

Západočeská univerzita v Plzni
Fakulta aplikovaných věd
Katedra informatiky a výpočetní techniky

Bakalářská práce

Detekce procesu učení z elektrofyziologických dat

Místo této strany bude
zadání práce.

Prohlášení

Prohlašuji, že jsem bakalářskou práci vypracoval samostatně a výhradně s použitím citovaných pramenů.

V Plzni dne 3. května 2016

Vítězslav Vacek

Abstract

Detection of the process of learning from electrophysiological data

In this document I am about to suggest a method of measurement and subsequently verify if its possible to detect the process of learning from electrophysiological data using this method. Next Im going to design and implement scenarios for this experiment. These scenarios will be tested on a reasonably large sample of people. Then the data will be processed and hypothesis will be formed. For measuring of electrophysiological data and its subsequent analysis I will use the equipment available in KIV/NTIS P2 the neuroinformatics laboratory.

Abstrakt

V tomto dokumentu navrhuji způsob měření a následně ověřuji, zda je možné s jeho pomocí detekovat učení z elektrofyziologických dat. Navrhuji a implementuji scénář měření experimentu a provedu jej na přiměřeně velkém vzorku lidí. Naměřená data zpracuji a zároveň se pokusím provést částečnou interpretaci výsledků měření. K měření elektrofyziologických dat a v jejich následné analýze použiji vybavení neuroinformatické laboratoře KIV/NTIS P2.

Obsah

1	Úvod	7
2	State of the Art	8
2.1	Lidský mozek	8
2.1.1	Dělení mozku	8
2.2	Neuron	9
2.3	Neuroplasticita mozku	10
2.4	Mozek a jeho vztah k učení	11
2.5	Elektroencefalografie	13
2.6	ERP	13
2.6.1	Důležité ERP komponenty	14
2.7	Články využití pro návrh experimentu	16
2.8	Shrnutí druhé kapitoly	21
3	Experiment	23
3.1	Návrh experimentu	23
3.1.1	Úkoly experimentu - první typ	24
3.1.2	Úkoly experimentu - druhý typ	25
3.2	Implementace experimentu a prototypové měření	26
3.3	Vybavení laboratoře a potřebné nástroje	27
3.3.1	Verze použitého softwaru	27
3.4	Průběh jednotlivých měření	28
4	Zpracování a vyhodnocení naměřených dat	29
4.1	Pomůcky použité při měření a struktura EEG dat	29
4.2	Předzpracování dat	30
4.2.1	Filtrace	30
4.2.2	Odstraňování artefaktů	32
4.2.3	Výsledná kvalita zpracovaných dat	34
4.3	Analýza předzpracovaných dat	34
4.3.1	Objevené vzory	34
4.4	Analýza - bodové ohodnocení scénářů	38
4.5	Analýza - vztahy PSD	38
4.6	Diskuze naměřených výsledků	39

5 Závěr	41
5.1 Poděkování	42
A Seznam zkratk	43
B Seznam použité literatury	44
C Přílohy	46
C.1 Dokument pro sběr metadat k měřením	46
C.2 Dokument pro podporu učení notového názvosloví	50

1 Úvod

Učení nás provází celým životem. Tuto vrozenou schopnost člověka přizpůsobovat se a učit se novým věcem využíváme od narození do dospělosti, ale i ve stáří. Neustále tak sami sebe obohacujeme a zlepšujeme. Ať už jde o sport, zájmovou činnost nebo jazyky, každý z nás se dokáže těmto věcem naučit. Učení je proces, který z nás dělá to co jsme, a tak se pokusím zjistit, zda je možné něco z tohoto procesu částečně zmapovat pomocí elektrofyziologických dat.

Během dne také narazíte nejspíše na mnoho situací, ve kterých si potřebujete zapamatovat kousek informace v hlavě, i když například jen na pár sekund. Možná je to telefoní číslo, které si potřebujete rychle zapsat, nebo přesvědčivý argument, který sdělíte hned, jakmile druhá osoba domluví. V těchto příkladech potřebujete používat paměť. Pokusím se tedy nahlédnout, jak naše paměť funguje.

Učení způsobuje strukturální změny a přestavby mozku. Tyto změny mohou způsobit vytváření nových neuronových synapsí, či naopak zánik určitých, již existujících, spojení. Mozek tedy dokáže měnit svou vlastní strukturu v závislostech na nově získaných zkušenostech a neustále se tak vyvíjet a zlepšovat.

V kapitole 2 “State of the Art“ rozeberu podrobně používanou terminologii a uvedu i vědecké články, ze kterých tato práce čerpala. V kapitole 3 “Experiment“ se detailněji zaměřím na otázky, jak probíhal návrh a implementace experimentu. V této kapitole také nastíním jaké softwarové a hardwarové nástroje byly použity při vytváření samotného experimentu. V kapitole 4 “Zpracování a vyhodnocení naměřených dat“ se zaměřím na otázky, jak data byla měřena, předzpracována a pokusím se dosažené výsledky částečně interpretovat. Nakonec v kapitole 5 “Závěr“ shrnu dosažené výsledky této práce.

2 State of the Art

Následující část dokumentu se bude zabývat teoretickou částí řešeného problému a podklady, ze kterých tato práce čerpala. Také se seznámíte s terminologií, kterou potřebujete pochopit, než se začneme zabývat otázkami, jakou roli hraje mozek a jeho části v procesu učení.

2.1 Lidský mozek

Lidský mozek kontroluje veškeré části našeho těla od srdečního tepu přes emoce, paměť a učení. Mozek (cerebrum) je řídicí centrum našeho těla, které je rozděleno do různých částí a tyto části jsou následně zodpovědné za zpracovávání různých informací. Když se zamyslíte, vnímáte, plánujete a nebo rozumíte mluveným jazykům, tak právě pracují různé části mozku.


2.1.1 Dělení mozku

Mozek se skládá ze dvou hemisfér (pravá a levá), které jsou mezi sebou spojeny shlukem vláken (corpus callosum), která umožňují komunikaci mezi oběma hemisférami. Povrch mozku (nazývaný také koncový mozek) tvoří tenká vrstva tkáně nazývaná mozková kůra (cerebral cortex), která se podle své barvy spíše označuje jako šedá hmota mozková.

Vrásčitý vzhled mozku lze tedy přisoudit právě šedé hmotě mozkové. Více než 2/3 této vrstvy jsou složeny do různých záhybů, které zvětšují povrch mozku, a tím vytváří prostor pro další neurony. Šedá hmota mozková se dělí na další části s vlastní funkcí (viz obrázek 2.1). [5]

Čelní lalok (frontal lobe) je převážně zodpovědný za uskutečňování a koordinaci pohybů a vyšší kognitivní dovednosti (např. řešení problémů, myšlení, plánování, ...). Temenní (parietální) lalok (parietal lobe) zodpovídá zejména za smyslové procesy, pozornost a mluvený jazyk. Týlní okcipitální lalok (occipital lobe) pomáhá s převodem vizuálních informací včetně poznávání tvarů a barev. Spánkový temporální lalok (temporal lobe) pomáhá s převodem zvukových informací a spojuje informace z ostatních smyslů. [5]

BRAIN STRUCTURE




Obrázek 2.1: Rozdělení mozkové kůry do zón s různým účelem. Převzato z [7].

2.2 Neuron

Buňky nervového systému se nazývají neurony. Neuron je specializovaná buňka mozku, schopná přenášet informace do dalších nervových buňek, svalů nebo žláz. Právě schopnost neuronů přenášet signály je základem pro naši schopnost učit se a fungovat.

Každý neuron v lidském těle se skládá ze čtyř částí, a to buněčného těla (cell body), dendritů (dendrites), axonu (axon) a axionálních zakončení (axon terminals). Buněčné tělo obsahuje jádro (nucleus) a cytoplazmu. Axon vyrůstá z těla neuronu a vede do axionálních zakončení. Axionální zakončení slouží pro přenos vyslaných zpráv. Dendrity vyrůstají z těla neuronu a slouží k přenášení příchozích zpráv od ostatních neuronů. Myelinová pochva (myelin sheath) obklopuje axon a slouží ke zrychlení přenosu signálu podél axonu. Synapse jsou místa kontaktu mezi neurony, která slouží ke vzájemné komunikaci. Na obrázku 2.2 jsou zobrazeny tyto části neuronu. [5]



Obrázek 2.2: Jednotlivé části neuronu. Převzato z [8].

2.3 Neuroplasticita mozku

Neuroplasticita (dále jen plasticita) je schopnost mozku sama sebe modifikovat a přizpůsobovat problémům prostředí. Plasticita sama o sobě není unikátní pouze pro člověka, ale schopnost našich mozků přizpůsobit se okolí je pro nás jedinečná.

Existují tři důvody, které ovlivňují plasticitu: [10]

- první důvod – trvá od narození po dospělost. Mozek v této fázi roste a organizuje se. Změny plasticity jsou převážně způsobeny růstem a učením,
- druhý důvod – probíhá v dospělosti, změny jsou způsobeny už převážně jen učením a využíváním paměti,
- třetí důvod – po poranění mozku dojde k pokusu o obnovení ztracené funkcionality nebo znovuzapojení zbylých částí.

Hebbovo pravidlo

Hebbovo pravidlo vysvětluje adaptaci neuronů umístěných v mozku během procesu učení. Toto pravidlo říká, že vytrvalost nebo opakování určité aktivity vede k dlouhodobým buněčným změnám v nervovém systému a ke

zvýšení stability nervového systému.

Například pokud axon buňky A je dostatečně blízko buňky B a vytrvale nebo opakovaně vysílá signály, tak následně dojde k metabolickým změnám v buňce A i B, a to k propojení nebo k zrychlení přenosu.


Jednoduše řečeno, neurony, které jsou neustále používány, jsou posilovány anebo propojovány.

2.4 Mozek a jeho vztah k učení

Naše schopnost učit se a vědomě si zapamatovat každodenní fakta a události se nazývá deklarativní paměť. Když narazíme na novou zkušenost, tak informace nejdříve vstoupí do pracovní paměti (working memory). Studie, které využívaly funkční zobrazování mozku, identifikovaly velkou síť oblastí v mozkové kůře (cerebral cortex), které spolupracují s hipokampem (hippocampus) na podporu deklarativní paměti. Tyto oblasti sehrávají významnou roli ve vnímání, pohybu, emocích a poznávání, kde každá oblast přispívá do celkové zkušenosti deklarativních vzpomínek. [5]

Pracovní paměť je přechodná forma paměti deklarativní, která závisí na prefrontální kůře (prefrontal cortex), kde jsou následně uschovány relevantní informace. Zároveň se zde kombinují různé typy smyslových informací. U člověka je prefrontální kůra velmi aktivní během udržování a manipulací se vzpomínkami. Jednotlivé části mozku, které pracují s pamětí, jsou uvedeny na obrázku 2.3. [5]

The Brain and Memory



Obrázek 2.3: Různé oblasti a systémy mozku zodpovědné za různé typy paměti. Hipokampus a oblasti mozkové kůry (včetně prefrontální kůry) spolupracují na podpoře deklarativní nebo kognitivní paměti. Různé typy ne-deklarativní paměti nebo chování jsou podporovány amygdalou, striatem a mozečkem (cerebellum). Převzato z [9].

Různé části prefrontální kůry podporují výkonné funkce, jako například výběr, opakování a sledování informací, které jsou vyvolány z dlouhodobé paměti. Aby prefrontální kůra byla schopna této funkce, tak musí komunikovat s velkou sítí posteriorních kortikálních oblastí (posterior cortical areas), která kóduje, udržuje a získává specifické typy informací (např. zvuky, slova, vizuální obrazy, ...), také sleduje i další závislosti, jako například čas, kdy se důležité události staly, atd. [5]

Sémantická paměť je formou deklarativních znalostí (declarative knowledge), které obsahují obecná fakta a data. I když vědci teprve začínají chápat, jaká je podstata a organizace kortikálních oblastí spojených se sémantickou pamětí, tak se zdá, že souvisí s jednotlivými druhy informací (např. obličej, domy, nástroje, ...). [5]

Vzpomínky, které se udály na určitém místě a v určitém čase, se nazývají epizodní vzpomínky (episodic memories). V oblastech středního temporálního laloku se obecně předpokládá, že epizodní vzpomínky mají důležitou roli v počátečním zpracování a ukládání těchto epizodních vzpomínek. Studie také ukázaly, že různé parahipokampální (parahippocampal) oblasti hrají důležitou roli ve zpracování “co“, “kde“ a “kdy“ informací o specifických událostech. [5]

Nedeklarativní znalosti (nondeclarative knowledge), nebo-li znalosti jak něco dělat, se také často nazývají procedurální paměť (procedural memory). Mozeček (cerebellum) je zapojen do motorických úkolů, které vyžadují koordinované načasování. Amygdala hraje důležitou roli v emocionálním aspektu paměti. Vyjádření emocionálních vzpomínek také souvisí s hipotalamem a sympatickým nervovým systémem, které podporují emociální reakce a pocity. [5]

2.5 Elektroencefalografie

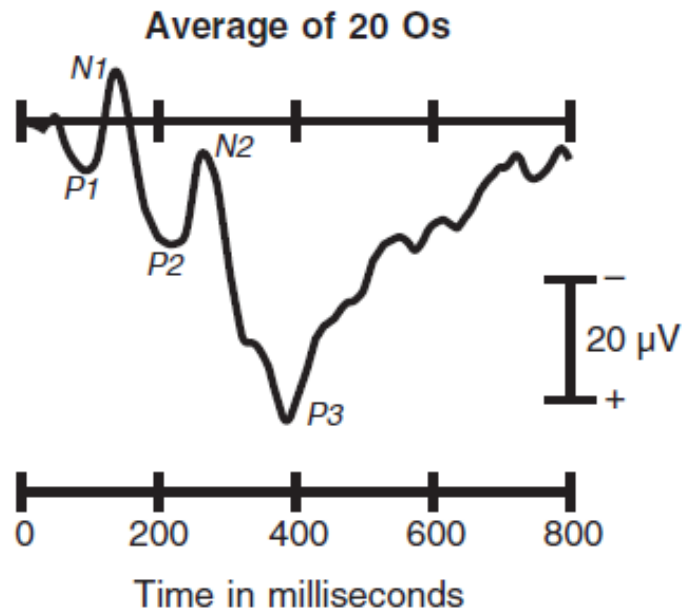
Elektroencefalografie je jednou z diagnostických metod používaných pro záznam elektrické aktivity mozku. Elektroencefalografie patří mezi neinvazivní metody měření. Elektroencefalogram (EEG) je záznam časových změn polarizace neuronů a neurologie v centrálním nervovém systému (CNS). Měřená amplituda potenciálů z povrchu kůže lebky je v rámci desítek microvoltů (μV). [11]

2.6 ERP

Event-related potential nebo-li ERP je měřitelná elektrofyzilogická odpověď těla na specifický vnější stimul. Například, když zahlédnete předmět v dálce a pokusíte se ho rozpoznat, tak dojde k určitým změnám elektrického napětí na povrchu kůže. Pomocí ERP je tak možné měřit činnost mozku bez potřeby provádět invazivní zákrok (přímý zásah do mozku).

ERP se často zobrazuje jako vlna zprůměrovaných hodnot napětí vzhledem k času, který uplynul od stimulu. Tyto vlny obsahují sekvence pozitivních a negativních odchylek napětí, které jsou nazývány vrcholy (také vlny nebo komponenty). Vrcholy jsou označovány P1, N1, P2, N2, P3, atd. P a N se používají k označení toho, zda je v dané části vlny pozitivní nebo negativní vrchol a čísla určují pozici vrcholu uvnitř vlny (viz obrázek 2.4). Číslo

za P a N také může označovat latence (např. P300 označuje pozitivně jdoucí vrchol okolo 300 ms od doby stimulu). Sekvence těchto vrcholů následně odráží tok informací skrze mozek. [6]



Obrázek 2.4: Příklad, jak může vypadat naměřená vlna ERP (převzato z zdroje [6] str. 12).

2.6.1 Důležité ERP komponenty

C1 – První velká vizuální komponenta bývá často nazývaná C1. Není označena jako P nebo N, protože se její polarita může měnit. C1 bývá pozitivní, pokud se stimul nalézá v spodní části vidění a negativní, pokud v horní části vidění. Také je velmi závislá na parametrech stimulu jako například kontrast a prostorová frekvence. C1 začíná na 40 - 60 ms po stimulu a dosahuje vrcholu v 80 - 100 ms po stimulu. [6]

P1 – Po vlně C1 přichází vlna P1, která je také závislá na různých parametrech stimulu a to zejména na směru prostorové pozornosti (direction of spatial attention) a na stavu vzrušení subjektu (state of arousal). Zpoždění P1 se velmi liší podle kontrastu stimulu. P1 běžně začíná na 60 - 90 ms po stimulu a dosahuje vrcholu v 100 - 130 ms po stimulu. [6]

N1 – Po vlně P1 přichází vlna N1, která se skládá hned z několika subkomponent. První přední subkomponenta dosahuje vrcholu 100 - 150 ms po

stimulu, kterou následují ještě dvě zadní N1 komponenty s mají vrcholy 150 - 200 ms po stimulu. Studie ukázaly, že prostorová pozornost (spatial attention) ovlivňuje i tyto komponenty. [6]

P2 – Přichází po vlně N1. Tato komponenta je větší při stimulech obsahující cílové vlastnosti (features) a tento efekt je zesílen, pokud jsou cíle relativně vzácné (infrequent). P2 se často špatně rozlišuje od překrývajících se N1, N2 a P3 vln. [6]

N170 – N170 se objevuje při rozpoznávání obličejů. N170 reaguje více na převrácené obličej než na vzpřímené (upright) obličej, ale tento efekt byl pozorován i u účastníků experimentu, kteří mají rozsáhlé zkušenosti s pozorováním stimulů ve vzpřímené poloze. N170 se také vyskytuje i pro jiné velmi známé stimuly jako například slova. [3, 6]

ERN – ERN (error-related negativity) je charakterizováno negativní výchytkou objevující se od 50 - 100 ms po stimulu následována centroparietálním pozitivním vrcholem (Pe). ERN slouží jako signál doprovázející mechanismus detekce chyb (error-detection). Pe komponenta ERN odráží vědomné zpracování chyb a následnou úpravu reakční strategie (response strategies). [1]

ErrP – ErrP (interaction error-related potential) je charakterizován dvěma frontocentrálními pozitivními vrcholy, které se objevují okolo 200 - 320 ms po stimulu, a následnou frontocentrální negativitou okolo 250 ms po stimulu. Pravidelně následuje dlouhá a širší frontocentrální negativní odchylka 450 ms po stimulu. Tento signál je po delší dobu stabilní (objevuje se pokaždé přibližně ve stejnou dobu). Tento potenciál převážně souvisí s provedenými chybami, ale téměř se neobjevuje v reakci na jiné experimentální proměnné (jak často se stimulus objevil, oddball paradigm, ...). [1]

FRN – FRN (feedback-related negativity) je signál, který souvisí s odhadem a očekávaným výsledkem. Následně signalizuje, zda šlo o správnou či špatnou předpověď. Experimentální výsledky naznačují, že pro každého člověka je možné zjistit, zda je tento signál více citlivý na správné či špatné předpovědi. [1, 2]

N400 – N400 lze typicky nalézt v reakci na porušení sémantických očekávání v jazyce. Například, když by byly věty prezentovány jedním slovem po druhém na monitor, tak by byla větší reakce na poslední slovo ve větě.

“Když jsem dorazil do města, sešel jsem se na oběd s tričky.“ Nastala by menší N400 aktivita, pokud by věta končila “s přáteli“ než “s tričky“. Komponentu N400 můžeme také nalézt v druhém slově z uvedeného páru slov. “Pneumatika ... cukr“ vzbudí větší aktivitu N400 než “mouka ... cukr“. [3, 6]

PSD – PSD (Power spectral density function) neboli spektrální hustota je důležitá veličina pro stanovení rozložení energie ve spektru u náhodných procesů a velmi často je v praxi využívána. Jednotka PSD se udává ve W/Hz na Hz (W/Hz). PSD je velmi užitečný nástroj, pokud chceme znát frekvence a amplitudy oscilujícího signálu v datech s omezeným časovým intervalem.


2.7 Články využité pro návrh experimentu

Následující články byly využity při tvorbě experimentu a rozhodování, které veličiny budou použity k detekci procesu učení z naměřených EEG dat.

Learning From EEG Error-Related Potentials in Noninvasive Brain-Computer Interfaces [1]

Tento článek se zabývá neinvazivním způsobem komunikace mezi lidským mozkem a počítačem (BCI), kde jako komunikační prostředek slouží EEG měřeného subjektu, podle kterého se následně samostatný systém učí ze svých chyb. Z naměřeného EEG se následně sledovaly evokované potenciály (ERN, ErrP, FRN). Následující experiment byl proveden pro dvě úrovně chybovosti systému (20%, 40%).

Účastníci experimentu byli posazeni před počítačovou obrazovku a měli za úkol sledovat pohyblivý čtvercový kurzor (zelený). Kurzor byl ovládán počítačem, který měl za úkol dostat kurzor z jednoho místa obrazovky do druhého (červeného, viz obr. 2.5). Účastníci experimentu pouze sledovali pohyb kurzoru po obrazovce s tím, že systém měl k dispozici jejich měřené EEG a předem nastavenou chybu systému, tj. kurzor se pohnul do špatného směru nezávisle na rozhodování pomocí naměřeného EEG. V okamžiku chyby se systém “učil“ z naměřeného EEG a určil správný směr pohybu.



Obrázek 2.5: V tomto experimentu měl počítač za úkol dostat kurzor (šedý čtverec, pohyblivý, čas t , vlevo) do černého čtverce (čas t , vpravo, cíl). Čárkovaný čtverec označuje předchozí pozici zeleného kurzoru. Na obrázku jsou zobrazeny příklady pohybu pro čas t , $t+1$ a $t+2$.

Článek poukazuje na to, že je možné, aby se autonomní systém dokázal učit a upřesňoval svá rozhodnutí na základě naměřeného EEG subjektu. Průměrné hodnoty pro rozpoznávání chybných a správných rozhodnutí systému z EEG měřeného subjektu byly 75,8% a 63,2%.

Learning from experience: Event-related potential correlates of reward processing, neural adaptation, and behavioral choice [2]

V tomto článku se řeší neurální důležitost FRN. Zkoumá se zde také důležitost a funkce FRN v učení. Abychom se dokázali přizpůsobovat, potřebujeme se učit ze svých chyb. Studie, které zkoumají ERP, byly poučné s ohledem na otázku, jak k učení dochází. Tyto studie odhalily přední-centrální negativitu nazývanou FRN, která se objevuje za negativní zpětnou vazbou. Podle teorie predikční chyby, FRN reaguje na rozdíl mezi skutečným a očekávaným výsledkem nebo očekáváním chyby (reward prediction errors). FRN může sloužit jako nástroj pro studování očekávaných výsledků (reward valuation) a rozhodování (decision making).

Tento článek se zabývá tím, jak různé způsoby učení (temporal difference learning, actor-critic model, ...) pomáhají předvídat očekávané výsledky. Také řeší to, jaké části mozku se do tohoto učení zapojují. Dále se zabývají neurální důležitostí FRN. Tedy podrobně řeší odkud a jak FRN vychází a jaké má rozložení po skalpu.

V tomto článku se přesněji řeší následující 4 hypotézy:

1. FRN odráží velikost predikční chyby (reward prediction error)
2. FRN je evokován pomocí stimulů, které předpovídají výsledky (outcomes)
3. FRN a chování FRN se mění se zkušenostmi
4. Systém, který produkuje FRN, je maximálně využívaný během volného jednání (volitional actions)

An ERP study on initial second language vocabulary learning [3]

Zde byly sledovány ortografické¹ počátky, které souvisí s učením druhého jazyka. Jako druhý jazyk (prvním jazykem byl anglický) posloužila zjednodušená čínština, ze které bylo použito 200 slov (75% jednoslovných, 25% dvouslovných). Sledovanými ERP komponentami byly v tomto případě N170 a N400. Komponenta N170 sloužila jako ortografický index učení² a N400 k posuzování sémantického kontextu slova. Lekce probíhaly každý den po 10 dnů. ERP komponenty byly měřeny v 1., 4., 7. a 10. lekci.

Účastníci byli po první lekci rozděleni do skupin na rychle a pomalu se učící, aby bylo možné sledovat individuální rozdíly v učení. Rozdělení do těchto skupin proběhlo na základě procentuální úspěšnosti během testů v první lekci.

Účastníci tohoto experimentu neměli žádné zkušenosti s jiným než anglickým jazykem. Následně během 10 lekcí měli za úkol naučit se čínská slova. Kromě 200 slov k naučení obsahovaly stimuly i 100 slov, která byla použita pouze k rozptýlení účastníků při poznávacích a překládacích úkolech (nebylo úkolem se tato slova naučit). Pro tento experiment byly použity celkem 4 typy úkolů.

Prvním úkolem byl test, ve kterém měl účastník pouze zmáčknout tlačítko, pokud byl na monitoru zobrazen stejný čínský znak jako jeden z posledních tří znaků (s 10% pravděpodobností se objeví 1 - 3 kroky na zpět). První úkol se zaměřil na to, aby účastníci kladli větší důraz na vzhled znaku

¹ortografie - zásady a pravidla psaní v jazyce

²ortografický index učení - index učení se pravidlům a zásadám pravopisu nového jazyka

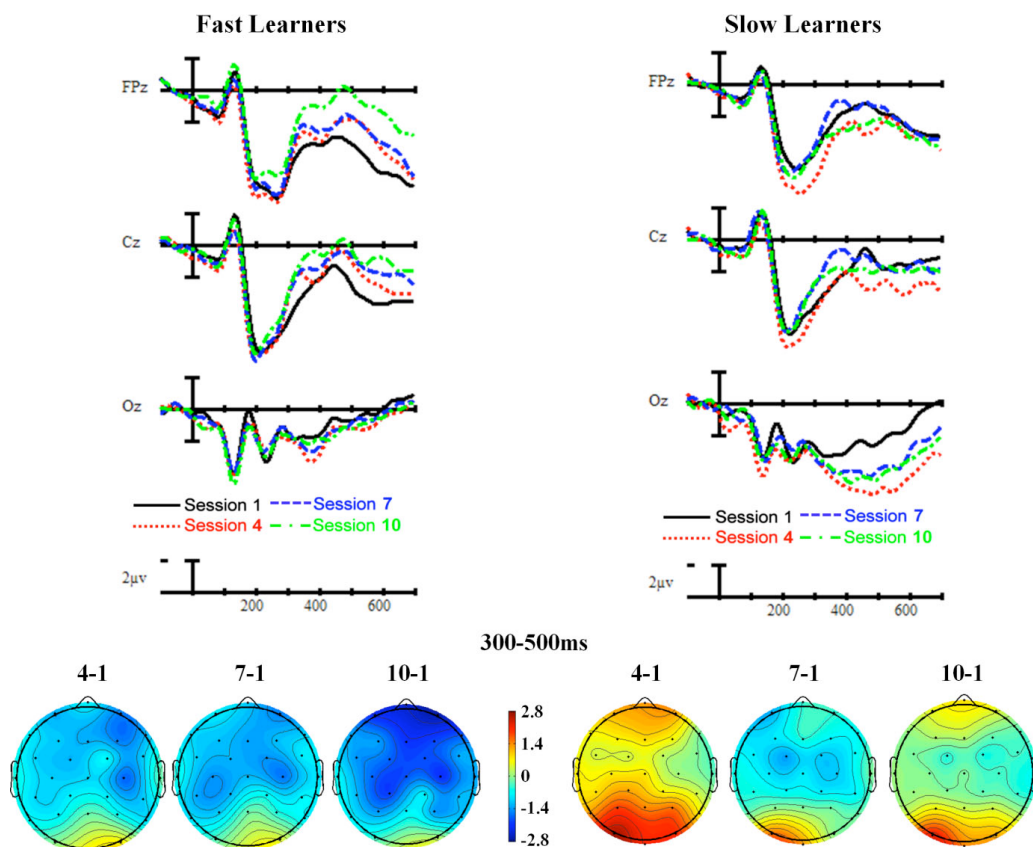
než na jeho pravopis.

Druhým úkolem bylo přiřazování slov. Účastníci nemuseli v tomto úkolu odpovídat, ale pouze sledovat přiřazení anglických slov k čínským překladům.

Třetím úkolem byly překlady slov, kde byly prezentovány páry slov a po účastnících se vyžadovala odpověď, zda je překlad správný nebo ne. Třetí úkol byl rozdělen do dvou bloků, a to na překlad z angličtiny do čínštiny a obráceně.

Čtvrtým úkolem byl překlad čínských slov do angličtiny, kde účastníci museli napsat odpověď. Po napsání odpovědi byl zobrazen správný překlad, a to i v případě, když byla odpověď správně. Tento úkol vyžadoval vytvoření překladu a ne pouze poznání čínských slov. Zároveň bylo možné měřit množství naučených čínských slov.

Naměřená ERP u obou skupin ukazují kvalitativně odlišné vzory učení (learning patterns). Pouze rychle se učící se vyznačovali vlevo-lateralizovaným zvýšením amplitudy N170. Dále také pouze rychle se učící vykazovali postupně zvyšující se amplitudu N400 s odlišnou frontální distribucí napětí (distinct anterior distribution). Pomalu se učící vykazovali zadní pozitivní (posterior positive) rozložení napětí se zvětšujícím se průběhem v okcipitálních oblastech (viz obr. 2.6).



Obrázek 2.6: Na obrázku jsou zachyceny mapy napětí u rychle se učících (vlevo) a pomalu se učících (vpravo), které byly získány pomocí mastoid referenční elektrody (reference umístěná na skalpu pod uchem). Tyto mapy byly vypočteny pomocí diferenčních vln lekci 4, 7 a 10 (od naměřených hodnot v těchto lekcích byly odečítány hodnoty z první lekce) v intervalu 300 - 500 ms po stimulu.

Co tyto závěry mohou znamenat, je popsáno detailněji ve zdroji [3], ale jednou z uvedených možností může být, že rychle se učící si dokáží urychleně vytvořit jakousi strukturální reprezentaci čínských slov, do které následně pouze připojují významy mnohem efektivněji než pomalu se učící.

Assessing the Acquisition of a New Skill with Electroencephalography [4]


Tento článek se zabývá posuzováním, zda je možné sledovat osvojování nových zkušeností pomocí EEG. Důraz byl kladen na sledování EEG rytmů (v pásmech α , β , γ , δ , θ) zpracovaných pomocí statistické analýzy PSD, ve kterých byly následně sledovány změny související s učením během měření.

Účastníci experimentu byli posazeni před počítač, kde následně probíhalo měření. Jako nová znalost k učení posloužila Colemakova klávesnice, která se liší v rozložení kláves na klávesnici od standardních (QWERTY a QWERTZ). Testy použité během měření byly použity z online stránek (colemak.com/Typing_lessons), kde každé z těchto cvičení bylo 5x opakováno a probíhalo denně po 11 dní. Následně byly mezi sebou porovnávány naměřené hodnoty z 4., 8. a 11. lekce.



Obrázek 2.7: Rozložení kláves na colemak klávesnici (převzato ze zdroje [4]).

Byly objeveny velké změny (zvýšení/snížení hodnot PSD) v rytmech β a γ mezi všemi sedmi účastníky experimentu (viz obr. 2.8). Takovéto hodnoty jsou v souladu s předchozími citovanými články o změnách v PSD, které souvisí s osvojováním dovedností a fluidní inteligencí. Fluidní inteligence je schopnost jednat a řešit nové problémy, aniž bychom měli jakékoliv předchozí znalosti se související problematikou.



Obrázek 2.8: Na obrázku jsou uvedeny odhady PSD γ rytmu, když subjekt 5 prováděl jedenáctou (poslední) colemak lekci. Červené body označují první opakování, zatímco modré označují páté opakování.

2.8 Shrnutí druhé kapitoly

V této práci se pokusím částečně zobrazit proces učení za pomoci vypočtených PSD z EEG dat, ve kterých byly sledovány změny (dle článku [4]),

které souvisely s učením. Jedná o základní EEG rytmy jejichž frekvence jsou α (8 - 12 Hz), β (13 - 29 Hz), γ (30 - 40 Hz), δ (1 - 2 Hz), θ (3 - 7 Hz). Změny způsobené učením byly největší v hodnotách PSD u rytmů β a γ .

Zajímá mě také, jestli se zvýšená podpora učení projeví na naměřených EEG datech v průběhu experimentu. V následujícím experimentu tedy rozdělím účastníky experimentu na učící se (U) a neučící se (N) a pokusím se sledovat, zda nastanou rozdíly v měřených hodnotách PSD mezi U a N.

3 Experiment

Tato část dokumentu se bude zabývat popisem samotného experimentu a použitých laboratorních pomůcek.

3.1 Návrh experimentu

Nejdříve jsem řešil otázku, jaká činnost není příliš těžká k učení a zároveň není příliš známá. Po delším uvažování jsem zvolil znalost, kterou jsem já osobně ovládal, ale většina lidí okolo mě ne. Jednalo se o hru na hudební nástroj. Ale naučit se hrát na hudební nástroj je poměrně dlouhý proces. Zvolil jsem tedy vlastnost, kterou musí ovládat každý hráč na hudební nástroj a tou je čtení notového zápisu. Rozhodl jsem se tedy s vytvořit experiment, kde úkolem bude se naučit tvorbu názvosloví not.

Osoby účastníci se experimentu byly po dobu dvou týdnů podrobovány měření, ve kterém šlo o určení správného názvosloví notového zápisu podle uvedeného obrázku. Před tím, než probíhala jednotlivá měření, byly všem účastníkům předány podpůrné dokumenty k učení. V experimentu byly používány noty v rozmezí od velkého C až po c3 včetně předznamenání a znamení uvedených u not. Po celou dobu experimentu se používala pouze jedna délka noty a to celá (dlouhá 4 doby).

Měření byla prováděna nepravidelně, ale každý účastník musel absolvovat celkem 5 měření s tím, že mohl být měřen pouze jednou za den. Testy se skládaly ze 2 typů úkolů (viz kapitoly 3.1.1 a 3.1.2), které se mezi sebou navzájem střídaly a dohromady jeden test obsahoval 30 not k pojmenování. Délka jednoho testu byla přibližně 10 minut.

Účastníci byly na začátku rozděleni do dvou skupin a to na učící se (U) a na neučící (N). U učících probíhalo učení každý den, kdežto neučící se začali učit až den před měřením. Všichni účastníci experimentu používali dokument pro podporu učení názvosloví not (viz příloha C.2). Na následujícím obrázku jsou uvedeny termíny měření jednotlivých účastníků.

Id	Datum měření				
	1. Scénář	2. Scénář	3. Scénář	4. Scénář	5. Scénář
1. Účastník - U	4.4.2016	5.4.2016	6.4.2016	11.4.2016	12.4.2016
2. Účastník - U	4.4.2016	5.4.2016	6.4.2016	12.4.2016	13.4.2016
3. Účastník - U	1.4.2016	4.4.2016	7.4.2016	8.4.2016	9.4.2016
4. Účastník - N	12.4.2016	13.4.2016	14.4.2016	15.4.2016	16.4.2016
5. Účastník - N	9.4.2016	11.4.2016	12.4.2016	14.4.2016	15.4.2016
6. Účastník - N	7.4.2016	8.4.2016	9.4.2016	14.4.2016	15.4.2016

Obrázek 3.1: Na tomto obrázku jsou uvedena data jednotlivých měření pro všechny účastníky experimentu.


U jednotlivých účastníků se sledovali i další údaje. Příklady těchto údajů jsou na následujícím obrázku.

Id	Další informace o účastnících				
	Věk	Pohlaví	Nejvyšší předchozí znalost not [1 – 7]	Doba učení [roky]	Doba nepoužívání [roky]
1. Účastník - U	28	Muž	7	0	20
2. Účastník - U	52	Žena	4	4	34
3. Účastník - U	78	Žena	2	42	17
4. Účastník - N	40	Žena	6	2	27
5. Účastník - N	50	Žena	7	0	35
6. Účastník - N	28	Muž	7	0	13

Obrázek 3.2: Příklad dalších informací, které byly sledovány u všech účastníků. U položky nejvyšší předchozí znalost not se jedná o stupnici, kde 1 znamená nevyšší znalost a 7 znamená neznalost.

3.1.1 Úkoly experimentu - první typ


Účastníkovi experimentu byl zobrazen obrázek noty se všemi potřebnými náležitostmi, které jsou nutné pro určení názvu noty. Účastník je poté vyzván k napsání jedno až čtyřpísmenného názvu noty (obr. 3.3). Odpovědi byly v průběhu měření zaznamenávány a na konci došlo k vyhodnocení.



Obrázek 3.3: Takto vypadal úkol prvního typu, kde měl účastník napsat správnou odpověď v programu Presentation.

3.1.2 Úkoly experimentu - druhý typ

Účastníkovi experimentu byl zobrazen obrázek noty podobně jako v prvním případě, ale tentokrát měl účastník k dispozici 8 možných odpovědí, ze kterých právě jedna odpověď byla správná. Zde bylo úkolem účastníka vybrat správný název noty (obr. 3.4). Odpovědi byly zaznamenávány a na konci testu došlo k vyhodnocení.



Vyberte jednu z uvedených možností, která odpovídá názvu noty uvedené na obrázku.

1) e	5) e2
2) h	6) h1
3) a1	7) cis2
4) c2	8) ais1

Obrázek 3.4: Takto vypadal úkol druhého typu, kde měl účastník vybrat správnou odpověď z 8 možností v programu Presentation.

3.2 Implementace experimentu a prototypové měření

Pro jednotlivá měření byly vytvořeny scénáře v programu Presentation od Neurobehavioral Systems. Tento program používá svůj vlastní jazyk pro psaní scénářů (příklad jazyka je uveden na obr. 3.5). Jeden tento scénář obsahuje 30 not. Tyto noty byly rozděleny do 15 úkolů typu 3.1.1 a 15 úkolů typu 3.1.2, které se mezi sebou navzájem střídaly.

```

sub bool key_input (picture pic)
begin
    loop int i = 1;
        string input = system_keyboard.get_input (pic, input_text);
        string total_in;
        input_text.set_caption(" ");
        input_text.redraw();
    until i == 1
    begin
        input = system_keyboard.get_input (pic, input_text);
        i = i + 1;
    end;
    return false;
end;

```

Obrázek 3.5: Zde je uveden příklad jazyka Presentation. Tato subrutina řeší vstup z klávesnice od uživatele. Tento vstup je zároveň zobrazován na obrazovce.

Scénáře byly před ostrým měřením otestovány na dvou prototypových měřeních. Zjištěné nedostatky z těchto měření byly do výsledných scénářů zapracovány. Ostré verze scénářů se již od sebe liší pouze v použitých úkolech (tj. použité noty a možnosti na výběr v úkolu typu 3.1.2).

3.3 Vybavení laboratoře a potřebné nástroje

Experimenty probíhaly na Západočeské univerzitě v Plzni v budově FAV v neuroinformatické laboratoři KIV/NTIS P2. Testy probíhaly ve zvukotěsné komoře, kde účastník odpovídal na promítané otázky pomocí klávesnice. EEG bylo měřeno pomocí EEG čepic, na kterých jsou elektrody rozmístěny podle mezinárodního standardu 10-20. Dále byly na tělo účastníka experimentu připevněny dodatečné elektrody, a to zemní a referenční.

Experimentální scénář byl vytvořen v programu Presentation od Neurobehavioral Systems. Naměřená data byla zpracována v modulech EEGLab a ERPLab pro Matlab. Obrazy notového zápisu byly vytvořeny programem MuseScore.

3.3.1 Verze použitého softwaru

- **Presentation** – 18.3 03.11.16
- **MuseScore** – 2.0.2
- **Matlab** – R2010b

- EEGLab – 12.0.2.6b
- ERPLab – 5.0.0.0

3.4 Průběh jednotlivých měření

Na začátku měření byli účastníkovi předány dokumenty k vyplnění. Jednalo se zejména o povolení k měření a dotazník obsahující další metadata. Následně byl účastník předpřipraven k měření EEG (zapojení elektrod, namažání vodivým gelem, ...). Poté vstoupil do zvukotěsné komory, kde se posadil do připravené židle. Na monitor v komoře byly po spuštění testu promítány otázky, na které účastník odpovídal pomocí bezdrátové klávesnice. Na konci měření došlo k vyhodnocení výsledků a odpojení účastníka z přístrojů.

Měření se konala od 1. do 16. dubna. Ve všední den probíhala měření od 17.00 do 20.00 a v sobotu od 10.00 do 13.00. Přípravné práce trvaly přibližně 20 minut a dokončovací práce včetně úklidu laboratoře zhruba 45 minut.

4 Zpracování a vyhodnocení naměřených dat


Tato část dokumentu se bude zabývat otázkami, jak byla data pořízena, jak zpracována. Také bude provedena diskuze nad zjištěnými výsledky.

4.1 Pomůcky použité při měření a struktura EEG dat

Data byla pořízena za pomoci následujícího hardware a software. K snímání elektrofyziologických dat byly použity EEG čepice, na kterých byly elektrody rozmístěny podle mezinárodního standardu 10-20 a ze kterých se používalo pouze 16 elektrod (přesné umístění a názvy jsou uvedeny na obr. 4.1). Zároveň byly použity dvě externí elektrody, a to zemní a referenční. Zemní elektroda se nalézala na ušním lalůčku a referenční elektroda byla umístěna u kořene nosu. K namazání externích elektrod a samotné čepice byl použit elektrovedivý gel. Jako EEG zesilovač, do kterého byly zapojeny jak elektrody tak čepice, posloužil V-AMP 16 od firmy Brain Products.

K měřenému EEG signálu byly ještě přidány značky posílané programem Presentation, ve kterém byly jednotlivé scénáře napsány. Značky zaznamenávaly jaký typ úkolu byl řešen, a pokud se jednalo o úkol typu “výběr správné odpovědi“, tak i samotná odpověď byla zaznamenána do dat. Výsledný EEG signál a značky byly nahrávány programem BrainVision Recorder od firmy Brain Products.

Značky, které se přidávaly do záznamu, byly S 1 až S 8, S 10 a S 11. S 10 označuje časový okamžik, kdy byl zobrazen úkol “vyberte jednu správnou odpověď z 8 uvedených možností“, za tímto znakem vždy následuje jedna značka z rozsahu S 1 až S 8. Tyto znaky označují, jakou možnost účastník experimentu zvolil. S 11 označuje úkol typu “napište správnou odpověď“, kde bylo úkolem napsat název noty ze zobrazeného obrázku. U psaných odpovědí se odpověď v datech nesledovala. Za značkou S 11 vždy následuje S 10.



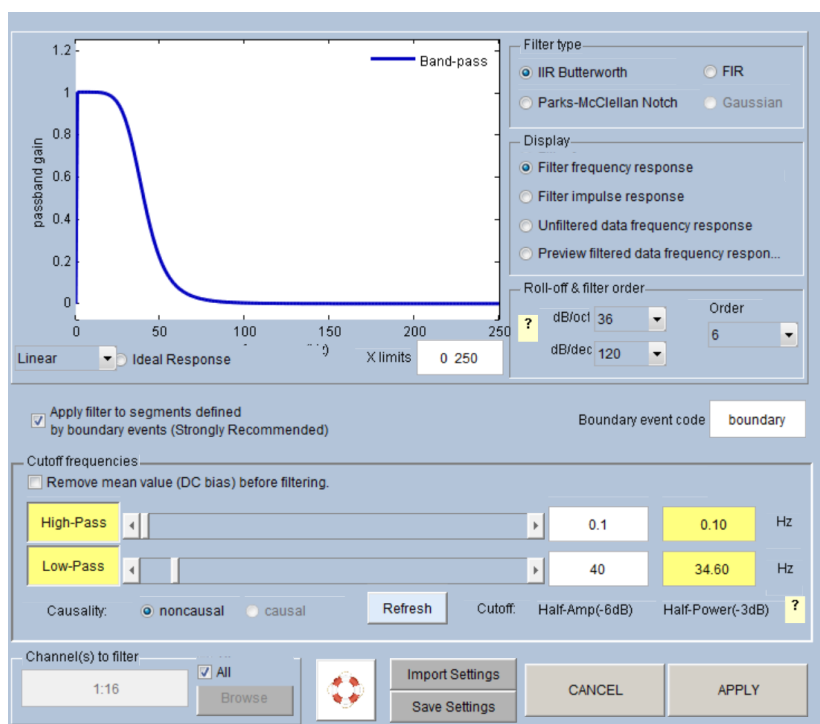
Obrázek 4.1: Na tomto obrázku jsou uvedeny jednotlivé pozice a názvy elektrod, které byly použity k měření EEG v tomto experimentu.

4.2 Předzpracování dat

Samotné předzpracování a následná analýza probíhala již v modulech EEGLab a ERPLab pro Matlab.

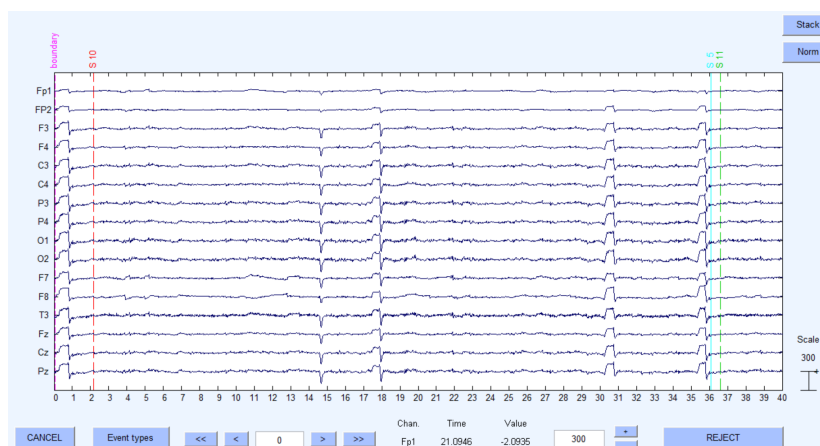
4.2.1 Filtrace

Data byla nejdříve jednou vyfiltrována pomocí filtru (ERPLab) pro kontinuální EEG data. Jednalo se o frekvenční filtraci typu IIR Butterworth s nastavením odstraněných frekvencí na horní mez (high-pass) 0.1 Hz a spodní mez (low-pass) 40 Hz. Nastavení této filtrace je detailněji uvedeno na obrázku 4.2. Filtrace následně zajišťovala i korekci baseline.



Obrázek 4.2: Na tomto obrázku jsou uvedeny detailnější informace ohledně použité filtrace z prostředí ERPLab pro Matlab.

Po provedení filtrace se stále nalézaly v datech artefakty. Mohlo se jednat například o mrknutí, pohyb jazyka, pohyb rukou a další. K analýze je stále potřeba takovéto chybné a nechtěné části dat odstranit. Jak tato hrubá data vypadala po filtraci, lze vidět na obrázku 4.3.

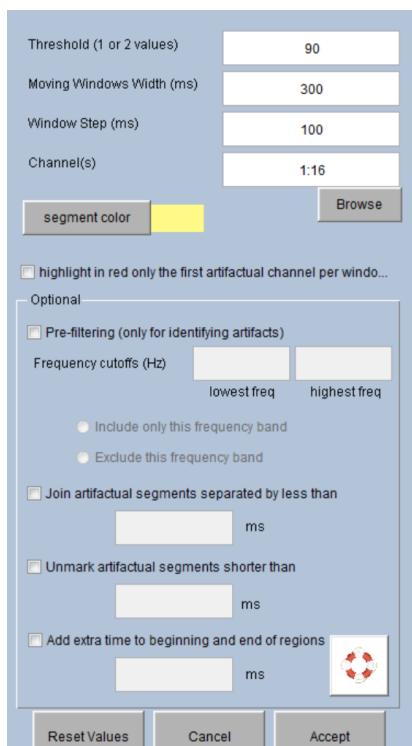


Obrázek 4.3: Na tomto obrázku jsou uvedena hrubá data po filtraci. Velké výkyvy, které vidíte na obrázku, jsou artefakty způsobeném pohybem určité části těla.

4.2.2 Odstraňování artefaktů

K odstranění artefaktů z již vyfiltrovaných dat byl použit algoritmus s pohyblivým okénkem (z modulu ERPLab). Tento algoritmus pracuje na základě “malého“ okénka, které se pohybuje s určitým krokem. Pokud je v tomto okénku nalezena část dat, u které je rozdíl mezi nejnižší a nejvyšší hodnotou (μV) vyšší než nastavená hranice, pak bude tento úsek odstraněn.

Pro předzpracování dat jsem na již vyfiltrovaná data z předešlého kroku spustil automatické odstraňování artefaktů. Parametry tohoto odstraňování artefaktů jsem nejdříve testoval a jejich výsledky ručně kontroloval, zda se u vyznačených úseků skutečně jedná o artefakty. Následně jsem nastavil následující parametry. Přípustnou hranicí byla hodnota $90 \mu\text{V}$ s velikostí okénka 300 ms a krokem 100 ms se sledováním všech měřených kanálů. Jak toto nastavení vypadalo lze vidět na obrázku 4.4.



The image shows a settings dialog box for artifact removal in ERPLab. The main settings are:

- Threshold (1 or 2 values): 90
- Moving Windows Width (ms): 300
- Window Step (ms): 100
- Channel(s): 1:16

There is a 'segment color' selector set to yellow and a 'Browse' button. Below these are several optional checkboxes:


- highlight in red only the first artifactual channel per window...
- Pre-filtering (only for identifying artifacts)
 - Frequency cutoffs (Hz): lowest freq and highest freq (both empty)
 - Include only this frequency band
 - Exclude this frequency band
- Join artifactual segments separated by less than [] ms
- Unmark artifactual segments shorter than [] ms
- Add extra time to beginning and end of regions [] ms

At the bottom are 'Reset Values', 'Cancel', and 'Accept' buttons.

Obrázek 4.4: Na tomto obrázku lze vidět použité nastavení pro odstraňování artefaktů v prostředí ERPLabu.


Bohužel po jednom spuštění tohoto algoritmu nedošlo k odstranění všech artefaktů, bylo tak třeba spustit odstraňování artefaktů několikrát. Artefakty byly odstraňovány tak dlouho, dokud se již žádné artefakty nepo-

dařilo pomocí tohoto algoritmu nalézt. Jak se detekce artefaktů projevila na datech lze vidět na obrázku 4.5.



Obrázek 4.5: Na tomto obrázku lze vidět, jak se detekce artefaktů projevila na datech. Červené části dat jsou označeny pro odstranění. I když se objevil artefakt pouze na jednom kanálu (např. T3), tak byl tento kousek dat odstraněn ze všech kanálů.

Poté, co byly z dat odstraněny veškeré artefakty, které odpovídaly nastaveným parametrům, jsem přistoupil k samotné analýze. Jak data po vícenásobném spuštění detekce artefaktů vypadala je zobrazeno na obr. 4.6.



Obrázek 4.6: Značky boundary (černé svislé čáry) na tomto obrázku znázorňují oblast, kde byl detekován artefakt a byl vyříznut.

4.2.3 Výsledná kvalita zpracovaných dat

Na následjícím obrázku jsou uvedeny hodnoty původních a vyčištěných EEG dat.

Id	Předpříprava dat		
	Hrubá data – čas [s]	Čistá data – čas [s]	Čistá data [%]
1. Účastník – U – SC01	712,419	586,108	82,270
1. Účastník – U – SC05	633,599	503,062	79,398
2. Účastník – U – SC01	356,119	148,813	41,787
2. Účastník – U – SC05	490,919	233,132	47,489
3. Účastník – U – SC01	777,639	312,855	40,231
3. Účastník – U – SC05	766,439	241,207	31,471
4. Účastník – N – SC01	445,139	226,254	50,828
4. Účastník – N – SC05	557,499	312,368	56,030
5. Účastník – N – SC01	673,359	224,591	33,354
5. Účastník – N – SC05	368,219	116,177	31,551
6. Účastník – N – SC01	1015,559	784,408	77,239
6. Účastník – N – SC05	662,779	371,939	56,118

Obrázek 4.7: Časové délky záznamů EEG před a po očištění pomocí filtrů a automatického odstraňování artefaktů.


4.3 Analýza předzpracovaných dat

Z předzpracovaných dat byly následně vypočteny hodnoty PSD pro jednotlivé kanály a tyto hodnoty byly vzájemně poměřeny mezi hodnotami v prvním a posledním scénáři. Podobně jako tomu bylo v článku [4]. Objevilo se pět následujících vzorů, jak byly tyto křivky PSD proti sobě orientovány.

4.3.1 Objevené vzory


Na následujících obrázcích jsou na ose Y použita logaritmická měřítka a na ose X jsou uvedeny frekvence od 0 do 40 Hz.

P – převážný celkový pokles mezi prvním a posledním scénářem. Jak tento stav vypadal je vidět na obrázku 4.8.




Obrázek 4.8: Vztah typu P mezi křivkami PSD mezi prvním scénářem (červená) a posledním (zelená). Černá zde označuje průměr těchto křivek.

R – převážný celkový růst hodnot PSD v posledním scénáři oproti prvnímu. Tento stav je uveden na obrázku 4.9.




Obrázek 4.9: Vztah typu R mezi křivkami PSD mezi prvním scénářem (červená) a posledním (zelená). Černá zde označuje průměr těchto křivek.

X1 – X1 označuje překřížení prvního typu. Zde převážně docházelo k poklesu nebo kolísání hodnot PSD v první polovině křivky (přibližně do 15-20 Hz) a pak přešlo k následnému nárůstu v hodnotách PSD posledního scénáře v druhé polovině křivky. Tento stav je uveden na obrázku 4.10.



Obrázek 4.10: Vztah typu X1 mezi křivkami PSD mezi prvním scénářem (červená) a posledním (zelená). Černá zde označuje průměr těchto křivek.


X2 – X2 označuje překřížení druhého typu. Zde převážně docházelo k nárůstu hodnot PSD v první polovině křivky (přibližně do 15-20 Hz) a pak přešlo k následnému poklesu v hodnotách PSD posledního scénáře v druhé polovině křivky. Tento stav je uveden na obrázku 4.11.




Obrázek 4.11: Vztah typu X2 mezi křivkami PSD mezi prvním scénářem (červená) a posledním (zelená). Černá zde označuje průměr těchto křivek.

X3 – X3 označuje překřížení třetího typu. Zde převážně docházelo k častému kolísání po celé délce křivky PSD. Překřížení typu X3 si byla velmi

podobná v rámci jednoho účastníka experimentu. Ale každý účastník měl svoji variantu. Příklady těchto variant překřížení X3 jsou vidět na obrázcích 4.12 a 4.13.



Obrázek 4.12: Vztah typu X3 mezi křivkami PSD mezi prvním scénářem (červená) a posledním (zelená). Černá zde označuje průměr těchto křivek. Tato varianta platila pro 5. účastníka - N.



Obrázek 4.13: Vztah typu X3 mezi křivkami PSD mezi prvním scénářem (červená) a posledním (zelená). Černá zde označuje průměr těchto křivek. Tato varianta platila pro 1. účastníka - U.

4.4 Analýza - bodové ohodnocení scénářů

Na konci každého scénáře byly odpovědi vyhodnoceny. Bodování probíhalo tak, že pokud účastník odpověděl správně, dostal jeden bod. V opačném případě nedostal žádný (maximální počet bodů byl tedy 30). Na následujícím obrázku jsou uvedeny body pro různé scénáře pro všechny účastníky experimentu.

Id	Počet bodů				
	1. Scénář	2. Scénář	3. Scénář	4. Scénář	5. Scénář
1. Účastník - U	12	23	29	27	30
2. Účastník - U	2	10	10	11	19
3. Účastník - U	11	19	14	18	23
4. Účastník - N	10	14	17	19	24
5. Účastník - N	27	25	25	27	30
6. Účastník - N	8	27	29	29	30

Obrázek 4.14: Na tomto obrázku jsou uvedena bodová hodnocení pro každého účastníka experimentu v rámci jednotlivých scénářů.

4.5 Analýza - vztahy PSD

Mezi jednotlivými účastníky experimentu byly sledovány následující změny v hodnotách PSD mezi prvním a posledním scénářem. Tyto vztahy jsou popsány pomocí vzorů uvedených v podkapitole 4.3.1. Elektrody jsou na následujícím obrázku rozděleny do dvou skupin, a to na elektrody ve střední oblasti hlavy (horní tabulka) a elektrody umístěné po obvodu hlavy (spodní tabulka). Pozice jednotlivých elektrod na hlavě jsou uvedeny na obr. 4.1.

Id	Elektrody								
	F3	Fz	F4	C3	Cz	C4	P3	Pz	P4
1. účastník – U	P	P	P	P	P	P	P	P	P
2. účastník – U	X1	X1	X1	X1	X1	X1	X3	X1	X1
3. účastník – U	X2	X2	X2	X2	X2	X2	X2	X2	X2
4. účastník – N	X1	X1	X1	X1	X1	X1	X3	X1	X1
5. účastník – N	X3	X3	X3	X3	X3	X3	X3	X3	X3
6. účastník – N	X2	X2	X3	X2	X2	X3	X2	X2	X2

Id	Fp1	Fp2	F7	F8	T3	O1	O2
	1. účastník – U	P	P	P	P	X3	P
2. účastník – U	P	X3	X1	R	X3	P	X1
3. účastník – U	P	P	P	P	R	P	P
4. účastník – N	R	X1	X1	X1	X3	P	P
5. účastník – N	P	X2	X3	X2	P	X3	X3
6. účastník – N	X2	X2	X3	X2	X2	X2	X2

Obrázek 4.15: Na tomto obrázku jsou zaznamenány veškeré změny v hodnotách PSD mezi prvním a posledním scénářem na všech sledovaných elektrodách.

4.6 Diskuze naměřených výsledků

Nejlépejších bodových výsledků dosahovaly v tomto experimentu účastníci 1, 5 a 6.

Zdá se, že u účastníka 1, který patřil mezi učící se, docházelo ve většině případů ke snížení hodnot PSD v 5. scénáři oproti 1. scénáři. To může značit, že porozuměl problematice. Zřejmě proto, že se zároveň průběžně učil, došlo k celkovému poklesu naměřeného PSD. Jednoduše řečeno, odpovědi na promítané otázky nestály tohoto účastníka již tolik energie jako při prvním scénáři. Na většině elektrod u tohoto účastníka převážil vzor P.

U účastníků 5 a 6, kteří patřili k neučícím se, učení probíhalo pouze den před samotným měřením. U každého z nich se projevil jiný dominantní vzor. U účastníka 5 se jednalo o vzor X3 a u účastníka 6 byl dominantním vzorem X2. Toto by mohl být projev toho, že vytváření odpovědí stálo tyto účastníky více energie než u účastníka 1, ale pořád dobře porozuměli nastudované látce.

Domnívám se, že úspěšné naučení látky označují vzory P a X2 s tím, že u vzoru P se jednalo o průběžné učení a u X2 o nárazové učení (případně dril ¹). U typu X3 by se mohlo jednat o zásah podvědomí (např. obrazová paměť), protože výsledky jsou mnohem lepší než průměrné výsledky ², ale

¹Dril – naučení se látky nazpaměť

²Bodový průměr 1. scénáře je přibližně 12 bodů, ale účastník č. 5 dosáhl 27 bodů.

hodnoty PSD kolísají.

Naopak špatné naučení se látky nebo její nepochopení vede nejspíše k vzorům X1 a R. Tyto vzory mohou výslovně poukazovat na nepochopení studované látky, protože v posledním scénáři docházelo vždy k nárůstu PSD než k jejímu snížení oproti prvnímu scénáři. Tak tomu bylo u bodově úspěšnějších účastníků. I přesto ale docházelo u těchto vzorů k postupnému zlepšování. Toto zlepšování ale nebylo tak rychlé jako u bodově úspěšnějších.

5 Závěr

V tomto dokumentu jsem se snažil zjistit, zda je možné pomocí elektrofyziologických dat určit, jestli se člověk něčemu naučil. Podle článku ze zdroje [4] byl zvolen jako nástroj pro sledování učení výpočet PSD z naměřených EEG dat. Zároveň jsme podle tohoto článku měli očekávat změny v hodnotách PSD zejména v β (13 - 29 Hz) a γ (30 - 40 Hz) pásmech.

Účastníci tohoto experimentu byli po dobu dvou týdnů podrobeni pěti měřením. V těchto měřeních se vždy zaznamenávala EEG data i s dalšími značkami z programu Presentation, ve kterém byly tyto scénáře napsány. Účastníci byli na začátku rozděleni do dvou skupin, a to na učící se (U) a neučící se (N). Zjišťovalo se tímto způsobem, zda existuje rozdíl mezi průběžným učením a učením “na poslední chvíli”.

Výsledná naměřená data byla zpracovávána v modulech EEGLab a ERPLab pro Matlab. Naměřená data byla nejdříve předzpracována. Jednalo se o filtraci a automatické odstranění artefaktů. Po tomto předzpracování bylo z dat vypočteno PSD pro všechny kanály. Následně byly mezi sebou poměřovány vypočtené PSD mezi prvním a posledním scénářem na všech měřených kanálech.

V takto zpracovaných datech se objevilo pět vzorů mezi hodnotami PSD z prvního a posledního scénáře. Nejúspěšnějšími účastníky v tomto experimentu byli účastníci 1, 5 a 6. U těchto účastníků byly dominantní různé vzory. Pro účastníka 1 se jednalo o vzor P, pro účastníka 5 se jednalo o vzor X3 a u účastníka 6 se jednalo o vzor X2. Domnívám se tedy, že tyto vzory poukazují na úspěšné pochopení látky, ale s různou úrovní “zapamatování”. Pro typ P se jednalo o průběžné učení a pro typy X2 a X3 o učení “na poslední chvíli”. U ostatních účastníků docházelo také k průběžnému zlepšování, ale ne tak rychlému jako u těchto účastníků.

Dalším krokem této práce by mohla být rozsáhlá analýza účastníků přes všechny sledované scénáře a zakomponování dalších metadat ze sesbíraných dotazníků. Bohužel takto rozsáhlou analýzu jsem vzhledem k časovým podmínkám této práce nebyl schopen vytvořit.

5.1 Poděkování

Chtěl bych poděkovat svému vedoucímu práce Ing. Romanu Moučkovi Ph.D. za neustálou pomoc ve všech fázích mé bakalářské práce a všem doktorandům z neuroinformatického oddělení, kteří mi pomohli zdolat mé nesnáze.

Dále si také přeji poděkovat své rodině za podporu a všem účastníkům experimentu, že se na měření dostavovali včas.

A Seznam zkratek

BCI - Brain-Computer interface

CNS - Centrální nervový systém

EEG - Elektroencefalogram

ERP - Event-Related potential

ERN - Error-Related negativity

ErrP - Interaction error-related potential

FRN - Feedback-Related negativity

PSD - Power spectral density

B Seznam použité literatury

- [1] CHAVARRIAGA, Ricardo, R. MILLAN, José. *Learning From EEG Error-Related Potentials in Noninvasive Brain-Computer Interfaces*, [online], 2010, [cit. 2015-12-7], Dostupné z: <http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=5491194&url=http%3A%2F%2Fieeexplore.ieee.org%2Fiel5%2F7333%2F5545713%2F05491194.pdf%3Farnumber%3D5491194>.
- [2] M. WALSH, Matthew, R. ANDERSON, John. *Learning from experience: Event-related potential correlates of reward processing, neural adaptation, and behavioral choice*, [online], 2012, [cit. 2015-12-7], Dostupné z: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC3432149/pdf/nihms383481.pdf>.
- [3] YEN NA, Yum, MIDGLEY, Katherine J., HOLCOMB, Phillip J., GRAINGER, Jonathan. *An ERP study on initial second language vocabulary learning*, [online], 2014, [cit. 2015-12-7], Dostupné z: <http://onlinelibrary.wiley.com/doi/10.1111/psyp.12183/pdf>.
- [4] GUTIÉRREZ, D., RAMÍREZ-MORENO, M. A., LAZCANO-HERRERA, A. G. *Assessing the Acquisition of a New Skill with Electroencephalography*, [online], 2015, [cit. 2015-12-7], Dostupné z: http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=7146726&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D7146726.
- [5] The society for Neuroscience. *Brain Facts: A primer on the brain and nerve system*, [online], 2012, [cit. 2015-12-12], Dostupné z: <http://www.brainfacts.org/~media/Brainfacts/Article%20Multimedia/About%20Neuroscience/Brain%20Facts%20book.ashx>.
- [6] LUCK, Steven J. *An Introduction to the Event-Related Potential Technique*, 2nd Revised edition, MIT Press Ltd, 2014, ISBN10: 0262525852, ISBN13: 9780262525855.
- [7] Optimize Health, *Harness the Full Potential of Your Brain*, [online], 2015, [cit. 2016-4-15], Dostupné z: <http://optimizehealth.co/?p=1>.

- [8] WordPress, *Structure of a Neuron*, [online], 2013, [cit. 2016-4-15], Dostupné z: http://www.weallhaveuniquebrains.com/brain_microbiology/structure_of_a_neuron/.
- [9] Iskander Kapkayev, *Memory; What it is, and How it is*, [online], 2014, [cit. 2016-4-15], Dostupné z: <http://mfa2014.weebly.com/memory-what-it-is-and-how-it-is.html>.
- [10] TopCounselingSchools, *Neuroplasticity: The Remarkable Ability of Our Brain to Adapt*, [online], 2014, [cit. 2016-4-15], Dostupné z: <http://www.topcounselingschools.org/neuroplasticity/>.
- [11] WikiSkripta, *Elektroencefalografie*, [online], 2016, [cit. 2016-4-25], Dostupné z: <http://www.wikiskripta.eu/index.php/Elektroencefalografie>.

C Přílohy

C.1 Dokument pro sběr metadat k měřením

Samotný dokument začíná na další stránce.

II. Metadata

A. Informace o měřené osobě

Jméno: _____

Příjmení: _____

Věk: _____

Pohlaví (nehodící škrtnout): **Muž** **Žena**

Email: _____

Tel. Číslo: _____

Dominantní ruka (nehodící škrtnout): **Levá** **Pravá**

Fyzické vady (oční, sluchové, ...):

1. Na stupnici od 1 do 7 (1 – velmi dobře, 7 – velmi špatně), jak dobře snášíte stres?

1 - 2 - 3 - 4 - 5 - 6 - 7

2. Na stupnici od 1 do 7 (1 – velmi rychle, 7 – velmi pomalu), jak rychle se dokážete naučit novým věcem?

1 - 2 - 3 - 4 - 5 - 6 - 7

3. Na stupnici od 1 do 7 (1 – velmi rád/(a) , 7 – nerad/(a)), jak moc rád/(a) se učíte novým věcem?

1 - 2 - 3 - 4 - 5 - 6 - 7

4. Měl/(a) jste předchozí zkušenost s hudebním nástrojem nebo notovým zápisem?

ANO NE

Pokud ano, jaké bylo Vaše nejvyšší vzdělání v tomto odvětví:

5. Na stupnici od 1 do 7 (1 – absolutní znalost, 7 – neznalost), jaká byla Vaše **největší** předchozí znalost s notovým zápisem?

1 - 2 - 3 - 4 - 5 - 6 - 7

Jak dlouho jste se notovému zápisu učil, než jste dosáhl této znalosti:

6. Jak dlouho se jste již tuto znalost nepoužíval/(a)?

7. Na stupnici od 1 do 7 (1 – skvěle, 7 – hrozně), jak se právě teď cítíte?

1 - 2 - 3 - 4 - 5 - 6 - 7

8. Na stupnici od 1 do 7 (1 – skvělá, 7 – vyčerpaný/(á)), zhodnoťte Vaši **aktuální** fyzickou kondici.

1 - 2 - 3 - 4 - 5 - 6 - 7

9. Na stupnici od 1 do 7 (1 – žádnou, 7 – velmi špatná), zhodnoťte Vaši **aktuální** psychickou kondici.

1 - 2 - 3 - 4 - 5 - 6 - 7

10. Na stupnici od 1 do 7 (1 – skvělá, 7 – vyčerpaný/(á)), zhodnoťte Vaši **dlouhodobou** fyzickou kondici.

1 - 2 - 3 - 4 - 5 - 6 - 7

11. Na stupnici od 1 do 7 (1 – žádnou, 7 – velmi špatná), zhodnoťte Vaši **dlouhodobou** psychickou kondici.

1 - 2 - 3 - 4 - 5 - 6 - 7

12. Na stupnici od 1 do 7 (1 – extrovert, 7 – introvert), zhodnoťte Vaši sociální aktivitu.

1 - 2 - 3 - 4 - 5 - 6 - 7

Komentář:

B. Informace o měřící osobě

Jméno: Vítězslav

Příjmení: Vacek

Email: vacekvi@students.zcu.cz

C. Informace o experimentu

Název projektu: **Detekce procesu učení z elektrofyziologických dat**

Popis:

- Měřená osoba bude podrobena notovému testu, kde úkolem bude správně pojmenovat uvedené noty.
- Test bude zároveň psán ve dvou typech. První typ je pouze napsat správné pojmenování noty uvedené na obrázku. Druhý typ je vybrání správného názvu noty z 8 uvedených možností.
- Těchto not bude celkem v testu 30. Odhadovaná doba na absolvování testu je 10 minut.

Typ (EEG, ERP, EKG): EEG a ERP

D. Informace o měření

Datum:

Začátek:

Konec:

Komentář:

E. Informace o prostředí

Počasí:

Teplota v místnosti:

Vlhkost vzduchu:

F. Sensory

Název	Umístění	Počet

G. Stimulační protokol

Název: _____

Autor: Vítězslav Vacek

Email: vacekvi@students.zcu.cz

Popis:


C.2 Dokument pro podporu učení notového názvosloví

Samotný dokument začíná na další stránce.

1. Dokument pro podporu učení notového názvosloví

1.1 Co bude úkolem


Vaším úkolem v tomto experimentu bude určovat notové názvosloví, které je zobrazeno na obrázcích. Celkem se v experimentu objevují dva typy úkolů. Pokaždé uvidíte obrázek s veškerými náležitostmi pro určování názvosloví, u kterého buď budete psát samotný název noty a nebo vyberete jednu z osmi uvedených možností. Na následujícím obrázku je uveden příklad, jak bude tento obrázek vypadat.



Obrázek 1: Obrázky se budou skládat ze čtyř částí. První část (modrá) je použitý notový klíč. Druhá část (zelená) určuje jaké jsou použita předznamenání. Třetí část (fialová) označuje takt, ale v celém experimentu budeme používat stejný. A poslední část (béžová) označuje samotnou notu, u které bude třeba určit název (vždy se bude jednat o celou notu).

1.2 Notová abeceda


První věc, kterou si potřebujeme vysvětlit je, jak se vůbec noty nazývají a jak se pohybovat v notovém zápisu. Notová abeceda slouží k zapamatování posloupnosti písmen, která se následně opakují a nebo jdou pozpátku. Na následujícím obrázku uvidíte základní notovou abecedu. Také si všimněte, že noty se umísťují jednou **na linku** a podruhé **do mezery**.



Obrázek 2: Jak vidíte na obrázku, notová abeceda připomíná naši jazykovou abecedu až na jednu malou změnu. Od C do G jsou písmena písmena za sebou řazena ve stejném pořadí v obou abecedách, ale mezi G a H je vsunuta nota A. Notou H končí notová abeceda při růstu a notou C

při poklesu.

Jednou ze zvláštností notové abecedy je, že se neustále opakuje. A to, když roste nahoru, tak se pokračuje v opakování podle notové abecedy (na obr. 2 – C2 označuje začátek dalšího opakování). A když se klesá, tak se jde v notové abecedě pozpátku.



Obrázek 3: Příklad růstu a poklesu v notové abecedě. Jsou zde použity již správné názvy not.

Všimněte si černých označení. Toto je naše výchozí notová abeceda. Když začneme růst, tak po notě **h1** začneme opakovat notovou abecedu od noty **c**, změna nastane pouze v čísle za notou, které se v tomto případě zvětší o jedna - vznikne tak **c2**. Pokud začneme klesat, tak jdeme v notové abecedě pozpátku a zároveň snížíme číslici za notou.

Pokud se dostaneme v číslování na 0, tak se jedná o takzvanou „**malou stupnici**“, tzn. nepoužíváme k označení těchto not žádné číslo a píšeme názvy not malými písmeny. Příkladem malé stupnice zde jsou noty malé **a** a malé **h**. Pokud v notové abecedě klesáme, opakujeme ji pozpátku. Všimněte si mezi notami **c1**, **h**, **a** na obr. 3., že vlastně čteme notovou abecedu pozpátku.

Pod malou stupnicí se nalézají ještě **velká stupnice**. Ta se označuje pouze velkými písmeny bez čísel.


2. Používané značky

V experimentu budeme využívat následující značky.

2.1 Notové klíče (světle modrá část na obr. 1)


Houslové klíče určují v notovém zápisu výchozí bod od kterého se následné noty „odpočítávají“ po směru a nebo pozpátku v notové abecedě. Zapamatujte si jak vypadají.

- 1) **Houslový klíč** – V tomto klíči se používají 4 výchozí body. Těmito body jsou noty **c1**, **e1**, **c2**, a **f2**. Noty **e1** a **f2** leží na spodní a horní lince a noty **c1** a **c2** jsou začátky jednotlivých notových abeced. Na následujícím obrázku jsou tyto noty zobrazeny pomocí houslového klíče.



Obrázek 4: Na tomto obrázku vidíte doporučené výchozí pozice, od kterých se dobře určují další noty v **houslovém klíči**.

- 2) **Basový klíč** – V tomto klíči se také používají 4 výchozí body. Těmito body jsou noty **velké C**, **velké G**, **malé c** a **malé a**. **Velké G** a **malé a** leží na spodní a horní lince v basovém klíči a **velké C** s **malým c** označují začátky notových abeced. Na následujícím obrázku jsou tyto noty zobrazeny pomocí basového klíče.




Obrázek 5: Na tomto obrázku vidíte doporučené výchozí pozice, od kterých se dobře určují další noty v **basovém klíči**. Noty na obrázku (zleva doprava) se nazývají **velké C**, **velké G**, **malé c** a **malé a**.

2.2 Předznamenání (světle zelená část obr. 1)

Určují jak se budou měnit noty v celém notovém zápisu. Je důležité, že i když například uvidíte určité předznamenání na pozici **noty c2** v houslovém klíči, vztahuje se toto předznamenání na veškeré noty, které mají stejnou hodnotu v celém notovém zápisu (tzn. neovlivní to pouze notu c2 ale i c1, c3, c, ...).

V předznamenání se mohou objevit 2 typy značek a to takzvané **křížky** a **béčka**. Zároveň předznamenání, které já říkám **negace**. Negace vlastně ruší jakýkoliv vliv předznamenání. Takže když uvidíte na obrázku negaci, musí se jednat o nějakou z ovlivněných not v předznamenání. Nyní si tato předznamenání rozebereme podrobněji.


- 1) **Křížky** – Zvyšují hodnotu noty o půltónu. To se v názvu projeví tak, že se k běžnému názvu noty připojí koncovka **-is**. Takže když bude například ležet křížek na pozici **c2**. Znamená to, že **místo veškerých not C budou noty CIS**. Na následujícím obrázku uvedu pár příkladů.



Obrázek 6: Na tomto obrázku jsou zobrazeny vlivy křížků v předznamenání. Červené noty jsou ovlivněny předznamenáním, černé noty nejsou ovlivněny vůbec a modré noty jsou ovlivněny předznamenáním, ale zároveň jsou pod vlivem negace, takže se jejich hodnoty a názvy vrací do zpět do původního stavu. Dobře si zapamatujte vzhled symbolu pro negaci.

Všimněte si na obr. 6, že i když jsou křížky na pozicích **c2** a **f2**, tak jsou ovlivněny veškeré noty **c**, **f**. Střed křížku určuje jakou notu ovlivňuje (první křížek nad **f2** – prochází skrze střed křížku linka, druhý křížek **c2** – neprochází skrze střed křížku žádná linka).

- 2) **Béčka** – Béčka naopak snižují hodnotu noty o půltónu. To se v názvu noty projeví tak, že k běžnému názvu noty připojíme koncovku **-es**. Zde jsou však i výjimky, které platí pouze pro béčka a to pro noty E a A. Běžně se pouze přidá koncovka k názvu noty bez označení, ale v případě těchto not by došlo k názvům **ees** a **aes**. Proto se používají odlišné názvy. Pro snížené E je název pouze „**es**“ a pro snížené A „**as**“.



Obrázek 7: Na tomto obrázku jsou zobrazeny vlivy béček v předznamenání. Červené noty jsou ovlivněny béčky v předznamenání. Černé noty nejsou ovlivněny vůbec. Modré noty jsou ovlivněny předznamenáním, ale zároveň jsou pod vlivem negace, takže se jejich hodnoty a názvy vrací do zpět do původního stavu.

2.3 Notová část (běžová část obr. 1)

U samotných not lze také podle pravidel přidávat další znaménka. Tato znaménka mohou být křížky, béčka a negace. Noty, které jsou ovlivněny přeznamenáním, nemohou být již ovlivněny jiným znamínkem než negací.

Tedy pokud máme v předznamenání znamínko pro FIS (nota f s křížkem), tak před všemi notami F může být pouze negace, která vrátí hodnotu zpět na F. Ale znaménka před notami a v předznamenání mohou být různého typu. Takže v notovém zápisu mohou být křížky v přeznamenání, ale i béčka před notou (viz obr. 8). Křížky a béčka mají stejné vlastnosti jako v předznamenání.



Obrázek 8: Na obrázku je zobrazena možná kombinace znamének v přeznamenání a před notou. Na obrázku je nota **as1**.


3.1 Opakování důležitých bodů

- Obrázek se bude skálat ze 4 částí. **Notový klíč, předznamenání, takt a samotná nota.** Takt se nebude v celém experimentu měnit (není třeba se na takt zaměřovat).
- **Notový klíč** pro tento experiment může být buď **houslový** nebo **basový**.
- **Houslový klíč** – výchozí body vhodné pro zapamatování jsou **c1, c2, e1, f2**.
- **Basový klíč** – výchozí body vhodné pro zapamatování jsou velké **C**, malé **c**, velké **G**, malé **a**.
- **Předznamenání** mohou být **křížky, béčka** nebo **nic**. **Křížky** zvyšují hodnotu noty o půl tónu (přidává se **koncovka -is** k názvu noty). **Béčka** snižují hodnotu noty o půl tónu (přidává se **koncovka -es** k názvu noty pokud není ovlivněna nota E nebo A). Pro béčka před notami E nebo A jsou názvy snížených not **ES** a **AS**.
- **Předznamenání** může obsahovat od 3 křížků po 3 béčka. Tyto znaménka budou v obou klíčích znamenat stejné noty. Pro křížky se jedná o noty FIS, CIS a GIS (ovlivněné noty jsou F, C, G). Pro béčka se jedná o noty HES, AS, ES (ovlivněné noty jsou H, A, E).
- Před notou se mohou také nalézat další znaménka a to nezávisle na předznamenání. Znaménka mohou být **křížky, béčka** a **negace**. Křížky a béčka mají stejné vlastnosti jako by byly v předznamenání. **Negace** vrací ovlivněné noty v předznamenání na původní hodnotu. To znamená, že FIS se po negaci vrátí na F.


4.1 Přehled not použitých v experimentu

Na následujících obrázcích ukážu veškeré noty z notové abecedy, které budou využity v experimentu.

4.1.1 Houslový klíč




Obrázek 9: První část základních not v houslovém klíči (tzn bez předznamenání či jiných úprav).




Obrázek 10: Poslední část základních not v houslovém klíči (tzn bez předznamenání či jiných úprav).

4.1.2 Basový klíč



Obrázek 11: První část základních not v basovém klíči (tzn bez předznamenání či jiných úprav).



Obrázek 12: Poslední část základních not v basovém klíči (tzn bez předznamenání či jiných úprav).


5.1 Příklady

Nyní uvedu pár příkladů k procvičení názvosloví not. Řešení jednotlivých příkladů jsou v kapitole 5.2.


1)



2)



3)



4)



5)



6)



5.2 Řešení příkladů

Řešení jsou vždy uvedena na obrázcích zleva do prava.

- 1) c1, fis1, a, ais1, hes1, cis2, d2, fis2
- 2) e1, gis1, hes, a1, f1, fis2, c2, d1
- 3) gis1, d1, h, f1, es2, hes1, es1, c2
- 4) cis, HES, fis, as, f, D, G, HIS
- 5) f, fis, es, AS, C, E, ces, HES
- 6) gis, a, HES, c1, d, e, fis, d1