

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2016

Bc. Libor Strakoš



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

VYUŽITÍ EEG VE VYHODNOCOVÁNÍ EMOCIONÁLNÍCH STAVŮ ČLOVĚKA

THE USE OF EEG IN ASSESSING THE EMOTIONAL STATE OF A PERSON

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Libor Strakoš

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Tomáš Potočňák

BRNO 2016



Diplomová práce

magisterský navazující studijní obor **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

Student: Bc. Libor Strakoš

ID: 136489

Ročník: 2

Akademický rok: 2015/16

NÁZEV TÉMATU:

Využití EEG ve vyhodnocování emocionálních stavů člověka

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši na téma multimediální stimulace (zejména audiovizuální) a jejího vlivu na emocionální stav člověka. Zaměřte se zejména na využití přístroje EEG Emotiv (případně klinického EEG) doplněného o další biologické signály dle dostupného přístrojového vybavení. 2) Na základě poznatků navrhnete měření s vhodně zvolenými multimediálními podněty, které vyvolají změny v emocionálním stavu člověka. 3) Na základě dostupné literatury zvolte kontrolní data, vůči kterým budete porovnávat Vámi zvolené podněty multimediálního charakteru. 4) Realizujte měření na definovaném vzorku populace. 5) Vhodně zvolenými postupy proveďte zpracování naměřených dat. Různé postupy srovnajte. 6) Statisticky vyhodnoťte naměřená data. Zaměřte se na srovnání emocionální odezvy u zvolených skupin v rámci definovaného vzorku populace. Srovnajte výsledky ze signálů z EEG a ostatních fyziologických dostupnost a zhodnoťte přínos EEG při vyhodnocování emocionálního stavu člověka.

DOPORUČENÁ LITERATURA:

[1] MIŠUREC J, CHMELAR M, Elektroencefalografie, IDV SZP Brno 1990, 194s. ISBN 80-7013-080-6.

[2] KULIŠŤÁK P, Neuropsychologie, Portál 2011, 384s. ISBN 978-80-7367-891-3.

Termín zadání: 8.2.2016

Termín odevzdání: 20.5.2016

Vedoucí práce: Ing. Tomáš Potočňák

Konzultant diplomové práce:

prof. Ing. Ivo Provazník, Ph.D., předseda oborové rady

UPOZORNĚNÍ:

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

Abstrakt

Diplomová práce se zabývá možnostmi zpracování EEG a klasifikací emocí do tříd v rámci emočního dvoudimenzionálního prostoru. První část tvoří literární rešerše na téma využití záznamu EEG pro zachycení emoční odezvy člověka na stimulační podněty zvukového, vizuálního a audiovizuálního (multimediálního) charakteru. Je zde diskutováno hledisko emoce z pohledu fyziologie a psychologie. Následně jsou uvedeny technické poznatky ze záznamu emoce různými modalitami a jejich zpracování, analýzy a klasifikace v rámci dvoudimenzionálního prostoru Valence - Arousal.

Na základě teoretických poznatků byl navržený komplexní postup měření a vyhodnocení emocí za použití EEG. Za tímto účelem byly sestaveny dva měřicí protokoly s audiovizuální stimulací. Dále je zde uveden postup předzpracování a analýzy dat, výběr příznaků a klasifikace za použití moderních i zavedených metod.

Celý navržený postup byl následně realizován a otestován v rámci dvou měření za využití moderního EEG přístroje EGI GES 400MR v laboratorních podmínkách a komerčního, cenově dostupného přístroje Emotiv EPOC v podmínkách mimo laboratorní prostředí. Signály byly zpracovány a emoce klasifikovány na základě vybraných popisných elementů. Výsledkem práce je hodnocení úspěšnosti klasifikace emocí v různých konfiguracích pro výběr popisných elementů a klasifikačních metod a jejich parametrů.

Klíčová slova: Emoce, multimediální stimulace, klasifikace emocí, EEG, ICA, DWT, PCA, EMD, SVM, ANN

Abstract

This thesis is focused on EEG processing and emotion classification within two-dimensional emotion space. First part consists of theoretical research about emotional responses of human subjects on sound, image and video stimuli. Emotions are examined from aspect of physiology and psychology. Furthermore technical overview of measurement, analysis and emotion classification within two-dimensional Valence – Arousal emotional space is discussed.

Based on gathered knowledge measurement setup with audiovisual stimuli was designed and measured with two independent instruments – EGI GES400MR in laboratory conditions and Emotiv EPOC device in non-laboratory conditions. Signals were processed and emotions were classified based on chosen features. Performance of classifiers in multiple feature selection setups was evaluated.

Key words: Emotions, audiovisual stimulation, emotion classification, EEG, ICA, DWT, PCA, EMD, SVM, ANN

Bibliografická citace

STRAKOŠ, L. *Využití EEG ve vyhodnocování emocionálních stavů člověka*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2016. 66 s. Vedoucí diplomové práce Ing. Tomáš Potočňák.

Prohlášení

Prohlašuji, že svou diplomovou práci na téma Využití EEG ve vyhodnocování emocionálních stavů člověka jsem vypracoval samostatně pod vedením vedoucího diplomová práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

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

V Brně dne 20. května 2016

.....

Podpis autora

Poděkování

Tímto bych chtěl poděkovat svému vedoucímu Ing. Tomáši Potočňákovi za pomoc, odborné vedení, podnětné konzultace mé diplomová práce a zprostředkování komunikace s měřicí laboratoří. Dále bych chtěl poděkovat Mgr. Petrovi Telenskému, PhD. za doporučení při sestavování měřícího protokolu a také Ing. Karlovi Bubníkovi.

Obsah

Úvod.....	1
1 Koncept emoce	2
1.1 Psychologie emoce	2
1.2 Anatomie a fyziologie emoce	2
1.3 Klasifikace emocí	5
2 Multimediální stimulace.....	7
2.1 Audiostimulace	7
2.2 Vizuální stimulace	8
2.3 Audiovizuální stimulace	8
3 Záznam a vyhodnocování emocí	10
3.1 Elektroencefalografie.....	10
3.1.1 Základní principy encefalografie	11
3.1.2 Individuální alfa frekvence (IAF)	12
3.2 Fotopletysmografie	12
3.3 Kožní vodivost.....	13
3.4 Neurozobrazování a emoce.....	14
4 Klasifikace emocí s využitím záznamu EEG	15
4.1 Předzpracování signálů	15
4.2 Extrakce vektoru příznaků	17
4.2.1 Analýza v časové oblasti.....	17
4.2.2 Frekvenční analýza	17
4.2.3 Časově – frekvenční analýza	18
4.2.4 Redukce vektoru příznaků	23
4.3 Možnosti klasifikace emocí z elektroencefalografických signálů	24
4.3.1 K-nejbližší soused	24
4.3.2 Umělé neuronové sítě	25
4.3.3 Support Vector Machines (SVM)	26
4.4 Hodnocení úspěšnosti klasifikace	27
5 Návrh měření	29
5.1 Přístroj Emotiv EPOC+	30
5.2 Přístroj EGI GES400MR	32
5.3 Podněty pro měření s EGI GES 400 MR a Emotiv EPOC	33
5.4 Kontrolní data	34
5.5 Vyhodnocení výsledků	35
6 Realizace klasifikace signálů EEG	36
6.1 Odstranění síťového rušení a driftu	36
6.2 Detekce použitelných elektrod	37

6.3	Automatická detekce a odstranění zarušených komponent ICA, interpolace chybějících kanálů a finalizace předzpracování	38
6.4	Předzpracování dat Emotiv	41
6.5	Výběr elektrod	41
6.6	Výběr popisných elementů	41
6.6.1	Redukce prostoru popisných elementů pomocí PCA	43
6.7	Učení klasifikátorů a krosvalidace.....	43
7	Výsledky.....	44
7.1	Binární klasifikace EGI a Emotiv dle elektrodové konfigurace Emotiv	45
7.2	Klasifikace do 4 tříd ze záznamů přístroje EGI dle elektrod Emotiv	49
7.3	Klasifikace EGI ze všech elektrod a elektrod prefrontálního kortexu.....	51
7.4	Klasifikace testovacích dat	54
	Závěr	58
	Bibliografie	60
	Seznam zkratk	65
	Přílohy.....	67

Seznam obrázků

Obrázek 1: Umístění amygdaly v mozku, amygdala je spojována s negativními emocemi (převzato z [8], [9])	3
Obrázek 2: Prefrontální kortex (vyznačeno červeně), střed zájmu záznamu EEG u emocionální stimulace (převzato z [10]).....	4
Obrázek 3: Russelův 2D model (převzato z [1]).....	5
Obrázek 4: SAM odpovídající 3D reprezentaci emocí valence/arousal/dominance (převzato z [12]).....	6
Obrázek 5: Ukázka z měření používající vizuální stimulaci obrázky (převzato z [19]).....	7
Obrázek 6: Příklad výsledku hodnocení u filmu Šampión (1979) v Grossově studii, dominující emoce smutek (převzato z [26])	9
Obrázek 7: Aktivita v jednotlivých pásmech EEG (převzato z [32]).....	11
Obrázek 8: Surová křivka variability srdečního rytmu získaná zpracováním fotopletysmografického záznamu.....	13
Obrázek 9: Křivka vodivosti kůže (SCR složka) normovaná na maximální rozsah [%].....	14
Obrázek 10: ilustrace fungování ICA[43]	16
Obrázek 11: Půlení frekvenčního pásma na poloviny v rámci tří úrovní diskrétní vlnkové transformace (BW – bandwidth, šířka pásma, DP – dolní propust, HP – horní propust) [54]	19
Obrázek 12: Postup při zpracování EEG a klasifikaci emocí (převzato z [60]).....	24
Obrázek 13: Perceptron, nejjednodušší typ neuronové sítě s jedním neuronem (převzato z [64])	25
Obrázek 14: SVM rozděluje data do dvou tříd, w – vektor bodů kolmých na oddělující nadrovinu, b – posun nadroviny, x – body (souřadnice) (převzato z [65])	26
Obrázek 15: Měřicí protokol	29
Obrázek 16: Umístění elektrod Emotivu (vyznačeno černě) s 256 svodovým EEG EGI GES400 MR(převzato z [73]).....	30
Obrázek 17: synchronizační signál pro Emotiv	31
Obrázek 18: Kompletní obsah balíčku přístroje EGI GES 400 MR Series (měřicí čepice, přístroj se zesilovači, další HW příslušenství (převzato z [73])	32
Obrázek 19: Kalibrační podněty a jejich umístění v Russelově 2D prostoru (převzato z [1], [25], [26]).....	34
Obrázek 20: Postup při předzpracování EEG z přístroje EGI pro následnou klasifikaci	36
Obrázek 21: Rozložení elektrod se záznamem EOG (převzato z [73])	37
Obrázek 22: Zhodnocení korelace mezi vEOG a ICA aktivací pro detekci mrkání v okně o délce 1s s 50 % překryvem	39
Obrázek 23: Zhodnocení korelace mezi hEOG a ICA aktivací pro detekci mrkání v okně o délce 4 s s 50 % překryvem	39
Obrázek 24: Výsledek ICA, odstraněna komponenta odpovídající mrkání.....	40

Obrázek 25: Výsledek ICA, odstraněna komponenta odpovídající pohybům očí	40
Obrázek 26: Ukázka zarušeného záznamu přístroje Emotiv	41
Obrázek 27: Postup při extrakci popisných elementů tréninkového setu	42
Obrázek 28: Hierarchie klasifikace, šedě vyznačené pole se netýkají klasifikace pro přístroj Emotiv, červené křížky značí klasifikaci od které bylo upuštěno na základě výsledků binárního klasifikátoru.....	44
Obrázek 29: Elektrody vybrané pro srovnání Emotiv a EGI, postupně zvoleno 2, 4, 8 a 14 elektrod.....	48
Obrázek 30: Konfúzní matice nejlepšího klasifikátoru pro popisné elementy DWT „db4“	49
Obrázek 31: Konfúzní matice nejlepšího klasifikátoru pro popisné elementy DWT „bior1.3“	49
Obrázek 32: Konfúzní matice nejlepšího klasifikátoru pro popisné elementy EMD.....	50
Obrázek 33: Konfúzní matice nejlepšího klasifikátoru pro 203 elektrod	51
Obrázek 34: Konfúzní matice nejlepšího klasifikátoru pro 34 elektrod frontálního a prefrontálního kortexu.....	51
Obrázek 35: Konfúzní matice nejlepšího klasifikátoru do 4 tříd pro 34 elektrod frontálního a prefrontálního komplexu	52
Obrázek 36: Konfúzní matice nejlepšího klasifikátoru do 4 tříd pro 203 elektrod redukovaného prostoru elektrod EGI.....	52
Obrázek 37: Elektrody vybrané pro klasifikaci, červeně – redukovaný systém 203 elektrod EGI, černě – 34 elektrod frontálního a prefrontálního kortexu.....	53
Obrázek 38: Výsledek binární klasifikace videa Fidorka	54
Obrázek 39: Výsledek binární klasifikace videa Jägermeister.....	54
Obrázek 40: Výsledek binární klasifikace videa Kaufland	55
Obrázek 41: Výsledek binární klasifikace videa Airwaves.....	55
Obrázek 42: Výsledek klasifikace do 4 tříd videa Radegast	55
Obrázek 43: Výsledek klasifikace do 4 tříd videa Alza	56
Obrázek 44: Výsledek klasifikace do 4 tříd videa GE Money	56
Obrázek 45: Výsledek klasifikace do 4 tříd videa Kofola	56

Seznam tabulek

Tabulka 1: Confusion matrix.....	27
Tabulka 2: Vybrané reklamní spoty a délek jejich trvání pro EGI GES 400MR, pořadí odpovídající měření.....	33
Tabulka 3: Vybrané reklamní spoty a délek jejich trvání pro Emotiv EPOC, pořadí odpovídající měření.....	33
Tabulka 4: Kalibrační podněty pro EGI GES400 MR, zeleně – kalibrační podněty shodné i pro Emotiv EPOC.....	34
Tabulka 5: Úspěšnosti SVM binární klasifikace pro emoce vzrušení a smutek pro přístroj EGI (Se – senzitivita, Sp – specificita, Spr - správnost), z bazových funkcí je vždy vybrána ta nejúspěšnější.....	45
Tabulka 6: Úspěšnosti SVM binární klasifikace pro emoce vzrušení a smutek pro přístroj EGI (Se – senzitivita, Sp – specificita, Spr - správnost), z bazových funkcí je vždy vybrána ta nejúspěšnější.....	46
Tabulka 7: Porovnání úspěšnosti ANN binární klasifikace pro emoce vzrušení a smutek mezi přístroji Emotiv a EGI (Se – senzitivita, Sp – specificita, Spr – správnost)	47

Úvod

Záznam emočních stavů člověka dnes nemá čistě psychologický význam, ale vzhledem ke komplexnosti procesu emočního prožitku získává na významu i v oblasti diagnostiky správného fungování mozku či autonomního nervového systému a následné terapie (Yuvaraj a spol., 2014). Postupným vývojem v záznamu emocí se od subjektivního vyhodnocování dostáváme k polygrafickým systémům až k nejmodernějším technologiím jako je např. funkční magnetická rezonance. Předložená práce se zaměřuje na přínos EEG jako přijatelné technologie záznamu emočního stavu subjektu na základě elektrické aktivity mozku.

V rámci práce s EEG a emocemi je jedním z fenoménů snaha o klasifikaci emocí na základě odezvy na stimulaci. Klasickým přístupem v této problematice je sestavení protokolu měření se stimulačními impulzy v jedné z možných podob (zvukové, optické, audiovizuální, multimediální) a následná realizace měření na vzorku testovaných osob. Osoby po měření písemně, v rámci dotazníku rozličných forem (slovní hodnocení, obrázkové hodnocení), ohodnotí prezentované stimulační podněty. Následně jsou výsledky zpracovány a jsou vybrány popisné elementy pro klasifikaci jednotlivých stimulů. Klasifikace je ve většině případů binární podle každé z os 2D emočního prostoru valence, arousal. Třídy emocí pro jednotlivé stimuly jsou odvozeny na základě výsledků dotazníků. Spojením výsledků klasifikace na obou osách se odvodí míra vzrušení (arousal) a mohutnosti (valence) emoce. Výsledky je následně možné zakreslit do dvoudimenzionálního prostoru emocí. [1]

Tato práce se snaží jít ve výzkumu emocí o další krůček dále. V rámci jednotlivých kapitol se snaží odhalit metody vykazující účinnost při klasifikaci emocí a jejich syntézou vytvořit metodiku pro klasifikaci do dvou a čtyř tříd definovaných diskrétními emocemi – zábava, vzrušení, smutek, strach. Oprošťuje se od dotazníkového hodnocení tím, že vybírá kalibrační stimulační podněty na základě hodnocení z předchozích výzkumů. Tyto kalibrační stimuly jsou následně použity jako tréninková množina pro klasifikaci, na jejímž základě je poté klasifikováno několik dalších testovacích audiovizuálních stimulů. Všechny stimuly použité v rámci této práci jsou výhradně audiovizuální.

1 Koncept emoce

Emoce je natolik komplexní a subjektivní záležitost, že během více než půlstoletí, kdy se psychologie a další vědní obory o tento fenomén zajímají, nedošlo ke shodě nad základní koncepcí či definicí. Oblast psychofyziologie emoce je díky novým možnostem záznamu obohacována o objektivní informace. Naopak v oblasti psychologie emoce se setkáváme s odlišnými názory odvislými od nutně subjektivního přístupu.[2]

1.1 Psychologie emoce

Jedním z úkolů psychologie je popis vlastností emocí a spojení tohoto popisu se skrytými fyziologickými procesy. Informace pro dosažení tohoto cíle jsou získávány z prostředí, změn v tělesných procesech či pozorování chování jedinců.[3]

Gross (2014) prezentuje modální model emoce složený z dvou hlavních prvků. Prvním prvkem je období, kdy se emoce začne projevovat. To se stane v případě, kdy člověk vyhodnotí, že daná situace ovlivňuje dosažení cíle, kterého chce momentálně dosáhnout. Druhým prvkem je mnohoznačnost emoce, kdy emoce ovlivňuje chování a subjektivní zkušenost spolu s centrální i periferní fyziologií. Frijda (1986) upozorňuje na rozdíl mezi cítěním a emocí, kdy nás emoce nutí jednat ve formě změn ve výrazu tváře, postavení těla či dalších komplexnějších reakcí v podobě fyziologických změn. Emoce jsou prostředkem k hodnocení informací v jeho životním prostředí. Mezi základní prvky emoce patří integrace poznávání, hodnocení a jednání. V nejzákladnější podobě jde o prožití příjemné či nepříjemné emoci [2], [4].


Emoce hrají důležitou roli při regulaci činností jedince. Stejně jako pro další psychické procesy platí, že se dá jenom velice těžko oddělit z komplexního celku psychických aktivit, do kterých zapadá. Při abstrahování emocí se můžeme zaměřit pouze na ty znaky, kterými se významně odlišují od ostatních fyziologických funkcí.

1.2 Anatomie a fyziologie emoce

Nervový systém je rozdělen do dvou částí. Na centrální nervový systém (CNS) a periferní nervový systém. Oba systémy jsou navzájem propojeny. CNS se skládá z mozku a míchy, a periferní nervový systém ze somatického a autonomního nervstva. Autonomní nervový systém (ANS) ovládá hladké svalstvo a žlázy, proto můžeme jeho aktivitu sledovat pomocí měření signálů srdce nebo kožního odporu (změny srdečního rytmus, zalití potních žláz vodou a nárůst vodivosti kůže). Základními komponentami ANS jsou sympatikus a parasympatikus. Sympatikus má aktivační vlastnosti naopak parasympatikus funkci regenerativní (deaktivační). Somatické nervstvo inervuje příčně pruhované svalstvo. Vzhledem ke komplexnosti emoce, která ovlivňuje aktivitu ve všech částech nervové soustavy, se zejména kognitivní psychofyziologie zaměřuje také na signály mozku (EEG). [5]

Pocity a paměť nejsou výlučně výsledkem mozkové aktivity, ale výsledkem interakce mezi prefrontální kůrou a diencephalem (thalamus a hypothalamus). V rámci centrálního nervového systému (CNS) hraje zvláště amygdala a hypothalamus význačnou roli.[6]

Součástí anatomického celku zodpovědného za emoce je limbický systém. Limbický systém je centrem našich emocí, učení a paměti. Skládá se z cingula, hippocampu a amygdaly. Struktura zodpovědná za emocionální reakce se nazývá amygdala, ale všechny struktury limbického systému mají svá oddělená centra pro uspokojení a averzi. Stimulací center zodpovědných za uspokojení pociťujeme potěšení, naopak stimulace center averze vyvolává nepříjemné pocity jako strach či žal. Pozitivní emoce dominují ve struktuře zvané nukleus accumbens, kdežto při negativní reakci hraje klíčovou roli amygdala. Amygdala dostává a zpracovává informace ze smyslů (zrak, sluch, chuť, čich) a ze somatických a viscerálních sensorů. Je schopna mediovat emoční odezvu k rozličným stimulům od pěkného obrázku až po bolest žaludku. Odezva z amygdaly na podněty je přenášena po dvou drahách, jedna směřuje směrem k hypothalamu a tím ovlivňuje somatický a autonomní nervový systém (ANS). Druhá cesta směřuje k prefrontální kůře, která zprostředkovává vědomou kontrolu a expresi emocí (například vyjádření lásky, ale kontrola vzteku). [6], [7]




Obrázek 1: Umístění amygdaly v mozku, amygdala je spojována s negativními emocemi (převzato z [8], [9])

Ukazuje se, že při vnímání veskrze negativních emocí jako je například strach nebo úzkost, ale i obecně u negativních emocí hraje klíčovou roli amygdala a její komplex, viz Obrázek 1. Role amygdaly při vnímání strachu byla odhalena u pacientů s funkční poruchou amygdaly či afektivními poruchami (Damasio, 1994). Neurozobrazovací metody ukázaly na aktivitu amygdaly při negativní emocionální stimulaci jak u zdravých, tak i u pacientů s funkční poruchou amygdaly (Lane a spol., 1997). [9]

Základním prvkem v psychofyziologii emocí je ANS jako podsložka somatického nervového systému. Díky aferentnímu spojení s CNS se dá předpokládat, že se informace z tělních periférií a útrobních orgánů významně podílejí na tvorbě emoce. Zároveň eferentní spojení a vliv CNS na ANS, můžeme zaznamenat jako změny v signálech a snažit se spojit funkční vlivy s fyziologickými změnami a vyhodnocovat emoční odezvu pomocí reakčních vzorů ANS, ověřeno Ekmanem (1983). V návaznosti na poznatky získané Ekmanem (1983) vzniklo množství prací zabývajících se právě vzory emočních odezev (Cacciopo, 2000, Pauls a Stemmler, 2003, Britton et al., 2006).[5]

Další součástí periferního nervstva je somatický nervový systém. Při zkoumání jeho reakcí na pociťované emoce je potřeba zaznamenat aktivitu příslušného kosterního svalstva. Pro záznam se nejčastěji volí oblast obličeje, zejména mimické svaly a svaly pohybující s očními víčky. Byla stanovena vazba mezi výrazem v obličeji a pociťovanou emoci, Ekman (1973).[5]



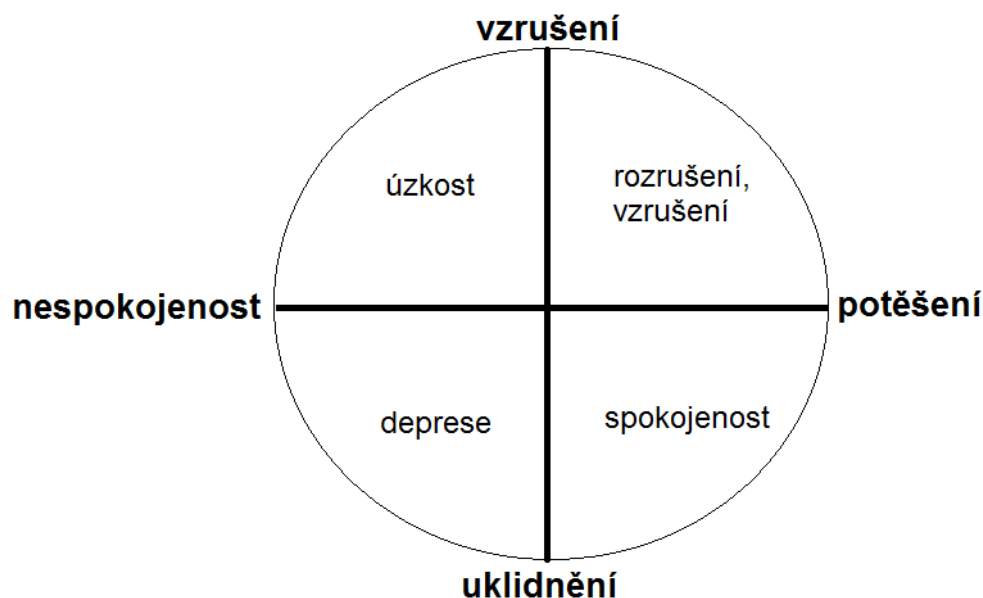
Obrázek 2: Prefrontální kortex (vyznačeno červeně), střed zájmu záznamu EEG u emocionální stimulace (převzato z [10])

Aktivitu CNS můžeme zaznamenat přímo pomocí EEG, což je rozdíl oproti záznamu zprostředkovaných vlivů somatického nervstva. CNS stojí nad všemi částmi NS popsány v předchozích odstavcích, může tak poskytnout nejkompexnější obraz působení emoce i přes nízké prostorové rozlišení a velký vliv externích zdrojů rušení. Při záznamu a vyhodnocování EEG při emoční stimulaci byly zaznamenány asymetrie v jednotlivých frekvenčních pásmech v různých částech mozku (hlavně v prefrontálním kortexu – levý a pravý, viz Obrázek 2), které ovlivňují vnímání emocí daného jedince (Davidson, 2003). Tyto asymetrie zároveň hovoří pro aktivaci v různých částech mozku pro různé emoce. [5], [11]

1.3 Klasifikace emocí

Konkrétní popis něčeho tak subjektivního a složitého jako je emoce, je značně komplikovaný. Pro praktické využití a laboratorní měření je potřeba emoce klasifikovat na základě předchozích poznatků a vhodně je reprezentovat.

Prvním z průkopníků na poli reprezentace emocí byl Wundt (1886), který představil tři základní rozměry emoce pojmenované Lust (potěšení), Spannung (napětí) a Beruhigung (uklidnění). Studie navazující na Wundtovu práci se ztotožňují s trojrozměrným konceptem emoce (Osgood, 1952, Osgood, Suci & Tanenbaum, 1957), ale jednotlivým dimenzím přiřazují rozdílné názvy s cílem co nejlépe popsat daný prostor a jeho hranice. V těchto pracích se se psychologové zabývají verbálními stimuly v podobě emočně zbarvených slov. Významným posunem v oblasti verbální stimulace je důkaz, že shodnou třídímenzionální strukturu můžeme nalézt i v jiných jazycích než v angličtině, ve které byl originální výzkum prováděn a zároveň důkaz, že obdobnou strukturu můžeme nalézt i v hodnocení nonverbálních podnětů jako zvukové signály či malby (Osgood a spol., 1957). Tyto struktury se povedli najít i při klasifikaci emočního zbarvení výrazů tváře, pohybů těla a posturálních pozic (Russel, 1970). V návaznosti na tyto poznatky sestavili Russel a Mehrabian (1974) Semantic Differential Scale (stupnice sémantických rozdílů) pro hodnocení verbálních textů. Stupnice se skládá ze tří dimenzí pojmenovaných pleasure (potěšení), arousal (vzrušení), dominance (mohutnost), které dohromady tvoří cirkulární prostor.



Obrázek 3: Russelův 2D model (převzato z [1])

Každá z emocí má vlastní hodnotu na jednotlivých osách a může být v tomto prostoru zobrazena. Kvůli relativní složitosti (18 rozdílných hodnocení dostupných hodnocení pro jednotlivý stimul), časové náročnosti a komplikované přenositelnosti do ostatních jazyků (problémy s překladem a validací pojmů) vyvinuli Hodes, Cook a Lang (1985) Self –


Assesment Manikin (SAM, sebehodnotící panáčkový test, viz Obrázek 4). Skládá se tří sérií po pěti piktozramech odpovídající každé ose emočního prostoru. Tím se zmenšuje počet hodnocení pro každou emoci, ale její tři rozměry zůstávají zachovány. Russel (1980) zredukoval díky do té doby dostupným poznatkům třídímní model emočního prostoru na dimenze dvě, viz Obrázek 3. [1]

V jeho 2D prostoru se objevují osy arousal (vzrušení) a pleasure (potěšení). Ve svém výzkumu použil 28 emotivně zabarvených slov, které nechal hodnotit v rámci jím navrženého systému ve třech různých hodnotících setech. Podobnost mezi výsledky podpořila jeho teorii kruhového 2D emocionálního prostoru. I pro tento model je použitelný SAM, upravený pro dvě osy – valence a arousal. Přesto, že se Russel a Mehrabian (1980) při vytváření 3D reprezentace či Russel (1980) při redukci na 2D zaměřili na verbální stimulaci, v podobě emotivně zabarvených slov, využívají se v současné době oba modely pro hodnocení emocí i za stimulační multimediální (Soleymani a spol., 2011, Singh a spol. 2013, Yadati a spol., 2014). [1], [12], [13]

Mohutnost (Valence)



Vzrušení (Arousal)



Převaha (Dominance)




Obrázek 4: SAM odpovídající 3D reprezentaci emocí valence/arousal/dominance (převzato z [12])

2 Multimediální stimulace

Od doby, kdy se zájem psychologů obrátil na emoce, bylo potřeba emoce nějakým způsobem vyvolat, popsat a vyhodnotit. V prvopočátcích šlo o stimulaci verbální (Russel, 1980). Postupným vývojem se dostáváme ke stimulaci audiovizuální v podobě emočně zabarvených zvuků (Bradley & Lang, 2000), hudby (Anttonen & Surakka, 2007), obrázků (Lane a spol., 1999) či jejich kombinací a v neposlední řadě ke stimulaci za použití videosekvencí (Soleymani a spol., 2011). [1], [14], [15]

2.1 Audiostimulace

Původním pokusem v audiostimulaci byl Osgoodův pokus (1957), jehož výsledky podporovaly trojrozměrnost emočního prostoru. Bradley a Lang (2000) provedli měření za použití audiostimulace pomocí zvuků, se kterými se můžeme běžně v životě setkat (řev, brek, atd.). Šedesát vybraných zvuků bylo prezentováno testovaným osobám. Během měření testované osoby subjektivně hodnotili stimuly pomocí SAM testu. Během prezentace stimulů zaznamenávali elektromyografický (EMG) signál, tep srdce a vodivost kůže. Podle subjektivních hodnocení poté hledali vazbu na fyziologickou odezvu zaznamenanou pomocí signálů. [1], [16]



Obrázek 5: Ukázka z měření používající vizuální stimulaci obrázky (převzato z [19])

Jaimovich (2013) provedl experiment založený na záznamu odezvy fyziologických signálů (Elektrodermální aktivita – EDA, srdeční rytmus – HR) a subjektivního hodnocení pomocí dotazníků. Jako stimulační podněty byly použity hudební nahrávky náhodně vybírané z databáze 53 skladeb nejrozličnějších žánrů, které měly vyvolat reakci v rámci 2D prostoru valence/arousal. Pro hodnocení použil Geneva Emotional Music Scale (GEMS, Ženevská stupnice emocionální hudby). GEMS je speciálně vyvinutá stupnice pro hodnocení hudebních podnětů, protože se ukázalo, že základní emoce prezentované Ekmanem (1992) neposkytují dostatečnou podporu pro klasifikaci hudebních podnětů, existuje ve třech formách GEMS 45, 25 a 9. Číslo určuje počet kategorií v rámci klasifikace. [17], [18]

2.2 Vizuální stimulace


V případě výběru emotivně zabarvených podnětů bývají vybírány podněty ze základních databází stimulů vyvolávajících emoce jako IAPS (International Affective Picture System) či GAPED (Geneva Affective Picture Database). IAPS je databáze vytvořená Mezinárodním institutem mentálního zdraví Floridské univerzity, viz Obrázek 5. V současné době obsahuje databáze přes tisíc obrázků, které jsou využívány ke studiím emocí. GAPED je databáze vytvořená jako alternativa k IAPS, která řeší problémy, jako je velký záběr obrázků v IAPS, ale jejich malý počet pro jednotlivé případy, což omezuje studie více zaměřené na konkrétní spektrum podnětů. Obsahuje pozitivní, negativní a neutrální podněty koncentrované v tématech (děti, pavouci, atd.) [20], [21], [22], [23]

Například Franzitis (2010) použil ve své studii obrázky z IAPS a snímal signály CNS a ANS: EEG a EDA. Obrázky vyhodnocoval ve 2D prostoru na základě komponent arousal a valence.[24]

2.3 Audiovizuální stimulace

V emocionální audiovizuální stimulaci se používají krátké úseky videí, kterým je přisuzován emocionální obsah nebo obsah, u kterého se emocionální odezva očekává. Existují databáze s audiovizuálními podněty, např. MAHNOB-HCI (Multimodal Analysis of Human Nonverbal Behavior – Human Computer Interface, Multimodální analýza nonverbálního lidského chování – rozhraní člověk počítač), což je databáze ohodnocených videoklipů na základě explicitního a implicitního hodnocení videosekvencí. Další databází je DEAP (Dataset pro emoční analýzu za použití EEG a fyziologických signálů), která obsahuje minutové úseky hudebních videí. Klipy jsou ohodnoceny na základě korelacemi mezi frekvencemi v signálu EEG a subjektivním hodnocení měřených osob. Hodnocení je vztahováno ke 2D emocionálním prostoru valence/arousal a pro subjektivní hodnocení je užit SAM test. Základem k metodice vytvoření databází s videostimuly je práce Grosse (1995). Gross použil 16 cíleně vybraných filmových klipů, které prezentoval 494 osobám. A vyhodnocoval odezvu. Každý klip získával hodnocení v rámci osmi základní emocí prezentovaných Ekmanem (1992): zábava, hněv, uvolnění,

nechuť, strach, smutek, překvapení a neutrální emoce, viz Obrázek 6. Nakonec byla videa ohodnocena na základě dominantní emoce, v případě, že se o tom dalo rozhodnout. Tato studie používala subjektivní hodnocení, bez podpory z pohledu záznamu a vyhodnocení fyziologických reakcí. [21], [25], [26]



Obrázek 6: Příklad výsledku hodnocení u filmu Šampión (1979) v Grossově studii, dominující emoce smutek (převzato z [26])

Soleymani a spol. (2011) použil jako podněty krátké sekvence hudebních videoklipů. Z každého vybraného videoklipu byl vybrán emocionálně nejvýraznější 60 s úsek. Čtyřicet minutových videosekvencí bylo prezentováno 32 testovaným osobám a současně byly zaznamenávány fyziologické signály v podobě EEG, GSR, EMG, PPG a tělesná teplota. Účastníci poté hodnotili všechny videa pomocí dotazníku ekvivalentního ke znázornění emocí v 3D prostoru valence/arousal/dominance [14]

Rosenthal (2014) se soustředil přímo na reakce vyvolané konkrétními událostmi v krátkých úsecích počítačově vytvořených videosekvencí. Zopakoval jednu scénu videa, která proběhla ve čtyřech různých variantách a zajímala ho odezva na konkrétní scénář v EEG signálu (topografické mapování), kdy osoba očekávala již známý scénář, ale ve skutečnosti má video jiný průběh. [27]

3 Záznam a vyhodnocování emocí

Samotná emoce vzniká v mozku jako částí centrálního nervového systému. Zde vzniká prostor pro využití elektroencefalografie jako prostředku ke klasifikaci emočních stavů člověka v závislosti na prezentované stimuly. Jak bylo v textu popsáno dříve, vznik emoce v centrálním nervovém systému (patřičné části mozku) je doprováze změnami v činnosti periferního nervstva. Pro získání co nejkompexnější informace, je vhodné záznam EEG doplnit záznamem signálů související s odezvou ANS. ANS se jako součást periferního nervstva podílí na procesu tvoření emoce a jeho odezvu na emoci vzniklou v CNS můžeme zaznamenat. V takovém případě musíme měřit signály, jejichž změny korespondují se změnami vyvolanými působením ANS. Tyto změny můžeme zaznamenat například pomocí fotopletysmografické sondy, měření vodivosti kůže či tělesné teploty.[13]

Nejpokročilejším způsobem pro získání informací o emoční odezvě jsou funkční neurovizuální metody. Jejich nevýhodou je vysoká finanční náročnost pokusů a nedostupnost přístrojového vybavení.


3.1 Elektroencefalografie

Elektroencefalografie je komplexní metodou v oblasti klasifikace emocí. Zaznamenává elektrickou aktivitu mozku v místech umístění elektrod. Vysoké časové rozlišení je vykoupeno nízkou prostorovou rozlišovací schopností, ale je možnost konstruovat topografické mapy aktivace a jejich změny v průběhu času. Zde jde hlavně o porovnání aktivace v jednotlivých oblastech mozku, většinou pravá část proti levé části či přední část proti zadní, většina zájmu je směřována v porovnání aktivace v přední levé a přední pravé části – frontální asymetrie. Tomarken a spol. (1990) zjistili, že větší levostranná aktivace predikuje intenzivnější prožitek u pozitivních emocí, to potvrdil také Davidson a spol. (1990), kteří pro stimulaci použili filmové klipy. Sutton a Davidson (1997) poukázali na fakt, že levostranná aktivace souvisí s dispozicí k přístupu kdežto pravostranná aktivace dispozicí k zamezení. [13]

Elektroencefalografie se dostává ze striktně diagnostického prostředí a prosazuje se jako prakticky využitelná metoda při tvorbě rozhraní mozek - počítač (BCI – Brain-Computer Interface). Reakcí trhu je nabídka nízkorozpočtových EEG systémů, využitelných v praktických aplikacích, či experimentálních měření, kdy není vyžadována měřící spolehlivost a robustnost jako u klinických diagnostických přístrojů. Nicméně klinické přístroje jsou pro zkoumání emocí stále používány. Klinický přístroj EGI GES 400 MR použil například Löw a spol. (2013) při využití intenzivní sériové vizuální prezentace (RSVP – rapid serial visual presentation). V této studii prezentovali emočně zbarvené obrázky měřeným subjektům po dobu 330 ms a zajímali se o včasnou odezvu v okolí okcipitálních senzorů v přítomnosti emočně zbarvených podnětů ve srovnání proti podnětům neutrálním. [28], [29]

3.1.1 Základní principy encefalografie

EEG signál je měření proudů protékajících neurony díky synaptickým excitacím v dendritech. Při aktivaci neuronu dochází ke vzniku proudu. Tento proud generuje magnetické a elektrické pole, měřitelné pomocí EEG. EEG zaznamenává elektrickou aktivitu mozku. Samotný signál vzniká sumací velkého množství postsynaptických potenciálů z pyramidálních buněk. Pyramidální buňky vytvářejí mezi tělem a apikálním dendritem elektrický dipól. Aby bylo možné signál zaznamenat (dochází k utlumení vlivem průchodu mozkovou tkání, lebkou a kožní tkání) musí být aktivováno velké množství neuronů. Proti původní myšlence, že se jedná o sumované akční potenciály, hovoří fakt, že nervová a kostní tkáň se chovají jako dolní propust a vysokofrekvenční složky akčních potenciálů se rychle vytrácí se vzdáleností od zdroje. Metoda má vysoké časové rozlišení, což umožňuje sledování dynamických změn v krátkých časových úsecích.[30], [31]



Obrázek 7: Aktivita v jednotlivých pásmech EEG (převzato z [32])

Hlavními deskriptory EEG signálu jsou frekvence a amplituda. Na základě odlišných behaviorálních stavů byly odvozeny následující pásma EEG signálu, viz Obrázek 7.

- **Delta (1 – 4 Hz):** vyskytuje se u zdravých jedinců při hlubokém spánku, mohou být přítomny v bdělém stavu. Jedná se o pomalé vlny s vysokou amplitudou.
- **Théta (4 – 7,5 Hz):** vlny théta se objevují při ospalosti či v bezvědomí, zdá se, že jejich aktivita je spojena s úrovní vzrušení. Vlny théta hrají důležitou roli v mozkové aktivitě dětí.
- **Alfa (8 – 13 Hz):** alfa vlny se objevují v přední části hlavy, zejména v okcipitální oblasti. Projevují se jako sinusové vlny. Alfa rytmus je nejvýraznějším projevem elektrické aktivity mozku a označuje se jako klidová aktivita v bdělém stavu se

zavřenými očima, při jejich zavření se alfa aktivita zmenšuje. Amplituda se pohybuje okolo 50 μV .

- **Beta (14 – 26 Hz):** elektrická aktivita v mozku v bdělém stavu spojená s aktivním přemýšlením, pozorností či řešením problémů. Rytmická beta aktivita se objevuje ve frontálních a centrálních regionech mozku. Amplituda beta vln se pohybuje okolo 30 μV .
- **Gama (přes 30 Hz):** vyznačují se malou amplitudou a jejich výskyt je vzácný.

Z předchozího výčtu vyplývá, že v následujících částech, hlavně v oblasti vyhodnocování emocí ze signálu EEG nás bude zajímat aktivita alfa a beta, které jsou hlavními nosiči informace o aktivaci v bdělém stavu.[31]

3.1.2 Individuální alfa frekvence (IAF)

Záznam emocí je zatížen vysokou intraindividuální variabilitou. Jeden z možných přístupů k smysluplnému snížení chyby měření, která tímto způsobem vzniká při návrhu komplexního experimentu, je záznam individuální alfa frekvence. [33]

Alfa frekvence je dominantní frekvencí lidského EEG v klidu v bdělém stavu. Popisuje fungování CNS, mentální zdraví a kognitivní funkce. Díky vysoké stabilitě může IAF posloužit nejen jako silný marker neuropatologických změn, ale také jako prostředek k větší individualizaci měření a následného zpracování, kdy stanovené IAF zpřesní výsledky výpočtů arousal a valence, kde v první řadě vystupují poměry alfa aktivit z levé a pravé části mozku. [11], [33]

3.2 Fotopletysmografie


Fotopletysmografie je jednodušší variantou oxymetrie. Na základě měření odraženého záření o vhodné vlnové délce z fotoemitující diody zaznamenává objem krve. Čím více krve, tím více záření se odráží a tím větší je elektrický signál oximetru.[34]

Fotopletysmografie může mimo jiné posloužit jako prostředek k odhadu tepové frekvence či R-R intervalů. Tyto intervaly slouží následně k analýze změn srdečního rytmu. Na změnu srdečního rytmu má vliv ANS. Nervová zakončení sympatiku stimulují srdeční svalstvo a zvyšují tepovou frekvenci. Naopak nervová zakončení parasympatiku snižují srdeční zátěž. Ze změn srdečního rytmu se dá usuzovat intenzita pocíťované emoce, protože ANS při aktivaci připravuje tělo na předpokládaný energetický výdej.[35]

Při stanovení vlivů ANS na srdeční činnost při emocionální stimulaci nás zajímá variabilita srdečního rytmu (HRV – Heart Rate Variability). HRV může být zkoumáno v časové oblasti, kde nás zajímají časové rozdíly mezi po sobě jdoucími R-R intervaly. Ty můžeme přepočítat na tepovou frekvenci a její změny v rámci jednotlivých R-R intervalů, viz Obrázek 8. [36]

Při vyhodnocování emocionální odezvy z HRV nás zajímají tyto pásma a parametry HRV:

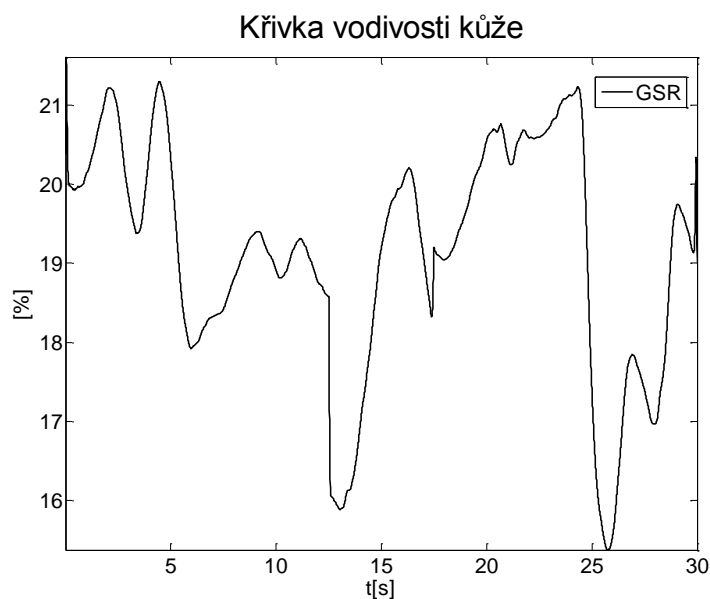
- **High Frequency** (HF, vysokofrekvenční pásmo, 0,15 – 0,40 Hz): reprezentuje eferentní signál z nervu vagu modulovaný dýchací sinovou arytmií (zvýšení srdeční frekvence při nádechu)
- **Low Frequency** (LF, nízkofrekvenční pásmo, 0,04 – 0,15 Hz): reprezentuje příspěvek vlivu nervus vagus a sympatickou modulaci R – R intervalů [36]
- **LF/HF ratio** (poměr LF/HF): index autonomní reakce, vysoké hodnoty ukazují na predominanci sympatiku, nízké hodnoty na predominanci parasympatiku. [37]



Obrázek 8: Surová křivka variability srdečního rytmu získaná zpracováním fotopletysmografického záznamu

3.3 Kožní vodivost

Vodivost kůže (GSR) je ovlivňována činností ANS, kdy vlivem vzrušení dochází k zalití potních žláz vodou a rozšíření vlásečnic a jejich zalití krví. Tím dochází ke změnám vodivosti. Nejvýraznější změny se týkají oblasti dlaně a prstů, kde dochází k výraznému rozšiřování vlásečnic a jejich zalití krví, což taktéž ovlivňuje vodivost. Výhodou při měření GSR je výhradní inervace potních žláz sympatikem (sudomotorická nervová vlákna). Každé sudomotorické vlákno inervuje potní žlázy na ploše zhruba 1,28 cm². Aktivita sudomotorických vláken odpovídá frekvenci 0,62 Hz. Změny kožní vodivosti mohou být charakterizovány pomalu kolísající tonickou aktivitou SCL (Skin Conductance Level – úroveň kožní vodivosti) a rychle se měnící fázičkou aktivitou SCR (Skin Conductance Response – odezva kožní vodivosti), viz Obrázek 9. SCR může vypovídat o specifické odezvě na stimulaci a objevuje se v intervalu 1 – 3 s po stimulu. Výsledný signál kožní vodivosti je superpozicí obou složek. [36], [38]



Obrázek 9: Křivka vodivosti kůže (SCR složka) normovaná na maximální rozsah [%]

Při zpracování signálu GSR nás zajímá právě stimulačně specifická SCR složka. Ta se dá z výsledného signálu získat odečtením minimální linie, získané jako sérii minimálních hodnot signálu v okně o vhodně zvolené délce. [39]

Syntéza HRV s GSR: za normálních podmínek je vodivost kůže nízká a v pásmu LF HRV jsou viditelné píky kolem 0,1 Hz a v HF od 0,15 do 0,5 Hz. Při správné emocionální stimulaci dochází k nárůstu kožní vodivosti, ale z těch se nedá přesně určit reakce ANS. Frekvenční analýza HRV ukáže pík o nižší frekvenci než 0,1 Hz v pásmu LF v případě zrychlení srdečního rytmu – predominance sympatiku. V případě zpomalení srdečního rytmu se pík v pásmu HF posune k vyšším hodnotám oproti normálu. [36]

3.4 Neurozobrazování a emoce

Neurozobrazovací studie využívají funkční magnetické rezonance (fMRI) a pozitronové emisní tomografie (PET) pro záznam a lokaci aktivace v jednotlivých regionech mozku. Funkční MRI odhaluje hladinu okysličení krve (Blood Oxygenation Level Dependent – BOLD signál), PET zaznamenává metabolickou aktivitu skrz měření koncentrace pozitron – emisního radioizotopu. Aktivace v konkrétním regionu mozku se u obou modalit projeví zvýšením signálu z daného místa. Ačkoliv se jedná spíše o aktivace celých nervových okruhů, dá se usuzovat, které části mozku hrají v rámci okruhu klíčovou roli. Příklad je aktivace amygdaly v případě stimulu vyvolávající pocit strachu (Murphy a spol., 2003) či její klíčové roli v nervovém okruhu při pocíťování negativních emocí (Cahill a spol., 1996). [13]

4 Klasifikace emocí s využitím záznamu EEG

Následující kapitoly obsahují shrnutí postupů pro předzpracování a přehled metod pro zkoumání záznamů EEG z hlediska klasifikace emocí. Cílem této kapitoly bylo získání přehledu o metodách práce s EEG při analýze emocí. Na základě těchto znalostí byl navržen postup pro zpracování změřených EEG signálů směrem ke klasifikaci.

4.1 Předzpracování signálů

Surový EEG signál obsahuje množství artefaktů nespojených s aktivitou mozku, mezi tyto artefakty patří zejména kolísání izoliny signálu, EMG v podobě mrkání a pohybů očí, síťové rušení či EKG. Základní metodou odstranění artefaktů je filtrace filtry typu FIR nebo IIR (Infinite Impulse Response) s lineární fázovou charakteristikou. Filtrace se uplatní hlavně při odstranění driftu (horní propust s nízkou mezní frekvencí, např. 0.5 Hz), síťového rušení (notch filtr pro 50 Hz) nebo vysokofrekvenčního rušení (dolní propust s vyšší mezní frekvencí, např. 100 Hz). Hlavním úkolem při volbě filtrů a jejich mezních frekvencí je snaha co nejméně ovlivnit signál EEG, jehož frekvenční rozsah se mnohdy překrývá s frekvenčním rozsahem rušení. V případě periodického rušení se v posledních letech prosadila metoda Independent Component Analysis (ICA). ICA je metoda založená na lineárním rozkladu signálů. Aby byla metoda účinná, musí na jejím vstupu být signály s nulovou izolinií, protože kolísání izoliny není lineární proces. [40]

Independent Component Analysis

ICA je dnes již běžně používaná metoda pro odstranění artefaktů v podobě mrkání, EKG, případně EMG. Jejím výstupem je rozklad EEG signálů jako směs prostorově nezávislých aktivit v časově nezávislých zdrojích. Základním předpokladem ICA je, že suma potenciálů přicházejících z různých částí mozku je lineární a zpoždění přenosu potenciálů z různých míst mozku je zanedbatelné. Metoda předpokládá, že všechny tyto předpoklady jsou u EEG splněny.

Prvním krokem ICA je vybělení matice dat, aby byly odstraněny veškeré korelace v datech ve všech dimenzích (dimenze odpovídá počtu elektrod). Výsledná vybělená matice je následně rotována tak, aby měla ve všech dimenzích rozdělení co nejdál od Gaussova rozdělení, jinak řečeno se snažíme najít takovou projekci dat, aby jejich kovarianční matice byla diagonální se stejnými prvky na diagonále (ideálně jednotková matice). ICA poté převede vybělenou matici (její rotací) do prostoru jednotlivých nezávislých zdrojů. [41], [42], [43]


Matematicky je ICA lineární transformací z prostoru signálu do prostoru zdrojů, viz (4.1), kde X jsou data a S je aktivace (signál) nezávislých zdrojů. W je váhová matice pro transformaci z prostoru X do S .

$$S = WX \tag{4.1}$$

Z rovnice (4.2) vyplývá, že matice inverzní k W (W^{-1}) určuje, jakým způsobem se signály jednotlivých zdrojů promítají do jednotlivých elektrod. Jinak řečeno signál na jednotlivých elektrodách vzniká sumou váhovaných signálů jednotlivých (aktivací) nezávislých zdrojů, viz Obrázek 10. Úkolem ICA je výpočet právě váhovací matice W , viz rovnice (4.2).

$$X = W^{-1}S \quad (4.2)$$

Pokud je provedena ICA dekompozice, cílem je nalézt a odstranit zdroje odpovídající různým druhům rušení (EKG, EOG, EMG, síťové rušení,...) a provést zpětnou projekci, viz rovnice (4.2), tak aby toto rušení nebylo v zpětně sestavené signálové matici přítomno. To se provede tak, že příslušné váhy pro dané zdroje rušení se ve W^{-1} vynulují. [44], [41]



Obrázek 10: ilustrace fungování ICA[43]

Běžná praxe je, že se výsledky ICA prochází manuálně a označují se zdroje pro odstranění pro zpětnou kompozici signálu. Tento postup je ovšem velice časově náročný pro dlouhé časové záznamy, kde se při zpracování neklade důraz na získání ERP v relativně početných, ale krátkých úsecích celého EEG záznamu. Řešením je snaha o automatickou detekci zdrojů rušení a jejich automatické odstranění, viz kapitola 0.

Pro kroky předzpracování signálů existují volně dostupné toolboxy, jedním z nich je i EEGLAB. Jedná se o ucelený volně dostupný toolbox v prostředí MATLAB pro zpracování EEG (dostupný na <http://scn.ucsd.edu/eeglab/>). Vyznačuje se velkým obsahem nástrojů vhodných pro zpracování dlouhodobých i krátkodobých úseků EEG (Evokované potenciály) jako je například Independent Component Analysis (ICA), časově – frekvenční analýza, odstraňování artefaktů, statistika či vizualizace dat. EEGLAB může být použit skrz grafické uživatelské prostředí nebo jako prostředek ke psaní skriptů za využití funkcí dostupných v Matlabu a EEGLABu. Další výhodou EEGLABU je rozsáhlá webová podpora skrz internetovou komunitní stránku a dostupnost informací a ukázek (tutorialů), jak s EEGLABem pracovat. EEGLAB je v současné době jedním ze standartních a preferovaných nástrojů pro zpracování EEG. V rámci této práce je EEGLAB využíván jako zdroj funkcí pro psaní skriptů pro předzpracování surových záznamů EEG či pro vizualizaci dat. [44], [45]

4.2 Extrakce vektoru příznaků

Po předzpracování signálů a odstranění artefaktů následuje krok extrakce důležitých informací. Snahou je popsat signál a jeho vlastnosti konečným počtem popisných elementů různého charakteru (statistické ukazatele, ukazatele popisující frekvenční charakter signálů, atd.), tak aby důležitá informace zůstala zachována pro potřeby hledání vzorů v datech a klasifikaci do skupin podle emocí.

4.2.1 Analýza v časové oblasti

Analýza v časové oblasti je nejjednodušším přístupem. Signál EEG jako takový reprezentuje vznik a šíření akčních potenciálů v mozku. Nevýhodou zpracování v časové oblasti je značná kontaminace šumem a artefakty.

V této nás můžou zajímat statistické ukazatel jako: průměr signálu, směrodatná odchylka průměr absolutních hodnot první diference, průměr absolutních hodnot první diference normalizovaného signálu (4.3), průměr absolutních hodnot druhé diference signálu (4.4), průměr absolutních hodnot druhé diference normalizovaného signálu (4.5). Tyto ukazatele použila ve svém výzkumu o klasifikaci emocí Picard (2009). [46], [47]

$$\bar{\delta}_x = \frac{1}{N-1} \sum_{t=1}^{N-1} |\bar{X}(t+1) - \bar{X}(t)| \quad (4.3)$$

$$\gamma_x = \frac{1}{N-2} \sum_{t=1}^{N-2} |X(t+2) - X(t)| \quad (4.4)$$

$$\bar{\gamma}_x = \frac{1}{N-2} \sum_{t=1}^{N-2} |\bar{X}(t+2) - \bar{X}(t)| \quad (4.5)$$

Další metodou časové analýzy je High Order Crossings (HOC) – počítání průchodů nulou. Pokud je signál filtrován změní se jeho oscilační charakteristiky, v tomto případě počet průchodů nulou. Pokud je původní signál filtrován, počet průchodů nulou je pro různě filtrované signály odlišný. Změny v této charakteristice signálu se pro vhodně zvolené filtry dají použít pro jeho klasifikaci, Petrantonakis (2010, 2012). [46], [48]

4.2.2 Frekvenční analýza

Nejlepší definicí frekvenční analýzy je, že se z konečného záznamu stacionárního signálu snaží získat informaci, jak je celkový výkon rozložen mezi frekvenční složky signálu. Frekvenční analýza může odhalit skryté periodicity v signálu. [49]

Při práci s krátkými úseky EEG o délce v rozsahu 1 - 2,5 s (takové jsou považovány za stacionární) je frekvenční analýza metodou pro zkoumání energie signálu v různých frekvenčních rozsazích. Pro emoční odezvu jde obvykle o rozsah pásem alfa a beta (odpovídá zhruba rozsahu 8 – 30 Hz). Jako vhodná metoda pro hodnocení emocí z hlediska frekvenční

analýzy může být odhad hustoty spektrálního výkonu signálu - Power Spectral Density (PSD), viz (4.6) na frekvencích odpovídajícím alfa a beta pásmům EEG v krátkých časových úsecích, kdy se dá signál považovat za stacionární. Tyto popisné elementy použil k stanovení emoční odezvy Soleymani a spol. (2013). [50]

$$\widehat{PSD}(\omega) = \frac{1}{N} \left| \sum_{t=1}^N y(t) e^{-i\omega t} \right|^2 \quad (4.6)$$

Pro výpočet PSD je možné použít neparametrickou Welchovu metodu. Vychází z metody odhadu periodogramu, ale signál je rozdělen na segmenty o stejné délce s vzájemným částečným překryvem mezi segmenty. Následně je pro každý segment vypočten periodogram, kde $y(t)$ je konečný diskretní signál s N vzorky. Periodogramy všech segmentů se poté průměrují, viz výpočet periodogramu pro segment j , viz (4.7), kde P je výkon časového okna a (4.8), kde je výsledné PSD vypočítáno jako průměr napříč všemi segmenty. Tímto přístupem by mělo dojít ke snížení rozptylu výpočtu PSD z celého úseku signálu. [49]

$$\widehat{PSD}(\omega) = \frac{1}{MP} \left| \sum_{t=1}^N v(t) y_j(t) e^{-i\omega t} \right|^2, P = \frac{1}{M} \sum_{t=1}^N |v(t)|^2 \quad (4.7)$$

$$\widehat{PSD}(\omega) = \frac{1}{S} \sum_{j=1}^S \widehat{PSD}(\omega) \quad (4.8)$$

4.2.3 Časově – frekvenční analýza

U časově – frekvenční analýzy nás zajímá, jak se frekvenční vlastnosti signálu mění v průběhu času. Metody časově – frekvenční analýzy mapují jednorozměrný signál v čase do dvourozměrné funkce času a frekvence.

STFT spektrogram

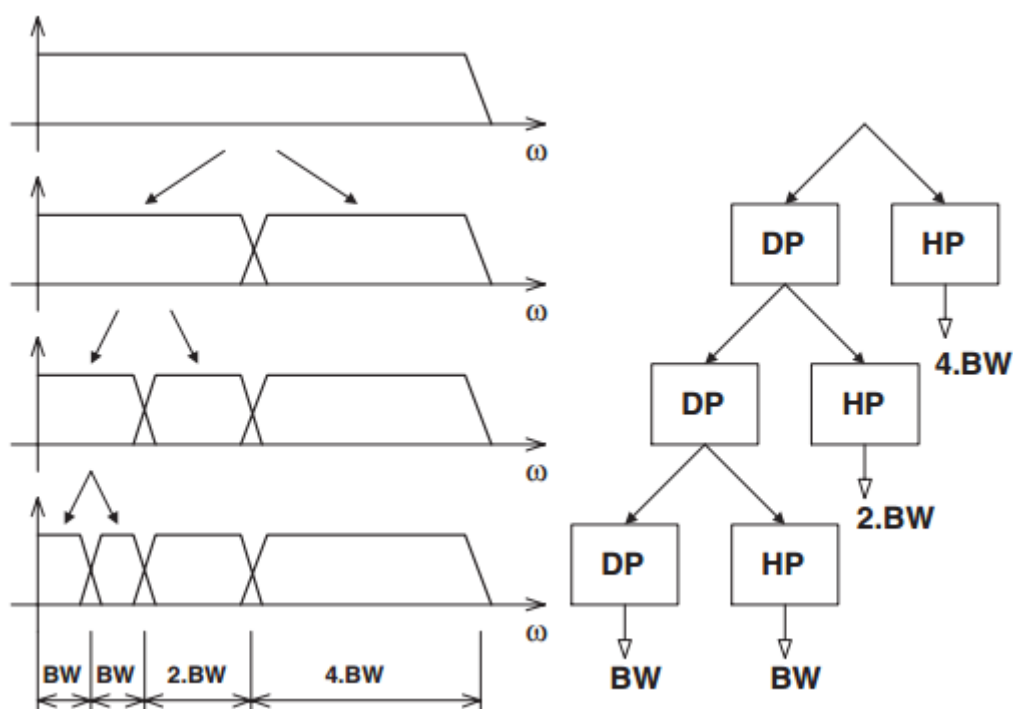
Nejjednodušší metodou je metoda spektrogramu využívající Short – Time Fourier Transform (STFT). Jedná se o diskretní Fourierovu transformaci aplikovanou na pohybující se okno po zkoumaném signálu o pevné délce. Spektrogram je poté čtverec magnitudy $s(t)$ získaného STFT. [46],[51]

Diskretní vlnková transformace

Pokročilejším přístupem je použití diskretních vlnkových transformací (DWT). Jedná se o neparametrickou metodu časově spektrální analýzy. Základem pro použití DWT je rozhodnutí o rozsahu frekvencí pro analýzu, spektrální a časové rozlišení a volba báze funkce (vlnky). Jak již bylo v tomto textu několikrát zmíněno, v případě rozhodování o frekvenčním rozsahu nás zajímají frekvence odpovídající pásmu alfa a beta EEG, tedy zhruba 8 – 30 Hz. Pro danou báze funkci jsou poté vypočítány koeficienty odpovídající alfa a beta frekvencím.

Murugappan a spol. (2010) použil k stanovení těchto koeficientů vlnku Daubechies 4. řádu (*db4*). [46], [52]

Diskrétní vlnkovou transformaci si můžeme představit jak průchod signálu řetězcem filtrů, horní a dolní propusti dělí frekvenční doménu signálu na polovinu. Následuje podvzorkování obou vzniklých signálů s faktorem dva. Tak se získají přibližné (podvzorkování výstupu dolní propusti) a detailní koeficienty (podvzorkování výstupu horní propusti) první úrovně DWT. V následujícím kroku se vezmou přibližné koeficienty a opět se filtrují dvěma filtry, které rozdělí pásmo signálu na poloviny a výstupy se podvzorkují s faktorem dva (úroveň dva DWT), atd. [53]



Obrázek 11: Půlení frekvenčního pásma na poloviny v rámci tří úrovní diskrétní vlnkové transformace (BW – bandwidth, šířka pásma, DP – dolní propust, HP – horní propust) [54]

Filtrace probíhá konvolucí signálu s bázovou funkcí (vlnkou), jejíž šířku a polohu lze měnit, viz (4.9), kde p odpovídá měřítku a k poloze. Z podmínek pro bázové funkce vyplývá, že Fourierova transformace bázové funkce je nulová na nulové frekvenci a tudíž se vlnka chová jako pásmová propust, filtrující signál kolem centrálního kmitočtu. S tímto souvisí, že průměr vlnky je roven nule a tudíž vlnka musí mít charakter oscilace. Centrální kmitočet je závislý na měřítku s mocninou dvou a tudíž půlí frekvenční pásmo. Nevýhodou metody je závislost na volbě bázové funkce (vlnky), aby co nejlépe reprezentovala oscilace přítomné v samotných datech. [52], [54]

$$\psi_{k,p}(t) = \frac{1}{\sqrt{2^p}} \psi\left(\frac{t - 2^p k}{2^p}\right) \quad (4.9)$$

Popisné elementy ve formě koeficientů DWT v pásmech odpovídajících alfa a beta použil například Murugappan (2010) či Tazrin (2013). Energie a entropie koeficientů DWT použil Haiyan (2012).

Hilbert-Huanagova transformace

Další variantou časově – frekvenční analýzy je Hilbert-Huanagova transformace (HHT, Huang a spol. 1996, 1998, 1999), která se skládá z Empirical Mode Decomposition (EMD) a Hilbertové transformace. EMD rozkládá signál do souboru monokomponentních signálů v závislosti na datech, proto je schopná zachovat nestacionarity a nelinearity signálu. Spolu s tím, že nepotřebuje předem známou bázi je zajímavou alternativu pro analýzu signálu. Touto vlastností se hodí i pro analýzu dlouhých EEG záznamů, které jsou pro potřeby FFT a STFT považovány za stacionární pouze v krátkých úsecích okolo 1 – 2,5 s. Dále se EMD uplatňuje při analýze okamžité frekvence signálu (Instantaneous frequency – IF) skrz výběr IMF (Intrinsic Mode Functions), viz níže. HHT poskytuje časově – frekvenčně – energetickou reprezentaci dat. [46], [55]

Dekompozice je založena na předpokladu, že signál obsahuje různé jednoduché Intrinsic Mode Function (IMF). Každá IMF reprezentuje jednoduchou oscilaci – dle podmínky, že obsahuje stejný počet extrémů a průchodu nulou (nebo se liší maximálně o jedna) a musí být zároveň symetrická podle lokálního průměru, viz výpis níže. Data se tímto způsobem dají rozložit na konečný počet oscilací, jejichž superpozici vznikne zpět původní signál. Přesné restrikce pro IMF jsou:

- V celém signálu je počet extrémů shodný nebo se liší nejvíce o jedna
- V každém bodě je průměrná hodnota obálky definované lokálním maximem a obálky definované lokálním minimem roven nule [55]

IMF je mnohem více obecná než konstantní harmonická funkce, na rozdíl od harmonické funkce může mít v čase proměnnou amplitudu a frekvenci. Proces dekompozice probíhá následovně:

- Nalezení všech lokálních maxim a jejich proložení kubickým splajnem pro získání horní obálky signálu, stejný postup opakovat pro lokální minima, původní signál musí být ohraničen mezi oběma obálkami, vypočítat průměr m_l mezi oběma obálkami
- Odečíst průměr m_l od původního signálu $x(t)$ a získat h_l , viz (4.10).

$$h_1 = x(t) - m_1 \quad (4.10)$$

- Opakovat první dva body k -krát dokud nejsou splněny podmínky pro IMF c_l . viz (4.11), (4.12).

$$h_{1k} = h_{1(k-1)}m_{1k} \quad (4.11)$$

$$c_1 = h_{1k} \quad (4.12)$$

- Stanovit kritérium, kdy je dekompozice ukončena. Jednou variantou je dostatečně malá normalizovaná kvadratická diference SD_k mezi h_{k-1} a h_k , viz (4.13), ta ovšem nezaručuje stejný počet průchodů nulou a extrémů a není definováno jak malé číslo je obecně dostatečné pro úspěšné ukončení procesu. Druhou variantou je volba čísla S , proces se zastaví, jakmile počet průchodu nulou a extrémů je stejný a liší se maximálně o jedna S -krát po sobě. Obecně platí, že S by mělo být zvoleno v rozsahu $\langle 4,8 \rangle$.

$$SD_k = \frac{\sum_{t=0}^T |h_{k-1}(t) - h_k|^2}{\sum_{t=0}^T h_{k-1}^2} \quad (4.13)$$

- Pokud je nalezena první IMF c_1 , separujeme ji od dat odečtením od signálu, viz (4.14) a získáme residuum r_1 , r_1 je dále považováno za nová data a celý proces se opakuje s dalšími r_j . Proces je zastaven, když komponenta c_n nebo residuum r_n jsou menší než určený práh nebo residuum r_n je monotónní funkce, ze které už nelze dostat další IMF.
- Původní signál získáme jako sumu všech IMF c a posledního rezidua r_n (trend nebo konstantní signál), viz (4.15). [55]

$$r_1 = x(t) - c_1 \quad (4.14)$$

$$x(t) = \sum_{j=1}^n c_j + r_n \quad (4.15)$$

Dalším krokem po získání IMF je Hilbertova spektrální analýza. Po provedení Hilbertovy transformace na každou IMF získanou předchozími kroky se originální data vyjádří jako reálná složka rovnice (4.16), kde není obsaženo residuum r_n . V rovnici je amplituda a frekvence každé komponenty závislá na čase. Tímto způsobem mohou být vyjádřena i nelineární a nestacionární data. [55]

$$x(t) = \Re \left\{ \sum_{j=1}^n a_j(t) e^{i \int \omega_j(t) dt} \right\} \quad (4.16)$$

EMD s Hilbertovou transformací slouží odhalení okamžité frekvence signálu (IF – Instantaneous frequency), která je definována jako derivace fáze analytického signálu podle času (Ville, 1958), (4.18). Analytický signál je popsán rovnicí (4.17), kde $\hat{x}(t)$ je Hilbertova transformace originálního signálu $x(t)$. EMD použil pro klasifikaci emocí například Kahsnobish a spol. (2013). [56]

$$z(t) = a(t)e^{i\phi(t)}, a(t) = \sqrt{x^2(t) + \hat{x}^2(t)} \quad (4.17)$$

$$IF(t) = \frac{d\phi(t)}{dt} \quad (4.18)$$

Výše popsaný postup EMD (HHT) se dá aplikovat na jednotlivý signál, ale při záznamu EEG máme k dispozici signály z více nezávislých elektrod a frekvenční obsah IMF ze signálů jednotlivých elektrod by nebyl shodný a tudíž v rámci dalšího zpracování velice obtížný. [46]

Alternativní způsoby výpočtu okamžité frekvence

Pro získání okamžité frekvence jednotlivých komponent je možné použít algoritmus typu DESA-1 (Discrete energy separation algorithm), který pro výpočet okamžité frekvence vychází z kontinuálního Teager – Kaiserova energetického operátoru, viz (4.19), který může být pro amplitudově a frekvenčně modulovaný signál přepsán do podoby (4.20), ze kterého byla odvozena okamžitá úhlová frekvence (4.21). [57]

$$\Psi_c[x(t)] \triangleq \left(\frac{dx}{dt}(t)\right)^2 - x(t)\frac{d^2x}{dt^2}(t) \quad (4.19)$$

$$\Psi_c \approx [a(t)\omega_i(t)]^2 \quad (4.20)$$

$$\omega_c = \sqrt{\frac{\Psi[x'(t)]}{\Psi[x(t)]}} \quad (4.21)$$

Při nahrazení derivací diferencemi, viz (4.22) dostaneme podobu diskrétního operátoru pro výpočet okamžité frekvence signálu. Při použití algoritmu DESA-1 je derivace nahrazena dopřednou a zpětnou diferencí, což vede na vzorec (4.23). Algoritmus DESA-1 je schopen vypočítat okamžitou frekvenci do hodnoty poloviny vzorkovací frekvence signálu s přesností v řádu 1%. [57]

$$\Psi_d = x^2(n) - x(n-1)x(n+1) \quad (4.22)$$

$$\Omega_i(n) = \arccos\left(1 - \frac{\Psi[y(n)] + \Psi[y(n+1)]}{4\Psi[x(n)]}\right), y(n) = x(n) - x(n-1) \quad (4.23)$$

4.2.4 Redukce vektoru příznaků

Soubor popisných elementů extrahovaných z EEG datasetů je multidimenzionální, kdy počet popisných elementů n většinou převyšuje počet měření m . Takový prostor popisných elementů je obtížné statisticky zpracovat či klasifikovat, protože velký počet popisných elementů komplikuje odhalení procesů a závislostí, které odhalují a zároveň může obsahovat elementy nepopisující zkoumané procesy – šum, či elementy popisující stejný proces shodným způsobem – nadbytečnost. Jedním z možných postupů je redukce dimenze prostoru popisných elementů do nového podprostoru, kdy se snažíme zredukovat matici popisných elementů $X(m \times n)$ do nové matice $Y(m \times k, k < n)$, která popisuje co největší množství informace v původní matici F .

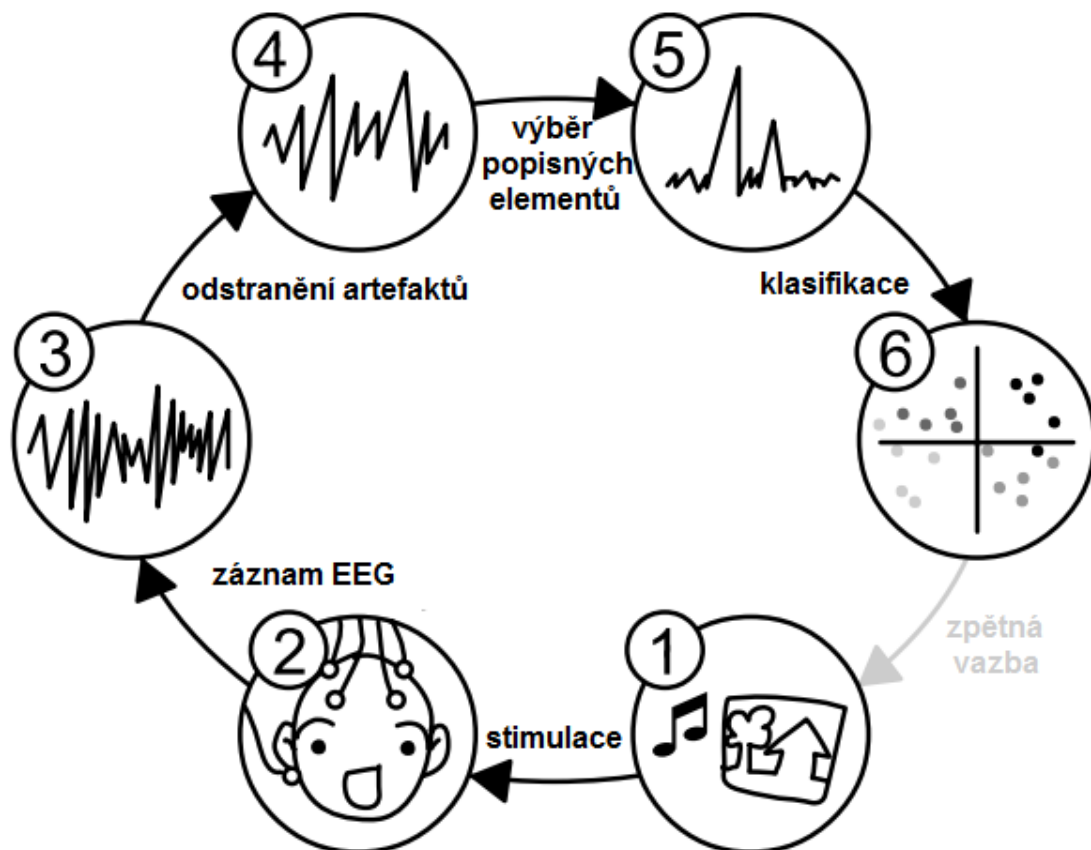
Principal Component Analysis

Za předpokladu, že skryté procesy jsou lineární je vhodnou metodou Principal Component Analysis (PCA, analýza důležitých komponent). PCA se snaží najít projekci n – dimenzionálních dat do nového prostoru. Cílem je, aby nový prostor (nová lineární kombinace popisných elementů) popisoval data lépe než prostor původní a zbavil se šumu či nadbytečnosti vzniklého nevhodnou volbou původního prostoru, kdy jednotlivé lineární kombinace vlivu všech popisných elementů nemusely být pro popis procesu vhodné.

Důležité komponenty jsou lineární kombinací s vah w ($w=(w_1, \dots, w_n)$, $\|w\|_2 = 1$) komponent a vektoru x_i měření (sloupec v X) a cílem je najít takovou lineární kombinaci vah w a vektorů x_i , která popisuje co nejvíce rozptylu v původních datech. Taková kombinace s je první principiální komponenta. Další principiální komponenty jsou získány opět jako lineární kombinace vah a vektorů, ale musí splňovat, že jsou navzájem ortogonální, tzn. skalární součin každého dalšího vektoru vah s vektorem vah přechází principiální komponenty musí být roven nule. Pro redukci velikosti matice popisných elementů X vybereme z matice vah složené z vektorů vah prvních n komponent (n sloupců matice), které popisují většinu rozptylu v datech (práh musíme zvolit, obvykle 80 – 90 % rozptylu). Vybrané váhy poté vynásobíme s původní maticí popisných elementů X a získáme redukovanou matici Y . Tuto matici použijeme jako novou matici popisných elementů pro potřeby klasifikace.[58], [59]

4.3 Možnosti klasifikace emocí z elektroencefalografických signálů

Tato kapitola je přehledem metod úspěšně použitých při klasifikaci emocí (Sandel a spol., 2014, Khalili a spol., 2011, Singh a spol., 2013). Základní stavební prvky celého procesu klasifikace jsou zobrazeny na Obrázek 12. Klíčovým úkonem je správný výběr popisných elementů vhodný pro zvolenou klasifikační metodu. Klasifikační metody vhodné pro klasifikaci emocí jsou popsány v kapitolách níže.



Obrázek 12: Postup při zpracování EEG a klasifikaci emocí (převzato z [60])

4.3.1 K-nejbližší soused


Metoda k-nejbližšího souseda (k-NN – k-Nearest Neighbor) je jednoduchá a robustní klasifikační metoda. Metoda porovnává nové data (testovací data) s již klasifikovanými daty (tréninková data). Zjednodušeně přiřazuje nové data do třídy, která se ve zvoleném okolí klasifikovaných dat nachází nejčastěji, jedná se tedy o shlukovací metodu. Základním parametrem klasifikace je k , tento parametr se projevuje v rámci měřítka podobnosti, kterým může být například Euklidovská vzdálenost u spojitých proměnných nebo Hammingovská vzdálenost u diskrétních proměnných. Parametr k ovlivňuje přesnost klasifikace a v rámci tréninkové fáze se stanoví jeho hodnota tak, aby přesnost klasifikace byla co nejvyšší, jedná se

o kladné celé číslo, obvykle v řádu jednotek. Pro stanovení co nejlepší hodnoty k může být použita například metoda krosvalidace (Chaovalitwongse a spol., 2007). [61], [62]

Klasifikační metodu k -NN použili Khalili a Moradi (2008). Klasifikovali snímky v rámci prostoru valence/arousal do tří tříd: pozitivní vzrušení, negativní vzrušení a uklidnění. Pro klasifikaci použili záznamy EEG a periferních signálů (GSR, povrchová tělesná teplota, dechová frekvence). Při klasifikaci dosáhli nejvyšší přesnosti 51%. Jako popisné elementy použili průměr, směrodatnou odchylku, koeficient šikmosti a špičatosti, a průměr absolutních hodnot první diference signálu pro úsek signálu odpovídající každému obrázku.[63]

4.3.2 Umělé neuronové sítě

Umělými neuronovými sítěmi (ANN – Artificial Neural Networks) se za využití výpočetní techniky snažíme co nejlépe napodobit spojení mezi neurony v lidském mozku. Základními prvky umělé neuronové sítě jsou stejně jako v lidském mozku neurony. Neurony jsou uspořádané tak, aby tvořily síť.



Obrázek 13: Perceptron, nejjednodušší typ neuronové sítě s jedním neuronem (převzato z [64])


Neuronová síť je organizovaná do vrstev, kdy neurony jedné vrstvy nejsou vzájemně propojeny mezi sebou, ale jsou propojeny se všemi neurony navazující vrstvy. V rámci každé ANN je přítomna jedna vstupní a jedna výstupní vrstva. Dále jsou přítomny skryté vrstvy, jejich počet může být teoreticky neomezený. Každá vrstva obsahuje určitý počet neuronů. ANN funguje tak, že výstup jedné vrstvy je zároveň vstupem vrstvy nadcházející. Každý neuron provádí lineární kombinaci všech jeho vstupů $x = [x_1, \dots, x_n]$ s patřičnými váhami $w = [w_1, \dots, w_n]$, která resultuje v jednu samostatnou hodnotu y na výstupu perceptronu – získanou pomocí přechodové funkce $f(\dots)$, viz Obrázek 13. Výstup slouží jako vstup neuronů další vrstvy nebo jako výstup ANN v případě, že se daný neuron nachází ve výstupní vrstvě ANN. Počet neuronů na vstupní vrstvě ANN odpovídá počtu zvolených popisných elementů a počet neuronů

na výstupu je dán komplexností klasifikace, např. při binárním výstupu neuronu a binární klasifikaci stačí jeden výstupní neuron, ale při binárním výstupu neuronu a klasifikaci do tří tříd musí být ve výstupní vrstvě dva neurony. Aby klasifikace proběhla správně je potřeba ANN řízeně učit. To znamená postupně upravovat váhy vstupu každého neuronu. [64], [65]

Klasifikaci emocí pomocí ANN provedl Singh (2013), který jako popisné elementy signálu EEG použil entropie, odchylku a výkon všech pásem EEG signálu z vybraných elektrod (6 elektrod, celkem 30 parametrů pro každý typ popisného elementu). Zajímalo se o klasifikaci v rámci dvou tříd a to vysoké vzrušení (HA – high arousal) a nízké vzrušení (LA – low arousal). Při klasifikaci dosáhl nejvyšší přesnosti klasifikace (74,3%) při použití entropie samostatné elektrody Cz (10 – 20 systém). Při použití všech vybraných elektrod a jejich entropie dosáhl nejvyšší přesnosti klasifikace (79,17%). Odchylka a výkon se neukázaly jako účinnější popisné elementy pro klasifikaci. [66]

4.3.3 Support Vector Machines (SVM)

SVM je typ binárního klasifikátoru schopný klasifikovat vícerozměrná data. Rozděluje data do tříd konstrukcí nadrovin mezi třídami. Nadrovina odděluje třídy pomocí bodů s nejvyšší vzdáleností na základě odvozené funkce (např. rovnice přímky u oddělení dvou tříd, viz Obrázek 14).



Obrázek 14: SVM rozdělující data do dvou tříd, w – vektor bodů kolmých na oddělovací nadrovinu, b – posun nadroviny, x – body (souřadnice) (převzato z [65])

Body nejméně vzdálené od nadroviny, která rozděluje dané dvě třídy, se nazývají support vectors. Proto se hledají body s největší vzdáleností od nadroviny a zároveň jsou nejbližšími body dvou různých tříd. Výhodou této metody je možnost použití transformace dat do vícerozměrného prostoru pomocí jádrových funkcí usnadňující jejich klasifikaci. SVM umí pracovat v N – rozměrném prostoru (kde N je počet tréninkových vektorů), ale se zvyšujícím

se N roste i výpočetní náročnost. Konstrukce nadroviny přidává další rozměr, SVM tedy ve výsledku pracuje s $N+1$ rozměrném prostoru. Klasifikace do více tříd pomocí SVM je možná vhodnou kombinací binárních klasifikátorů v různých schématech (např. jeden proti všem, jeden proti jednomu), dle modelů ECOC (Error-correcting Output Codes). [65], [67]

Sandel (2014) použil SVM pro klasifikaci valence emocí při vizuální stimulaci pomocí obrázků z databáze IAPS. Zkoumal emocionální odezvu z EEG. Použil popisné elementy týkající se evokovaných potenciálů ze tří elektrod Cz, F3 a P4. Při dělení do tříd vysoká valence a nízká valence dosáhl přesností klasifikace 95%, 93,75% resp. 92,5%. [68]

4.4 Hodnocení úspěšnosti klasifikace

U každého natrénovaného klasifikátoru se hodnotí úspěšnost klasifikace. Riziko, které existuje při trénování klasifikátoru, je přetrénování klasifikátoru. Co značí, že klasifikátor je natrénován na tréninková data, ale není schopen správně klasifikovat neznáma data. Úspěšnost takového klasifikátoru je nízká. Jedním z prostředků hodnocení úspěšnosti a zamezení přetrénování klasifikátorů je krosvalidace. Jedna se o postup, kdy se část tréninkových dat oddělí a ponechá se jako testovací data pro hodnocení úspěšnosti klasifikace:

- **K-fold:** rozdělení tréninkového setu na K stejně velkých částí, jedna z částí slouží jako testovací set, $K-1$ částí jako tréninkový set, úspěšnost klasifikace je určena jako průměr úspěšnosti, kdy každá rozdělená část setu je jednou vyřazena z trénování a klasifikována jako testovací množina
- **Holdout:** tréninkový set je náhodně rozdělen na 2 části ve zvoleném poměru, jedna část slouží jako tréninkový set druhá jako testovací set
- **Leave-one-out:** střídavě je ze setu odebráno jedno měření, které je použito jako testovací data, tento postup se opakuje tak, aby bylo odebráno každé měření, úspěšnost klasifikace je poté průměrem napříč úspěšnostmi každého testovacího setu [69]

Tabulka 1: Konfúzí matice

		Správný výsledek	
		Pozitivní třída	Negativní třída
Výsledek klasifikace	Pozitivní třída	TP	FP
	Negativní třída	FN	TN
		Senzitivita	Specificita

Z krosvalidovaného klasifikátoru (jeho konfúzní matice, viz Tabulka 1) se následně dají odvodit ukazatele přesnosti klasifikace jako senzitivita (4.24), specificita (4.25), správnost (4.26). Kde TP (true positive), je počet správně pozitivně klasifikovaných do třídy označené jako pozitivní, FP (false positive) je počet falešně klasifikovaných do třídy označené jako pozitivní, TN (True Negative) je počet správně klasifikovaných do třídy označené jako negativní a FN (False Negative) je počet špatně klasifikovaných do třídy označené jako negativní. [70], [71]

$$\text{Senzitivita} = \frac{TP}{TP + FN} \cdot 100[\%] \quad (4.24)$$

$$\text{Specificita} = \frac{TN}{FP + TN} \cdot 100[\%] \quad (4.25)$$

$$\text{Správnost} = \frac{TP + TN}{TP + FP + TN + FN} \cdot 100[\%] \quad (4.26)$$

Pro klasifikaci do více tříd jsou odvozené metriky vycházející z metrik pro binární klasifikátory. Jsou jimi například průměrná preciznost (4.27), průměrná úplnost (4.28) a průměrná správnost (4.29), kde l je počet tříd. [71]

$$\overline{\text{preciznost}} = \frac{\sum_{i=1}^l \frac{TP_i}{(TP_i + FP_i)}}{l} \quad (4.27)$$

$$\overline{\text{úplnost}} = \frac{\sum_{i=1}^l \frac{TP_i}{(TP_i + FN_i)}}{l} \quad (4.28)$$

$$\overline{\text{správnost}} = \frac{\sum_{i=1}^l \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i}}{l} \quad (4.29)$$

5 Návrh měření

Na základě poznatků vypracovaných v teoretické části práce byl sestaven návrh měření s emocionální stimulací. Protože dostupné technické vybavení umožňovalo pouze záznam EEG signálu, byla níže uvedena studie zaměřena na analýzu bez účasti jiných fyziologických signálů.

Měření proběhne jako jeden souvislý blok (Obrázek 15) trvající celkově 1038 s pro jednu osobu, během celého bloku je zaznamenávám EEG signál. Každý blok má tři části:

- **Část uklidnění**, kdy je prezentován neutrální nebo lehce pozitivní stimul po dobu zhruba pěti minut, tak aby si testovaná osoba co nejlépe zvykla na prostředí a měřicí senzory a dokázala se co nejlépe uvolnit.
- **Blok stimulů**. Ten sestává z jedenácti reklamních spotů. Reklamní spoty byly vybrány, kvůli tomu, že mají cíleně působit na člověka a ovlivňovat jeho myšlení a citění. Těmito atributy jsou vhodné pro vyhodnocování emocionální odezvy na videosekvence.
- **Část kalibrační**. Kalibrační část obsahuje úseky videosekvencí, jejichž emocionální odezva je známá – jejich původ je v databázi stimulů nebo byly ohodnoceny v rámci studií zabývajících se multimediální audiovizuální emoční stimulací. Videá v kalibrační části pokrývají dominantní emoce na osách kvadrantů 2D emocionálního prostoru valence/arousal.




Obrázek 15: Měřicí protokol

S neustálým vývojem technologií se na trhu začínají objevovat cenově dostupné EEG přístroje, s cílem usnadnit přístup k vývoji rozhraní mozek – počítač vývojářům mimo medicínské prostředí. Zástupcem této kategorie je i přístroj Emotiv EPOC, který se, mimo jiné, profiluje jako zařízení vhodné k záznamu a vyhodnocení emocí člověka. Na opačném konci stojí EGI GES 400 MR jako zástupce čistě klinických přístrojů pro laboratorní prostředí, sloužící k záznamu EEG s co nejvyšší kvalitou. Pro potřeby diplomové práce byly použity oba dva přístroje. Klinický přístroj má sloužit k co nejlepší kvalitě signálů pro klasifikaci, vzhledem k měření v laboratorních podmínkách. Výsledky Emotiv EPOC mají ukázat, zda je tento dostupný přístroj schopen poskytnout přijatelné výsledky při měření v terénu.

5.1 Přístroj Emotiv EPOC+

Emotiv EPOC+ je EEG přístroj primárně určený pro výzkum zprostředkování BCI, výzkum trhu a neuroterapii. Jedná se o bezdrátové přenosné EEG zařízení umožňující záznam signálu mozku ze čtrnácti skalpových elektrod vůči dvěma elektrodám referenčním. Elektrody jsou salinové, pro zvýšení vodivosti se aplikuje fyziologický roztok, nevyžadují tak kontaktní gel. Signály jsou bezdrátově přenášeny do počítače přes bezdrátové rozhraní. K zobrazení, ukládání surových EEG dat v počítači, synchronizaci měření a ověřování vodivosti elektrod slouží programové prostředí TestBench™ dostupné v rámci vývojářského klíče (Software Development Key Emotiv – SDK Emotiv). Data jsou ukládána ve formátu EDF (European Data Format) spolu s časovými značkami pro správnou synchronizaci signálu a prezentace stimulů. [72]

Výhodou přístroje Emotiv v měřicích aplikacích je jednoduchost instalace a přijatelný poměr ceny a výkonu co se týče kvality naměřených signálů a výdrž baterie, viz Tabulka 3. Další výhodou je snadná manipulace s přístrojem, která neobtěžuje měřené osoby tolik jako klasické klinické EEG – menší počet elektrod, viz Obrázek 16. Elektrody jsou salinové, pro zvýšení vodivosti se aplikuje fyziologický roztok. [72]




Obrázek 16: Umístění elektrod Emotivu (vyznačeno černě) s 256 svodovým EEG EGI GES400 MR(převzato z [73])

Tabulka 2: Základní parametry přístroje Emotiv EPOC+

Parametr	Přístroj Emotiv EPOC+
Počet kanálů	14
Počet referenčních kanálů	2 (P3/P4)
Názvy kanálů (systém 10-20)	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4
Vzorkovací frekvence	128 Hz
Rozlišení	0,51 μ V
Konektivita	proprietární bezdrátová komunikace, 2,4 GHz, Bluetooth
Šířka pásma	0,2 – 45 Hz

Sestava pro měření s Emotivem EPOC se skládá ze samostatného přístroje EEG přístroje, počítače s obrazovkou s prezentačním softwarem MSP, záznamovým softwarem Emotiv Testbench, a synchronizační jednotkou pro synchronizování EEG záznamu s prezentací pro výsledné zpracování signálů. Přenos z čelenky Emotiv je bezdrátový, synchronizace probíhá přes převodník sériového portu na USB (fyzicky připojeno přes sběrnici USB). Synchronizace probíhá tak, že prezentační software na začátku každého stimulu pošle dvakrát rychle po sobě decimální čísla z ASCII odpovídající znaku čísla daného stimulu na vybraný sériový port propojený s MSP. Poté jsou další impulsy ve shodné podobě zasílány každou vteřinu. Při přechodu na následující stimul se opět odešlou dvě inkrementované čísla z ASCII krátce po sobě, atd. sériový port přenáší synchronizační ASCII znaky USB kabelem s převodníkem na sériový port na další sériový port. Tento port je spojen se softwarem pro záznam EEG z Emotivu (přes Nastavení programu) a přijímá je a tvoří značky v synchronizačním kanálu. Tento způsob synchronizace lehce komplikuje následnou detekci synchronizačních impulsů, protože ty nejsou zcela unikátní. Například: Znak 1 je kódován číslem 49, znaky 1 0 odpovídající desátému stimulu v pořadí se odešlou jako 49 48, do synchronizačního signálu se zapisuje každý znak. U přístroje Emotiv je synchronizační signál, viz Obrázek 17, zapsán spolu s EEG záznamy do souboru ve formátu EDF. [19], [74]



Obrázek 17: synchronizační signál pro Emotiv

5.2 Příklad EGI GES400MR

EGI GES400MR je moderní klinický EEG přístroj s čepicí osazenou 256 Ag/AgCl elektrodami vlhčenými salinovým roztokem. Tento přístroj používá zesilovač Net Amps 400 s vlastním procesorem podporující jeho výpočetní výkon a spektrum výpočetních operací. Signál je veden po optickými kabely, což zvyšuje izolaci od rušení způsobeného externími vlivy. Jedná se o EEG určené pro výzkum s hustým elektrodovým polem. Podle typu měřicí čepice může zaznamenávat signál z 32, 64, 128 či 256 elektrod. Přístroj je uzpůsoben pro měření v silném magnetickém poli (MRI). [73]

Původně plánované měření pomocí přístroje Emotiv bylo díky možnostem spolupráce s profesionální laboratoří doplněno přístrojem EGI GES 400 MR Series, viz Obrázek 18



Obrázek 18: Kompletní obsah balíčku přístroje EGI GES 400 MR Series (měřicí čepice, přístroj se zesilovači, další HW příslušenství (převzato z [73])

Přístroj EEG je skrz zesilovač propojen s počítačem Mac Pro, zde je pomocí softwaru NetStation zaznamenávaný signál ukládán do paměti počítače. Software dále umožňuje sledovat impedanci elektrod, volit zesílení signálů a zaznamenávat časové značky při synchronizaci stimulace a měření. Samotná stimulace probíhá pomocí dalšího počítače se stimulačním softwarem E-Prime, stimuly byly zobrazovány projektorem na plátno. Software posílá živě skrz sériový port časové synchronizační značky do zesilovače EEG. Zpoždění vlivem hardwaru (51 ms) je programově kompenzované, aby bylo možné záznamy všech signálů lícovat podle přené doby stimulace. Výstup měření tvoří signály a *.xml soubor s časovými značkami. Signály jsou změřeny za použití vzorkovací frekvence 1000 Hz.

5.3 Podněty pro měření s EGI GES 400 MR a Emotiv EPOC

Na základě konzultace s vedoucím práce a neurofyziologem Mgr. Petrem Telenským, Ph. D. byly jako podněty vybrány zhruba třicetisekundové reklamní spoty, tak aby simulovaly reklamní blok v hlavním vysílacím čase komerčního televizního kanálu, viz Tabulka 3, Tabulka 4.

Tabulka 3: Vybrané reklamní spoty a délek jejich trvání pro EGI GES 400MR, pořadí odpovídající měření

Reklamní spot	Délka trvání
Fidorka - Koupání	30 s
Jägermeister – Volání divočiny	25 s
Kaufland – Z lásky k Česku	30 s
Airwaves – Máš na to	30 s
Radegast – Záchranáři	30 s
Alza – Oddělitelné zařízení	29 s
GE Money - Konsolidace	30 s
Kofola - Nádraží	60 s
Kooperativa – Můžeš, můžeš	20 s
Komerční banka – Čas na nové hračky	31 s
Tullamore Dew – Legendárně jemná	30 s
Celková doba stimulačního bloku	345 s

Tabulka 4: Vybrané reklamní spoty a délek jejich trvání pro Emotiv EPOC, pořadí odpovídající měření

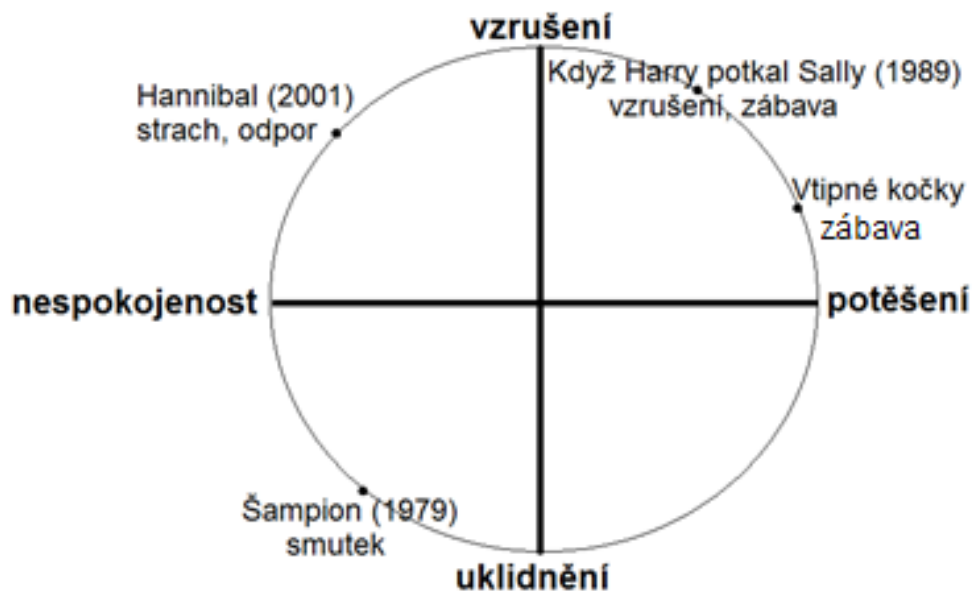
Reklamní spot	Délka trvání
Plzeň	30 s
Whiskas	30 s
ČEZ - Svíčky	30s
Skitles	20 s
Jägermeister	25 s
O2	30 s
Palette	20 s
Prostenal	30 s
Radegast	30 s
ČEZ - Sportovec	30 s
GE Money Bank	30 s
Mart'ánci	30 s
Celková doba stimulačního bloku	335 s

5.4 Kontrolní data

Kontrolní data byla vybrána na základě studií používajících videostimulaci. Gross a Levenson (1995) vyhodnocovali vybrané úseky z 250 filmů na 494 anglicky hovořících subjektech. Výsledkem jejich výzkumu byly úseky z 16 filmů, které úspěšně vyvolávaly emoce jako strach, znechucení, zábava, atd. Na základě této studie byly vybrány kalibrační stimuly vyvolávající vzrušení, smutek a spokojenost, odpovídající umístění v prvním, třetím a čtvrtém kvadrantu prostoru valence/arousal, viz Tabulka 5. Ondrášková (2013) použila scény filmů dle databáze MAHNOB-HCI, obsahující podněty pro rozpoznávání emocí. Jako kontrolní data byla vybrána scéna ze snímku Hannibal (2001), která dle databáze MAHNOB-HCI vyvolává pocit strachu, odporu, viz Tabulka 5. Vybrané kalibrační podněty většinu kvadrantů prostoru valence/arousal, viz Obrázek 19. [26], [25]

Tabulka 5: Kalibrační podněty pro EGI GES400 MR, zeleně – kalibrační podněty shodné i pro Emotiv EPOC

Název snímku	Délka scény	Emoce pro kalibraci; kvadrant V/A
Když Harry potkal Sally (1989)	106 s	Vzrušení, zábava; I.
Šampion (1979)	74 s	Smutek; III.
Hannibal (2001)	78 s	Strach, odpor; II.
Vtipné kočky	67s	Zábava; I
Celková doba kalibračního bloku	325s	



Obrázek 19: Kalibrační podněty a jejich umístění v Russellově 2D prostoru (převzato z [1], [25], [26])


5.5 Vyhodnocení výsledků

Cílem vyhodnocení je klasifikace podčástí EEG záznamů do čtyř, resp. dvou kategorií. K dispozici jsou záznamy z přístrojů EGI GES 400 MR a Emotiv EPOC+. Tyto záznamy se značně liší v přístrojové technologii záznamu. Bohužel se skladba stimulačních videí liší v rámci měření pro oba přístroje. Odlišnost je způsobena předem nepředpokládanou syntézou obou měření pro vzájemné porovnání použitelnosti pro záznam emocí. Kontrolní data se prolínají ve videích pro oblast vzrušení, zábava a deprese, viz Obrázek 19.

6 Realizace klasifikace signálů EEG

Celkový objem dat naměřených oběma přístroji je poměrně značný. Jedná se několikaminutové multikanálové záznamy. Přístrojem EGI bylo změřeno 15 dobrovolníků z řad studentů 3. ročníku bakalářského ročníku ve věku 22 let. Pro měření s přístrojem Emotiv se dostavilo 23 dobrovolníků.

Při vyhodnocování takového objemu dat je vhodnější, k dosažení globálnějšího pohledu, postupovat způsobem odpovídajícím zpracování velkého množství dat. Cílem není odhalit lokální změny signálu v podobě evokovaných potenciálů (ERP) při změnách vizuálních stimulů, ale odhalit podobnost reakce na stimulační impulsy daného charakteru. K tomuto účelu slouží kalibrační videa. Za předpokladu nalezení jednotných změn signálu EEG v kalibrační části experimentu, je hlavním cílem následně klasifikovat ostatní stimulační videa do čtyř, respektive dvou kategorií, dle zvoleného druhu klasifikace a použitého přístrojového vybavení. Při předzpracování dat takového rozsahu je hlavní motivací co nejvíce automatizovat odstranění rušení a artefaktů, které mají pro všechny záznamy podobný charakter. Jedná se zejména o: síťové rušení, drift vlivem změn vodivosti elektrod, artefakty spojené se svalovou aktivitou (mrkání, pohyb hlavou, pohyb čelistí), úplné výpadky elektrod. Většina těchto problematických jevů přímo zasahuje do frekvenčního pásma EEG, které nás zajímá. Přesto vzhledem k objemu dat budou použity pouze obecné postupy jak příslušné rušení a artefakty odstranit.



Obrázek 20: Postup při předzpracování EEG z přístroje EGI pro následnou klasifikaci

6.1 Odstranění síťového rušení a driftu

Drift je v rámci záznamu EEG způsoben nestacionárními změnami vodivosti na rozhraní elektroda – kůže, což způsobuje kolísání nulové izoliny signálu. Má nízkofrekvenční charakter. Nejjednodušší variantou odstranění driftu je filtrace. Jelikož středem zájmu této práce jsou pásma alfa a beta (frekvence vyšší než 3 Hz) je pro odstranění driftu použit jednoduchý FIR (Finite Impulse Response) filtr typu horní propust s mezní frekvencí 0,5 Hz, útlumem 40 dB v nepropustné oblasti a povoleným zvlněním 0,3 dB v propustné oblasti. Filtr typu FIR byl zvolen z důvodu lineární fázové charakteristiky. [40]


Síťové rušení není problémem u záznamů z EGI. Měření s tímto přístrojem bylo provedeno v kvalitně odstíněné místnosti s oddělovacími transformátory a optickým vedením

signálů. U přístroje Emotiv EPOC je rušení komplikací při záznamech, které běžně probíhají v místnostech neuzpůsobených pro snímání EEG. Jedinou možnou prevencí je nalezení takové polohy měřeného subjektu s čelenkou, kde je rušení nejmenší.

6.2 Detekce použitelných elektrod

Pro větší pravděpodobnost úspěšné Independent Component Analysis, je nutné, aby na vstupu ICA byly co nejkvalitnější signály. Při záznamu EEG se může stát, že signál z některých elektrod je silně zarušen vlivem špatného kontaktu na kůži či poruše samotné elektrody. Takové kanály je třeba nalézt a vyřadit z následné analýzy. V rámci této diplomové práce je použit následující postup: je vypočítána statistika pro každý kanál samostatně. Kanály, jejichž statistické rozdělení je významně odlišné od ostatních kanálů jsou vyřazeny. Jako metrika je použit koeficient špičatosti, počítaný z centrálního momentu čtvrtého stupně, viz (6.1). Jako práh je použit pětinašobek směrodatné odchylky průměru špičatosti přes všechny elektrody. [45]

$$\gamma^2 = \frac{m_4}{m_2^2} - 3, m_k = \frac{\sum_{i=1}^n (x_i - \bar{x})^k}{n} \quad (6.1)$$



Obrázek 21: Rozložení elektrod se záznamem EOG (převzato z [73])

6.3 Automatická detekce a odstranění zarušených komponent ICA, interpolace chybějících kanálů a finalizace předzpracování

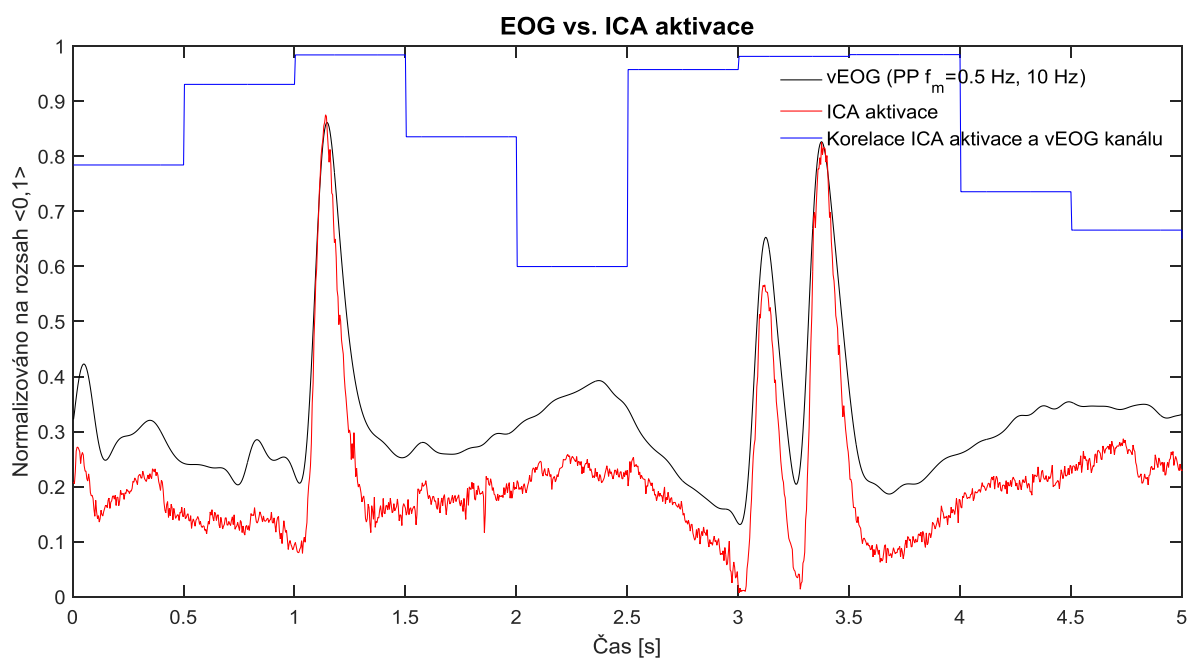
ICA je efektivní nástroj pro odstraňování rušení. Takovému charakteru odpovídají zejména vertikální a horizontální pohyby očí a mrkání. V rámci záznamu z přístroje EGI máme k dispozici záznamy z elektrod, které těmto pohybům očí odpovídají. Tudíž mohou sloužit jako reference vůči aktivacím ICA (projevy jednotlivých nezávislých zdrojů).

Jako metoda pro hodnocení podobnosti mezi aktivací nezávislých zdrojů a EOG je použita korelace v překrývajících se oknech (50 %) o různých délkách pro mrkání (1 s) a pohyby očí (4 s). Pro srovnávání je použito EOG ze 4 kanálů, viz Obrázek 21 a Obrázek 23, aby byla metoda senzitivní na různou polaritu signálu. Porovnávají se všechny aktivace vůči všem čtyřem EOG kanálům. EOG kanály jsou pro zvýraznění horizontálního EOG (hEOG), vertikálního EOG (vEOG) a mrkání (součást vEOG) filtrovány pásmovou propustí o mezních frekvencích 0,5 Hz a 10 Hz. Pásmová propust je aplikována proto, aby se zvýraznily hlavně trendy v EOG signálech a nedocházelo k náhodným korelacím mezi vysokofrekvenčními složkami EOG a aktivace. Vzhledem k tomu, že signál mrkání a pohybů očí má velký výkon a není tolik zarušen vysokofrekvenčními složkami, korelace mezi filtrovaným EOG a aktivací je v příslušných úsecích vysoká.


Práh pro určování míry „zarušenosti“ aktivace je stanoven na základě počtu úseků mezi EOG a aktivací s korelací vyšší než ± 0.8 . Empiricky bylo stanoveno, že pokud aktivace obsahuje více než 5 % podíl oken, kdy je korelace vyšší než ± 0.8 považuje se aktivace a tím i daná komponenta (sloupec ve W^{-1}) jako zdroj rušení. Odstraní se tedy vynulováním příslušného sloupce ve W^{-1} . Při zpětné projekci do prostoru původního signálu se zdroj rušení neprojeví, viz Obrázek 24 a Obrázek 25, na kterých je vidět výsledný EEG signál získaný zpětnou projekcí do originálního prostoru, kdy jsou patřičné sloupce W^{-1} vynulovány. [41]

Z Obrázek 22 a Obrázek 23 lze na filtrovaném EOG vidět, že projevy mrkání a pohybů očí zasahují do frekvenčního pásma odpovídající mozkové aktivitě alfa. Jejich odstranění je tudíž pro další analýzu a klasifikaci nutností.

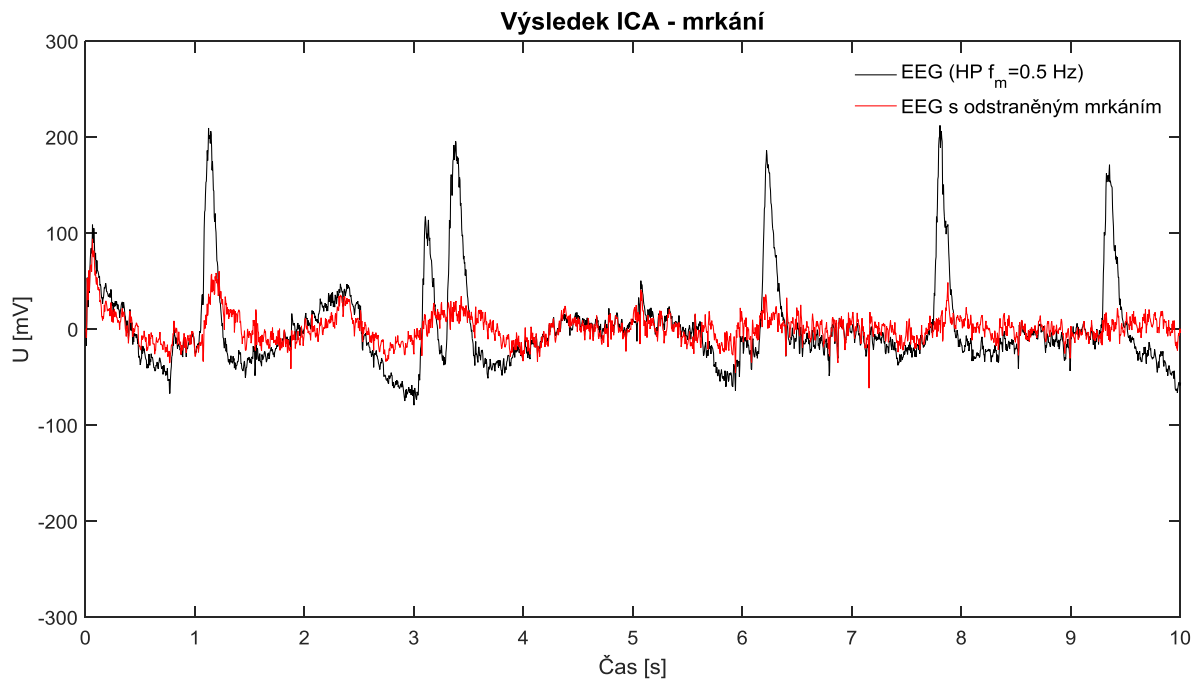
Po úspěšné zpětné projekci do prostoru signálu jsou interpolovány chybějící kanály, vyňaté pře ICA pro jejich velkou zarušenost, viz 4.1. Následuje filtrace dolní propustí typu FIR s mezní frekvencí 40 Hz. Tím se odstraní případné zbylé vysokofrekvenční rušení a omezí se frekvenční rozsah signálu do oblasti pásma alfa a beta mozkové aktivity. [45]




Obrázek 22: Zhodnocení korelace mezi vEOG a ICA aktivací pro detekci mrkání v okně o délce 1s s 50 % překryvem



Obrázek 23: Zhodnocení korelace mezi hEOG a ICA aktivací pro detekci mrkání v okně o délce 4 s s 50 % překryvem




Obrázek 24: Výsledek ICA, odstraněna komponenta odpovídající mrkání



Obrázek 25: Výsledek ICA, odstraněna komponenta odpovídající pohybům očí

6.4 Předzpracování dat Emotiv

Předzpracování u záznamů s přístroje Emotiv je značně problematické. Vzhledem k nízkému počtu elektrod se artefakty, i když s různou vahou, projevují do všech elektrod záznamu. Nízký počet elektrod, je zároveň důvodem pro nemožnost použití ICA. Optickou kontrolou záznamů z Emotivu bylo zjištěno, že signály jsou natolik zarušené, že účinnost jakékoliv pokročilé metody zpracování by byla diskutabilní, viz Obrázek 26. Proto byla pro předzpracování zvolena filtrace FIR filtry typu HP a DP s lineární impulsní charakteristikou a mezními frekvencemi 0.5 (HP) a 40 Hz (DP).



Obrázek 26: Ukázka zarušeného záznamu přístroje Emotiv

6.5 Výběr elektrod

Výběr vhodných elektrod, z jejichž signálů se extrahují popisné elementy, je důležitým krokem v rámci zlepšení úspěšnosti klasifikace. S ohledem na předchozí teoretickou část byly vybrány konfigurace elektrod umístěné na frontální a prefrontální části hlavy měřeného subjektu, elektrody byly voleny v různém počtu od 2 do 32 vždy symetricky v rámci levé a pravé strany. Dále byly zvoleny elektrody kopírující elektrodový systém přístroje Emotiv z nichž byly vybrány elektrody v počtu 2, 4, 8 a 14, tak aby se shodovali s umístěním elektrod přístroje EGI, viz Obrázek 16. Tento výběr byl dále použit pro porovnání výsledků klasifikace ze signálů přístroje Emotiv a EGI.

6.6 Výběr popisných elementů

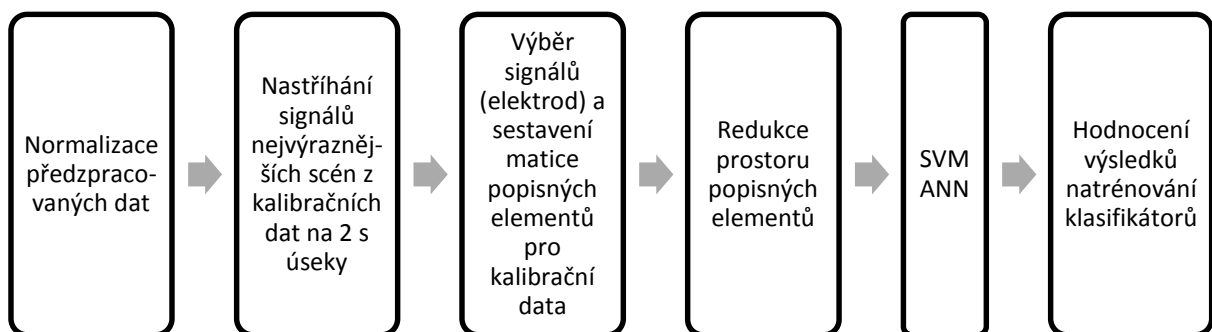
Prvním krokem pro výběr popisných elementů je správné nastříhání signálů na úseky odpovídající jednotlivým stimulačním impulsům. Následně jsou z každého úseku z vybraných elektrod extrahovány popisné elementy. Počet a pozice vybraných elektrod se liší v závislosti na EEG přístroji, obecně platí, že středem zájmu jsou frontální elektrody, ale je vybráno několik

schémat elektrod pro vzájemné srovnání EGI a Emotivu a další schémata samostatné pro EGI s zaměřením na frontální části mozku a prefrontální komplex jak bylo popsáno v teoretické části. Úseky jsou rozděleny do trénovací a testovací množiny z kalibračních dat popsaných v předcházejících kapitolách. Důležitým krokem před samotnou extrakcí je normalizace dat, aby se co nejvíce potlačila intraindividuální variabilita. Data jsou normalizována na rozsah mediánu horní obálky všech signálů a mediánu dolní obálky všech signálů pro každou jednotlivou osobu, viz (6.2), kde s je normalizovaný signál, x je signál pro normalizaci a O_{low} , O_{max} jsou spodní a horní obálky všech EEG signálů jedné osoby. Použitím mediánu je také potlačen vliv artefaktů impulsního charakteru, které se nepodařilo odstranit ve fázi předzpracování.

$$s = \frac{x - \text{median}(O_{low})}{\text{median}(O_{up}) - \text{median}(O_{low})} \quad (6.2)$$

Z normalizovaných dat byly následně extrahovány popisné elementy. Jako popisné elementy byly vybrány detailní koeficienty DWT získané multidimenzionální 1D dekompozicí pomocí funkce *mdwtdec*, za použití vlnek *db4* a *bior1.3* na úrovních odpovídajících pásmům alfa a beta. Co se týče popisných elementů extrahovaných z EMD je v této práci použito řešení, že pro další zpracování jsou vybrány ty IMF, jejichž průměrná okamžitá frekvence vypočtená pomocí DESA-1 spadá do pásma alfa nebo beta EEG. IMF odpovídající aktivitě alfa jsou sečteny do jednoho signálu a tentýž postup platí i pro IMF s aktivitou beta. Z takto vzniklých signálů jsou extrahovány popisné elementy, jako je směrodatná odchylka, šikmost a strmost.

Všechny popisné elementy pro trénovací a testovací množinu jsou vybírány z dvousekundových úseků. Aby se navýšil počet pozorování, je z každého kalibračního videa vybrán 20 s úsek s nejvýraznější scénou a ten je poté rozdělen na deset dvousekundových úseků. Každý dvousekundový úsek je poté považován za jedno pozorování.



Obrázek 27: Postup při extrakci popisných elementů tréninkového setu

6.6.1 Redukce prostoru popisných elementů pomocí PCA

Konečný prostor popisných elementů je matice, kdy řádky odpovídají jednotlivým subjektům a sloupce jednotlivým popisným elementům. Vzhledem k tomu, že matice má nesrovnatelně větší rozměr ve směru popisných elementů je pro redukci použita metoda PCA. Do klasifikace poté vstupuje jen prvních n komponent, které se podílejí na 90 % variability v datech. Takto zredukovaný prostor následně jde na vstup klasifikačních algoritmů. Při použití se ukázalo, že redukce pomocí PCA nemá vliv na úspěšnost klasifikace. PCA proto posloužilo jako prostředek pro snížení výpočetní a paměťové náročnosti klasifikace.

6.7 Učení klasifikátorů a krosvalidace

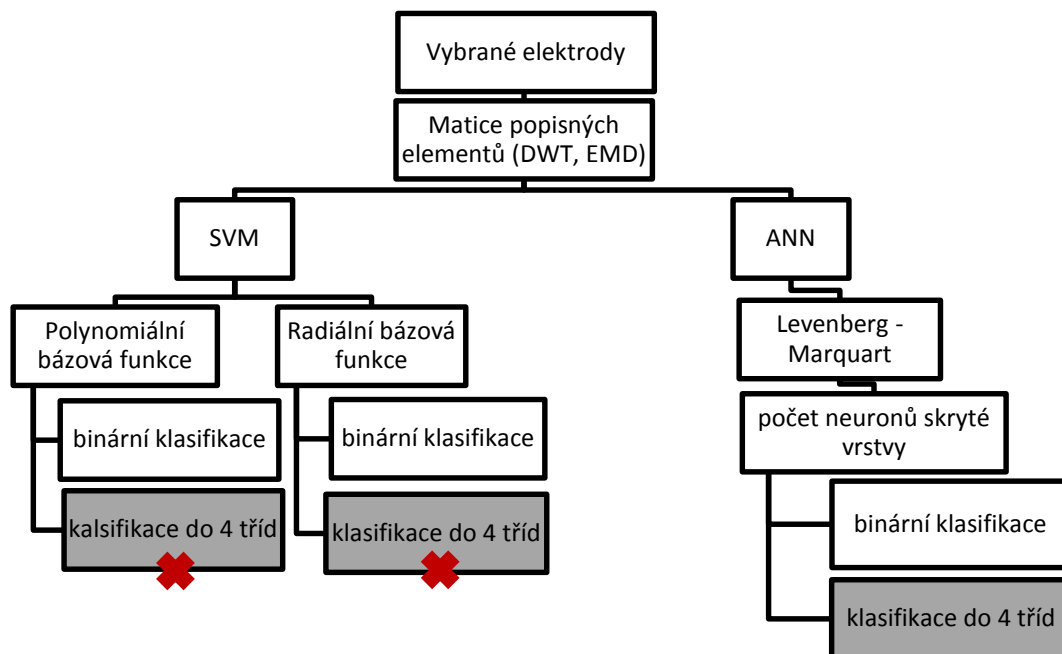
Pro klasifikaci byly použity dvě metody a to klasifikace pomocí SVM a ANN. Učení probíhalo na matici popisných elementů extrahovaných z kalibračních dat. Bylo natrénováno několik klasifikátorů obou typů (SVM, ANN) s různými parametry, které byly optimalizovány, pro co nejlepší výsledky klasifikace:

- **Dimenze tréninkového setu:** velikost tréninkového setu neovlivňuje počet pozorování (subjektů), které zůstává konstantní, ale počet popisných elementů. Popisné elementy jednoho pozorování vstupují do klasifikace jako vektor. Délka vektoru je ovlivněna jak množstvím vybraných popisných elementů z daného úseku signálu, ale také počtem signálů (elektrod), ze kterých jsou popisné elementy extrahovány. Klasifikátory jsou natrénovány na několika kombinacích elektrod, dle znalostí získaných při zpracování teoretické části.
- **Počet tříd:** 2 třídy (vzrušení, smutek) pro Emotiv a EGI, 4 třídy (vzrušení, smutek, zábava strach) pro EGI
- **Parametry SVM:** typ bázové funkce (radiální, polynomiální) a jejich parametry, model ECOC pro klasifikaci do více tříd
- **Parametry ANN:** Počet neuronů ve skryté vrstvě, typ sítě, přechodová funkce

Aby nedošlo k přetrénování klasifikátorů, bylo SVM krosvalidováno metodou k-fold. Následně se byl zvolen prostor parametrů každé bázové funkce, který byl prohledáván metodou gridsearch, tak aby se minimalizovalo procento neúspěšně klasifikovaných emocí u krosvalidovaného klasifikátoru. Nejúspěšnější parametry byly uloženy pro natrénování konečné verze daného klasifikátoru. Výše popsany postup byl aplikován u binární klasifikace pomocí SVM. U klasifikace do čtyř tříd bylo vyzkoušeno několik modelů kombinace binárních klasifikátorů SVM (funkce *fitococ*). U ANN byl tréninkový set náhodně rozdělen na tréninkový, validační a testovací podmnožinu v poměru 70%, 15%, 15%. Pro návrh ANN byl použit příkaz *nnstart*. ANN byla optimalizována z hlediska počtu neuronů ve skryté vrstvě s přechodovou funkcí *logsig*.

7 Výsledky

Jako výsledky jsou generovány metriky hodnocení úspěšnosti klasifikace krosvalidovaných klasifikátorů natrénovaných na tréninkových datech. Přehled natrénovaných klasifikátorů viz Obrázek 28.



Obrázek 28: Hierarchie klasifikace, šedě vyznačené pole se netýkají klasifikace pro přístroj Emotiv, červené křížky značí klasifikaci od které bylo upuštěno na základě výsledků binárního klasifikátoru

Pro binární klasifikátor typu SVM jsou vypsány nejlepší výsledky klasifikátorů s polynomiální a radiální bázovou funkcí v závislosti typu popisných elementů, počtu elektrod, z nichž se elementy extrahují. Jako metrika hodnocení klasifikace je použita sensitivita, specifická a správnost, kdy emoce vzrušení je přiřazena jako pozitivní třída a moce smutek jako negativní třída. U binární ANN jsou testovány sítě s různým počtem neuronů ve skryté vrstvě s přechodovou funkcí typu *logsig*. Jako metrika opět slouží sensitivita, specifická a správnost klasifikátoru.

Pro klasifikaci do 4 tříd by u SVM byly otestovány modely ECOC (one vs. all, one vs. one) skladby více binárních klasifikátorů, aby klasifikovali do více tříd. Jako metrika úspěšnosti klasifikace slouží preciznost, úplnost a průměrná přesnost. Jejich výsledky nejsou zveřejněny, jejich průměrná správnost se pohybovala v rozmezí 25 – 30 %. U ANN byl optimalizován počet neuronů ve skryté vrstvě. Jako prostředek pro hodnocení kvality klasifikace jsou zobrazeny konfúzní matice nejlepší klasifikátorů.

7.1 Binární klasifikace EGI a Emotiv dle elektrodové konfigurace Emotiv

Tabulka 6: Úspěšnosti SVM binární klasifikace pro emoce vzrušení a smutek pro přístroj EGI (Se – senzitivita, Sp – specifická, Spr - správnost), z bázových funkcí je vždy vybrána ta nejúspěšnější

SVM Binární klasifikace : vzrušení - smutek									
Přístroj	Popisné elementy	Redukce prostoru popisných elementů	Počet elektrod	Bázová funkce	Se [%]	Sp [%]	Spr [%]		
EGI	DWT ("db4")	PCA	2	radiální	62.1	52.9	57.5		
				polynomiální	63.6	52.9	58.2		
			4	radiální	52.9	57.1	55.0		
				polynomiální	53.6	55.0	54.3		
			8	radiální	41.4	74.3	57.9		
				polynomiální	42.9	70.7	56.8		
			14	radiální	50.0	70.0	60.0		
				polynomiální	58.6	57.1	57.9		
			DWT ("bior1.3")	PCA	2	radiální	62.1	65.7	63.9
						polynomiální	60.7	66.4	63.6
	4	radiální			57.1	65.7	61.4		
		polynomiální			55.7	66.4	61.1		
	8	radiální			57.1	65.7	61.4		
		polynomiální			63.6	62.1	62.9		
	14	radiální			60.0	59.3	59.6		
		polynomiální			58.6	63.6	61.1		
	EMD	PCA			2	radiální	34.3	80.0	57.1
						polynomiální	100.0	0.7	50.4
			4	radiální	55.7	60.0	56.1		
				polynomiální	57.1	60.0	58.6		
			8	radiální	62.1	50.0	56.1		
polynomiální				62.1	50.7	56.4			
14			radiální	69.3	41.4	55.4			
			polynomiální	55.0	56.4	55.7			

Tabulka 7: Úspěšnosti SVM binární klasifikace pro emoce vzrušení a smutek pro přístroj EGI (Se – senzitivita, Sp – specificita, Spr - správnost), z bázových funkcí je vždy vybrána ta nejlépeší

Emotiv	DWT ("db4")	PCA	2	radiální	4.0	99.7	51.8
				polynomiální	23.1	83.1	53.1
			4	radiální	28.7	78.7	53.7
				polynomiální	35.5	77.6	56.6
			8	radiální	53.3	56.3	54.8
				polynomiální	39.3	75.5	57.4
	14	radiální	53.7	58.7	56.2		
		polynomiální	53.7	53.7	53.7		
	DWT ("bior1.3")	PCA	2	radiální	43.7	64.3	54.0
				polynomiální	54.0	58.7	56.3
			4	radiální	80.3	29.7	55.0
				polynomiální	80.3	25.7	53.0
			8	radiální	50.3	62.3	56.3
				polynomiální	41.3	69.7	55.5
	14	radiální	54.3	58.3	56.3		
		polynomiální	51.0	60.7	55.8		
	EMD	PCA	2	radiální	61.7	46.6	54.1
				polynomiální	23.1	83.1	53.1
4			radiální	40.3	68.6	54.5	
			polynomiální	35.5	77.6	56.6	
8			radiální	40.3	74.1	57.2	
			polynomiální	39.3	75.5	57.4	
14	radiální	65.2	51.4	58.3			
	polynomiální	59.3	54.8	57.1			

Tabulka 8: Porovnání úspěšnosti ANN binární klasifikace pro emoce vzrušení a smutek mezi přístroji Emotiv a EGI (Se – senzitivita, Sp – specificita, Spr – správnost)


ANN Binární klasifikace : vzrušení - smutek							
Přístroj	Popisné elementy	Redukce prostoru popisných elementů	Počet elektrod	Počet neuronů skryté vrstvy	Se [%]	Sp [%]	Spr [%]
EGI	DWT ("db4")	PCA	2	30	76.4	71.4	73.9
			4	30	83.6	78.6	81.1
			8	30	82.1	65.7	73.9
			14	20	77.1	74.3	75.7
	DWT ("bior1.3")	PCA	2	5	53.6	89.3	71.4
			4	30	72.1	75.0	73.6
			8	30	68.6	89.3	78.9
			14	20	85.0	73.6	79.3
	EMD	PCA	2	30	56.4	50.	53.2
			4	30	64.3	62.9	63.6
			8	20	56.4	72.1	64.3
			14	20	75.0	84.3	79.6
Emotiv	DWT ("db4")	PCA	2	5	40.0	69.3	54.7
			4	20	40.3	83.0	61.7
			8	30	45.0	81.0	63.0
			14	20	45.3	79.3	62.3
	DWT ("bior1.3")	PCA	2	10	22.0	89.3	55.7
			4	10	58.0	69.0	63.5
			8	10	76.0	54.0	65.0
			14	5	67.3	68.0	67.7
	EMD	PCA	2	10	70.7	38.6	54.7
			4	30	51.4	66.9	59.1
			8	30	65.2	57.9	61.6
			14	20	69.0	59.7	64.3

Diskuze

V této kapitole byly srovnány dvě metody pro klasifikaci stimulačních videí (SVM, ANN) pro záznamy ze dvou EEG přístrojů. Na použitých kalibračních stimulech se za vybraných podmínek klasifikátor typu SVM ukázal jako neúčinný, když se správnost klasifikace pohybovala v rozsahu 50 – 60 %, jak pro záznamy z EGI, tak pro záznamy z Emotivu. Nejlepší správnosti dosáhl SVM pro záznamy EGI ze dvou frontálních elektrod (63,9 %). Přes tento výsledek to vypadá, že obecně je úspěšnější klasifikace za použití více elektrod. To potvrzují výsledky klasifikace za použití ANN, která dosahovala nejvyšších správnosti při použití signálu ze 14 elektrod. Přesto bylo maximální správnosti dosaženo při použití koeficientů DWT za použití vlnky Daubechies 4. řádu (81.1%) ze 4 elektrod. Srovnání přístrojů ukázalo nižší

úspěšnost za použití přístroje Emotiv (67,7 %, DWT, „bior1.3“), což je vzhledem ke kvalitě signálů očekávaný výsledek. Zajímavé je že rozložení elektrod přístroje Emotiv se ukázalo jako vhodné pro detekci a binární klasifikaci rozdílů v emoční odezvě, zde popsanych jako vzrušení a smutek. Jedinou překážkou pro klasifikaci je nižší kvalita záznamu, která je v případě Emotivu obtížně řešitelná. Použití popisných elementů extrahovaných z EMD se celkově ukázalo jako neúspěšné.

Ukázalo se, že je možné rozlišit emoční reakci na dvě videa rozličného charakteru, ale dá se předpokládat, že striktní ohodnocení na emoci vzrušení a smutek je pouze aproximativní a emoční prožitek bude mnohem komplexnějšího charakteru s rozdíly v emočním prožitku u každého jedince. Každý z kalibračních stimulů byl i v rámci hodnocení dotazníkem hodnocen z hlediska obsahu emocí, kdy dominantní emoce byla vybrána pro ohodnocení daného videa.



Obrázek 29: Elektrody vybrané pro srovnání Emotiv a EGI, postupně zvoleno 2, 4, 8 a 14 elektrod

7.2 Klasifikace do 4 tříd ze záznamů přístroje EGI dle elektrod Emotiv

Vzhledem ke špatné úspěšnosti klasifikátoru typu SVM ve srovnání s ANN, jsou pro další klasifikace použity pouze neuronové sítě, které prokázaly vysokou správnost při binární klasifikaci.

Konfúzní matice klasifikace do 4 tříd
ANN, 50 neuronů ve skryté vrstvě, DWT "db4" popisné elementy z 8 elektrod

Výstup klasifikátoru	zábava	83 14.8%	11 2.0%	21 3.8%	22 3.9%	60.6% 39.4%
	vzrušení	20 3.6%	106 18.9%	24 4.3%	11 2.0%	65.8% 34.2%
	smutek	15 2.7%	11 2.0%	77 13.8%	9 1.6%	68.8% 31.3%
	strach	22 3.9%	12 2.1%	18 3.2%	98 17.5%	65.3% 34.7%
		59.3% 40.7%	75.7% 24.3%	55.0% 45.0%	70.0% 30.0%	65.0% 35.0%
	zábava	vzrušení	smutek	strach		
	Cílová skupina					

Obrázek 30: Konfúzní matice nejlepšího klasifikátoru pro popisné elementy DWT „db4“

Konfúzní matice klasifikace do 4 tříd
ANN, 50 neuronů ve skryté vrstvě, DWT "bior1.3" popisné elementy z 8 elektrod

Výstup klasifikátoru	zábava	78 13.9%	25 4.5%	20 3.6%	25 4.5%	52.7% 47.3%
	vzrušení	13 2.3%	78 13.9%	9 1.6%	13 2.3%	69.0% 31.0%
	smutek	26 4.6%	17 3.0%	87 15.5%	19 3.4%	58.4% 41.6%
	strach	23 4.1%	20 3.6%	24 4.3%	83 14.8%	55.3% 44.7%
		55.7% 44.3%	55.7% 44.3%	62.1% 37.9%	59.3% 40.7%	58.2% 41.8%
	zábava	vzrušení	smutek	strach		
	Cílová skupina					

Obrázek 31: Konfúzní matice nejlepšího klasifikátoru pro popisné elementy DWT „bior1.3“

Konfúzní matice klasifikace do 4 tříd
ANN, 30 neuronů ve skryté vrstvě, EMD popisné elementy z 14 elektrod

Výstup klasifikátoru	zábava	63 11.3%	41 7.3%	31 5.5%	33 5.9%	37.5% 62.5%
	vzrušení	43 7.7%	71 12.7%	62 11.1%	36 6.4%	33.5% 66.5%
	smutek	19 3.4%	13 2.3%	31 5.5%	23 4.1%	36.0% 64.0%
	strach	15 2.7%	15 2.7%	16 2.9%	48 8.6%	51.1% 48.9%
		45.0% 55.0%	50.7% 49.3%	22.1% 77.9%	34.3% 65.7%	38.0% 62.0%
	zábava	vzrušení	smutek	strach		
	Cílová skupina					


Obrázek 32: Konfúzní matice nejlepšího klasifikátoru pro popisné elementy EMD

Diskuze

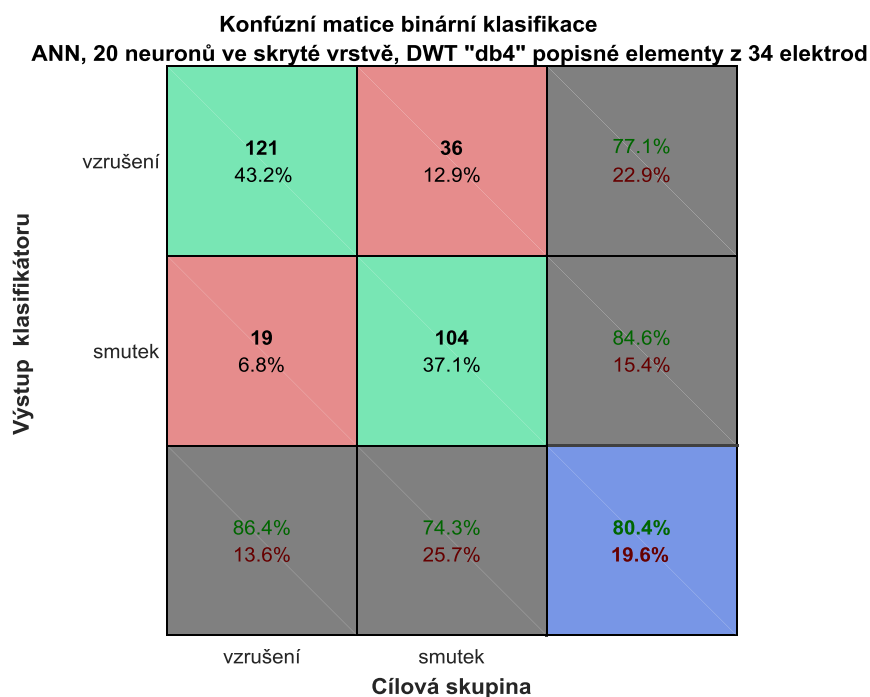
Úkolem této kapitoly bylo zhodnotit, zda je možné klasifikovat emoce do 4 tříd (vzrušení, smutek, zábava, strach) na základě elektrodového rozestavení dle přístroje Emotiv. Pro klasifikaci byly na základě předchozích výsledků vybrány pouze neuronové sítě a signály z přístroje EGL. Maximální průměrné správnosti dosáhla neuronová síť s padesáti neurony ve skryté vrstvě, na jejímž vstupu byly koeficienty DWT s bázovou vlnkou typu „db4“ ze signálů z 8 elektrod (65%). Koeficienty DWT s vlnkou „bior1.3“ a popisné elementy EMD se neukázaly jako vhodné pro klasifikaci emocí do čtyř tříd. U klasifikace do 4 tříd se projevuje obtížnost stanovení konkrétnější odezvy na audiovizuální stimuly. Reakce subjektů na kalibrační data se může lišit, s postupem času může klesat soustředěnost lidí na prezentované videostimuly. Zároveň odchylky ve vnímání jednotlivých videí nemusí být dostatečně rozpoznatelné použitou metodikou. Je zde i riziko, že relativně agresivní preprocessing mohl odstranit část informace o emoční odezvě. Důležitou poznámkou je, že celé měření neprobíhalo v kontrolovaných podmínkách, bez dohledu psychologa, který by vyhodnotil případné rizika rozptýlení zkoumaného subjektu okolními vjemy. Všechny tyto vlivy tvoří šumovou složku, která měla při binární klasifikaci menší vliv, ale mohla se projevit právě při klasifikaci do 4 tříd. Zároveň navýšení počtu pozorování za předpokladu, že daný subjekt pociťuje danou emoci v deseti po sobě jdoucích dvousekundových úsecích a každý úsek je jedno nezávislé pozorování, mohl vnést chybu. Na druhou stranu klasifikace úplně neselhalo, tudíž nabízí prostor pro lepší nastavení kontroly kvality měření a laboratorních podmínek či výběru kalibračních videí pro případné navazující zkoumání.

7.3 Klasifikace EGI ze všech elektrod a elektrod prefrontálního kortexu

V této části je použito pro klasifikaci pouze neuronových sítí, cílem této kapitoly je ověřit zda signály z prefrontálního a frontálního komplexu souvisejí s emoční odezvou, jak bylo zmíněno v teoretické části.



Obrázek 33: Konfúzní matice nejlepšího klasifikátoru pro 203 elektrod



Obrázek 34: Konfúzní matice nejlepšího klasifikátoru pro 34 elektrod frontálního a prefrontálního kortexu

Konfúzní matice klasifikace do 4 tříd
ANN, 60 neuronů ve skryté vrstvě, DWT "db4" popisné elementy z 34 elektrod


Výstup klasifikátoru	zábava	58 10.4%	17 3.0%	13 2.3%	20 3.6%	53.7% 46.3%
	vzrušení	17 3.0%	64 11.4%	8 1.4%	15 2.7%	61.5% 38.5%
	smutek	57 10.2%	54 9.6%	109 19.5%	60 10.7%	38.9% 61.1%
	strach	8 1.4%	5 0.9%	10 1.8%	45 8.0%	66.2% 33.8%
		41.4% 58.6%	45.7% 54.3%	77.9% 22.1%	32.1% 67.9%	49.3% 50.7%
	zábava	vzrušení	smutek	strach		
	Cílová skupina					

Obrázek 35: Konfúzní matice nejlepšího klasifikátoru do 4 tříd pro 34 elektrod frontálního a prefrontálního komplexu

Konfúzní matice klasifikace do 4 tříd
ANN, 40 neuronů ve skryté vrstvě, DWT "db4" popisné elementy z 203 elektrod

Výstup klasifikátoru	zábava	86 15.4%	29 5.2%	53 9.5%	22 3.9%	45.3% 54.7%
	vzrušení	27 4.8%	87 15.5%	21 3.8%	20 3.6%	56.1% 43.9%
	smutek	9 1.6%	5 0.9%	27 4.8%	5 0.9%	58.7% 41.3%
	strach	18 3.2%	19 3.4%	39 7.0%	93 16.6%	55.0% 45.0%
		61.4% 38.6%	62.1% 37.9%	19.3% 80.7%	66.4% 33.6%	52.3% 47.7%
	zábava	vzrušení	smutek	strach		
	Cílová skupina					

Obrázek 36: Konfúzní matice nejlepšího klasifikátoru do 4 tříd pro 203 elektrod redukovaného prostoru elektrod EGI




Obrázek 37: Elektrody vybrané pro klasifikaci, červeně – redukovaný systém 203 elektrod EGI, černě – 34 elektrod frontálního a prefrontálního kortexu

Diskuze

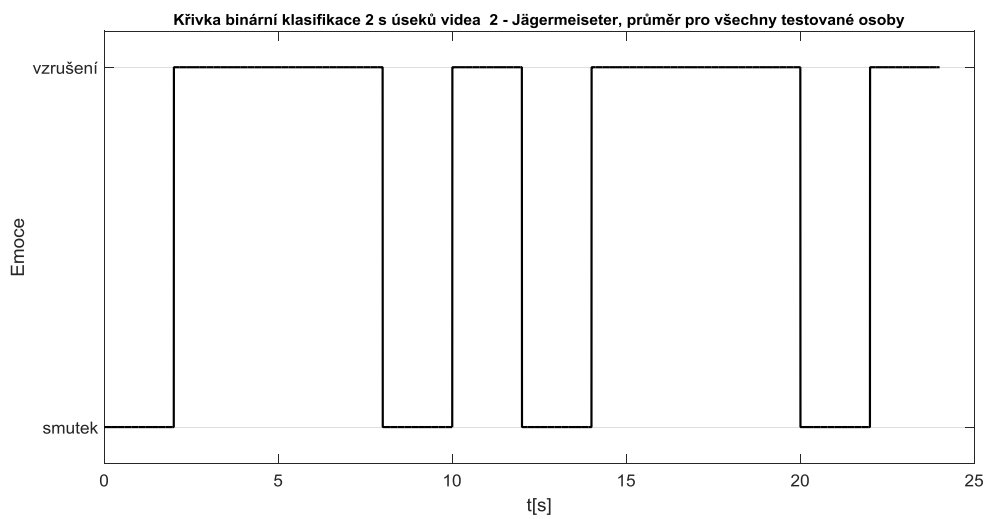
Snaho této části je ověřit, zda je klasifikace úspěšná za použití frontálních elektrod, jak je doporučováno v teoretické části. Pro srovnání je použit klasifikátor natrénovaný na všech 203 elektrodách redukovaného elektrodového prostoru EGI a klasifikátor natrénovaný na 34 elektrodách odpovídajících prefrontálnímu a frontálnímu kortexu, viz Obrázek 37. Pro binární klasifikaci se klasifikátor natrénovaný na 34 elektrodách ukázal jako lehce účinnější a dosáhl správnosti 80.4 % oproti 78.6 % u 34 elektrod. Malý rozdíl v úspěšnosti hovoří pro rozdělení emoční informace do většího objemu než je oblast prefrontálního kortexu. Další přidání elektrody nezanáší šum a klasifikátor je stále schopen binárního rozdělení do dvou tříd i s nadbytkem informace z 203 elektrod. Při klasifikaci do 4 tříd se žádná z konfigurací neukázala jako účinná pro klasifikaci do 4 tříd. Tento výsledek hovoří pro konfiguraci dle Emotivu jako nejúčinnější pro klasifikaci při daném nastavení podmínek.

7.4 Klasifikace testovacích dat


V této části jsou představeny výsledky klasifikace pro nejlepší klasifikátory pro popisné elementy extrahované ze signálů z přístroje EGI. Výsledky jsou prezentovány jak pro binární klasifikaci, tak pro klasifikaci do 4 tříd.



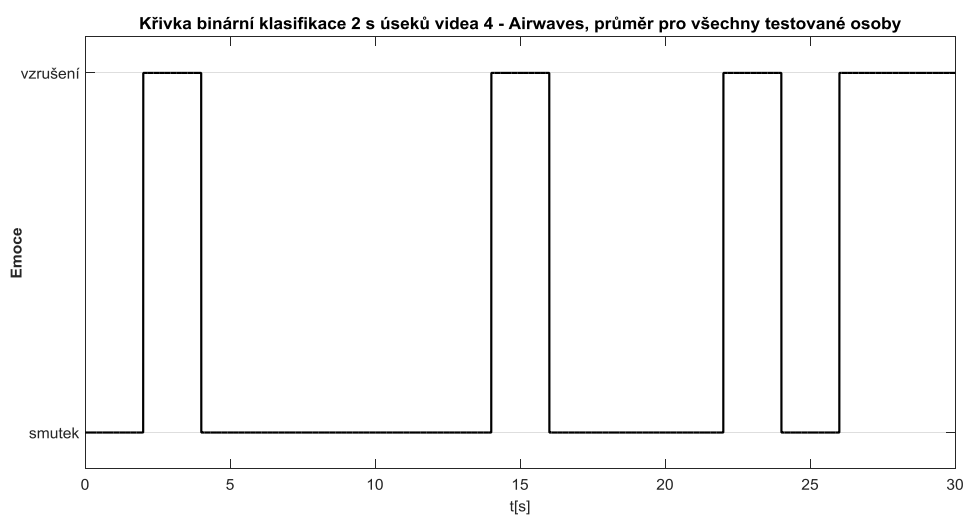
Obrázek 38: Výsledek binární klasifikace videa Fidorka



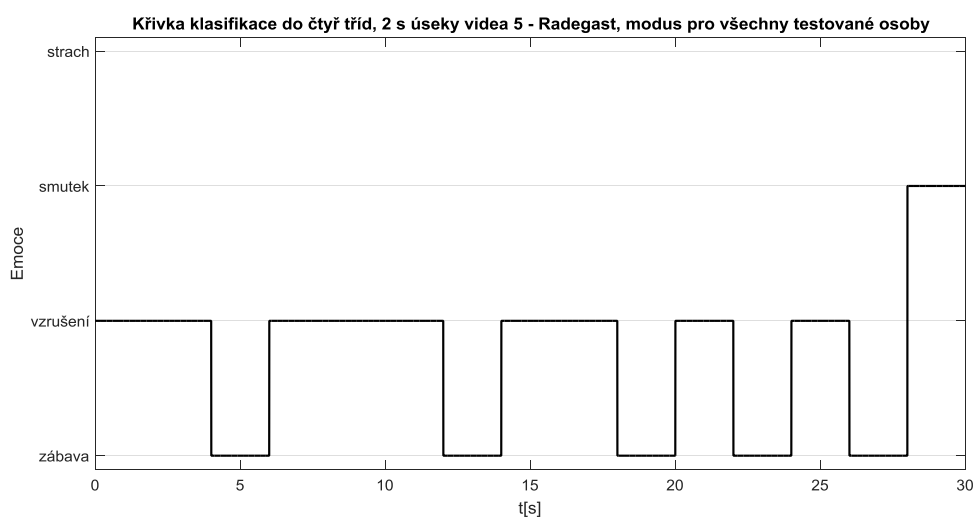
Obrázek 39: Výsledek binární klasifikace videa Jägermeister



Obrázek 40: Výsledek binární klasifikace videa Kaufland



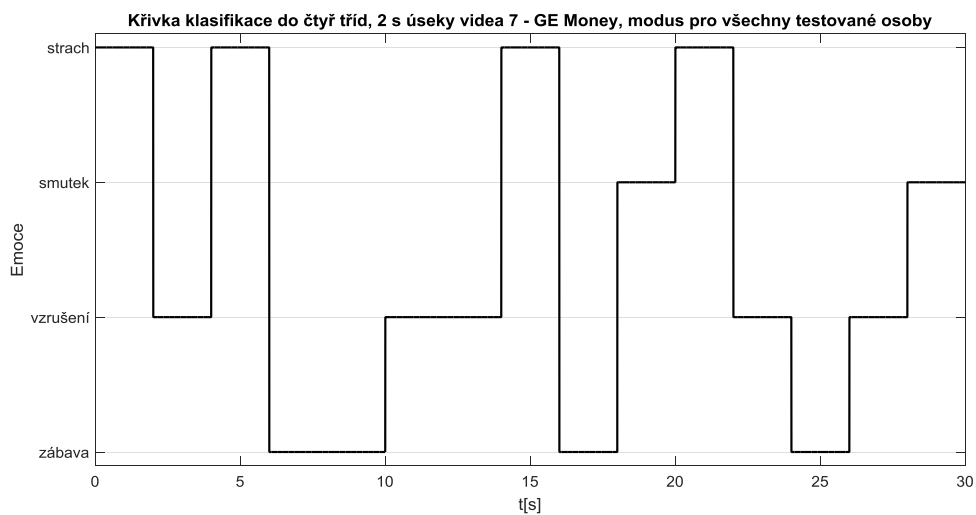
Obrázek 41: Výsledek binární klasifikace videa Airwaves



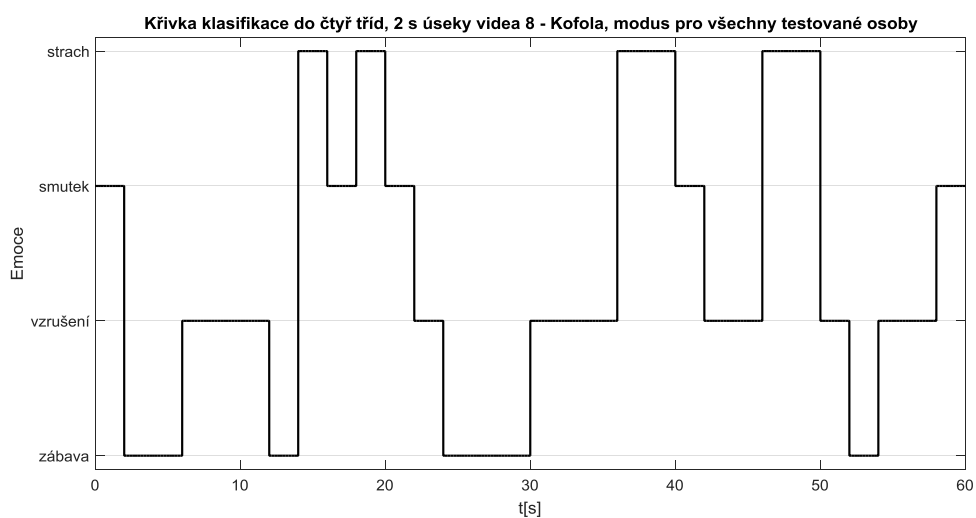
Obrázek 42: Výsledek klasifikace do 4 tříd videa Radegast



Obrázek 43: Výsledek klasifikace do 4 tříd videa Alza



Obrázek 44: Výsledek klasifikace do 4 tříd videa GE Money



Obrázek 45: Výsledek klasifikace do 4 tříd videa Kofola

Diskuze:

V této části byly prezentované vybrané výsledky klasifikace do 4 tříd, křivky mají schodovitý charakter, jelikož byly klasifikovány po oddělených dvousekundových úsecích jednotlivých videí. Výsledné křivky byly generovány jako modus výsledků klasifikace pro všechny osoby. Emoce, která se v daném úseku objevila nejčastěji, byla označena jako výsledek. Tuto generalizaci je třeba brát při velikosti testované populace s rezervou. Zároveň popisky emocí nemusí zcela odpovídat skutečnému emočnímu prožitku, spíše ukazují na rozdílnost emoční odezvy dle kalibračních videí. Zároveň je třeba brát v potaz, že klasifikátor do 4 tříd není příliš úspěšný (průměrná správnost 65%).

Závěr

Diplomová práce se zabývala emocionální stimulací a klasifikací emocí za využití signálů EEG. První část práce je literární rešerše shrnující dosavadní výzkum a výsledky v rámci této problematiky. Zabývá se zejména možnostmi multimediální stimulace, záznamu emocí pomocí EEG, předzpracováním signálů pro extrakci popisných elementů spjatých s emoční odezvou a možnostmi klasifikace emocí z EEG signálů. Na základě těchto poznatků jsou navrženy dva postupy (v závislosti na dostupném přístrojovém vybavení). Od sestavení měřicího protokolu s tréninkovými a testovacími daty, přes automatizovaný postup předzpracování signálů pomocí filtrace či ICA po volbu a extrakci popisných elementů. Dále redukce jejich dimenze pomocí PCA, natrénování klasifikátorů, vyhodnocení jejich účinnosti pro záznamy z dostupných EEG přístrojů a následné klasifikace vybraných testovacích dat, pro hodnocení odezvy na multimediální stimulaci u měřených subjektů.

Měření bylo provedeno pomocí dvou rozdílných EEG přístrojů. Jedním přístrojem byl Emotiv EPOC jako finančně dostupné řešení pro záznam EEG pro BCI (měření s 23 dobrovolníky). Druhým přístrojem byl EGI GES400MR jako klinický přístroj se záznamem nejvyšší kvality (měření s 15 dobrovolníky). V rámci těchto konfigurací bylo stanoveno několik cílů pro vyhodnocení úspěšnosti klasifikace emocí.

Jedním z cílů bylo vyhodnocení vhodnosti jednoho z klasifikátorů (SVM a ANN) pro klasifikaci emocí. Již při binární klasifikaci se ukázalo, že klasifikátor typu SVM není vhodný a dosahuje maximální správnosti pouze 63,9 % v rámci všech otestovaných konfigurací. Proto byl pro potřeby další klasifikace vyřazen.

Dalším z cílů bylo porovnání úspěšnosti binární klasifikace na shodných testovacích datech s popisnými elementy extrahovanými ze signálů z elektrod se shodným umístěním u obou přístrojů. Zde se ukázalo, že záznamy z přístroje EGI jsou úspěšnější a při binární klasifikaci (emoce vzrušení a smutek) pomocí ANN dosahují správnosti 81,1 % při použití koeficientů DWT s vlnkou „db4“ jako popisných elementů ze signálů ze 4 elektrod. Při stejné konfiguraci pro Emotiv bylo dosaženo maximální správnosti 61,7%. Nejlepší výsledek u přístroje Emotiv byla správnost 67,7 % při konfiguraci se 14 elektrodami a koeficienty DWT „bior1.3“ jako popisnými elementy. V návaznosti na toto zjištění byla provedena binární klasifikace u přístroje EGI na elektrodové konfiguraci zahrnující elektrody frontálního a prefrontálního kortexu (34 elektrod) a celého redukovaného prostoru elektrod EGI (204 elektrod), jako srovnání vhodnosti konfigurace elektrod přístroje Emotivu pro záznam emoční odezvy. Zde se ukázalo, že konfigurace elektrod Emotivu je dostatečná pro záznam emoční odezvy, jelikož správnost klasifikátorů z obou výše zmíněných konfigurací pro EGI je nižší (78,6% pro 203 a 80,4 % pro 34) než pro konfiguraci Emotivu, kdy za použití jeho 4 frontálních elektrod bylo dosaženo správnosti 81,1 %.

Následujícím cílem byla klasifikace do 4 tříd (zábava, vzrušení, smutek a strach) ze záznamů přístroje EGI. Pro klasifikaci byly použity popisné elementy ze signálů jak z

konfigurace elektrod shodných s elektrodovou konfigurací přístroje Emotiv tak z konfigurací zahrnujících frontální a prefrontální kortex (34 elektrod) a všechny dostupné elektrody redukovaného prostoru elektrod přístroje EGI (203 elektrod). V tomto případě se klasifikace ukázala jako neúčinná pro obě konfigurace. Výsledky hovoří ve prospěch konfigurace přístroje Emotiv jako nejvhodnějším nastavení pro klasifikaci do 4 tříd.

Z výsledků se dá usoudit, že je možné klasifikovat rozdílnost emoční odezvy na různé multimediální stimuly, což podporuje relativně dobrá úspěšnost binární klasifikace. Nicméně nižší účinnost u klasifikace do 4 tříd ukazuje na komplikace při pokusu o konkrétnější určení odezvy. Zde je potřeba vzít v potaz, že měření a výběr kalibračních dat neproběhl pod odborným dohledem psychologa. Trénovací množina byla pro zvětšení její velikosti budována za předpokladu nezávislých pozorování v rámci stimulace jednoho subjektu. Zároveň kalibrační data nepokryla celý 2D emoční prostor.

Nabízí se zde prostor pro úpravu měřicího protokolu z pohledu stimulačních videí, lepšího nastavení a kontroly laboratorních podmínek či většího vzorku populace pro zkoumání. Jedná se například o volbu kalibračních podnětů tak, aby pokryly všechny kvadranty emočního 2D emočního prostoru. Dále konzultaci těchto podnětů s psychologem a jeho dohled při měření. Co se týká zpracování, nabízí se možnost optimalizace výběru elektrod, pro získání co nejinformativnějšího setu popisných elementů. U popisných elementů se rovněž nabízí optimalizace jejich skladby, aby obsáhly co nejlepšího popisu emoční odezvy.

Bibliografie

- [1] RUSSELL, J. A. A circumplex model of affect. *Journal of Personality and Social Psychology* [online]. 1980, roč. 39, č. 6, s. 1161–1178 [vid. 23. březem 2014]. ISSN 0022-3514. Dostupné z: doi:10.1037/h0077714
- [2] GROSS, J. J. Emotion Regulation: Conceptual and Empirical Foundations. In: *Handbook of Emotion Regulation. Second Edition*. 2014. ISBN 978-1-4625-0350-6.
- [3] FRIJDA, N. H. The Psychologist's Point of View. In: *Handbook of Emotions*. 3rd vyd. 2008, s. 68 – 88. ISBN 978-1-59385-650-2.
- [4] NAKONEČNÝ, M. *Lidské emoce*. 1. vyd. Praha: Academia, 2000. ISBN 80-200-0763-6.
- [5] LARSEN, J. T., BRENTSON, G.G., POEHLMANN, K. M., ITO, T. A., CACCIPOPO, J. T.. The Psychophysiology of Emotion. In: *Handbook of Emotions*. 3rd vyd. 2008, s. 180–196. ISBN 978-1-59385-650-2.
- [6] SALADIN, K. S. *Human Anatomy*. 2. vyd. New York: Michelle Watnick, 2008. ISBN 9780072943689.
- [7] HAINES, D. E. *Neuroanatomy: An Atlas of Structures, Sections and Systems*. 6. vyd. 2004. ISBN 0781746779.
- [8] MYERS, C. E., MYERS, A. L. *Memory Loss and the Brain* [online]. 2006. Dostupné z: <http://www.memorylossonline.com/glossary/amygdala.html>
- [9] ANDERSON, A. K., PHELPS, E.. Is the human amygdala critical for the subjective experience of emotion? Evidence of intact dispositional affect in patients with amygdala lesions. *Journal of cognitive neuroscience* [online]. 2002, roč. 14, č. 5, s. 709–20. ISSN 0898-929X. Dostupné z: doi:10.1162/08989290260138618
- [10] OKUBO, K.. *BodyParts3D/Anatomography* [online]. 2009. Dostupné z: <http://lifesciencedb.jp/bp3d/?lng=en>
- [11] BROWN, L., GRUNDLEHNER, B., PENDERS, J. Towards wireless emotional valence detection from EEG. *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference* [online]. 2011, roč. 2011, s. 2188–91. ISSN 1557-170X. Dostupné z: doi:10.1109/IEMBS.2011.6090412
- [12] BRADLEY, M. M., LANG, P. J. Measuring emotion: The self-assessment manikin and the semantic differential. *Journal of Behavior Therapy and Experimental Psychiatry* [online]. 1994, roč. 25, č. 1, s. 49–59 [vid. 23. březem 2014]. ISSN 00057916. Dostupné z: doi:10.1016/0005-7916(94)90063-9
- [13] MAUSS, I. B., ROBINSON, M. D. Measures of emotion: A review. *Cognition & emotion* [online]. 2009, roč. 23, č. 2, s. 209–237. ISSN 1464-0600. Dostupné z: doi:10.1080/02699930802204677
- [14] SOLEYMANI, M., KOELSTRA, S., PATRAS, I., PUN, T. Continuous emotion detection in response to music videos. *Face and Gesture 2011* [online]. 2011, s. 803–808. Dostupné z: doi:10.1109/FG.2011.5771352
- [15] ANTONEN, J., SURAKKA, V.. Affective Computing and Intelligent Interaction [online]. 2007, roč. 4738, č. September, Lecture Notes in Computer Science [vid. 18. listopad 2014]. Dostupné z: doi:10.1007/978-3-540-74889-2
- [16] BRADLEY, M. M., LANG, P. J. Affective reactions to acoustic stimuli. *Psychophysiology* [online]. 2000, roč. 37, č. 2, s. 204–215. ISSN 0048-5772. Dostupné z: doi:10.1111/1469-8986.3720204
- [17] JAIMOVICH, J., COGHLAN, N., KNAPP, R. B. Emotion in motion: A study of music and affective response. In: *From Sounds to Music and Emotions*. B.m.: Springer, 2013, s. 19–43. ISBN 3642412475.

- [18] ZENTNER, M., GRANDJEAN, D., SCHERER, K. R.. Emotions evoked by the sound of music: characterization, classification, and measurement. *Emotion (Washington, D.C.)* [online]. 2008, roč. 8, č. 4, s. 494–521 [vid. 18. červenec 2014]. ISSN 1528-3542. Dostupné z: doi:10.1037/1528-3542.8.4.494
- [19] STRAKOŠ, L. *Odezva biologických signálů na akustickou a optickou stimulaci*. 2013. Vysoké učení technické Brno.
- [20] KATSIS, CH. D., KATERTSIDIS, N. S., FOTIADIS, D. I.. An integrated system based on physiological signals for the assessment of affective states in patients with anxiety disorders. *Biomedical Signal Processing and Control* [online]. 2011, roč. 6, č. 3, s. 261–268 [vid. 30. listopad 2014]. ISSN 17468094. Dostupné z: doi:10.1016/j.bspc.2010.12.001
- [21] KOELSTRA, S., MU, CH., SOLEYMANI, M., LEE, J. DEAP: A Database for Emotion Analysis Using Physiological Signals. 2012, roč. 3, č. 1, s. 18–31.
- [22] BRADLEY, M. M., LANG, P. J. The International Affective Picture System (IAPS) in the study of emotion and attention. In: *Handbook of emotion elicitation and assessment* [online]. 2007, s. 29–46. ISBN 0195169158. Dostupné z: [http://books.google.com/books?hl=en&lr=&id=ChiiBDGyewoC&oi=fnd&pg=PA29&dq=The+international+affective+picture+system+\(IAPS\)+in+the+study+of+emotion+and+attention&ots=pJyOP0Y8rD&sig=VJXcIRILIEtevfO38sLZ3rHCNT8](http://books.google.com/books?hl=en&lr=&id=ChiiBDGyewoC&oi=fnd&pg=PA29&dq=The+international+affective+picture+system+(IAPS)+in+the+study+of+emotion+and+attention&ots=pJyOP0Y8rD&sig=VJXcIRILIEtevfO38sLZ3rHCNT8) \n[http://books.google.com/books?hl=en&lr=&id=ChiiBDGyewoC&oi=fnd&pg=PA29&dq=The+In](http://books.google.com/books?hl=en&lr=&id=ChiiBDGyewoC&oi=fnd&pg=PA29&dq=The+international+affective+picture+system+(IAPS)+in+the+study+of+emotion+and+attention&ots=pJyOP0Y8yD&sig=N2aXd3cS4iiQ1nUDuVVkIc5DCWk)
- [23] DAN-GLAUSER, E. S., SCHERER, K. R. The Geneva affective picture database (GAPED): a new 730-picture database focusing on valence and normative significance. *Behavior research methods*. 2011, roč. 43, č. 2, s. 468–477. ISSN 1554-3528.
- [24] FRANTZIDIS, CH., BRATSAS, CH., KLADOS, M. On the classification of emotional biosignals evoked while viewing affective pictures: an integrated data-mining-based approach for healthcare applications. *IEEE transactions on information technology in biomedicine : a publication of the IEEE Engineering in Medicine and Biology Society* [online]. 2010, roč. 14, č. 2, s. 309–18. ISSN 1558-0032. Dostupné z: doi:10.1109/TITB.2009.2038481
- [25] ONDRÁŠKOVÁ, L. *Odezva biologických signálů na multimediální obsah*. 2013. Vysoké učení technické v Brně.
- [26] GROSS, J. J., LEVENSON, R. V.: Emotion elicitation using films.pdf. *Cognition and Emotion*. 1995, roč. 9, č. 1, s. 87–108.
- [27] ROSENTHAL, D. , DEGUZMAN, P., PARRA, L. C., SAJDA, P. Evoked Neural Responses to Event in Video. *IEEE Journal of Selected Topics in Signal Processing*. 2014, roč. 8, č. 3, s. 358–365.
- [28] MOLINA, G. G., TSONEVA T., NIJHOLT, A. Emotional brain-computer interfaces. *International Journal of Autonomous and Adaptive Communications Systems* [online]. 2013, roč. 6, č. 1, s. 9. ISSN 1754-8632. Dostupné z: doi:10.1504/IJAACS.2013.050687
- [29] LÖW, A., BRADLEY, A. M., LANG, P. J. Perceptual processing of natural scenes at rapid rates: effects of complexity, content, and emotional arousal. *Cognitive, affective & behavioral neuroscience* [online]. 2013, roč. 13, č. 4, s. 860–8 [vid. 26. prosinec 2014]. ISSN 1531-135X. Dostupné z: doi:10.3758/s13415-013-0179-1
- [30] DAVIDSON, R. J., JACKSON, D. C., LARSON, CH, L. Human Electroencephalography. In: *Handbook of psychophysiology*. 2000, s. 27–52.
- [31] SANEI, S., CHAMBERS, J. A. *EEG Signal Processing*. B.m.: John Wiley and Sons, 2007. ISBN 9780470025819.

- [32] KOLÁŘ, R. *Lékařská diagnostická technika*. Brno: VUT Brno, 2007. ISBN ABM 07-91.
- [33] GRANDY, T. H., WERKLE-BERGNER, M., CHICHERIO, CH. Peak individual alpha frequency qualifies as a stable neurophysiological trait marker in healthy younger and older adults. *Psychophysiology* [online]. 2013, roč. 50, č. 6, s. 570–82 [vid. 21. říjen 2014]. ISSN 1540-5958. Dostupné z: doi:10.1111/psyp.12043
- [34] ASIF-UL-HOQUE, M., AHSAN, M. D., MOHAJAN, B. Measurement of Blood Pressure Using Photoplethysmography. *2011 UkSim 13th International Conference on Computer Modelling and Simulation* [online]. 2011, s. 32–35 [vid. 23. říjen 2014]. Dostupné z: doi:10.1109/UKSIM.2011.16
- [35] AGRAFIOTI, F., HATZINAKOS, D., ANDERSON, A. K. ECG Pattern Analysis for Emotion Detection. 2012, roč. 3, č. 1, s. 102–115.
- [36] AGARWAL, A. K., MEHTA, N. H., MAHAJAN, N. M. GSR and HRV: Its Application in Clinical Diagnosis Author/Guide: nedatováno.
- [37] RAJENDRA A., JOSEPH, U. K., KANNATHAL, N., LIM, CH. M., SURI, J. S. Heart rate variability: a review. *Medical & biological engineering & computing* [online]. 2006, roč. 44, č. 12, s. 1031–51 [vid. 19. březen 2014]. ISSN 0140-0118. Dostupné z: doi:10.1007/s11517-006-0119-0
- [38] BENEDEK, M., KAERNBACH, CH. A continuous measure of phasic electrodermal activity. *Journal of neuroscience methods* [online]. 2010, roč. 190, č. 1, s. 80–91 [vid. 15. říjen 2014]. ISSN 1872-678X. Dostupné z: doi:10.1016/j.jneumeth.2010.04.028
- [39] BUBNÍK, K., KOLÁŘOVÁ, J. *Software pro zpracování a filtraci PPG signálu* [online]. Brno: FEKT VUT. 2012. Dostupné z: <http://www.dbme.fec.vutbr.cz/vyzkum-avyvoj/produkty>
- [40] BIGDELY-SHAMLO, N., MULLEN, T., KOTHE, CH., SU, K. M., ROBBINS, K. A.. The PREP pipeline: standardized preprocessing for large-scale EEG analysis. *Frontiers in Neuroinformatics* [online]. 2015, roč. 9, s. 16. ISSN 1662-5196. Dostupné z: doi:10.3389/fninf.2015.00016
- [41] DELORMA, A. Arnaud Delorme's Home Page. *ICA for dummies* [online]. [vid. 11. únor 2016]. Dostupné z: <http://scn.ucsd.edu/~arno/indexica.html>
- [42] JUNG, T. P., MAKEIG, S., HUMPHRIES, T. Removing electroencephalographic artifacts by blind source separation. *Psychophysiology* [online]. 2000, roč. 37, s. 163–178. ISSN 0048-5772. Dostupné z: doi:10.1111/1469-8986.3720163
- [43] LANGLOIS, D., CHARTIER, S., GOSSELIN, D.. An Introduction to Independent Component Analysis: InfoMax and FastICA Algorithms. *Tutorials in Quantitative Methods for Psychology* [online]. 2010, roč. 6, č. 1, s. 31–38. Dostupné z: <http://www.tqmp.org/Content/vol06-1/p031/p031.pdf>
- [44] DELORME, A., MAKEIG, S. EEGLAB: An open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods* [online]. 2004, roč. 134, č. 1, s. 9–21. ISSN 01650270. Dostupné z: doi:10.1016/j.jneumeth.2003.10.009
- [45] DELORME, A., MAKEIG, S. *EEGLAB Wiki - SCNN* [online]. 2015 [vid. 20. listopad 2015]. Dostupné z: http://scn.ucsd.edu/wiki/EEGLAB_Wiki
- [46] XU, H.. Towards Automated Recognition of Human Emotions using EEG. *Master of Applied Science Graduate Department of Electrical and Computer Engineering University of Toronto* [online]. 2012. Dostupné z: <https://tspace.library.utoronto.ca/handle/1807/42884>
- [47] PICARD, R. W. Future affective technology for autism and emotion communication. *Philosophical Transactions of the Royal Society of London B: Biological Sciences*. 2009, roč. 364, č. 1535, s. 3575–3584. ISSN 0962-8436.

- [48] PETRANTONAKIS, P. C., HADJILEONTIADIS, L. J. Adaptive extraction of emotion-related EEG segments using multidimensional directed information in time-frequency domain. In: *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC'10* [online]. 2010, s. 1–4. ISBN 9781424441235. Dostupné z: doi:10.1109/IEMBS.2010.5626588
- [49] HALL, P. a RIVER, U. S. *SPECTRAL ANALYSIS OF SIGNALS Petre Stoica and Randolph Moses* [online]. 2004. ISBN 0131139568. Dostupné z: <http://user.it.uu.se/~ps/SAS-new.pdf>
- [50] SOLEYMANI, M., ASGHARI-ESFEDEN, A., PANTIC, M., FU, Y. Continuous emotion detection using EEG signals and facial expressions. *IEEE Conference on Multimedia and Expo (ICME)* [online]. 2013, roč. 231287, č. 231287, s. 3–8. ISSN 1945788X. Dostupné z: doi:10.1109/ICME.2014.6890301
- [51] OKAMURA, S. The short time Fourier transform and local signals. 2011.
- [52] MURUGAPPAN, M.. Classification of human emotion from EEG using discrete wavelet transform. *Journal of Biomedical Science and Engineering* [online]. 2010, roč. 03, č. 04, s. 390–396. ISSN 1937-6871. Dostupné z: doi:10.4236/jbise.2010.34054
- [53] AHMED, T., ISLAM, M., YUSUF, S. U., AHMAD, M. Wavelet based analysis of EEG signal for evaluating mental behavior. *2013 International Conference on Informatics, Electronics and Vision (ICIEV)* [online]. 2013, s. 1–6. Dostupné z: doi:10.1109/ICIEV.2013.6572706
- [54] ŠMÍD, R. *Úvod do vlnkové transformace*. 2001.
- [55] HUANG, N. E. Introduction to the Hilbert Huang Transform. *Transform* [online]. 2005, roč. 5, s. 1–26. Dostupné z: doi:doi:10.1142/9789812703347_0001
- [56] KHASNOBISH, A., BHATTACHARYYA, S., SINGH, G. The Role of Empirical Mode Decomposition on Emotion Classification Using Stimulated EEG Signals. In: *Advances in Computing and Information Technology*. B.m.: Springer, 2013, s. 55–62. ISBN 3642315992.
- [57] MARAGOS, P., KAISER, J. F., QUATIERI, T. F. On separating amplitude from frequency modulations using energy operators. In: *ICASSP-92: 1992 IEEE International Conference on Acoustics, Speech, and Signal Processing* [online]. 1992, s. 1–4 vol.2. ISBN 0-7803-0532-9. Dostupné z: doi:10.1109/ICASSP.1992.226135
- [58] SHLENS, J. A Tutorial on Principal Component Analysis. *Systems Neurobiology Laboratory, University of California at San Diego*. 2005, s. 82.
- [59] HYVÄRINEN, A., HURRI, J., HOYER, P. O. Principal Component Analysis. In: *Natural Image Statistics: A Probabilistic Approach to Early Computational Vision*. B.m.: Springer Science & Bussines Media, 2009, s. 94 – 104.
- [60] KHOSROWABADI, R., QUEK, H.CH., WAHAB, A., ANG, K. R. EEG-based emotion recognition using self-organizing map for boundary detection. In: *Pattern Recognition (ICPR), 2010 20th International Conference on*. B.m.: IEEE, 2010, s. 4242–4245. ISBN 1424475422.
- [61] CHAOVALITWONGSE, W A, FAN, Y., SACHDEO, R. C. *On the Time Series K-Nearest Neighbor Classification of Abnormal Brain Activity* [online]. 2007. ISBN 1083-4427 VO - 37. Dostupné z: doi:10.1109/TSMCA.2007.897589
- [62] SULAIMAN, N., TAIB, M. N., LIAS, S. *EEG-based Stress Features Using Spectral Centroids Technique and k-Nearest Neighbor Classifier* [online]. 2011. ISBN VO -. Dostupné z: doi:10.1109/UKSIM.2011.23
- [63] KHALILI, Z., MORADI, M. H. Emotion detection using brain and peripheral signals. In: *Biomedical Engineering Conference, 2008. CIBEC 2008. Cairo International*. B.m.: IEEE, 2008, s. 1–4. ISBN 1424426944.
- [64] KOZUMPLÍK, J., PROVAZNÍK, I. *Umělá inteligence v medicíně*. Brno: Vysoké učení

- technické Brno, 2007.
- [65] HORLINGS, R.. *Emotion recognition using brain activity*. Delft, 2008. Delft University of Technology.
 - [66] SINGH, M., SINGH, M., GANGWAR S. Arousal Detection Using EEG Signal. *IJITKM*. 2013, roč. 7, č. 1, s. 11–15.
 - [67] ESCALERA, S., PUJOL, O., RADEVA, P. Separability of ternary codes for sparse designs of error-correcting output codes. *Pattern Recognition Letters* [online]. 2009, roč. 30, č. 3, s. 285–297. ISSN 01678655. Dostupné z: doi:10.1016/j.patrec.2008.10.002
 - [68] SANDEL, A. Valence Detection Using EEG Signals. 2014, July.
 - [69] KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: *Ijcai*. 1995, s. 1137–1145.
 - [70] GÜLER, I., BEYLI, I. D.. Multiclass support vector machines for EEG-signals classification. *Information Technology in Biomedicine, IEEE Transactions on*. 2007, roč. 11, č. 2, s. 117–126. ISSN 1089-7771.
 - [71] SOKOLOVA, M., LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information Processing & Management* [online]. 2009, roč. 45, č. 4, s. 427–437. ISSN 03064573. Dostupné z: doi:10.1016/j.ipm.2009.03.002
 - [72] Emotiv EPOC. *Brain Computer Interface and Scientific Contextual EEG* [online]. 2014. Dostupné z: <https://emotiv.com/product-specs/Emotiv EPOC Specifications 2014.pdf>
 - [73] *EEG Systems* [online]. 2014. Dostupné z: <http://www.egi.com/research-division/research-division-research-products/ges-400-series>
 - [74] NAVRÁTIL, R. *Software pro prezentaci multimediálních stimulů*. 2014. Vysoké učení technické Brno.

Seznam zkratek

ANN	Artificial Neural Network (umělá neuronová síť)
ANS	Autonomní nervový systém
BCI	Brain – Computer Interface (rozhraní mozek – počítač)
BOLD	Blood Oxygenation Level Dependent
CNS	Centrální nervový systém
DEAP	Database for Emotion Analysis using Physiological Signals
DESA	Discrete Energy Separation Algorithm
DWT	Discrete Wavelet Transform (diskrétní vlnková transformace)
ECOC	Error-correcting output codes
EDA	Elektrodermální aktivita
EEG	Elektroencefalografie
EKG	Elektrokardiografie
EMD	Empirical Mode Decomposition
EMG	Elektromyografie
EOG	Elektrookulografie
FFT	Fast Fourier Transform
FIR	Finite Impulse Response
fMRI	Funkční magnetická rezonance
GAPED	Genova Affective Picture Database
GEMS	Geneva Emotional Music Scale
GSR	Galvanic Skin Response (galvanická odezva kůže)
HA	High Arousal (vysoké vzrušení)
HHT	Hilbert- Huangova transformace
HR	Heart Rate (srdeční rytmus)
HRV	Heart Rate Variability (variabilita srdečního rytmu)
IAF	Individuální alfa frekvence
IAPS	International Affective Picture System
ICA	Independent Component Analysis (analýza nezávislých komponent)
IF	Instantaneous Frequency (okamžitá frekvence)
IIR	Infinite Impulse Response
IMF	Intrinsic Mode Function
k-NN	k-Nearest Neighbor
LA	Low Arousal (nízké vzrušení)
MAHNOB-HCI	Multimodal Analysis of Human Nonverbal Behavior – Human Computer Interface
PCA	Principal Component Analysis, analýza důležitých komponent

PET	Pozitronová emisní tomografie
PPG	Photoplethysmography (fotoplethysmografie)
PSD	Power Spectral Density (hustota spektrálního výkonu)
RSVP	Rapid Serial Visual Presentation
SAM	Self Assesment Manikin (sebehodnotící figurkový test)
SCL	Skin Conductance Level (úroveň kožní vodivosti)
SCR	Skin Conductance Response (odezva kožní vodivosti)
SDK	Software Development Key
STFT	Short Term Fourier Transform (krátkodobá Fourierova transformace)
SVM	Support Vector Machine

Seznam příloh

A CD

- A.1. Algoritmy_Soubory/
- A.2. Nejlepsi_klasifikatory/
- A.3. ReadMe.txt
- A.4. Elektronická verze diplomové práce