuroheadset sloužící zejména pro BCI aplikace, ale jeho nadstavbou je i vestavěné měření úrovní vybraných emocí. Jednotlivé kanály reflektují mezinárodní 10-20 systém. Konkrétně se jedná o kanály s pozicemi AF3, AF4, F3, F4, F7, F8, FC5, FC6, T7, T8, P7, P8, O1 a O2 (obr. 5).



Obr. 5: Umístění senzorů přístroje Emotiv EPOC+ na lebce (zdroj: Ekanayake, 2011).

Navíc je zařízení ještě vybaveno dvěma tzv. referenčními kanály na pozicích P3 a P4. Referenční kanály jsou nutné u přístrojů EEG s referenčním zapojením elektrod. Takové zařízení funguje na principu, v jakém jsou zaznamenávány rozdíly elektrických potenciálů mozku mezi aktivními kanály a právě referenčními kanály, které jsou inaktivní. Tyto kanály jsou nejčastěji umisťovány na ušní boltce či kořen nosu. Nevýhodou takového zapojení je riziko kontaminace těchto elektrod mozkovou aktivitou. (Pokorný, 2017). Jeví se jako pravděpodobné, že taková kontaminace mohla působit i na zařízení EPOC+, neboť referenční elektrody mají umístění přímo na lebce, konkrétně v oblasti temenní kosti. Jedná se ovšem pouze o domněnku, neboť software dodávaný se zařízením EPOC+ nezobrazuje hodnoty naměřeného EEG pro referenční elektrody, a ani v primárních (raw) datech se tyto hodnoty nevyskytují. Na zařízení se vyskytují ještě další dvě elektrody, které by měly doléhat z každé strany na skalní kost (os petrosum).



Tyto elektrody jsou také referenční, nicméně standardně obsahují gumové, nevodivé polštářky a mají tedy pouze kosmetickou funkci. Při určitých typech měření EEG je pak vhodnější jako referenční elektrody použít právě tyto, umístěné na skalních kostech, a v takovém případě se gumové polštářky vymění za vodivé, plstěné polštářky z elektrod na pozicích P3 a P4.

Zařízení EPOC+ disponuje záznamovou frekvencí až 256 Hz. Vzhledem k tomu, že zařízení bylo používáno výhradně v kombinaci s eye-trackerem SMI RED 250, byla záznamová frekvence sjednocena na 250 Hz. Reálná záznamová frekvence se však pohybovala mezi hodnotami 248 a 249 Hz.

K tomu, aby bylo možné provádět měření EEG, jsou nezbytné některé kroky. Jedním z nich je nabíjení zařízení, které se provádí pomocí adaptéru s mini USB konektorem. Výrobce uvádí, že zařízení je schopno při plném nabití běžet nepřetržitě po dobu 12 hodin, přičemž plné nabití baterie trvá přibližně 4 hodiny (Emotiv, 2014). Dalším krokem je zacházení se senzory a jejich ošetření. Hlavními částmi těchto odnímatelných senzorů jsou polštářky a pozlacené elektrické kontakty. Sensory se před každým měřením připevňují k EEG headsetu. Důležité je, aby byly polštářky nasáklé solným roztokem (např. roztok na kontaktní čočky), z důvodu zlepšení vodivosti a tím získání kvalitního signálu při měření EEG. Po skončení měření EEG se senzory sejmou z headsetu a uloží se do uzavíratelného držáku k tomu určenému, přičemž se znovu hydratují solným roztokem. Je možné, že se v průběhu času na pozlacených kontaktech vytvoří ušlechtilá rez zelené barvy. V takovém případě je vhodnější tuto rez ponechat, případně ji vyčistit pomocí alkoholu. Nikdy by se k čištění neměly používat ostré předměty, které by mohly poškodit funkčnost kontaktů.

Přenos dat z EEG headsetu do počítače je řešen bezdrátově pomocí Bluetooth® Smart připojení. Spárování headsetu s počítačem se provádí pomocí USB bezdrátového přijímače, který je dodáván společně s headsetem.

Pro samotné měření EEG dat zařízením Emotiv EPOC+ je nutné mít dva softwary, které jsou se zařízením dodávány na instalačním DVD. Prvním z nich je EPOC Control Panel™, který slouží pro nastavení spojení mezi headsetem a počítačem. V programu jsou ukazatele síly bezdrátového signálu, stav baterie a zejména kvalita signálu na jednotlivých senzorech. EPOC Control Panel™ také umožňuje vytvořit každému uživateli osobní uživatelský účet. Kromě výše uvedeného se v programu vyskytují nástroje Expressiv™ Suite, Affectiv™ Suite, Cognitive™ Suite a Mouse Emulator. Nástroj Expressiv™ Suite zaznamenává pomocí EEG pohyby lidské tváře, jako je mrknutí oka, zvednutí obočí či úsměv. Díky procesu EmoKey, který běží na pozadí, je možné tyto pohyby automaticky převádět na libovolnou kombinaci textu, která je pohybům tváře nastavena. Nástroj Affectiv™ Suite měří z EEG úroveň přednastavených emocí. Konkrétně se jedná o frustraci (frustration), zaujetí (engagement), meditace (meditation) a krátkodobé a dlouhodobé nadšení (excitement). Tyto emoce nelze měnit a nikde není popsáno, jakým způsobem či jakými algoritmy je hodnot u emocí dosaženo. Zároveň vzbuzuje zamyšlení fakt, že výše vypsané emoce působí současně, ačkoliv jejich

charakter je protichůdný (např. frustrace a nadšení). Nástroj Cognitive™ Suite vyhodnocuje uživatelskou mozkovou aktivitu a rozeznává jeho myšlenkové úmysly týkající se pohybu reálných či virtuálních objektů. Jinými slovy řečeno, uživatel se snaží pomocí myšlenek natrénovat pohnutí předmětem. Cognitive™ Suite analyzuje mozkové vlny uživatele, personalizuje je a přiřadí je k trénovanému pohybu. Tento pohyb lze pak převést, opět pomocí EmoKey, na libovolnou kombinaci kláves na klávesnici a lze ho uplatnit v různých aplikacích nebo při hraní her. Nástroj Mouse Emulator za pomoci gyroskopu, který je zabudovaný v headsetu, umožňuje pomocí otáčení hlavy ovládat kurzor myši. Veškeré nástroje obsažené v programu Eloc Control Panel™ mají uplatnění v oblasti BCI, nicméně pro dosažení cílů práce jejich použití nebylo nutné.

Druhým softwarem potřebným pro měření EEG dat je TestBench™. Ten lze použít při EEG experimentu, přičemž umí EEG data nahrát, zobrazit a analyzovat. V případě předkládané práce probíhalo měření EEG dat v kombinaci s eye-tracking experimentem. Vzhledem k situaci, kdy softwarové vybavení na katedře geoinformatiky, kde experiment probíhal, umožňuje simultánní nahrávání eye-tracking i EEG dat v softwaru SMI Experiment Center™, nebyl software TestBench™ komplexněji využíván.

## 4.2 Metodika práce s EEG daty


Navrhovaná metodika popisuje ve čtyřech dílčích kapitolách, jak pracovat s EEG daty s cílem získat z nich emoce. Postup prací byl strukturován do logických celků, které ve svém názvu reflektují hlavní činnost v daném celku. Ty mají pevně dané pořadí, které nelze zaměňovat. Postup prací je znázorněn na obr. 6.



Obr. 6: Postup prací při zpracování EEG dat (zdroj: vlastní zpracování autora, 2017).

### 4.2.1 Měření dat

Měření dat probíhalo při kombinovaném eye-tracking a EEG experimentu v eye-tracking laboratoři na katedře geoinformatiky. Na začátku experimentu bylo nutné účastníkovi vysvětlit princip experimentu a jeho účast v něm. Neboť se EEG data považují za osobní a citlivá, je třeba s nimi nakládat diskrétně v souladu s přístupem k ochraně osobních údajů (Reynolds a Picard, 2004). Vzhledem k citlivosti problematiky, byl každému účastníkovi po vysvětlení experimentu dán k podpisu informovaný souhlas (Příloha 1). V něm účastník potvrdil, že rozumí své části působení v experimentu, že

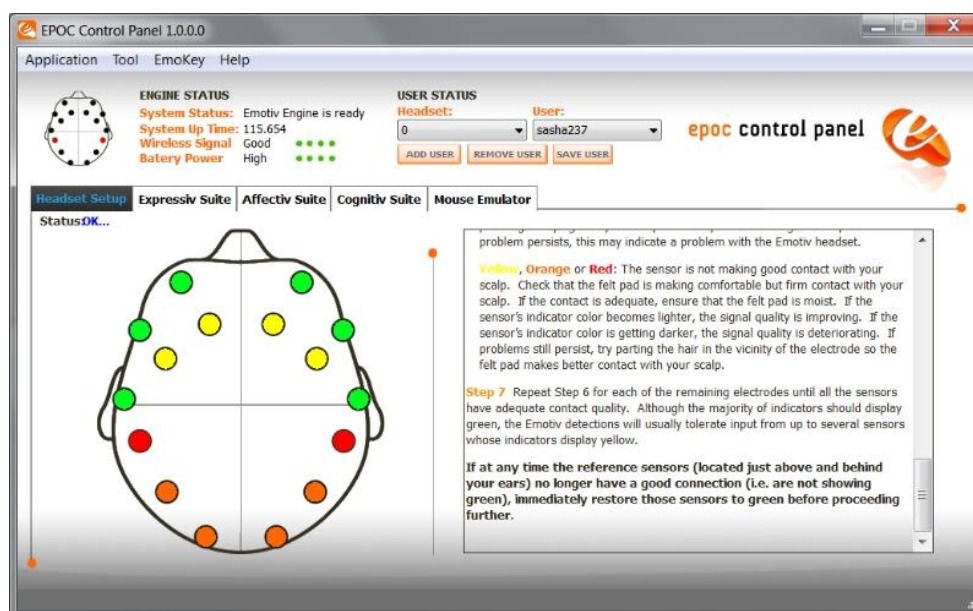


Obr. 7: Instalace headsetu na hlavu účastníka (zdroj: Emotiv EPOC, 2014).

s jeho daty bude nakládáno diskrétně, či že experiment není diagnostický a nelze z něj vyčíst žádné mozkové abnormality, i když by mohly být přítomny.

Po podepsání informovaného souhlasu účastníkem následovala instalace headsetu na účastníkovu hlavu. Při tomto kroku bylo důležité dodržovat doporučení výrobce o umístění senzorů (obr. 7). Klíčové senzory, podle kterých se řídilo umístění celého headsetu, byly ty na pozicích AF3 a AF4 a druhotné referenční elektrody (opatřené gumovými, ne plstěnými polštářky). Elektrody určené pro pozice AF3 a AF4 by se měly dotýkat lebky v místech vzdálených na tři šířky prstu od nadočnicového oblouku účastníka. Druhotné referenční elektrody by pak měly doléhat na skalní kosti účastníka. Důležitým faktorem je symetrické posazení headsetu na lebce a pokud možno kolmý dotyk plstěných polštářků s lebkou, čímž je dosaženo maximalního kontaktu mezi senzory a plochou lebky.

Po nasazení je třeba aktivovat senzory, které již byly napuštěny solným roztokem. Aktivace se provádí lehkým stiskem referenčních elektrod (pozice P3 a P4) a jejich přidržení po dobu 10 až 20 vteřin. Během té doby by se měla v softwaru EPOC Control Panel™ zobrazit aktivita a kvalita signálu na jednotlivých senzorech. Úroveň kvality signálu je znázorněna pěti barvami (obr. 8) – černá (žádný signál), červená (velmi slabý signál), oranžová (slabý signál), žlutá (dostatečný signál), zelená (ideální signál) -



Obr. 8: Zobrazení kvality signálu na senzorech v prostředí EPOC Control Panel™ (zdroj: <http://developers-club.com/posts/115055/>, 2011 ).

přičemž kvalita signálu na senzoru by měla dosahovat nejhůře žluté barvy.

Ve většině případů se při prvních pokusech nedařilo aktivovat přenos signálu na senzorech, neboť vlasy účastníků velmi rychle vysušovaly senzory. Headset tedy musel být účastníkovi sejmout z hlavy, senzory znovu hydratovány a celý postup nasazení a aktivace opakován. Ve výjimečných případech se ani po důkladné hydrataci nepodařilo senzory aktivovat. Řešením takové situace se stalo vypnutí a opětovné zapnutí headsetu spolu s odpojením a opětovným připojením USB bezdrátového přijímače. Dalším problémem vyskytujícím se při aktivaci elektrod, byla nefunkčnost vybraných senzorů. V takovém případě bylo nutné tyto vyměnit za jiné.

V průběhu instalace headsetu na účastníkovu lebku je vhodné popisovat úkony, které operátor experimentu provádí, včetně varování o možném nepříjemném pocitu kvůli mokřím senzorům. Před samotným spuštěním experimentu by měl být účastník upozorněn na fakt, že zařízení je velmi citlivé na jakékoliv změny polohy hlavy a sebemenší pohyby vnášejí do výsledných dat nežádoucí prvky, tzv. artefakty. Artefakty je dle Moráně (1995) možné dělit na fyzikální a biologické. Mezi fyzikální jsou řazeny elektromagnetická indukce či přechod signálu mezi senzorem a kůží, mezi biologické patří svalový potenciál, EKG, dech či pohyb očí a víček.

Po úspěšné instalaci headsetu, zajištění kvalitního signálu na elektrodách a informování účastníka proběhl samotný kombinovaný eye-tracking a EEG experiment,

při kterém byla naměřena data o pohybu očí během experimentu a EEG data, na které je v práci především kladen důraz. Data z experimentu lze exportovat v několika formátech. Nativním souborem pro spánková a EEG data je soubor formátu .EDF (European Data Format). Soubor takového formátu slouží zejména pro uložení a sdílení multikanálových biologických dat (Alvarez-Estevez, 2017). Další z možných exportních formátů dat je klasický .TXT formát. Ten byl v práci upřednostněn z důvodu možnosti prohlédnutí struktury souboru, což soubor formátu .EDF bezplatně neumožňuje.

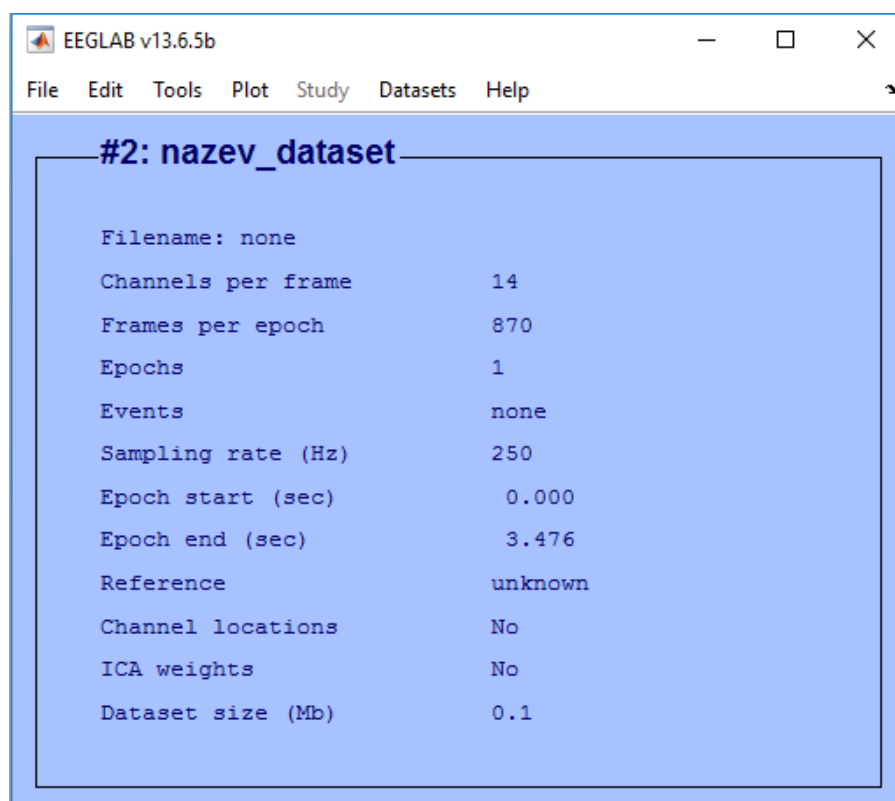
Výstupní soubor byl strukturován do tabelární formy, přičemž obsahoval 52 sloupců. Obsahem souboru byly základní informace o účastníkovi, název stimulu, informace o poloze očí účastníka, hodnoty emocí, které zařízení EPOC+ produkuje, hodnoty pocházející z gyroskopu a zejména hodnoty EEG z 14 senzorů.

#### **4.2.2 Předzpracování dat**

Následujícím krokem po naměření dat bylo předzpracování dat. Hlavním smyslem předzpracování dat je jejich úprava do takové podoby, aby na nich mohla být provedena následná analýza. Pro předzpracování dat byly použity softwary Microsoft Excel a EEGlab. Excel byl použit zejména pro filtrační, organizační a přípravné práce, zatímco EEGlab, což je open source toolbox pro Matlab, sloužil, jak již název napovídá, pro samotnou úpravu EEG dat. Výhodou toolboxu EEGlab je jeho dostatečně kvalitní a přehledné GUI (Graphic User Interface). I přes fakt, že toolbox je šířen jako open source, tedy zdarma, je pro jeho spuštění nutná instalace softwaru Matlab, jehož licence je zpoplatněna.

Počátečním krokem fáze předzpracování dat se stalo třídění a redukce dat. Z původního textového souboru obsahující veškeré informace bylo nutné vytvořit nové textové soubory. Pro každého účastníka a každý stimul, který byl účastníkovi během experimentu promítnut, byl vytvořen nový textový soubor v tabelární formě obsahující výhradně numerická data z jednotlivých senzorů. Přítomnost jiných informací včetně časové složky či názvů sloupců v textovém souboru byly nežádoucí z důvodu chyby načítání při nahrávání souboru do toolboxu EEGlab.

Grafické uživatelské rozhraní toolboxu EEGLab je dostatečně přehledné a intuitivní. Sestává se z hlavního okna, ve kterém jsou zobrazené informace o nahraných EEG datech (tzv. datasetu), a z lišty záložek, které obsahují různé příkazy a funkce (obr. 9). Mezi



Obr. 9: GUI toolboxu EEGLab (zdroj: vlastní zpracování autora, 2017).

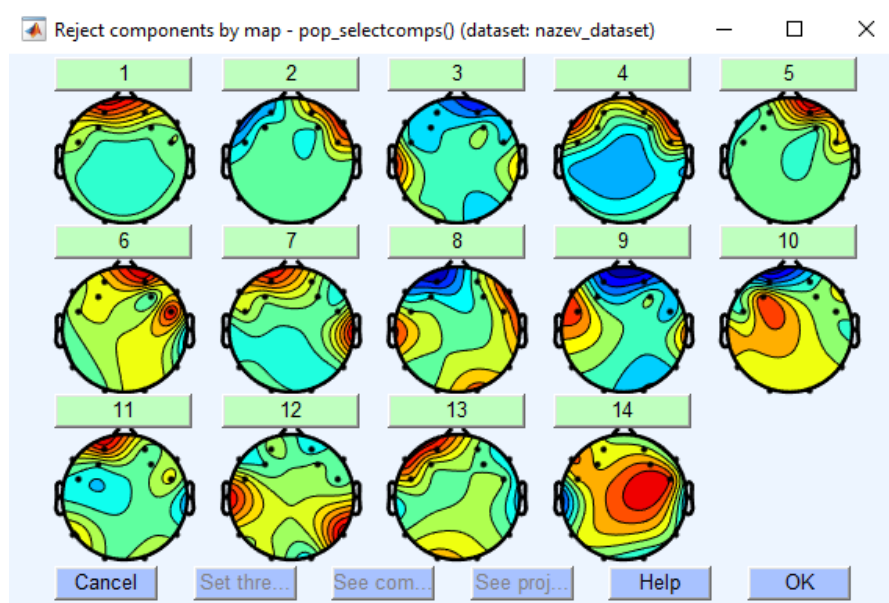
informace zobrazené v hlavním okně patří název datasetu, počet senzorů, počet epoch a událostí, počet zaznamenaných hodnot, záznamová frekvence a celkové trvání epochy. Záložka File obsahuje nástroje, týkající se nahrání, uložení a exportu EEG dat. V záložce Edit se skrývají nástroje zabývající se úpravami metadatových informací o datasetu, výběru pouze určité části nahraných dat či prostorové lokalizaci senzorů na lebce. Záložka Tools obsahuje již tematicky zaměřené nástroje pro úpravu EEG dat. Patří sem nástroje jako filtrace dat, vizuální odstranění dat, extrakce epoch, odstranění kolísání nulové izoliny, analýza nezávislých komponent (ICA) a další. V záložce Plot pak jsou k nalezení nástroje pro vizualizaci dat.

Prvotním krokem po spuštění toolboxu EEGLab je nahrání EEG dat v podobě připraveného textového souboru. Nahrání textového souboru se nachází v menu File > Import Data > Using EEGLAB functions and plugins > From ASCII/float file or Matlab array. Důležitým údajem, který je potřeba při nahrávání dat zadat do pole tomu určenému, je hodnota záznamové frekvence, která v případě předkládané práce činí 250 Hz.

Odstranění artefaktů by mělo být nedílnou součástí předzpracování (Aydin, 2016; Candra a kol., 2015; Gorgen, 2010; Hidalgo-Muñoz a kol., 2013; Murugappan a kol., 2010). Pro odstranění artefaktů lze použít vícero metod, avšak žádná kombinace

nepovede k absolutnímu odstranění artefaktů (Bos, 2006). Přílišné odstranění artefaktů naopak není žádoucí, neboť i data ovlivněná artefaktem mohou nést užitečnou informaci (Murugappan a kol., 2010). Jako jedna z variant pro odstranění artefaktů se jeví nástroj *Vizuální odstranění dat* (Tools > Reject continuous data by eye). Taková metoda, při které se označí a smaže časový úsek dat pouze na základě vizuálního vjemu, vyžaduje hlubokou a několikaletou znalost v oblasti elektroencefalografie. Další nevýhodou tohoto nástroje je jeho časová náročnost, kdy by se musel u každého textového souboru prohlížet elektroencefalogram.

Způsobem, jak odstranit část artefaktů, je použití nástroje *Analýza nezávislých komponent* (Tools > Run ICA). V oblasti zpracování signálů může velice často nastat problém, kdy naměřené signály jsou ovlivněny nějakým faktorem a neodpovídají tedy signálům původním. Jako tento faktor může vystupovat např. nízká selektivita senzoru, která způsobí, že výstup ze senzoru je ve skutečnosti kombinací více signálů (Ručkay, 2014). Analýza nezávislých komponent je metoda separace signálů, která odděluje smíchané nezávislé signály. Po spuštění nástroje *Analýza nezávislých komponent* vznikne takový počet nezávislých signálů, kolik je senzorů. Původ signálů lze vizualizovat pomocí nástroje *Mapové odstranění komponent* (Tools > Reject data using ICA > Reject components by map) (obr. 10). Vizualizována je lokace původu jednotlivých nezávislých komponent, přičemž červená barva značí ohnisko původu. V obecné rovině platí, pokud



Obr. 10: Vizualizace nezávislých komponent (zdroj: vlastní zpracování autora, 2017).

je poloha ohniska blízko nosu, jedná se o artefakt vzniklý mrkáním. Takovou komponentu je tedy vhodné odstranit. Nicméně i v tomto případě platí, že rozpoznání typů a původu nezávislých komponent vyžaduje expertní znalost problematiky (Decomposing data using ICA, 2016).

Následným krokem po analýze nezávislých komponent je odstranění kolísání nulové izoliny neboli driftu. Jedná se o jev, při kterém se dlouhodobě posouvá úroveň nulové hladiny, což má za následek zkreslení signálu (Procházka, 2015). Tento problém lze

odstranit pomocí nástroje *Odstranění průměru* (Tools > Remove baseline), který odečte od signálu jeho průměrnou hodnotu (Decomposing data using ICA, 2016).

Rozdílná vlnová pásma nesou různou charakteristiku dat (Lahane a kol., 2015). Z toho důvodu byla dalším krokem filtrace dat dle vlnových pásem  $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$  a  $\gamma$ . Hraniční hodnoty frekvencí vlnových pásem byly převzaty od Moráně (1995) (viz kapitola 3.1). Pro filtraci dat je v toolboxu EEGLab nástroj *Základní FIR filtr* (Tools > Filter the data > Basic FIR filter). V něm se zadávají dolní a horní hranice vlnových pásem. Filtraci je nutné na datasetu provést pětkrát, pro každé vlnové pásmo zvlášť, čímž vznikne pět nových datasetů.

Výsledných pět datasetů je potřebné z toolboxu EEGLab vyexportovat. Pro export slouží nástroj *Data a ICA do textového souboru* (File > Export > Data and ICA activity to text file). Vzhledem k požadavkům na strukturu souboru, vzhledem k dalšímu kroku práce, bylo nutné při exportu nastavit transponování struktury výsledného souboru, neboť nativně toolbox EEGLab exportuje data do řádků, nikoliv sloupců.

Výstupem z předzpracování dat je pět textových souborů pro každého uživatele a každý stimul. Vzhledem k očekávanému vysokému objemu dat bylo nutné proces předzpracování automatizovat. Výhodou automatizace je značná úspora času, nevýhodou pak je nemožnost manuální korekce dat v krocích *Vizuální odstranění dat* a *Mapové odstranění komponent*. Vzhledem k nízké erudici v oblasti elektroencefalografie bylo od manuálních úkonů upuštěno ve prospěch automatizace.

Úkony v toolboxu EEGLab lze provádět i bez GUI pomocí skriptů. Skripty jsou ve formátu skriptovacího jazyku používaném v softwaru Matlab. Pro tvorbu skriptů velmi dobře slouží nástroj *Uložit historii skriptu* (File > History Scripts > Save session history script), který vyexportuje skript všech provedených úkonů, které uživatel v toolboxu EEGLab vykonal. Právě skript, obsahující většinu úkonů popsanych v této kapitole, posloužil automatizaci předzpracování dat (obr. 11).

```
[ALLEEG EEG CURRENTSET ALLCOM] = eeglab; % spuštění toolboxu EEGLab
EEG = pop_importdata
('dataformat','ascii','nbchan',0,'data','absolutni_cesta_souboru',
'setname','eeg','srate',250,'pnts',0,'xmin',0); % nahrání textového souboru s EEG daty
[ALLEEG EEG CURRENTSET] = pop_newset(ALLEEG, EEG, 0,'gui','off');
EEG = eeg_checkset( EEG );
EEG = pop_runica(EEG, 'extended',1,'interrupt','on'); % spuštění nástroje ICA
[ALLEEG EEG] = eeg_store(ALLEEG, EEG, CURRENTSET);
EEG = eeg_checkset( EEG );
EEG = pop_rmbase( EEG, [0 3484]); % spuštění nástroje na odstranění kolísání nulové izolinnie
[ALLEEG EEG] = eeg_store(ALLEEG, EEG, CURRENTSET);
EEG = pop_eegfiltnew(EEG, 0.5, 4, 1650, 0, [], 1); % filtrace do pásma delta
[ALLEEG EEG CURRENTSET] = pop_newset(ALLEEG, EEG, 1,'setname','delta','gui','off');
EEG = pop_eegfiltnew(EEG, 5, 8, 414, 0, [], 1); % filtrace do pásma theta
[ALLEEG EEG CURRENTSET] = pop_newset(ALLEEG, EEG, 2,'setname','theta','gui','off');
EEG = pop_eegfiltnew(EEG, 9, 13, 368, 0, [], 1); % filtrace do pásma alfa
[ALLEEG EEG CURRENTSET] = pop_newset(ALLEEG, EEG, 3,'setname','alfa','gui','off');
```

Obr. 11: Ukázka skriptu pro práci v toolboxu EEGLab (zdroj: vlastní zpracování autora, 2017).

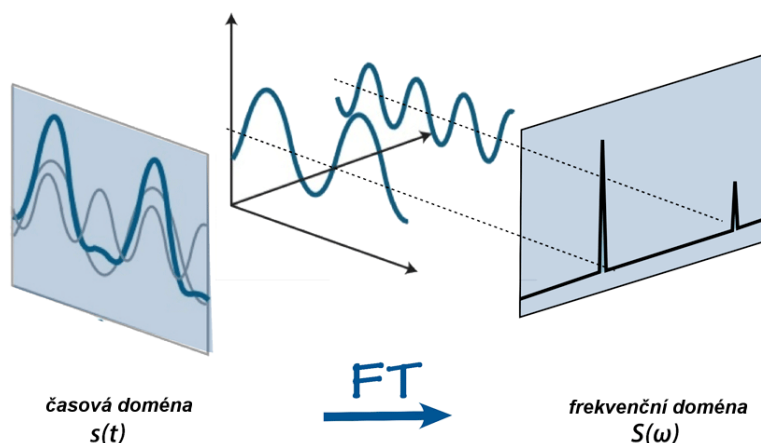
### 4.2.3 Extrakce charakteristických rysů

Krokem následujícím po předzpracování dat se stala analýza dat. Hlavním cílem analýzy dat bylo extrahovat charakteristické rysy signálů. Takovým charakteristickým rysem signálu je tzv. výkonové spektrum signálu (power spectral density, zkr. PSD)



(Vidaurre a kol., 2012; Al-Fahoum a Al-Fraihat, 2014). Postupné kroky v této kapitole směřují k výpočtu PSD. Veškeré výpočty fáze analýzy dat byly výlučně prováděny v softwaru Matlab. Pro výpočty by analogicky mohl být použit i jiný software určený pro matematické výpočty a statistickou analýzu, např. kterýkoliv frontend s grafickým rozhraním založený na programovacím jazyku R. I přes fakt, že oproti softwaru Matlab je programovací jazyk R volně šiřitelný, byl použit Matlab z důvodu zachování pracovního postupu diplomové práce v jednom softwarovém prostředí.

Prvním krokem po nahrání dat do prostředí Matlab je rychlá Fourierova transformace (FFT). Fourierova transformace je základním nástrojem pro zpracování signálů. Smyslem Fourierovy transformace je převod signálu z časové domény na frekvenční doménu (obr. 12) (Power spectra, 2017). Rychlá varianta transformace se nazývá rychlá Fourierova transformace. V softwaru Matlab odpovídá rychlé Fourierově transformaci funkce `fft`.



Obr. 12: Princip Fourierovy transformace (zdroj: [http://mriquestions.com/uploads/3/4/5/7/34572113/3311485\\_orig.gif](http://mriquestions.com/uploads/3/4/5/7/34572113/3311485_orig.gif), 2017).<sup>5</sup>

Po výpočtu rychlé Fourierově transformaci je možné na datech vypočítat výkonové spektrum signálu. Výkonové spektrum odpovídá na otázku, které frekvence daného signálu obsahují výkon signálu (Power spectra, 2017). Jinými slovy, výkonové spektrum je funkce, která nám říká, jaká část výkonu je nesena jakými frekvenčními složkami. Výkonové spektrum se udává ve wattech na hertz. Matematicky je výkonové spektrum vyjádřeno jako druhá mocnina hodnoty frekvence ve frekvenční doméně (Power spectra, 2017).

Doposud probíhaly výpočty takovým způsobem, že každý EEG signál vystupující z předzpracování, je v prostředí Matlab reprezentován maticí. Vzhledem k závěrečnému kroku celého postupu prací, jímž byla klasifikace dat, bylo nutné každý EEG signál převést na jedno číslo, neboť použitý klasifikátor neměl možnost použít celou matici, jako charakteristiku daného signálu. Z toho důvodu byla z výkonového spektra

<sup>5</sup> upraveno


vypočítána jeho průměrná hodnota. Tato hodnota pak reprezentovala hlavní charakteristiku signálu při závěrečné klasifikaci dat.

Výše sepsané kroky je nutné opakovat pro každého účastníka a každý stimul experimentu. Vzhledem k velmi vysokému počtu vstupních souborů (pro každý stimul a účastníka pět souborů s EEG daty rozdělených do vlnových pásem  $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$ ,  $\gamma$ ) a nutnosti opakovat proces pro každý soubor zvlášť, byl proces extrakce charakteristických rysů opět převeden do podoby skriptu za účelem automatizace procesu.

#### 4.2.4 Klasifikace dat

Závěrečným krokem celého zpracování dat se stala klasifikace dat. Smyslem klasifikace bylo rozřídění charakteristických rysů EEG dat do klasifikačních tříd. Klasifikace probíhala v aplikaci Classification Learner, což je aplikace implementovaná v softwaru Matlab. Právě integrita aplikace v softwaru, jenž byl používán pro většinu prací při zpracování diplomové práce, byla hlavním důvodem pro její použití, ačkoliv existují i volně šiřitelné softwary, které klasifikaci umožňují, mj. software Weka.

Vzhledem k rešerši bylo zvoleno použití klasifikátoru Support Vector Machine (SVM) (Aguinaga, 2015; Candra a kol., 2015; Hidalgo-Muñoz a kol., 2013; Inventado a kol., 2011; Lahane a kol., 2015; Liu a kol., 2010; Schaaff, 2008; Slanzi a kol., 2016; Sreeshakthy a Preethi, 2016; Strakoš, 2016). SVM je metoda strojového učení s učitelem, která se používá zejména při klasifikaci a regresní analýze. Principem SVM je hledání nadroviny, která rozděluje klasifikační třídy takovým způsobem, že mezi nadrovinou a hraničními body klasifikační třídy je největší vzdálenost (obr. 13). Nadrovinou se rozumí pro  $n$ -dimenzionální prostor jakýkoliv jeho podprostor o dimenzi  $n - 1$ . Pro rovinu (2D) je tedy nadrovinou přímka (1D), (Wikipedia, 2015).



Obr. 13: Optimální nadrovina u lineárního SVM (zdroj: Wikimedia Commons, 2015).

Aplikace Classification Learner obsahuje celkem šest různých typů SVM klasifikátorů – lineární, kvadratický, kubický a tři gaussovské. Kromě SVM klasifikátorů může klasifikace v aplikaci Classification Learner proběhnout i pomocí rozhodovacích stromů, diskriminační analýzy či metody k-nejbližšího souseda. Velkou výhodou aplikace je, že všechny typy klasifikace mohou být spuštěny najednou a uživatel aplikace si pak vybere, která klasifikační metoda je pro jeho potřeby nejvhodnější.

Začátkem klasifikace je tvorba klasifikačního modelu, tedy sady pravidel, podle kterých klasifikátor bude rozhodovat, jakým způsobem rozdělovat data do klasifikačních tříd. Tvorba klasifikačního modelu je součástí procesu trénování dat. Pro trénování dat v prostředí Matlab je nutné mít data připravená v jedné tabulce, resp. matici. Matice musí být strukturována do podoby, kdy v řádcích jsou prvky určené ke klasifikaci a ve sloupcích jsou atributy těchto prvků. V případě předkládané práce jsou atributy reprezentovány průměrnou hodnotou výkonového spektra signálu pro každý senzor a každé vlnové pásmo. Součástí matice také musí být atribut, který obsahuje hodnoty klasifikačních tříd. V tomto atributu je každému prvku přiřazena klasifikační třída, do které prvek spadá. Do trénování tedy vstupuje matice, která v případě této práce má celkem 71 atributů (14 senzorů  $\times$  5 vlnových pásem + klasifikační třídy).

Před samotným trénováním umožňuje aplikace Classification Learner nastavit křížovou validaci. Princip křížové validace spočívá v tom, že trénovací data jsou rozdělena na  $k$  částí. Trénování a tvorba klasifikačního modelu poté probíhá na všech částech, kromě jedné, na které se otestuje přesnost modelu. Tento proces probíhá opakovaně, ovšem mění se testovaná část (Arlot a Celisse, 2010). Proces křížové validace slouží jako ochrana pro přetrénování dat, což je stav, při kterém je klasifikátor natrénován na trénovací data, ale není schopen úspěšně klasifikovat neznámá data (Strakoš, 2016).

Po natrénování dat je vytvořen klasifikační model, který je poté používán pro klasifikaci dalších dat. Klíčovým ukazatelem schopnosti klasifikátoru je jeho úspěšnost vyjádřená v procentech.

### **4.3 Experiment se stimuly IAPS**

Prvním plánovaným experimentem byl ten, který obsahoval obrázky z databáze IAPS (International Affective Picture System). Smyslem experimentu bylo ověřit navrženou metodiku a zjistit, zda jsou data pořízená headsetem Emotiv EPOC+ úspěšně zpracovatelná.

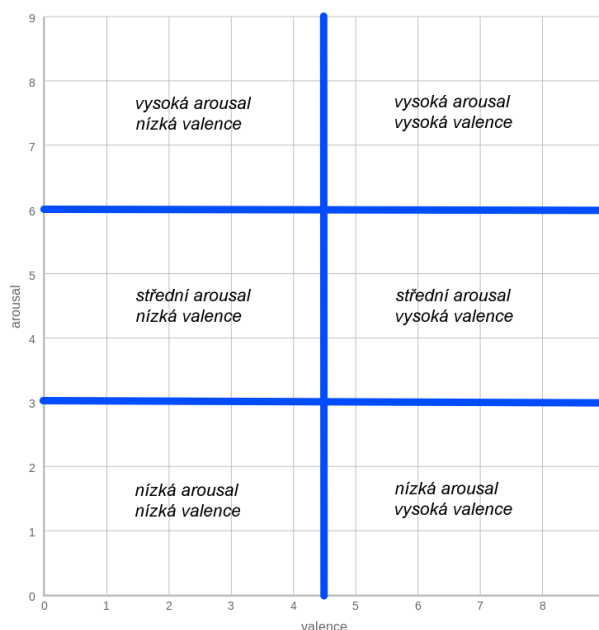
IAPS je systém vyvíjený a šířený z University of Florida, kde sídlí Centrum pro emoce a pozornost amerického Národního institutu duševního zdraví (National Institut of Mental Health, Center for Emotion and Attention). Systém je vyvíjen za účelem poskytnout emoční hodnocení pro velkou sadu mezinárodně srozumitelných, barevných fotografií, které obsahově zahrnují široké spektrum sémantických kategorií (Lang a kol., 2008). Vzhledem k rozsáhlým experimentům, které se na Floridě provedly, může být o obrázcích řečeno, jaké emoce by měly u jejich pozorovatelů navodit. Tyto emoce je možné odvodit ze tří ukazatelů, které byly při experimentech hodnoceny. Ukazatelé

odpovídají třem dimenzím z emočního modelu PAD State Emotional Model (viz kapitola 3.2.1). Konkrétně se jedná o dimenze arousal (zaujetí, vzrušivost), valence (pozitivita) a dominance. Poskytnutí databáze IAPS je bezplatné, stačí pouze zaslat žádost na institut. Použití stimulů z databáze je výhradně pro studijní a výzkumné účely. Není povoleno využívat databázi pro komerční účely a je zakázáno poskytovat jakýkoliv stimul z databáze třetím stranám, zejména médiím, je zakázána publikace i ve vědeckých časopisech či jejich publikace na internetu.

Hlavní myšlenkou experimentu bylo, že účastníkům bude promítnuta sada obrázků z databáze IAPS a vzhledem k faktu, že jsou u nich známé hodnoty dimenzí reprezentující emoce, bude možné k těmto hodnotám přiřadit EEG účastníků. Toto spojení pak bude figurovat jako sada trénovacích dat, ze které se vytvoří klasifikační model pro závěrečnou klasifikaci. Na základě takového modelu pak bude možné klasifikovat emoce účastníka, kterému bude promítnut kartografický stimul, jenž má neznámé hodnoty emocí.

### Sestavení experimentu

Příprava experimentu obsahovala zejména výběr stimulů z databáze IAPS, kterých je celkem 1 182. Pro účely experimentu byly stimuly rozděleny do šesti kategorií. Kritérii pro rozdělení se staly hodnoty dimenze arousal a valence, dimenze dominance nebyla zohledněna. Hodnoty jednotlivých dimenzí se pohybují v rozmezí 1–9, přičemž představují aritmetický průměr z měření emocí na University of Florida. Z každé kategorie bylo do experimentu vybráno deset stimulů. Stimuly byly vybrány takovým způsobem, při kterém byly postupně seřazeny dle obou zkoumaných dimenzí. Z pořadí potom byly vybrány ty stimuly s nejvyššími, nejnižšími a mediánovými hodnotami obou dimenzí. Při takovém způsobu výběru byla ještě zohledněna sémantická skladba stimulů, přičemž tematicky se opakující stimuly byly vyměněny za tematicky odlišné, nicméně



Obr. 14: Přibližné vymezení kategorií stimulů (zdroj: vlastní zpracování autora, 2017).

s podobnými hodnotami dimenzí arousal a valence. Taková výměna stimulů probíhala zejména u stimulů s explicitním obsahem (fotografie mrtvol, fotografie obsahující plnou nahotu). Vymezení jednotlivých kategorií s přibližnými hodnotami dimenzí arousal a valence znázorňuje obr. 14. Seznam použitých stimulů v experimentu včetně veškerých údajů je k diplomové práci přiložen jako příloha 2. Kromě stimulů z databáze IAPS byly do experimentu začleněny i snímky obsahující mapy. Jelikož smyslem experimentu bylo převážně zjistit, zda pohled na mapu probouzí v pozorovateli nějaké emoce, které jsou měřitelné pomocí EEG, nebyla sada snímků obsahující mapy nijak tematicky zaměřena či ucelena. V experimentu se tak vyskytly např. výřez geologické mapy ČR, výřez územního plánu, plánek autokempu, dvoustrana tematických map o Africe, plán londýnského metra či Quittova mapa klimatických oblastí ČR. Celkem bylo do experimentu začleněno 80 stimulů, z čehož bylo 20 stimulů obsahující mapy a 60 stimulů z databáze IAPS.

Stimuly měly v experimentu pevné pořadí, nebyly tedy účastníkům experimentu promítány náhodně. Pořadí bylo vybráno takovým způsobem, aby dva stimuly z databáze IAPS, klasifikované do stejné kategorie, nebyly promítnuty za sebou. Stimuly obsahující mapy byly rozprostřené do celé délky experimentu. Vždy po šestici stimulů z databáze IAPS následovala dvojice stimulů s mapami. Mezi každý stimul byl vložen snímek s černým křížkem uprostřed na bílé ploše, který sloužil pro centralizaci účastníkovy pohledu na střed monitoru. Pro celý experiment bylo nastaveno automatické časování snímků, účastník tedy nemusel obsluhovat posun mezi stimuly myší či klávesnicí. Stimuly byly promítány na monitoru po dobu 3 500 ms, snímky s křížky po dobu 500 ms.

### **Průběh experimentu**

Po sestavení experimentu přišlo na řadu samotné testování, které probíhalo v eye-tracking laboratoři na katedře geoinformatiky. Experimentu se zúčastnilo 15 osob ve věku 21–45 let, z toho 12 mužů a 3 ženy. Všichni účastníci jsou studenti či zaměstnanci katedry geoinformatiky Univerzity Palackého v Olomouci.

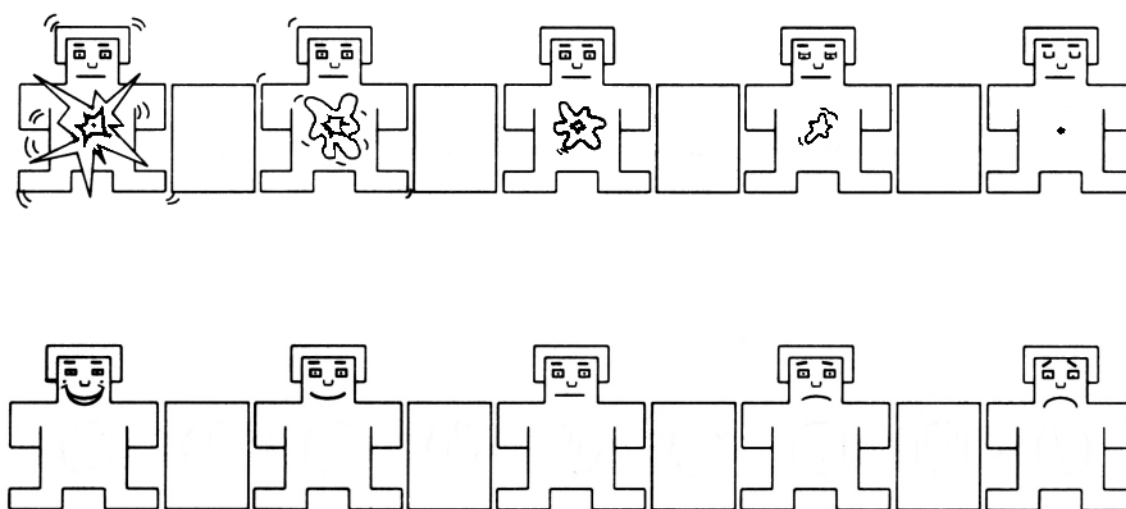
Po usazení účastníka před eye-tracker následovala instruktáž operátorem experimentu (autor předkládané práce). Účastníkovi byla detailně popsána jeho role v experimentu. Vzhledem k částečně explicitnímu obsahu stimulů v experimentu, byl účastník na tento fakt předem upozorněn. Důvodem takového upozornění bylo omezení překvapivých účastníkových reakcí, zejména reflexivní odvrácení pohledu mimo obrazovku, zakrytí si očí apod., což by mělo za následek vnesení šumu a artefaktů do měřených dat, přičemž tyto by se staly pro další zpracování nepoužitelné. Po tomto upozornění a ujištění, že účastník rozumí své účasti v experimentu, byl účastník požádán o potvrzení formuláře informovaného souhlasu (viz Příloha 1). Získáním potvrzeného informovaného souhlasu mohla začít instalace EEG zařízení na účastníkovu hlavu. Instalace probíhala stejným způsobem, jako je popsána v kapitole 4.2.1.

Následovalo již samotné spuštění experimentu. Na začátku účastník vyplnil základní národné, konkrétně se jednalo o jméno, pohlaví a věk. Poté již byly účastníkovi promítány samotné stimuly. Jak již bylo zmíněno, jednalo se o 80 stimulů, které se samy

promítaly. Účastník nemusel posouvat stimuly manuálně z důvodu, aby nedocházelo k vnášení šumu a artefaktů do měřeného signálu. Při průběhu experimentu bylo naprosté ticho, operátor nijak do experimentu nevstupoval, aby účastník nebyl nijak vyrušován a působily na něj pouze promítané stimuly.

### **Dotazník SAM**

Druhou částí experimentu se stal dotazník SAM (The Self-Assessment Manikin). Jedná se o nonverbální metodu, při které účastníci pomocí piktogramů hodnotí, jakým emočním prožitkem na ně působí stimul (Bradley a Lang, 1994). Základním stavebním kamenem dotazníku je sada piktogramů určená pro měření emočních dimenzí valence, arousal a dominance. Vzhledem k potřebám předkládané práce byly použity piktogramy pouze pro dimenze valence a arousal (obr. 15).



Obr. 15: Piktogramy pro dotazník SAM (zdroj: Bradley a Lang, 1994)

Piktogramy se snaží pomocí vizuální podoby asociovat pocíťovanou emoci. Označením příslušného piktogramu účastník experimentu sebehodnotí právě prožívanou emoci. Horní řada piktogramů slouží pro ohodnocení dimenze arousal, kdy na pravé straně je její nejnížší hodnota a na levé straně nejvyšší. Může být řečeno, že piktogram v horní řadě na pravé straně představuje pocit velmi nízkého vzrušení či nízkého zájmu oproti tomu piktogram na levé straně představuje velmi vysoké vzrušení či zaujetí. Ve spodní řadě se potom hodnotí emoční dimenze valence. Na pravé straně se nachází piktogram s nejnížší mírou valence představující velmi negativní pocit. Na opačné straně je piktogram s nejvyšší mírou valence představující velmi pozitivní pocit. Prázdné obdélníky vyskytující se mezi jednotlivými piktogramy představují také možnost ohodnocení dané dimenze. Označení obdélníku slouží v případech, kdy se účastník nemůže rozhodnout v označení mezi dvěma sousedícími piktogramy.

Pro potřeby dotazníku SAM byl vytvořen druhý kombinovaný eye-tracking a EEG experiment. V něm byly stejné stimuly jako v experimentu prvním a to ve stejném pořadí. Rozdíly oproti prvnímu experimentu mohou být nalezeny zejména ve skutečnosti, že nyní

u stimulů nebylo nastaveno automatické časování, účastníci si mohli stimuly prohlížet libovolně dlouho, a po každém stimulu následoval snímek s dotazníkem SAM v podobě jako na obr. 15.

Úkolem účastníků bylo prohlédnout si znovu stimuly a poté zhodnotit své pocity vycházející z nich a tyto zaznamenat kliknutím kurzorem myši na jeden piktogram v horní řadě hodnotící dimenzi arousal a jeden piktogram v dolní řadě hodnotící dimenzi valence. Pro tyto úkony byli účastníci před druhou částí experimentu instruováni. Byl jim detailně popsán princip dotazníku i s uvedením příkladu. I přes tento fakt, docházelo v ojedinělých případech buď k nechtěnému přeskočení snímku s dotazníkem, nebo k mnohonásobnému ohodnocení jedné dimenze. V takovém případě bylo v následujícím zpracování dat zohledněno pouze první ohodnocení dané dimenze, na ostatní ohodnocení nebyl brán zřetel.

I přes skutečnost, že i při této části byla účastníkům měřena EEG data, tato nebyla dále zpracovávána, a to z několika důvodů. Prvním důvodem byla nestejnoročnost v délce prohlížení stimulů. Vzhledem k tomu, že účastníci měli možnost si při dotazníku SAM prohlížet stimuly libovolně dlouho, bylo by obtížné následně sjednotit časové údaje pro všechny stimuly. Druhým důvodem se pak stalo prosté snížení kvality přenosu signálu. S přibývajícím časem hydratované senzory na EEG headsetu kvůli vlasům začaly postupně vysychat, čímž kvalita přenosu signálu zákonitě začala klesat. Sundání headsetu, hydratace senzorů a opětovná instalace by zabrala další čas. Již v takovéto podobě experimentu zabrala celá procedura přibližně 30 minut na účastníka, který po zhlédnutí 160 stimulů byl ve většině případů unavený. Třetím důvodem, který nelze opomenout je fakt, že účastníci vykonávali při této části experimentu drobné pohyby, čímž v signálu přibyl šum a artefakty. Smysl měření EEG při dotazování SAM byl zejména pozorovací.

## 5 VÝSLEDKY

V této kapitole jsou přehledně shrnuty dosažené výsledky v práci. Kromě popisu výsledků je i reflektován fakt, zda bylo dosaženo cílů uvedených v kapitole 1. Tato kapitola je rozdělena do tří částí, přičemž v první je shrnuta navrhovaná metodika pro měření a zpracování EEG dat, ve druhé jsou popsány výsledky provedeného experimentu se stimuly z databáze IAPS a ve třetí je rozebráno, proč nebyl uskutečněn další experiment.

### 5.1 Metodika měření a zpracování EEG dat

Hlavním cílem předkládané práce, jak je uvedeno v kapitole 1, je použití zařízení EEG Emotiv EPOC+ při kombinovaném eye-tracking a EEG experimentu s eye-trackerem SMI RED 250. Pro provedení takového experimentu bylo nutné nejdříve ustanovit metodiku. Ta je detailně popsána v kapitolách 4.2.1–4.2.4. Obsahuje čtyři části – měření dat, předzpracování dat, extrakci charakteristických rysů a klasifikaci dat, přičemž měření dat bylo provedeno v softwaru SMI ExperimentCenter™ Software, předzpracování dat probíhalo v toolboxu pro Matlab s názvem EEGLAB a extrakce charakteristických rysů společně s klasifikací probíhalo v softwaru Matlab a jeho zabudovaných aplikacích. Z výše uvedeného vyplývá, že dílčí cíl sestavení metodiky pro kombinovaný EEG a eye-tracking experiment a následné zpracování naměřených dat byl splněn.

### 5.2 Výsledky experimentu se stimuly IAPS

Cíl experimentu by se dal rozdělit do dvou částí. První částí bylo získání a zpracování dat z EEG headsetu. Druhou částí pak bylo provedení dotazování pomocí dotazníku SAM a získané výsledky porovnat s daty z EEG.

Naměřením EEG dat započal postup prací, který je detailně popisován v kapitolách 4.2.2, 4.2.3 a 4.2.4. Celkem byla naměřena data od 15 účastníků, každému z nich bylo promítnuto 80 stimulů, což dohromady tvořilo 1200 textových souborů nutných ke zpracování. Po předzpracování dat, při kterém se mj. data filtrovala do pěti vlnových pásem, bylo vytvořeno 6000 textových souborů, které vstupovaly do procesu extrakce charakteristických rysů. Pro závěrečné trénování dat bylo nutné vybrat pouze data od stimulů z databáze IAPS. Trénování dat probíhalo stejným způsobem, jako je popsáno v kapitole 4.2.4, přičemž bylo nastaveno šest klasifikačních kategorií odpovídajícím rozdělení na obr. 14. Při trénování byla nastavena desetinásobná křížová validace. Pro trénování byly kromě SVM klasifikátorů spuštěny i klasifikátory diskriminační analýzy k-nejbližšího souseda a rozhodovacích stromů, největší důraz byl ovšem kladen na klasifikátory typu SVM. Hodnoceným výsledkem se v případě trénování dat stal klasifikační model, který vznikl trénováním dat a který udává procentuální úspěšnost, s jakou byl schopný rozklasifikovat trénovací data. Nejúspěšnějšího klasifikačního modelu bylo dosaženo právě při nastavení desetinásobné křížové validace a použití



lineárního klasifikátoru SVM. Úspěšnost tohoto modelu ovšem činila pouhých 19,7 %. Úspěšnost může být graficky znázorněna pomocí konfúzní matice (obr. 16), ve které jsou zobrazeny hodnoty přesnosti klasifikátoru s ohledem na všechny klasifikované prvky. Čísla uvedená v matici na zeleném podkladu udávají počet prvků, které byly úspěšně predikovány do určité klasifikační třídy. Oproti tomu čísla uvedená v matici na červeném podkladu značí počet prvků, které byly při trénování dat klasifikovány do jiné klasifikační třídy, než jaká byla prvkům predikována. V ideálním případě je tedy rozložení prvků zejména na hlavní diagonále.

**Konfúzní matice**

klasifikované třídy	1	37	20	26	21	16	30
	2	32	23	21	27	24	23
	3	19	28	33	17	27	24
	4	34	19	20	30	22	25
	5	27	19	32	21	23	28
	6	28	20	25	19	27	31
		1	2	3	4	5	6
		predikované třídy					


Obr. 16: Konfúzní matice pro šest klasifikačních tříd (zdroj: vlastní zpracování autora, 2017).

Vzhledem k získání klasifikačního modelu s přesností klasifikace necelých 20 %, došlo následně k dalším pokusům trénování dat za účelem zvýšit přesnost klasifikačního modelu. Ale i přes několikrát změny nastavení hodnoty při křížové validaci či snížení objemu dat vstupujících do procesu trénování, nedošlo ke zvýšení přesnosti klasifikačního modelu. U ostatních typů klasifikátorů, které byly také spouštěny při trénování dat, nedosahovala přesnost vzniklých klasifikačních modelů statisticky významného vylepšení. Pokud byla hodnota přesnosti klasifikačního modelu vyšší, než u klasifikátorů typu SVM, rozdíl byl maximálně v řádu desetin procenta.

Dalším krokem, který mohl zvednout procentuální přesnost modelu, byla redukce počtu klasifikačních kategorií. Při tomto kroku byl počet kategorií snížen na dvě. Z dvoudimenzionálního Kruhového modelu Jamese Russella byla zcela opomenuta dimenze arousal a zachována byla pouze dimenze valence, která byla rozdělena na pozitivní a negativní. Do těchto dvou kategorií byly překategorizovány data ze stimulů z databáze IAPS. Při tomto nastavení s desetinásobnou křížovou validací dosáhl nejvyšší přesnosti lineární klasifikátor SVM a to 54,2 %. Ani tato hodnota nepůsobí příliš pozitivně, pokud se vezme v potaz, že se jednalo o přesnost klasifikačního modelu obsahující pouze dvě klasifikační třídy. Pokud má binární klasifikátor přesnost 50 %,

jedná se o tzv. nenaučený klasifikátor, což znamená, že klasifikuje prvky naprosto náhodně.

V druhé části experimentu účastníci vyplňovali dotazník SAM. Dalším výsledkem experimentu jsou tedy odpovědi účastníků, které lze zpracovat do podoby grafu, ve kterém jsou jednotlivé osy představovány dimenzemi valence a arousal (obr. 17). V grafu jsou, kromě zanesených odpovědí, zobrazeny i zprůměrovaná hodnota odpovědí účastníků a také referenční průměr pro daný stimul, který byl získán společně se stimuly z University of Florida. Takovýmto způsobem lze vizualizovat veškeré odpovědi



Obr. 17: Graf zobrazující odpovědi účastníků na dotazník SAM u stimulu č. 18 (zdroj: vlastní zpracování autora, 2017).

z dotazníku SAM, včetně odpovědí na stimuly, které nepocházely z databáze IAPS. U grafů, které zobrazují odpovědi na stimuly nepocházející z databáze IAPS, je rozdíl v tom, že neobsahují bod reprezentující referenční průměr.

Pro další práci s dotazníkem SAM bylo nutné zjistit, zda odpovědi účastníků reflektují referenční průměr a zda tedy tato metodika je validní a použitelná i pro hodnocení jiných stimulů. Pro zhodnocení úspěšnosti dotazníku SAM bylo použito porovnání hodnot průměru odpovědí účastníků s hodnotou referenčního průměru formou vypočítání průměrné vzdálenosti těchto bodů v grafu u všech stimulů pocházejících z databáze IAPS. Vzdálenost bodů A  $[x_A, y_A]$  a B  $[x_B, y_B]$  reprezentující průměry byla vypočítána formou euklidovské vzdálenosti:

$$|AB| = \sqrt{(x_A - x_B)^2 + (y_A - y_B)^2} \quad (1)$$

Jak je patrné z tab. 2, tak průměrná hodnota této vzdálenosti je cca 1,28, což v rovině s maximální hodnotou 9 dělá přibližně 14,22 % délky této roviny. Může být tedy řečeno,

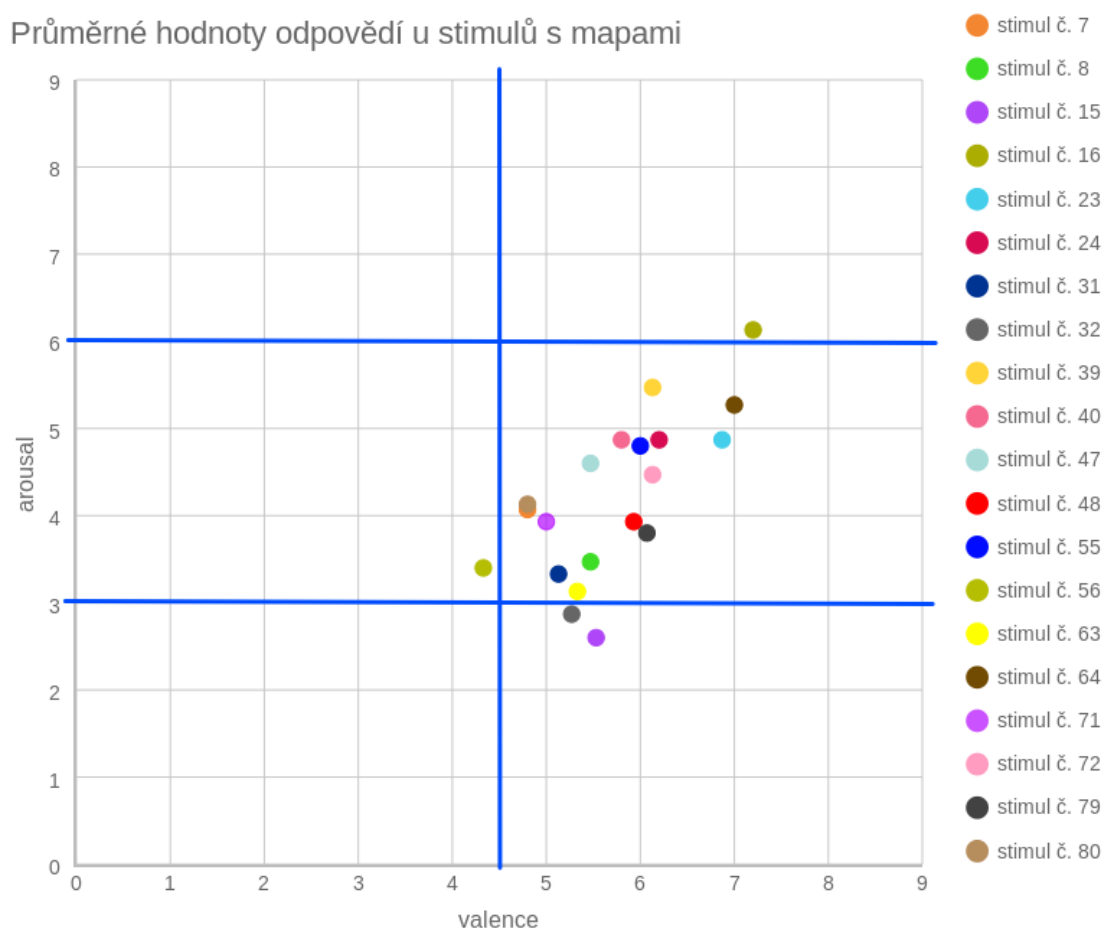
že přesnost odpovědí účastníků experimentu se přibližně z 85,78 % shodovala s referenčním průměrem poskytovaným vlastníkem a autorem dotazníku SAM.

Tab. 2: Vzdálenosti průměrných odpovědí a referenčních průměrů u stimulů z databáze IAPS (zdroj: vlastní zpracování autora, 2017).

č.	průměr odpovědí		referenční průměr		vzdálenost průměrů
	valence	arousal	valence	arousal	
1	3,27	5,73	1,95	4,53	1,78
2	6,13	3,13	7,14	3,00	1,02
3	7,20	4,67	8,28	4,10	1,22
4	6,47	5,73	7,73	6,65	1,56
5	2,07	7,40	1,66	6,04	1,42
6	4,60	1,87	4,43	2,55	0,70
9	3,33	4,93	2,56	4,61	0,84
10	4,47	3,27	4,45	2,51	0,76
11	7,40	5,20	8,03	4,60	0,87
12	6,40	4,80	7,63	6,07	1,77
13	6,07	3,13	6,51	2,74	0,59
14	2,73	7,13	1,83	6,08	1,39
17	4,73	3,27	4,25	2,95	0,58
18	2,27	6,40	1,76	6,81	0,65
19	3,40	5,87	2,58	4,95	1,23
20	7,00	5,33	8,00	4,92	1,08
21	5,93	2,47	7,08	2,67	1,16
22	7,00	4,27	7,38	6,28	2,05
25	4,60	2,07	4,55	2,27	0,21
26	6,47	4,40	6,50	2,60	1,80
27	7,80	6,40	8,10	6,28	0,32
28	2,13	7,73	1,46	7,21	0,85
29	7,07	4,60	7,90	4,27	0,90
30	3,20	6,00	2,20	4,88	1,50
33	6,27	3,87	7,14	2,90	1,30
34	1,93	7,87	1,45	6,41	1,53
35	2,87	6,20	2,56	4,92	1,32
36	7,13	4,73	8,19	4,61	1,06
37	4,93	1,67	4,45	2,81	1,24
38	6,33	5,13	7,57	7,27	2,47
41	5,67	3,33	6,37	2,83	0,86
42	4,53	2,67	4,23	2,96	0,42
43	6,00	3,27	7,91	6,44	3,70
44	2,13	7,53	1,51	7,07	0,78
45	7,07	5,20	7,77	4,68	0,87
46	3,80	5,73	2,56	4,31	1,89
49	2,00	7,80	1,31	6,91	1,13
50	6,67	4,07	6,31	2,79	1,33
51	5,00	1,80	4,63	2,71	0,98
52	6,80	4,93	7,77	6,73	2,04
53	3,27	5,93	2,06	4,00	2,28
54	6,60	4,93	8,21	4,31	1,73
57	2,20	6,93	1,69	6,58	0,62
58	6,67	4,53	8,03	4,90	1,41
59	3,67	4,93	2,54	4,86	1,13
60	6,87	5,47	8,02	7,17	2,06
61	6,33	4,13	6,23	2,84	1,30
62	5,13	4,13	4,03	2,63	1,86
65	6,40	4,33	7,74	6,14	2,25
66	4,73	2,47	4,52	2,03	0,49
67	3,20	4,80	2,67	4,63	0,56
68	2,67	4,93	2,04	6,05	1,28
69	5,47	4,00	6,17	2,90	1,31
70	7,07	4,73	8,20	4,57	1,15
73	7,00	4,73	7,35	6,02	1,33
74	2,67	6,80	2,44	5,00	1,81
75	6,33	4,53	7,61	4,51	1,28
76	6,93	4,00	6,36	2,51	1,60
77	5,27	2,87	4,49	2,63	0,81
78	2,40	6,27	1,62	7,15	1,18
			<b>průměr:</b>		<b>1,28</b>

Největších hodnot v rozdílech průměrů dosáhly stimuly z kategorie vysoká arousal-vysoká valence (stimuly č. 4, 12, 22, 27, 38, 43, 52, 60, 65, 73). Průměrná vzdálenost této kategorie stimulů činí přibližně 1,97. Naopak nejnižší průměrné hodnoty rozdílu průměrů dosáhly stimuly z kategorie vysoká arousal-nízká valence (stimuly č. 5, 14, 18, 28, 34, 44, 49, 57, 68, 78). Tato hodnota činí přibližně 1,07.

Díky dotazníku SAM, mohou být s velmi vysokou přesností klasifikovány i stimuly, které nepocházejí z databáze IAPS, což jsou v případě této práce stimuly obsahující mapy. Průměrné hodnoty odpovědí lze opět zanést do grafu spolu s vyznačenými šesti klasifikačními kategoriemi, které byly ustaveny v předchozích částech (obr. 18).



Obr. 18: Průměrné hodnoty odpovědí u stimulů s mapami společně s vyznačenými klasifikačními kategoriemi (zdroj: vlastní zpracování autora, 2017).

Z výsledného grafu je patrné, že všechny stimuly s mapami vyjma jedné spadají do kategorií s vysokou mírou valence, lze tedy říci, že působily na účastníky experimentu pozitivně. Veškeré mapy kromě tří spadají do kategorií střední míry arousal.

Cílem tvůrců map by mělo být, aby jejich výsledný produkt působil pozitivně a aby pokud možno měl co nejvyšší míru arousal, což by značilo vysokou míru zaujetí uživatele vůči produktu. Výsledky z grafu naznačují úspěšnost tvůrců stimulů použitých při experimentu, neboť většina stimulů působila na účastníky pozitivně, přičemž jejich

zaujetí bylo ve většině případů na střední úrovni. Tato skutečnost samozřejmě může být ovlivněna strukturou účastníků experimentu, neboť všichni pocházeli z katedry geoinformatiky a dají se tedy označit za experty v oboru, kterým jsou mapy blízké.

Nejlepších hodnot v dotazníku SAM dosáhly stimuly č. 16, 39 a 64, které získaly největší ohodnocení dimenzí valence a arousal. Nejhůře naopak z dotazníku vyšly stimuly č. 15, 32 a 56. Všechny šest stimulu je zobrazeno na obr. 19. Nejlépe hodnocené stimuly mají společné to, že se nejedná o mapy v pravém slova smyslu, ale jde o infografiky či designové obrázky u kterých chybí kompoziční prvky map.

Dílčí cíl práce, uvedený v kapitole 1, provést experiment, na kterém bude verifikována navržená metodika a který bude obsahovat stimuly z databáze IAPS, byl splněn. Z naměřených výsledků lze doporučit, že pro měření emocí účastníků je vhodnější použití dotazníku SAM než klasifikace emocí z primárních EEG dat.



Obr. 19: Stimuly č. 16, 39 a 64 (vlevo) a stimuly č. 15, 32 a 56 (zdroj: vlastní zpracování autora, 2017).

## 5.3 Kartografický experiment

Součástí zadání práce a jedním z cílů práce bylo i provedení kartografického experimentu. Jeho smyslem mělo být otestování účastníků a naměření EEG dat při jejich práci s mapami a při řešení jednoduchých prostorových úloh. Po konzultaci s vedoucím práce ovšem bylo od tohoto experimentu upuštěno a to z několika důvodů. Prvním z nich byla nízká úspěšnost klasifikačního modelu při experimentu se stimuly z databáze IAPS, jenž měl sloužit jako testovací experiment, ze kterého bude patrné, zda se dají úspěšně klasifikovat emoce z primárních EEG dat a ze kterého vznikne úspěšná sada trénovacích dat. Druhým důvodem, proč nebyl experiment uskutečněn, byla skutečnost, že při takovém experimentu by účastníci vykonávali pohyb (přínejmenším ovládní myši), což by, vzhledem k citlivosti EEG headsetu, vnášelo do dat šum a artefakty. Posledním důvodem pak byl i potenciálně odlišný přístup k experimentu a zpracování dat. Při tomto experimentu by každý účastník prováděl úkoly rozdílně dlouho, což by znesnadnilo zpracování dat. Vzhledem k tomu, že během daného úkolu by se účastníkovy emoce měnily, bylo by nutné data z jednoho úkolu rozdělit do několika částí. Otázkou by bylo, jak by takové části měly vypadat. Pokud by došlo k rozdělení na stejně dlouhé časové intervaly, mohlo by dojít k situaci, že ve stejném intervalu bude více než jedna emoce. Částečným řešením této situace by bylo vkládání časových značek do dat operátorem experimentu dle změn emocí účastníka, který by ovšem tyto změny musel například oznamovat nebo by musel celý experiment probíhat formou thinking aloud a účastník by hovořil o tom, jak se cítí a jaké prožívá emoce. V takovém případě by ovšem vyvstaly problémy s tím, že ne každý je schopný pojmenovat, jak se cítí, a v krajních případech by to mohlo být pro účastníka nepříjemné. Další problém spojený s mluvením účastníků by byl nárůst šumu a artefaktů v naměřených datech.

## 5.4 Manuál

Vzhledem k potřebám katedry geoinformatiky a pro zjednodušení budoucí práce se zařízením Emotiv EPOC+ byl sepsán 22stránkový strukturovaný manuál, který detailně popisuje práci s headsetem a následné zpracování EEG dat. Tento manuál je přiložen k diplomové práci jako příloha 4.

Manuál je rozdělen do pěti kapitol. V první je popsána základní údržba headsetu. Ve druhé kapitole je popsána metodika měření dat, včetně nasazování headsetu na hlavu účastníka při experimentu. Třetí kapitola popisuje jednotlivé kroky nutné pro předzpracování dat v toolboxu EEGLAB a čtvrtá kapitola tak činí pro extrakci charakteristických rysů v softwaru Matlab. Závěrečná pátá kapitola pak popisuje procesy trénování dat a tvorbu klasifikačního modelu v aplikaci Classification Learner. Podrobná struktura celého manuálu je znázorněna jeho obsahem v kapitole 5.4.1.

## 5.4.1 Obsah manuálu

<b>1</b>	<b>ÚDRŽBA ZAŘÍZENÍ EMOTIV EPOC+</b> .....	<b>4</b>
1.1	NABÍJENÍ HEADSETU .....	5
1.2	HYDRATACE HEADSETU .....	5
<b>2</b>	<b>MĚŘENÍ DAT</b> .....	<b>6</b>
2.1	INFORMOVANÝ SOUHLAS .....	6
2.2	NASAZENÍ SENZORŮ .....	6
2.3	SPÁROVÁNÍ HEADSETU S POČÍTAČEM .....	6
2.4	INSTALACE ZAŘÍZENÍ NA HLAVU .....	7
2.5	AKTIVACE SENZORŮ .....	7
2.6	EXPERIMENT .....	8
<b>3</b>	<b>PŘEDZPRACOVÁNÍ DAT</b> .....	<b>9</b>
3.1	IMPORT DAT .....	9
3.2	NAHRÁNÍ SOUBORU .CED .....	10
3.3	ODSTRANĚNÍ ARTEFAKTŮ .....	12
3.4	ANALÝZA NEZÁVISLÝCH KOMPONENT .....	12
3.5	ODSTRANĚNÍ KOLÍSÁNÍ NULOVÉ IZOLINIE .....	13
3.6	FILTRACE DO VLNOVÝCH PÁSEM .....	13
3.7	EXPORT DAT .....	14
3.8	SKRIPT .....	15
<b>4</b>	<b>EXTRAKCE CHARAKTERISTICKÝCH RYSŮ</b> .....	<b>16</b>
4.1	IMPORT DAT .....	16
4.2	FOURIEROVA TRANSFORMACE .....	17
4.3	VÝKONNOVÉ SPEKTRUM SIGNÁLU .....	17
4.4	PRŮMĚRNÁ HODNOTA VÝKONOVÉHO SPEKTRA .....	17
4.5	EXPORT DAT .....	18
4.6	SKRIPT .....	18
<b>5</b>	<b>KLASIFIKACE DAT</b> .....	<b>19</b>
5.1	PŘÍPRAVA DAT .....	19
5.2	TRÉNOVÁNÍ DAT .....	19
5.3	EXPORT KLASIFIKAČNÍHO MODELU .....	21
5.4	POUŽITÍ KLASIFIKAČNÍHO MODELU .....	22

## 6 DISKUZE

Tématem předkládané diplomové práce je měření emocí. Na základě získaných výsledků lze diskutovat, zda postupy měření emocí, jež jsou uvedeny v práci, jsou vhodné, jaké mají přednosti a jaké jsou jejich nedostatky.

Na začátku je ovšem třeba položit obecnou otázku ohledně měření emocí. Jedná se o měřitelnou veličinu? Odpověď na tuto otázku je zásadní. Při standardních měřeních jsou obvykle měřeny reálné, hmatatelné veličiny, ať už se jedná o vzdálenost, množství srážek či počet sakád a fixací oka. U emocí je tento přístup obtížnější, neboť se měří něco, co není vidět a není hmatatelné. Problematice nepřispívá ani fakt, že není ustanovena základní definice emoce, ani preferovaný emoční model. Stejně tak se překrývají rozdíly mezi definicemi emocí, pocitů a nálad.

Další otázkou zůstává, zda by zkoumání a měření emocí, ve smyslu jaké emoce vyvolává výsledný produkt, mělo být doménou kartografů. Zajisté, je vhodné, aby výsledný kartografický produkt působil přívětivě, pozitivně a pokud možno co nejvíce zaujal uživatele produktu. Nicméně tyto věci souvisí zejména s celkovým designem produktu, což už se tolik nedotýká samotné kartografie. Při tvorbě map se výzkum emocí může hodit zejména při rozhodování o použití různých barev, nicméně tím se již úspěšně zabývá obor psychologie barev.

Zajímavým výzkumem v oblasti kartografie by ovšem bylo, jak složitá je práce či jak vhodné je ovládání výsledného kartografického produktu. Pro zjištění takových údajů by bylo vhodné měřit lidskou kognitivní zátěž (angl. cognitive load), jenž udává celkový objem myšlenkového úsilí použitého při pracovní, krátkodobé paměti.

### **Měření emocí pomocí EEG**

I přes obtížnost měření emocí, se ve světě objevují nové přístupy k této problematice. Ve 21. století a zejména v posledních pěti letech se vyskytla celá řada studií, která získává hodnoty emocí z EEG dat. Nikdy se ovšem nejedná o získání konkrétní emoce, ale pouze o nějakou obecnou kategorii emocí. Díky tomu, že katedra geoinformatiky disponuje zařízením, které měří EEG, mohla být tato metoda měření emocí vyzkoušena. Metoda měření emocí pomocí EEG zůstává poněkud konzervativní a to z důvodu vzniku signálu a místě, kde emoce vznikají. Zaznamenaný EEG signál vzniká zejména díky aktivitě povrchových struktur mozku (Elektroencefalografie, 2016), zatímco původ emocí je v amygdale, jež je součástí limbického systému a nachází se až pod mozkovou kůrou. Kvůli tomuto faktu minimální počet studií zabývajících se klasifikací emocí z EEG dat pochází z medicínského prostředí. Většinou se jedná o technologicky zaměřené instituty s důrazem kladeným na IT.

Navržený postup zpracování EEG dat reflektuje vybrané studie. U některých studií byly použity jiné hardwary, softwary, transformace či metody klasifikace, což je podrobněji popsáno v kapitole 3.3. Důvodem, proč byly vybrány do metodiky právě ty kroky, které byly vybrány, je zejména softwarové vybavení. Klíčovým softwarem pro celou práci byl toolbox EEGLAB. Vzhledem k tomu, že toolbox EEGLAB lze spustit



pouze v softwaru Matlab, veškeré další kroky byly činěny s ohledem na skutečnost, aby byly realizovatelné v prostředí Matlab.

Výsledkem zpracování EEG signálu byl klasifikační model, který dosáhl přesnosti klasifikace pouhých 19,7 %. Důvodů, proč se dospělo k tak málo příznivému výsledku, může být několik. Prvním z nich může být chyba měření. To se mohlo stát kvůli chybnému usazení headsetu na hlavu. Ten není vůči nepřesnému usazení na hlavu nijak uzpůsoben. Ano, celý headset má pevně danou pozici senzorů vůči sobě navzájem, nicméně při nesprávné manipulaci s ním, může být umístěn na hlavu pod různými úhly. K úspěšnému přenosu signálu i přes chybné umístění dojde. Stačí, aby byly senzory headsetu řádně hydratovány. Další problém, který mohl ovlivnit měření dat, bylo postupné vysychání senzorů, s čímž bylo spojeno postupné snižování kvality přenosu signálu. I těch přibližně 8 minut, co trval experiment, stačilo v některých případech k tomu, aby se na senzoru ztratil signál.

Teoreticky k problémům mohlo dojít i v částech předzpracování dat a extrakce charakteristických rysů z nich. V tomto případě, ale došlo k převzetí postupů z ostatních studií.

Jiného výsledku mohlo být dosaženo při různém nastavení trénování dat a použití odlišného klasifikátoru. Potenciálních kombinací řešících, jak objemný použít soubor trénovacích dat, kolikanásobnou křížovou validaci nastavit a jaký nejvhodnější klasifikátor použít, je velké množství. Jistou pokročilejší možností se jeví použití umělých neurálních sítí pro klasifikaci.

I přes skutečnost, že se experimentu zúčastnilo pouze 15 osob, jeví se toto číslo jako nepodstatné pro negativní ovlivnění výsledků. V citovaných studiích často do experimentu vstupovala data od nižšího počtu účastníků, přičemž jejich úspěšnost klasifikace byla vyšší.

### **Dotazník SAM**

Dotazník SAM je druhá metoda, která byla v práci použita pro měření emocí. Jeho největší předností je jeho jednoduchost a asociativnost. Také lze o něm říci, že je akceptovaný lékařským prostředím, neboť byl vyvinut v americkém Národním institutu duševního zdraví (The National Institute of Mental Health).

Oproti klasifikaci EEG dat dosáhly výsledky z dotazníku SAM nepoměrně vyšší přesnosti. Díky tomu lze výsledky stimulů, které nepocházely z databáze IAPS, získané prostřednictvím tohoto dotazníku považovat za relevantní.

Co negativně ovlivňovalo provedení dotazníku SAM byl fakt, že experiment s dotazníkem následoval ihned po experimentu, při kterém byla měřena EEG data. Vzhledem k vysokému počtu stimulů (80), které účastníci viděli dvakrát po sobě, byli účastníci ke konci experimentu již unavení a celý proces ohodnocení emocí urychlovali, ať už vědomě či nevědomě.

Zajímavé je také bližší prozkoumání stimulů z databáze IAPS. Z výsledků v kapitole 5.2 vyplývá, že největší rozdíly mezi očekávanou emocí účastníků a projevenou emocí byly u stimulů z kategorie vysoká arousal-vysoká valence, tedy snímků, které by měly

nejvíce zaujmout a být pro člověka nejvíc pozitivní. Důvodem, proč zrovna tato kategorie dosáhla největších rozdílů mezi projevenou a očekávanou emocí může být skutečnost, že stimuly jsou proamericky laděné. Největšího rozdílu dosáhl stimul, na kterém jsou zobrazeny rozházené bankovky amerických dolarů, což Čecha zřejmě neovlivní natolik, jako by ovlivnil stimul, na kterém by byly zobrazeny české bankovky. Dalším příkladem je stimul zobrazující americkou gymnastku ve vítězném gestu. Pro Čechy by v takovém případě vhodnější stimul s českým sportovcem, který je všeobecně známý a je symbolem úspěchu.

## 7 ZÁVĚR

Motivací, proč zpracovat práci s tímto tématem, se stala přítomnost elektroencefalografu Emotiv EPOC+ na katedře geoinformatiky. Hlavním cílem práce bylo použití zařízení Emotiv EPOC+ společně s eye-trackerem SMI RED 250 při kombinovaném eye-tracking a EEG experimentu. Dílčími cíli, nezbytnými pro dosažení hlavního cíle, se staly nastudování problematiky v oblasti elektroencefalografie, emocí a zpracování signálu, navrnutí metodiky získání a zpracování EEG dat za účelem klasifikace emocí, popis hodnot emocí a primárních dat vycházejících z přístroje Emotiv EPOC+ a provedení dvou experimentů. První experiment měl za cíl ověřit navrženou metodiku a za pomoci stimulů z databáze IAPS ověřit validitu dat vycházejících z přístroje Emotiv EPOC+. Druhý experiment měl za cíl zjistit působení lidských emocí při práci s kartografickým produktem či při řešení prostorových úloh.

Navržená metodika zpracování EEG signálu za účelem získání emocí se skládá ze čtyř částí. První částí je samotné měření dat. Druhá část se zabývá předzpracováním dat. Tato část výhradně probíhala ve specializovaném toolboxu EEGLAB, který, jak již název napovídá, slouží pro analýzu a vizualizaci EEG dat. Předzpracování dat sestává z postupných kroků, jako je odstranění artefaktů, analýza nezávislých komponent, odstranění kolísání nulové izolinie signálu a filtrace dat do vlnových pásem. Třetí částí navržené metodiky je extrakce charakteristických rysů signálů. Jejím smyslem je získání hodnoty, která je charakteristická pro daný signál. Tím se v práci stala průměrná hodnota výkonového spektra signálu, jež byla získána za pomoci Fourierovy transformace. Poslední částí metodiky pak byla klasifikace dat, s čímž je spojeno i trénování dat. Pro klasifikaci dat byly vybrány klasifikátory typu SVM (Support Vector Machine), které se mj. nacházejí v aplikaci softwaru Matlab, která nese název Classification Learner a která byla pro klasifikaci dat použita.

Po sestavení metodiky proběhl kombinovaný eye-tracking a EEG experiment, jehož se zúčastnilo 15 osob. Experiment se skládal ze dvou částí. Při první části byly účastníkům promítány vizuální stimuly z databáze IAPS a stimuly, které obsahovaly mapy, přičemž bylo účastníkům snímáno EEG. Data z EEG poté byla zpracována navrženou metodikou. Výsledkem této části experimentu se stal klasifikační model, který má přesnost pouhých 19,7 %. Při druhé části experimentu účastníci sebehodnotili pomocí dotazníku SAM (The Self-Assessment Manikin), jak na ně stimuly působily. Přesnost odpovědí tohoto dotazníku dosáhla hodnoty 85,78 %. Z těchto hodnot je patrné, že vhodnějším způsobem pro hodnocení emocí se jeví dotazník SAM.

Druhý experiment, při kterém mělo být měřeno EEG účastníků při řešení prostorových úloh se neuskutečnilo z důvodu nízké úspěšnosti klasifikačního modelu z prvního experimentu. Z prvního experimentu totiž měla pocházet trénovací data, která by při druhém experimentu nebyla získána. Kvůli nízké úspěšnosti klasifikace provedení druhého experimentu pozbylo smysl.

Výsledky této práce poslouží zejména potřebám katedry geoinformatiky, neboť práce ustanovuje metodiku, jak měřit a zpracovat naměřená EEG data. Taková metodika do této doby na katedře nebyla. V budoucnu je možné na práci navázat a testovat odlišné přístupy v extrakci charakteristických rysů a zejména v možnostech klasifikace. Kromě studia emocí je také možné se zaměřit na studium kognitivní zátěže.

# POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE

AGUIÑAGA, Adrian Rodriguez, Miguel Angel López RAMÍREZ a María del Rosario Baltazar FLORES. Classification model of arousal and valence mental states by EEG signals analysis and Brodmann correlations. *International Journal of Advanced Computer Science and Applications*, [online]. 2015(6), 230–238 [cit. 2017-04-23]. Dostupné z: [http://thesai.org/Downloads/Volume6No6/Paper\\_33-Classification\\_model\\_of\\_arousal\\_and\\_valence\\_mental.pdf](http://thesai.org/Downloads/Volume6No6/Paper_33-Classification_model_of_arousal_and_valence_mental.pdf)

AL-FAHOUM, Amjed S. a Ausilah A. AL-FRAIHAT. Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains. *ISRN Neuroscience* [online]. 2014, **2014**, 1-7 [cit. 2017-04-27]. DOI: 10.1155/2014/730218. ISSN 2314-4661. Dostupné z: <http://www.hindawi.com/journals/isrn/2014/730218/>

ALVAREZ-ESTEVEZ, Diego. European Data Format. In: *European Data Format* [online]. 2017 [cit. 2017-04-27]. Dostupné z: <http://www.edfplus.info/>

ARLOT, Sylvain a Alain CELISSE. A survey of cross-validation procedures for model selection. *Statistics Surveys* [online]. 2010, **4**, 40-79 [cit. 2017-04-27]. DOI: 10.1214/09-SS054. ISSN 1935-7516. Dostupné z: <http://projecteuclid.org/euclid.ssu/1268143839>

AYDIN, Seda, Turgay KAYA a Hasan GULER. Wavelet-based study of valence–arousal model of emotions on EEG signals with LabVIEW. *Brain Informatics* [online]. 2016, **3**(2), 109-117 [cit. 2017-04-27]. DOI: 10.1007/s40708-016-0031-9. ISSN 2198-4018. Dostupné z: <http://link.springer.com/10.1007/s40708-016-0031-9>

BOS, Danny Oude. *EEG-based Emotion Recognition* [online]. 2006 [cit. 2017-04-26]. Dostupné z: [https://www.researchgate.net/publication/237777779\\_EEG-based\\_Emotion\\_Recognition](https://www.researchgate.net/publication/237777779_EEG-based_Emotion_Recognition)

BRADLEY, Margaret M. a Peter J. LANG. Measuring emotion: The self-assessment manikin and the semantic differential. *Journal of Behavior Therapy and Experimental Psychiatry* [online]. 1994, **25**(1), 49-59 [cit. 2017-04-27]. DOI: 10.1016/0005-7916(94)90063-9. ISSN 00057916. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0005791694900639>

CABANAC, Michel. What is emotion? *Behavioural Processes* [online]. 2002, **60**(2), 69-83 [cit. 2017-04-23]. DOI: 10.1016/S0376-6357(02)00078-5. ISSN 03766357. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0376635702000785>

CANDRA, Henry, Mitchell YUWONO, Ardi HANDOJOSENO, Rifai CHAI, Steven SU a Hung T. NGUYEN. Recognizing emotions from EEG subbands using wavelet analysis. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* [online]. IEEE, 2015, , 6030-6033 [cit. 2017-04-26]. DOI: 10.1109/EMBC.2015.7319766. ISBN 978-1-4244-9271-8. Dostupné z: <http://ieeexplore.ieee.org/document/7319766/>

Decomposing data using ICA. *SCCN Software* [online]. 2016 [cit. 2017-04-27]. Dostupné z: [https://scn.ucsd.edu/wiki/Chapter\\_09:\\_Decomposing\\_Data\\_Using\\_ICA](https://scn.ucsd.edu/wiki/Chapter_09:_Decomposing_Data_Using_ICA)

EKANAYAKE, Hiran. *P300 and Emotiv EPOC: Does Emotiv EPOC capture real EEG?* [online]. **2011** [cit. 2017-05-02]. Dostupné z: [https://www.researchgate.net/publication/260165618\\_P300\\_and\\_Emotiv\\_EPOC\\_Does\\_Emotiv\\_EPOC\\_capture\\_real\\_EEG](https://www.researchgate.net/publication/260165618_P300_and_Emotiv_EPOC_Does_Emotiv_EPOC_capture_real_EEG)

EKMAN, Paul. An argument for basic emotions. *Cognition*. 1992-5-1, **6**(3), 169-200. DOI: 10.1080/02699939208411068. ISSN 0269-9931. Dostupné také z: <http://www.informaworld.com/openurl?genre=article>

Elektroencefalografie. *WikiSkripta* [online]. 2016 [cit. 2017-04-27]. Dostupné z: <http://www.wikiskripta.eu/index.php/Elektroencefalografie>

- Emotion. *Encyclopaedia Britannica* [online]. 2017 [cit. 2017-04-23]. Dostupné z: <https://www.britannica.com/topic/emotion>
- Emotion - definition of emotion in English. *Oxford Dictionaries* [online]. Oxford University Press, 2017 [cit. 2017-04-23]. Dostupné z: <https://en.oxforddictionaries.com/definition/emotion>
- EMOTIV: Brainwear® Wireless EEG Technology [online]. San Francisco, 2017 [cit. 2017-04-23]. Dostupné z: <https://www.emotiv.com/>
- EMOTIV. User Manual. In: *Knowledge Base* [online]. 2014 [cit. 2017-04-27]. Dostupné z: <https://emotiv.zendesk.com/hc/en-us/articles/201222455-Where-can-I-find-a-user-manual->
- FABRIKANT, Sara Irina, Sidonie CHRISTOPHE, Georgios PASTEFANOU, Sara MAGGI. Emotional response to map design aesthetics. In: *7th International Conference on Geographical Information Science, Columbus, Ohio*. 2012. p. 18-21 [cit. 2017-04-23]. Dostupné z: <https://pdfs.semanticscholar.org/9587/18a7e7d08932b027cf2baf6fa8d02cc07c39.pdf>
- GEDMINAS, Laurynas. *Evaluating hurricane advisories using eye-tracking and biometric data*. Greenville, NC, 2011. East Carolina University.
- GÖRGEN, Kai. *Combining Eyetracking and EEG*. Osnabrück, 2010. Bakalářská práce. University of Osnabrück. Vedoucí práce Peter König.
- HIDALGO-MUÑOZ, A.R., M.M. LÓPEZ, I.M. SANTOS, A.T. PEREIRA, M. VÁZQUEZ-MARRUFO, A. GALVAO-CARMONA a A.M. TOMÉ. Application of SVM-RFE on EEG signals for detecting the most relevant scalp regions linked to affective valence processing. *Expert Systems with Applications* [online]. 2013, **40**(6), 2102-2108 [cit. 2017-04-27]. DOI: 10.1016/j.eswa.2012.10.013. ISSN 09574174. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S095741741201127X>
- HUDA, Tomáš. *Detection of emotions in event related potentials*. Plzeň, 2014. Diplomová práce. Západočeská univerzita v Plzni. Vedoucí práce Roman Mouček.
- ICA. Maps & Emotions. In: *International Cartographic Association* [online]. 2016 [cit. 2017-04-26]. Dostupné z: [http://icaci.org/wp-content/uploads/2016/07/2017\\_Emoional\\_Mapping\\_Workshop\\_CFP.pdf](http://icaci.org/wp-content/uploads/2016/07/2017_Emoional_Mapping_Workshop_CFP.pdf)
- INVENTADO, Paul Salvador, Roberto LEGASPI, Merlin SUAREZ a Masayuki NUMAO. Predicting student emotions resulting from appraisal of ITS feedback. *Research and Practice in Technology Enhanced Learning* [online]. 2011, **6**(2), 107–133 [cit. 2017-04-27]. Dostupné z: <http://www.apsce.net/uploaded/filemanager/4fd114ce-96f9-4849-bf1c-a83adc97b139.pdf>
- JAMES, William. What is an Emotion? *Mind* [online]. 1884, (9), 188-205 [cit. 2017-04-23]. Dostupné z: <https://psychcentral.com/classics/James/emotion.htm>
- KHOSROWABADI, Reza, Hiok Chai QUEK, Abdul WAHAB a Kai Keng ANG. EEG-based Emotion Recognition Using Self-Organizing Map for Boundary Detection. *2010 20th International Conference on Pattern Recognition* [online]. IEEE, 2010, , 4242-4245 [cit. 2017-04-26]. DOI: 10.1109/ICPR.2010.1031. ISBN 978-1-4244-7542-1. Dostupné z: <http://ieeexplore.ieee.org/document/5597763/>
- KLEINGINNA, Paul R. a Anne M. KLEINGINNA. A categorized list of motivation definitions, with a suggestion for a consensual definition. *Motivation and Emotion* [online]. 1981, **5**(3), 263-291 [cit. 2017-04-23]. DOI: 10.1007/BF00993889. ISSN 0146-7239. Dostupné z: <http://link.springer.com/10.1007/BF00993889>
- KOSMYNA, Nataliya, Franck TARPIN-BERNARD a Bertrand RIVET. *Towards Brain Computer Interfaces for Recreational Activities: Piloting a Drone* [online]. , 506 [cit. 2017-04-23]. DOI: 10.1007/978-3-319-22701-6\_37. Dostupné z: [http://link.springer.com/10.1007/978-3-319-22701-6\\_37](http://link.springer.com/10.1007/978-3-319-22701-6_37)

LAHANE, Prashant, Shrutika LOKANNAVAR, Apurva GANGURDE a Pooja CHIDRE. Emotion Recognition Using EEG Signals. *International Journal of Advanced Research in Computer and Communication Engineering* [online]. 2015(4), 54–56 [cit. 2017-04-23]. DOI: 10.17148/IJARCCCE.2015.4512. ISSN 2319-5940. Dostupné z: <http://www.ijarccce.com/upload/2015/may-15/IJARCCCE%2012.pdf>

LANG, P.J., BRADLEY, M.M., a CUTHBERT, B.N. *International affective picture system (IAPS): Affective ratings of pictures and instruction manual. Technical Report A-8*. University of Florida, Gainesville, FL, 2008.

LIU, Yisi, Olga SOURINA a Minh Khoa NGUYEN. Real-time EEG-based Human Emotion Recognition and Visualization. *International Conference on Cyberworlds*. Singapur, 2010, 262–269. Dostupné z: <http://www3.ntu.edu.sg/home/EOSourina/Papers/EmoRecVis2010.pdf>

MAVROS, Panos, Richard COYNE, Jennifer ROE a Peter ASPINALL. Engaging the brain: Implications of mobile EEG for spatial representation. *Digital Physicality | Physical Digitality* [online]. Proceedings of the 30th eCAADe Conference, 2012 [cit. 2017-04-23]. Dostupné z: [http://www.research.ed.ac.uk/portal/files/5310188/Engaging\\_the\\_Brain\\_eCAADe2012.pdf](http://www.research.ed.ac.uk/portal/files/5310188/Engaging_the_Brain_eCAADe2012.pdf)

MEHRABIAN, Albert. Pleasure-arousal-dominance: A general framework for describing and measuring individual differences in Temperament. *Current Psychology* [online]. 1996, **14**(4), 261-292 [cit. 2017-04-26]. DOI: 10.1007/BF02686918. ISSN 0737-8262. Dostupné z: <http://link.springer.com/10.1007/BF02686918>

MIŠUREC, Jiří a Milan CHMELAŘ. *Elektroencefalografie: vybrané kapitoly z obecné elektroencefalografie, přístrojové a registrační techniky a technické minimum*. Brno: Institut pro další vzdělávání středních zdravotnických pracovníků, 1990.

MORÁŇ, Miroslav. *Praktická elektroencefalografie*. Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví, 1995. ISBN 80-7013-203-5.

MURUGAPPAN, Murugappan, Nagarajan RAMACHANDRAN a Yaacob SAZALI. Classification of human emotion from EEG using discrete wavelet transform. *Journal of Biomedical Science and Engineering* [online]. 2010, **03**(04), 390-396 [cit. 2017-04-26]. DOI: 10.4236/jbise.2010.34054. ISSN 1937-6871. Dostupné z: <http://www.scirp.org/journal/PaperDownload.aspx?DOI=10.4236/jbise.2010.34054>

Nadrovina. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001- [cit. 2017-04-27]. Dostupné z: <https://cs.wikipedia.org/wiki/Nadrovina>

PLUTCHIK, Robert. The Nature of Emotions. *American Scientist* [online]. 2001, **89**(4), 344- [cit. 2017-04-26]. DOI: 10.1511/2001.4.344. ISSN 0003-0996. Dostupné z: <http://www.americanscientist.org/issues/feature/2001/4/the-nature-of-emotions>

POKORNÝ, Jan. Elektroencefalografie. In: *Fakulta biomedicínského inženýrství ČVUT v Praze* [online]. Praha, 2017 [cit. 2017-04-27]. Dostupné z: <http://fbmi.cvut.cz/files/nodes/657/public/EEG.pdf>

Power spectra. *WaveMetrics* [online]. 2017 [cit. 2017-04-27]. Dostupné z: <https://www.wavemetrics.com/products/igorpro/dataanalysis/signalprocessing/powerspectra.htm>

PROCHÁZKA, Petr. *Odstraňování kolísání izolínie v EKG pomocí empirické modální dekompozice*. Brno, 2015. Diplomová práce. Vysoké učení technické v Brně. Vedoucí práce Alena Kubičková.

RAMADAN, Rabie A. a Athanasios V. VASILAKOS. Brain computer interface: control signals review. *Neurocomputing* [online]. 2017, 223, 26-44 [cit. 2017-04-23]. DOI: 10.1016/j.neucom.2016.10.024. ISSN 09252312. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0925231216312152>

REISENZEIN, Rainer. A structuralist reconstruction of Wundt's three-dimensional theory of emotion, In: Westmeyer, Hans (ed.) *The Structuralist program in psychology: foundations and applications*. Seattle: Hogrefe, 1992, s. 141–189. ISBN 978-0889371002.

REUDERINK, Boris, Christian MÜHL a Mannes POEL. Valence, arousal and dominance in the EEG during game play. *International Journal of Autonomous and Adaptive Communications Systems* [online]. 2013, **6**(1), 45- [cit. 2017-04-27]. DOI: 10.1504/IJAACS.2013.050691. ISSN 1754-8632. Dostupné z: <http://www.inderscience.com/link.php?id=50691>

REYNOLDS, Carson a Rosalind PICARD. Affective sensors, privacy, and ethical contracts. *Extended abstracts of the 2004 conference on Human factors and computing systems - CHI '04* [online]. New York, New York, USA: ACM Press, 2004, , 1103- [cit. 2017-04-27]. DOI: 10.1145/985921.985999. ISBN 1581137036. Dostupné z: <http://portal.acm.org/citation.cfm?doid=985921.985999>

RUSSELL, James. A Circumplex Model of Affect. *Journal of Personality and Social Psychology*. 1980, **39**(6), 1161–1178.

SCHAAFF, Kristina. *EEG-based Emotion Recognition*. Karlsruhe, 2008. Universität Karlsruhe. Vedoucí práce Tanja Schultz.

SCHACHTER, Stanley a Jerome SINGER. Cognitive, social, and physiological determinants of emotional state. *Psychological Review* [online]. 1962, **69**(5), 379-399 [cit. 2017-04-23]. DOI: 10.1037/h0046234. ISSN 0033-295x. Dostupné z: <http://content.apa.org/journals/rev/69/5/379>

SCHWARTZ, Andrew B. CORTICAL NEURAL PROSTHETICS. *Annual Review of Neuroscience* [online]. 2004, **27**(1), 487-507 [cit. 2017-04-23]. DOI: 10.1146/annurev.neuro.27.070203.144233. ISSN 0147-006x. Dostupné z: <http://www.annualreviews.org/doi/10.1146/annurev.neuro.27.070203.144233>

SLANZI, Gino, Jorge A. BALAZS a Juan D. VELÁSQUEZ. Combining eye tracking, pupil dilation and EEG analysis for predicting web users click intention. *Information Fusion* [online]. 2017, **35**, 51-57 [cit. 2017-04-27]. DOI: 10.1016/j.inffus.2016.09.003. ISSN 15662535. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1566253516300756>

SREESHAKTHY M. a PREETHI J. Classification of emotion from EEG using hybrid radial basis function networks with elitist PSO. *2015 IEEE 9th International Conference on Intelligent Systems and Control (ISCO)* [online]. IEEE, 2015, , 1-4 [cit. 2017-04-26]. DOI: 10.1109/ISCO.2015.7282340. ISBN 978-1-4799-6480-2. Dostupné z: <http://ieeexplore.ieee.org/document/7282340/>

STRAKOŠ, Libor. *Využití EEG ve vyhodnocování emocionálních stavů člověka*. Brno, 2016. Diplomová práce. Vysoké učení technické v Brně. Vedoucí práce Tomáš Potočňák.

SYSLOVÁ, Zuzana, Dušan SYSEL, Oto MASÁR, Eliška KUBÍKOVÁ a Mária BROZMANOVÁ. *Elektroencefalografie v praxi*. Brno: Tribun EU, 2010. Librix.sk. ISBN 978-80-7399-913-1.

*Školní slovník současné češtiny*. V Brně: Lingea, 2012. ISBN 978-80-87471-59-3.

VANĚČKOVÁ, Tereza. *Vliv emoční stimulace na signál EEG*. Brno, 2014. Bakalářská práce. Vysoké učení technické v Brně. Vedoucí práce Karel Bubník.

VIDAURRE, D, E E RODRÍGUEZ, C BIELZA, P LARRAÑAGA a P RUDOMIN. A new feature extraction method for signal classification applied to cord dorsum potential detection. *Journal of Neural Engineering* [online]. 2012, **9**(5), 056009- [cit. 2017-04-27]. DOI: 10.1088/1741-2560/9/5/056009. ISSN 1741-2560. Dostupné z: <http://stacks.iop.org/1741-2560/9/5/a=056009?key=crossref.b5c53be7142518473606b79b01960c65>



## **PŘÍLOHY**

# **SEZNAM PŘÍLOH**

## **Vázané přílohy:**

- Příloha 1 Informovaný souhlas používaný při experimentu
- Příloha 2 Seznam použitých stimulů z databáze IAPS
- Příloha 3 Stimuly s mapami použité při experimentu

## **Volné přílohy:**

- Příloha 4 Manuál pro práci se zařízením Emotiv EPOC+ a následné zpracování a analýzu EEG dat
- Příloha 5 Poster
- Příloha 6 DVD



**Příloha 1**

# Informovaný souhlas pro měření EEG

(Tento formulář musí být vyplněn před každým EEG měřením)

**Název studie: Analýza emocí při čtení map a řešení prostorových úloh**

- Potvrzuji, že mi studie byla vysvětlena a bylo mi umožněno se na cokoliv zeptat.
- Potvrzuji, že mi studie byla vysvětlena a rozumím své účasti v této studii.
- Rozumím tomu, že má účast je dobrovolná a mám možnost kdykoliv studii opustit bez udání důvodu.
- Rozumím tomu, že studie není diagnostická a nedetekuje žádnou mozkovou abnormalitu, i když tato abnormalita může existovat.
- Rozumím tomu, že naměřená data mohou být zpřístupněna i třetí straně za účelem výzkumu, přičemž s veškerými daty bude zacházeno diskrétně v souladu s přístupem k ochraně osobních údajů.

**Zaškrtnutím všech okének souhlasím se svojí účastí na studii.**

_____ Podpis testované osoby	
Jméno a Příjmení: _____	Datum: _____

_____ Podpis vykonavatele studie	
Jméno a Příjmení: _____	Datum: _____

**Příloha 2**

<b>Název stimulu</b>	<b>Průměrná hodnota dimenze Valence (směrodatná odchylka)</b>	<b>Průměrná hodnota dimenze Arousal (směrodatná odchylka)</b>	<b>Klasifikační kategorie</b>
Neutral Girl	4,49 (1,03)	2,63 (1,70)	LV – LA
Rocks	4,45 (1,13)	2,51 (1,72)	LV – LA
Stool	4,63 (1,17)	2,71 (2,20)	LV – LA
Shoes	4,52 (1,11)	2,03 (1,51)	LV – LA
Trash Can	4,43 (1,16)	2,55 (1,77)	LV – LA
Hammer	4,55 (0,93)	2,27 (1,70)	LV – LA
File Cabinets	4,45 (1,36)	2,81 (1,94)	LV – LA
Ironing Board	4,23 (1,58)	2,96 (1,90)	LV – LA
Office	4,25 (1,45)	2,95 (2,17)	LV – LA
Empty Pool	4,03 (1,38)	2,63 (1,75)	LV – LA
Grieving Female	2,44 (1,64)	5,00 (2,03)	LV – MA
Hospital	1,95 (1,58)	4,53 (2,23)	LV – MA
Girl	2,67 (1,66)	4,63 (1,93)	LV – MA
Bum	2,56 (1,32)	4,31 (1,81)	LV – MA
Distressed Female	2,58 (1,56)	4,95 (2,27)	LV – MA
Cemetery	2,06 (1,54)	4,00 (2,09)	LV – MA
Mastectomy	2,56 (1,66)	4,92 (2,28)	LV – MA
Cigarettes	2,54 (1,75)	4,86 (2,63)	LV – MA
Woman	2,20 (1,31)	4,88 (2,21)	LV – MA
Crying Boy	2,56 (1,41)	4,61 (2,07)	LV – MA
Explosion	1,62 (1,20)	7,15 (2,24)	LV – HA
Skinhead	2,04 (1,57)	6,05 (2,71)	LV – HA
Hanging	1,76 (1,08)	6,81 (2,09)	LV – HA
Soldier	1,51 (1,15)	7,07 (2,06)	LV – HA
Sliced Hand	1,83 (1,17)	6,08 (2,40)	LV – HA
Hurt Dog	1,69 (1,10)	6,58 (2,12)	LV – HA
Starving Child	1,66 (1,10)	6,04 (2,40)	LV – HA
Burn Victim	1,31 (0,97)	6,91 (2,57)	LV – HA
Mutilation	1,45 (0,97)	6,41 (2,62)	LV – HA
Baby Tumor	1,46 (1,01)	7,21 (1,99)	LV – HA

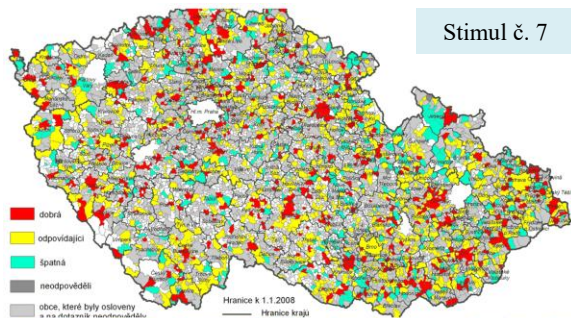
LV = nízká valence (low valence), LA = nízká arousal (low arousal), MA = střední arousal (middle arousal), HA = vysoká arousal (high arousal)

**Příloha 2**


<b>Název stimulu</b>	<b>Průměrná hodnota dimenze Valence (směrodatná odchylka)</b>	<b>Průměrná hodnota dimenze Arousal (směrodatná odchylka)</b>	<b>Klasifikační kategorie</b>
Girl	6,17 (1,51)	2,90 (1,89)	HV – LA
Gannet	6,37 (1,62)	2,83 (1,87)	HV – LA
Flower	7,08 (1,77)	2,67 (1,99)	HV – LA
Flower	7,14 (1,50)	3,00 (2,25)	HV – LA
Flower	6,51 (1,73)	2,74 (2,13)	HV – LA
Farmland	6,31 (1,60)	2,79 (2,20)	HV – LA
Three Men	7,14 (1,46)	2,90 (2,14)	HV – LA
Grain	6,23 (1,60)	2,84 (2,04)	HV – LA
Leaves	6,36 (1,70)	2,51 (2,01)	HV – LA
Violin	6,50 (1,72)	2,60 (2,08)	HV – LA
Seal	8,19 (1,53)	4,61 (2,54)	HV – MA
Bunnies	8,28 (1,07)	4,10 (2,31)	HV – MA
Porpoise	7,90 (1,48)	4,27 (2,53)	HV – MA
Baby	8,20 (1,31)	4,57 (2,53)	HV – MA
Seaside	8,03 (1,09)	4,60 (2,48)	HV – MA
Kitten	8,21 (1,21)	4,31 (2,63)	HV – MA
Family	8,03 (1,26)	4,90 (2,20)	HV – MA
Sunset	8,00 (1,48)	4,92 (2,65)	HV – MA
Sky	7,61 (1,48)	4,51 (2,85)	HV – MA
Couple	7,77 (1,43)	4,68 (2,43)	HV – MA
Money	7,91 (1,66)	6,44 (2,29)	HV – HA
Rollercoaster	7,63 (1,41)	6,07 (2,31)	HV – HA
Gymnast	7,74 (1,53)	6,14 (2,19)	HV – HA
Rafting	7,77 (1,29)	6,73 (2,24)	HV – HA
Skier	8,10 (1,39)	6,28 (2,57)	HV – HA
Skydivers	7,57 (1,52)	7,27 (2,08)	HV – HA
Sailing	7,73 (1,34)	6,65 (2,20)	HV – HA
Cupcakes	7,38 (1,73)	6,28 (2,16)	HV – HA
Astronaut	7,33 (1,51)	5,87 (2,50)	HV – HA
Erotic Female	8,02 (1,93)	7,17 (2,69)	HV – HA

HV = vysoká valence (high valence), LA = nízká arousal (low arousal), MA = střední arousal (middle arousal), HA = vysoká arousal (high arousal)

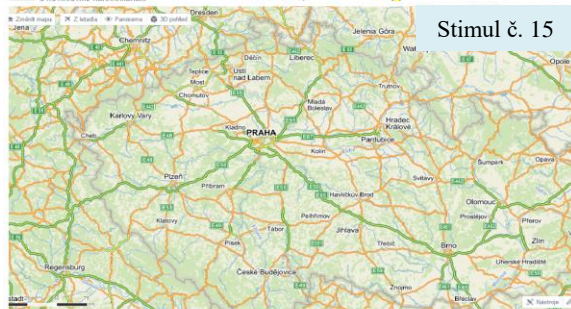
**Příloha 3**



Stimul č. 7



Stimul č. 8



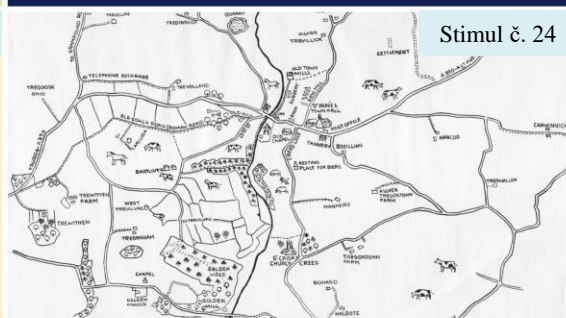
Stimul č. 15



Stimul č. 16




Stimul č. 23



Stimul č. 24



Stimul č. 31



Stimul č. 32




Stimul č. 39

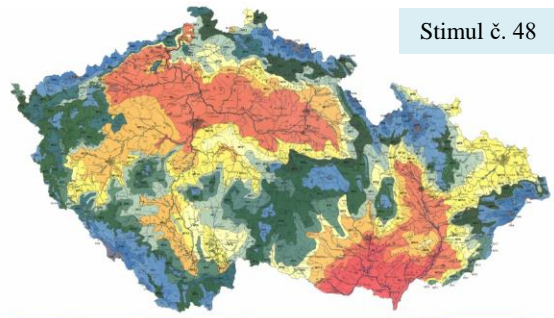


Stimul č. 40

# Příloha 3



Stimul č. 47



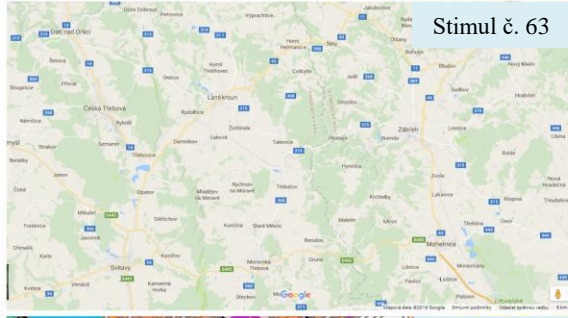
Stimul č. 48



Stimul č. 55




Stimul č. 56



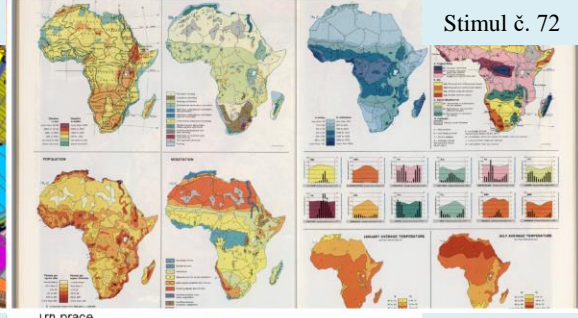
Stimul č. 63



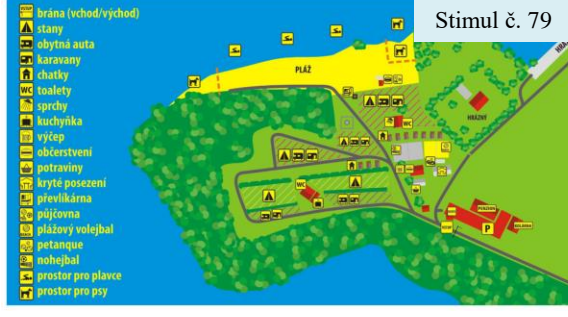
Stimul č. 64



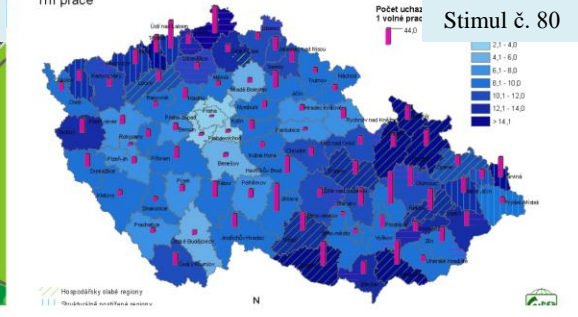
Stimul č. 71



Stimul č. 72



Stimul č. 79



Stimul č. 80