

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

## Bakalářská práce

# Metody vyhodnocování elektrofyziológických dat

Plzeň 2016

Alena Švelchová

# Prohlášení

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

V Plzni dne 23. června 2016

Alena Švelchová

# **Abstract**

## **Methods for evaluation of electrophysiological data**

This bachelor thesis deals with electrophysiological data processing. The first part focuses on introducing the technique electroencephalography, central nervous system, event-related potentials. The second part of the thesis describes a life cycle of electrophysiological data - experimental design, acquisition, storage, processing and publishing of electrophysiological data. The goal of this thesis is simplification experimental design and realization of future experiments and it will provide a guideline and recommendations for works with elektrophysiologicial data.

# **Abstrakt**

Tato bakalářská práce se zabývá tématem zpracování elektrofyziológických dat. První část práce se zaměřuje na seznámení se základy elektroencefalografie, centrální nervové soustavy, evokovaných potenciálů a jednotlivých složek EEG signálu. Druhá část práce je věnována problematice životního cyklu dat. Podrobněji se zabývá teorií oblasti návrhu experimentu, sběru, zpracování, uchovávání a publikování elektrofyziológických dat. Cílem této práce je usnadnění návrhu a realizace budoucích experimentů a poskytnutí podkladů a doporučení pro práci s naměřenými elektrofyziológickými daty.

# Obsah

<b>1</b>	<b>Úvod</b>	<b>1</b>
<b>2</b>	<b>Úvod do elektroencefalografie</b>	<b>2</b>
2.1	Centrální nervová soustava . . . . .	2
2.2	EEG . . . . .	3
2.3	Artefakty . . . . .	4
2.4	Evokované potenciály . . . . .	4
2.4.1	Komponenty ERP . . . . .	5
<b>3</b>	<b>Životní cyklus dat</b>	<b>7</b>
3.1	Design experimentu . . . . .	7
3.2	Měření . . . . .	9
3.2.1	Potřebné vybavení . . . . .	9
3.2.2	Příprava experimentu . . . . .	10
3.2.3	Průběh experimentu . . . . .	12
3.3	Uchovávání dat . . . . .	12
3.3.1	odML . . . . .	13
3.4	Zpracování dat . . . . .	15
3.4.1	Filtrace . . . . .	15
3.4.2	Segmentace epoch . . . . .	17
3.4.3	Korekce baseline . . . . .	17
3.4.4	Odstranění epoch s artefakty . . . . .	19
3.4.5	Průměrování . . . . .	19
3.4.6	Detekce komponent a EP . . . . .	21
3.5	Vyhodnocení dat . . . . .	22
3.5.1	ANOVA . . . . .	22
3.6	Interpretace výsledků . . . . .	24
<b>4</b>	<b>Zpracování konkrétních dat</b>	<b>25</b>
4.1	Experimenty neuroinformatické laboratoře . . . . .	25
4.1.1	Experiment 1 . . . . .	25

4.1.2	Experiment 2 . . . . .	26
4.1.3	Experiment 3 . . . . .	26
4.1.4	Experiment 4 . . . . .	26
4.2	Použité nástroje . . . . .	27
4.2.1	EEGLAB . . . . .	27
4.2.2	ERPLAB . . . . .	27
4.3	Seznámení se s obsahem souboru dat . . . . .	28
4.4	Zpracování dat . . . . .	29
4.5	Detekce P3 komponenty a určení latence . . . . .	29
<b>5</b>	<b>Interpretace výsledků</b>	<b>33</b>
5.1	Analýza rozptylu . . . . .	33
5.1.1	Výsledky . . . . .	35
<b>6</b>	<b>Závěr</b>	<b>39</b>

**Literatura****Přílohy****A Výsledné křivky signálu****B Obsah přiloženého DVD**

# 1 Úvod

Tato práce se zabývá metodami vyhodnocování a zpracování elektrofyziológických dat. Jejím cílem je usnadnění návrhu a realizace budoucích experimentů a poskytnutí podkladů a doporučení pro práci s naměřenými EEG daty.

Zadáním bakalářské práce je nastudovat problematiku sběru a zpracování vybraných elektrofyziologických dat, seznámit se s neuroinformatickou laboratoří na ZČU a dosavadními experimenty prováděnými v této laboratoři. Na základě získaných poznatků navrhnout a realizovat ucelenou studii nad vybranými elektrofyziologickými daty. Tuto studii nakonec realizovat nad daty konkrétního vybraného experimentu.

Teoretická část se dělí na dvě kapitoly. První kapitola obsahuje seznámení se základy elektroencefalografie, centrální nervové soustavy, evokovaných potenciálů a jednotlivých složek EEG signálu. Druhá je věnována problematice životního cyklu dat. Zabývá se teorií oblasti návrhu experimentu, sběru, uchovávání a zpracování dat a interpretací získaných výsledků. Největší prostor je věnován zpracování dat, na které navazuje praktická část.

V úvodu praktické části je seznámení experimenty prováděnými v neuroinformatické laboratoři Západočeské univerzity. Dále realizuji postup zpracování dat z teoretické části práce na datech konkrétního vybraného experimentu. Závěrem hodnotím a interpretuji získané poznatky a výsledky zpracování dat.

## 2 Úvod do elektroencefalografie

Elektroencefalografie (EEG) je neurofyziologická diagnostická metoda používaná k záznamu elektrické aktivity mozku. Tato aktivita se objevuje mezi 17. a 23. týdnem těhotenství a tyto signály představují nejen funkci mozku, ale odrážejí stav celého těla, což je hlavní předpoklad pro výzkum a práci se signálem EEG.

Elektroencefalografie má největší využití v lékařské praxi, a to v oblasti diagnostiky a léčby neurologických a fyzických abnormalit mozku a zbytku centrální nervové soustavy, kam patří například diagnostika onemocnění mozku (zvláště záchvatových onemocnění jako je epilepsie).

Kromě využití a výzkumů v medicíně má EEG uplatnění i v jiných odvětvích. Probíhají experimenty se zaměřením na mozkovou aktivitu při pozornosti nebo stresu a proniká i do zábavního průmyslu v podobě herních konzolí schopných využívat snímání EEG. [1, 2]

### 2.1 Centrální nervová soustava

Centrální nervová soustava (CNS) je ústřední část nervové soustavy obratlovců a je hlavním řídícím orgánem lidského těla. CNS zajišťuje předávání informace z vnějšího prostředí do organismu i předávání informací uvnitř celého organismu. Všechny přijaté informace okamžitě zpracovává a reaguje na ně. CNS je tvořena nervovými buňkami – neurony, které přijímají, vedou, zpracovávají a odpovídají na signály od ostatních nervových buněk, a gliovými buňkami, které jsou umístěny mezi neurony a mají podpůrnou funkci. [2, 9]

Neuron je tvořen buněčným tělem a výběžky – neuritem a dendrity. Pomocí téhoto výběžků jsou jednotlivé buňky propojeny takzvanými synapsami a probíhá mezi nimi přenos informace v podobě elektrického signálu. Tento signál (akční potenciál) je iniciován senzorickými nervy nebo chemickou reakcí přímo na synapsích. Akční potenciál po přenosu uvolní neurotransmittery, chemické látky, které vytvoří postsynaptický potenciál. Poté, co dojde k vytvoření dostatečného množství těchto postsynaptických potenciálů (a jejich součet překročí kritickou mez), je vytvořen nový akční potenciál, který se

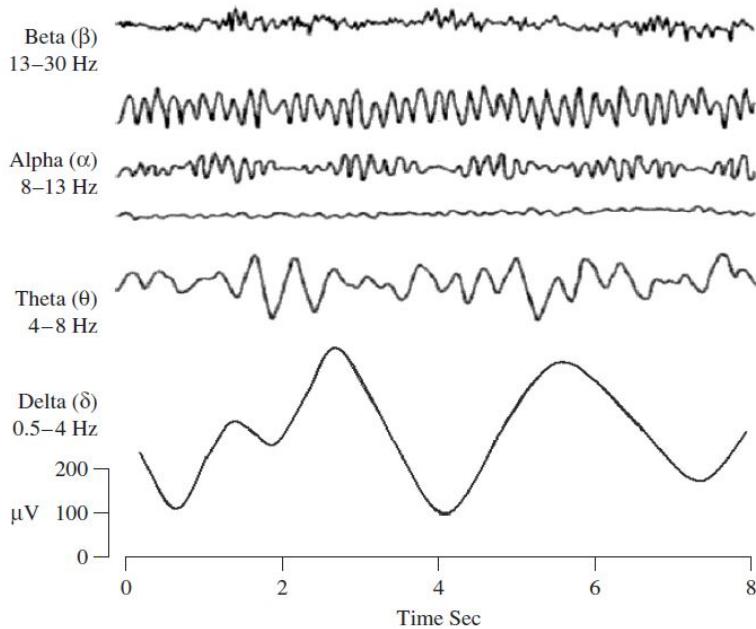
přenáší na další neuron, a šíří tak informaci dále do CNS. Amplituda akčního potenciálu nezávisí na počtu impulzů, které jej vyvolaly, ale uplatňuje princip „vše nebo nic“, což znamená, že se bud' vytvoří nebo nevytvoří, a v případě že se vytvoří, tak je pokaždé stejně velký. Velikost amplitudy závislou na podnětu vzniku mají naproti tomu receptorové potenciály. [2, 9, 12]

## 2.2 EEG

Jedná se o neinvazní metodu záznamu elektrické aktivity mozku, kdy jsou elektrody, které snímají změny polarizace neuronů (elektrické potenciály), umístěny na pokožce hlavy. Amplituda těchto změn se pohybuje v desítkách až stovkách mikrovolt [ $\mu\text{V}$ ]. Zaznamenaný signál je složením stovek aktivit různých neurálních zdrojů, navíc je ovlivněn svalovými aktivitami subjektu a může vzniknout šum a rušení například z elektronických zařízení. Je nutné jej tedy zesílit a vyčistit před dalším použitím. [1, 2]

EEG signály můžeme rozlišit do 4 základních skupin označených řeckými písmeny  $\alpha$ ,  $\beta$ ,  $\delta$  a  $\theta$  dle jejich frekvenčního rozsahu. Každá z těchto skupin patří ke specifické mozkové aktivitě a kromě frekvence mají různou i amplitudu. Můžeme je vidět na obrázku 2.1. [2]

- Alfa rytmus má frekvenci 8 až 14 Hz a projevuje se při relaxaci vleže se zavřenýma očima. Je to nejběžnější a nejvýraznější ze všech rytmů.
- Beta rytmus je spojen s aktivním myšlením, koncentrací, neklidem a stresem. Projevuje se zejména u dospělých jedinců. Pohybuje se v rozmezí 14–30 Hz.
- Delta rytmus se objevuje během hlubokého spánku – nejhlbší fázi spánku zdravého člověka a pohybuje se v rozmezí 0,5 až 4 Hz.
- Théta rytmus je typickým projevem kreativity, fantasie a představivosti. Nejvýraznější je u zrajícího mozku dítěte, u dospělých jedinců se objevuje při usínání, snění a meditaci. Jeho frekvence je 4–8 Hz.



Obrázek 2.1: Základní rytmus EEG (převzato z [2])

## 2.3 Artefakty

Součástí EEG signálu jsou i signály, jejichž původ je jinde než v mozku. Tyto signály nazýváme artefakty a je žádoucí jejich výskyt eliminovat již během měření. Ty, které se v signálu projeví, je nutné odstranit ze signálu před jeho dalším zpracováním. Artefakty mohou být biologického původu – svalová aktivita, pohyb očí, mrkání, tiky, tlukot srdce, nebo se může jednat o signály vysílané přístroji spuštěnými v okolí měřeného subjektu, jako je například rozvodná síť nebo mobilní telefon. Artefakty také mohou vzniknout z měřicího přístroje, a to například kvůli špatnému umístění elektrod, kabelům mezi přístroji, nebo poruše přístroje. [1, 10]

## 2.4 Evokované potenciály

Nervové odpovědi spjaté se specifickými senzorovými, kognitivními nebo motorickými událostmi se nazývají ERP (evokované potenciály, event-related potential) a projevují se jako výrazné změny EEG signálu. Výzkum EEG na ZČU se ubírá právě směrem analýzy a hledání ERP a jejich kompo-

nent. Podněty, které způsobují změnu ERP, se označují jako stimuly. Ty bývají nejčastěji akustické nebo vizuální. ERP je součástí základního signálu EEG a získává se pomocí průměrování signálu. To z něj činí jeden z nejsnáze získatelných signálů EEG. Poté, co ERP získáme, musíme do něj přidat časové značky – markery, které označují místo výskytu stimulu. Protože z jedné reakce nelze vyvozovat žádné výsledky, protože signál je zkreslený jinými mozkovými činnostmi, musíme stimul několikrát opakovat (doporučené množství je 40–60 opakování). Průměrováním se poté ze signálu odstraní ostatní mozkové činnosti, které nesouvisí se stimulem a zůstane pouze reakce na konkrétní stimul.

Amplituda ERP je míra nervové aktivity odpovědi na stimul. Existují dva druhy – měřená od základní linie a nebo mezikrová amplituda. Amplitudu dělíme podle napětí na nízkou (pod  $20\mu\text{V}$ ), střední ( $20\text{--}50\mu\text{V}$ ) a vysokou (nad  $50\mu\text{V}$ ).

Další parametr ERP, který v experimentech sledujeme, je latence. Latence je doba mezi podnětem a zjevným projevem reakce, nulou označujeme okamžik zahájení stimulu. Také můžeme sledovat frekvenci signálu nebo plochu pod křivkou signálu. Nejčastěji analyzovaným parametrem jsou komponenty ERP [viz 2.4.1] – můžeme zaznamenávat přítomnost nebo absenci jednotlivých komponent, jejich amplitudu a dobu trvání. [1, 14]

### 2.4.1 Komponenty ERP

Jednotlivé části ERP signálu označujeme jako komponenty. Jsou to změny signálu v určitých časech, které závisí zejména na typu stimulu, ale ovlivňují je i další faktory. Jednotlivé komponenty nejčastěji nazýváme podle jejich polarity a pořadí nebo času výskytu (N3 = 3. negativní část signálu). Je zvykem pozitivní hodnoty signálu zobrazovat pod osu X.

Nejznámější a nejvýznamnější komponenty a jejich stručný popis [1]:

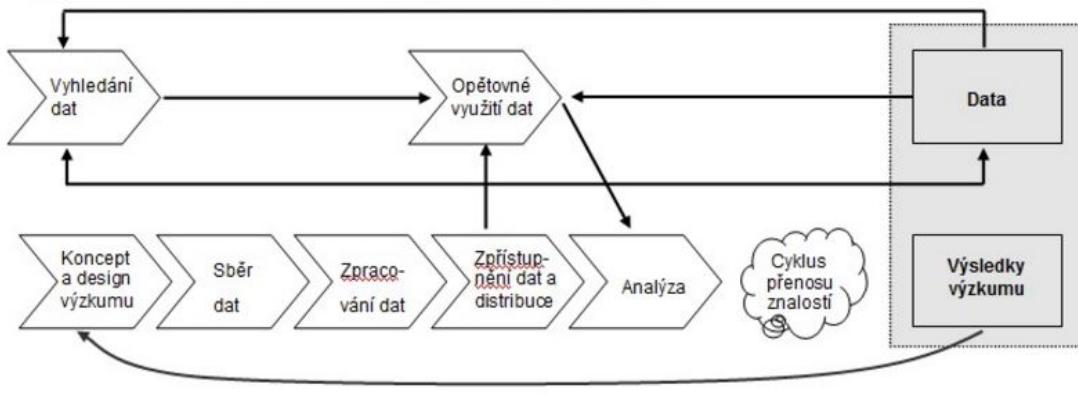
- C1 – Její název nevychází z její polarity, protože ta je proměnná a závisí na stimulu. Nabývá kladné hodnoty pro stimuly v dolní části zorného pole a záporné hodnoty pro stimuly v horní části zorného pole. Obvykle začíná 40–60ms po stimulu a vrcholu nabývá v 80–100ms. Tato komponenta je nejvíce citlivá na parametry stimulů jako je kontrast a frekvence.

- P1 – Následuje hned po komponentě C1. Její latence závisí na kontrastu stimulu, nejčastěji je to 60–90ms a vrcholu dosahuje 100–130ms po zahájení stimulu.
- N1 – Komponenta citlivá na pozornost, která má odlišné vlastnosti pro vizuální a akustické stimuly. Její latence je 100–150ms.
- P2 – Amplituda této komponenty nabývá největších hodnot u stimulů, na které má subjekt reagovat – target stimulů. Nicméně je citlivá na druh stimulu a četnost jeho výskytu. Její latence je 150–200ms. Pro nejvýraznější efekt je třeba volit jednoduché a jednoznačné stimuly a target stimuly používat méně frekventovaně než non-target stimuly (stimuly na které nemá subjekt reagovat).
- N2 – Tato komponenta je složena z několika subkomponent. Základní komponenta N2 je vyvolána opakujícím se non-target stimulem. Zvětšení amplitudy způsobí řidčeji vyskytující se non-target stimuly. Latence této komponenty je 200–250ms.
- P3 – Komponenta P3 je ze všech ERP komponent nejvýraznější. Tvoří ji subkomponenty P3a a P3b, které jsou vyvolány nečekanou a nepravidelnou změnou frekvence a intenzity stimulu, přičemž P3b se objevuje pouze při reakci subjektu. Svého maxima nabývá 250–400ms po stimulu a její amplituda a latence závisí na typu stimulu, stavu subjektu nebo pravděpodobnosti výskytu stimulu.

# 3 Životní cyklus dat

Než začneme s realizací experimentu, musíme si uvědomit, co vše patří do životního cyklu dat a s čím musíme při práci s nimi počítat.

Práce s daty začíná už při plánování projektu, kdy se rozhodujeme, jaká data budeme v experimentu potřebovat, jakou budou mít formu a jak je budeme uchovávat. Také musíme rozhodnout, zda pro experiment použijeme již existující data nebo vytvoříme data nová. Pokud se rozhodneme pro vytvoření vlastních dat, přesuneme se do fáze sběru dat, ve které probíhá samotné měření a úprava signálu do formy vhodné ke zpracování a archivaci. V dalších fázích probíhá distribuce a archivace dat a jejich samotná analýza a interpretace výsledků výzkumu. Poslední částí cyklu je jejich opětovné využití pro další výzkum. Celý cyklus je znázorněný na obrázku 3.1. [11, 13]



Obrázek 3.1: Životní cyklus dat. (převzato z [11])

## 3.1 Design experimentu

Návrh experimentu je nejdůležitější část výzkumu zabývajícího se ERP signálem. Při návrhu experimentu je potřeba zaměřit se na cíl experimentu a tomu přizpůsobit návrh stimulů, výběr vhodných subjektů a volbu vhodné strategie vyhodnocování dat.

Při navrhování je zapotřebí uvědomit si několik základních pravidel. Pro posouzení efektu stimulu je potřeba získat ERP signály od subjektů, které

stimulu byly vystaveny, i od subjektů, které stimulu vystaveny nebyly. Výběr, které subjekty budou vystaveny stimulům, by měl být náhodný. Rozdělení subjektů do skupin, které vykazují podobné vlastnosti (věk, rozpoložení, pochlaví, zdravotní stav atd.), usnadní zpracování signálu. Experiment může zkoumat vliv více faktorů a každý experiment musí být navržen tak, aby umožňoval posoudit nezávisle vliv každého z jednotlivých stimulů. Vícenásobné opakování měření umožní posoudit náhodnou variabilitu naměřených dat a zpřesnění měření. [1]

Vybrat správnou strategii interpretace ERP komponent je jedna z nejzásadnějších věcí. Steven Luck ve své knize [1] nabízí několik možností.

- Soustředit se na jednu konkrétní komponentu, protože na jedné komponentě jsou změny snáze detekovatelné než na celé křivce signálu.
- Použít již dříve použité a dostatečně prostudované metody výzkumu.
- Soustředit se na velké a dominantní komponenty.
- Izolovat komponenty pomocí rozdílných křivek tak, že porovnáme křivky pro jednotlivé typy stimulů a na základě jejich rozdílností izolujeme vybrané komponenty.
- Soustředit se na komponenty, které jsou snadno izolovatelné.
- Navrhnut experiment nezávislý na konkrétní komponentě.

Luck také definuje pravidla, která napomáhají vyhnout se špatné interpretaci signálu:

- Vrcholy signálu a komponenty nejsou totéž. Komponenty nenajdeme v lokálních extrémech signálu a je potřeba správně určit jak a kde v signálu komponenty hledat.
- Je nemožné odhadnout zpoždění a latenci komponent z jedné ERP křivky. Pouze z jednoho vzorku nemůžeme rozeznat vztah mezi stimulem, tvarem křivky a komponenty.
- Je nebezpečné vyvozovat výsledky experimentu pouze z naměřených signálů. Změny amplitudy mohou mít i jinou příčinu než předpokládáme.

- Rozdíly mezi vrcholy amplitudy nutně nesouvisí s rozdíly velikosti komponent a rozdíly latencí vrcholů amplitudy nemusí souviset se změnami časování komponent.
- Nemůžeme předpokládat, že zprůměrovaná ERP křivka reprezentuje individuální měření, ze kterých byla průměrována.

## 3.2 Měření

### 3.2.1 Potřebné vybavení

Před realizací samotného experimentu je třeba seznámit se s chodem laboratoře, kde bude experiment probíhat, zajistit všechny prostředky nutné pro experiment a naučit se je ovládat. Pro eliminaci co největšího množství artefaktů v budoucím signálu je nezbytné, aby laboratoř byla dostatečně odhlučněná místo a prostor, ve kterém se nachází subjekt během měření, by měl být elektricky stíněný, aby nedocházelo k ovlivňování napětí na měřících přístrojích. Kromě hardwarového a softwarového vybavení pro měření a následné využití získaných dat zde nesmí chybět teploměr pro zaznamenání teploty během měření a měřič vlhkosti vzduchu.

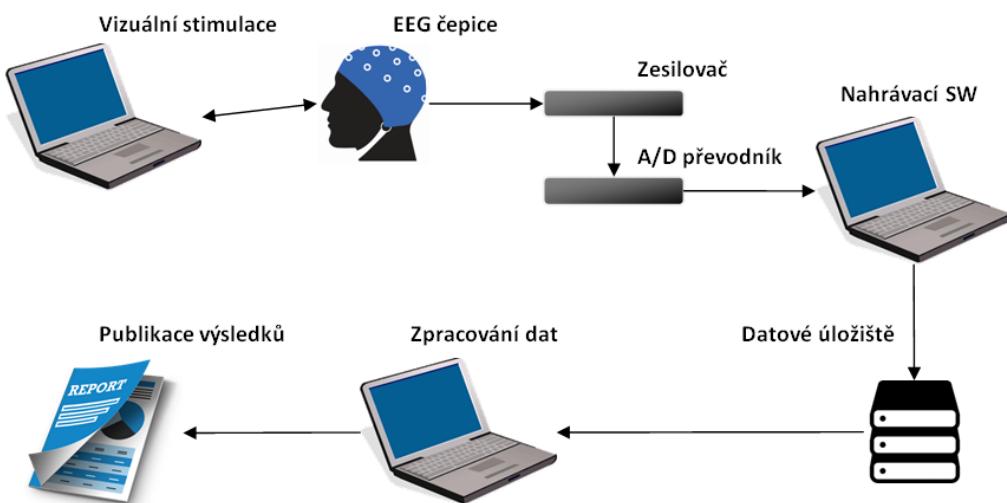
K uskutečnění experimentu je potřeba mít alespoň dva počítače. Jeden pro prezentaci stimulů a záznam časových značek a druhý pro nahrávání EEG. Je možné použít další počítač k monitorování subjektu (např. video a audio záznam, měření tepové frekvence), což nám pomůže v odhalování artefaktů a nebo k úpravě umístění časových značek.

Existují různá měřící zařízení, která se dají použít k realizaci experimentu. Nejběžnější a nejdostupnější zařízení je standardní EEG čepice. Jsou i bezdrátová zařízení, subjekt tedy nemusí nezbytně sedět, či ležet, ale může se během měření pohybovat, což přináší další možnosti při návrhu scénáře. Kromě neinvazivních přístrojů existují i invazivní, které se ale používají v lékařském prostředí.

Mezi počítačem a měřícím zařízením musí být zesilovač, který elektrické potenciály snímané z pokožky zesiluje před zpracováním softwarem v počítači. Výběr vhodného zařízení a jeho nastavení záleží na scénáři experimentu a na tom, jaká data budeme analyzovat.

Analogový signál ze zesilovače je nutné digitalizovat. K převodu analogového EEG signálu na digitální slouží zařízení nazývané analog-to-digital converter (ADC). Některé zesilovače jsou vázané k podporovanému digitalizačnímu programu. Obrázek 3.2 zobrazuje schéma sběru dat a jejich dalšího zpracování.

Pro analýzu dat existuje mnoho komerčních i nekomerčních programů, které nemusí vždy poskytovat požadovanou flexibilitu, proto je důležité ověřit si, zda možnosti zvoleného programu splní naše požadavky na analýzu dat. Pro vědecké účely je možné vytvořit si vlastní analyzační program, který bude vytvořen přesně na míru požadované analýzy. Je vhodné použít program vytištěný ve vývojovém systému, určenému pro zpracování numerických operací s poli a maticemi, jako je například MATLAB. [5, 6]



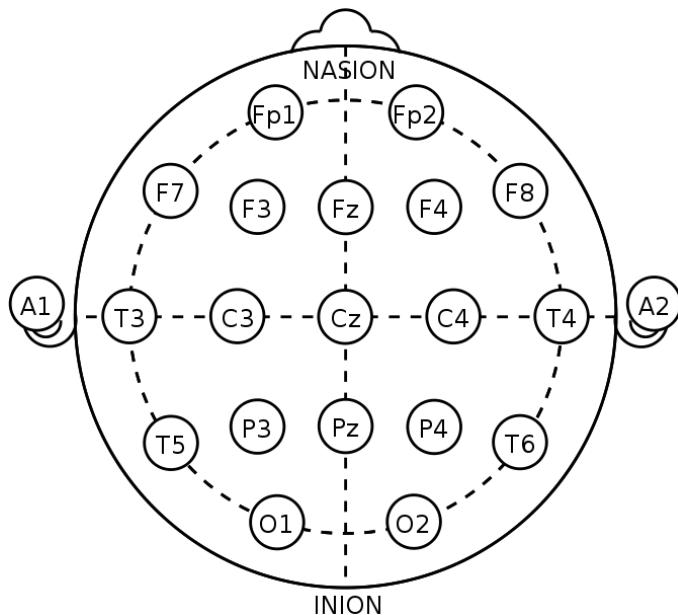
Obrázek 3.2: Schéma sběru dat a jejich dalšího zpracování.

### 3.2.2 Příprava experimentu

Před experimentem je potřeba všem vybraným subjektům předložit nebo zaslat informace o měření a požadavcích na subjekt. Ten s podmínkami musí souhlasit v plném rozsahu, což před prvním měřením stvrdí podpisem informovaného souhlasu. Před prvním měřením proběhne seznámení s ovládáním simulátoru (pokud je to nutné), seřízení všech přístrojů (projektor, měřící přístroje atd.). Subjektu jsou prezentovány stimuly a požadované reakce na

ně a další informace o měření jako je jeho průběh a jeho délka. Po zodpovězení případných dotazů následuje příprava měřícího zařízení. Vzhledem k tomu, že je EEG čepice nejdostupnější a nejběžněji používané zařízení pro získání EEG signálu, budu se v této práci zabývat získáváním EEG signálu s její pomocí. [5]

Při měření pomocí EEG čepice zaznamenáváme signál pomocí 19-ti elektrod, jejich rozložení je na obrázku 3.3. Přímo na EEG čepici je rozmístěno 19 elektrod, další se umisťuje na ucho a slouží jako uzemnění a poslední bývá umístěná na čele (tzv. referenční elektroda). Příprava EEG čepice zahrnuje hlavně mazání elektrod vodivým gellem, který zajistí co nejmenší odpor mezi elektrodou a pokožkou. Ke snížení odporu u referenční a zemnící elektrody je dobré pokožku čela a ušního lalúčku očistit abrazivním gelem. Ideální odpor mezi elektrodou a pokožkou je  $\leq 2k\Omega$ .



Obrázek 3.3: Rozložení elektrod. (převzato z [15])

### 3.2.3 Průběh experimentu

Na začátku experimentu subjekt vyplní krátký dotazník. Zpravidla se jedná o údaje o subjektu, které jsou relevantní pro vyhodnocení experimentu (věk, pohlaví, fyzický stav, zdravotní omezení, atd.). Těsně před započetím experimentu je potřeba překontrolovat veškerá zařízení a zaznamenat podmínky měření (teplota v místnosti, vlhkost vzduchu, čas, atd.).

Spusťme nahrávání EEG signálu a další zařízení monitorující subjekt v případě, že nějaká taková používáme. Po ověření správnosti nahrávání se spustí stimulační scénář. Na začátku by měla být testovací část se všemi stimuly (případě i vysvětlivkami), která slouží k ověření správnosti reakcí na stimuly. Následuje experimentální část scénáře, která by měla začínat i končit delším časovým úsekem bez stimulů. Během měření je potřeba zaznamenávat veškeré nastalé problémy, které by mohly ovlivnit výsledky experimentu, a kontrolovat reakce subjektu a správný zápis časových značek.

Po skončení scénáře se zastaví nahrávání a subjekt je odpojen od zesi-lovače a je mu sundána čepice a obě elektrody. Bezprostředně poté vyplní v dotazníku informace týkající se průběhu měření. Aby v elektrodách nezů-stal zaschlý gel, je potřeba čepici i elektrody vždy dobře umýt. [5, 6]

## 3.3 Uchovávání dat

Získaná data se kromě zpracování musí uchovávat. Hlavními důvody proč se zabývat uchováváním a správou dat jsou zvýšení efektivity výzkumné práce a zajištění zpětné kontroly výsledků. Kromě toho umožňuje sdílení dat pro další použití dat. Pro výzkum zpravidla není žádoucí získávat naměřená data vlastními silami, zvláště když jich je potřeba velké množství, jejichž získání vlastním měřením by výzkumný tým stálo finanční prostředky a čas. Je vhodné umožnit přístup jak k již předem zpracovaným datům, tak k surovým datům.[11, 13, 16]

Pokud získaná data publikujeme a sdílíme, pak je může dále využít jiný experimentátor, aby získal větší vzorek dat, ušetřil čas a prostředky, popř. pro kontrolu vlastních výsledků. Jedná se o takzvanou sekundární analýzu dat, kdy analyzujeme data pořízená pro jiný výzkumný záměr. Problémem je, že aby byla data v ideálním případě použitelná pro libovolný výzkum, musí být archivována v dostatečné kvalitě a univerzálním formátu a musí být sdílená

tak, aby nedošlo k narušení jejich důvěrnosti, integrity a dostupnosti. Pokud se experimentátor rozhodne přistoupit k použití cizích dat, potřebuje kromě dat samotných i informace o tom kde, kým, jak a za jakých podmínek byla data pořízena. Na základě těchto informací identifikuje data vhodná pro svůj experiment. Tato data o datech nazýváme metadata. [11, 13, 17]

Nicméně mnoho z dnešních komerčních záznamových nástrojů používá vlastní datový formát a využívá omezené, konkrétně zaměřené nástroje pro získávání a analýzu příchozích dat. Tento fakt výrazně zpomaluje a znesnadňuje vývoj výzkumu. V současné době se o zavedení jednotného formátu dat (konkrétně formátu odML) zasazuje např. německá výzkumná skupina German Neuroinformatics Node (zkráceně G-Node), která vyvíjí software pro ukládání a analýzu experimentálních dat. [16]

Dalším rozšířeným formátem pro ukládání dat je HDF5 (Hierarchical Data Format 5). Tento formát je (jedinečný) balík technologií, který umožňuje správu velkých a složitých souborů dat.

### 3.3.1 odML

Open metadata Markup Language (zkráceně odML) je iniciativa definovat a vytvořit otevřený, flexibilní a snadno použitelný formát pro uchování a přepravu metadat. Projekt je propojen se staršími softwarovými projektům German Neuroinformatics Node – RELACS<sup>1</sup> a LabLog<sup>2</sup>.

OdML je jazyk sloužící k záznamu metadat. Patří sem zejména data o podmínkách za kterých byla příchozí data získána. Většinu z těchto dat lze sice vyčíst z programu, který byl použitý pro sběr dat, ale téměř každý program používá vlastní formát uchování metadat, nezřídka je ukládá přímo do samotného naměřeného vzorku a tyto informace jsou pak těžko čitelné nebo se mohou úplně ztratit.

Povědomí o existenci naměřených dat a jejich dostupnost k opětovnému zpracování je přímo úměrná kvalitě jejich metadat. Pouze kvalitně popsaná a dokumentovaná data mohou být vícenásobně použita. Uchovávat data, o kterých nevíme, za jakých podmínek a kdy byla získána, popř. neumíme

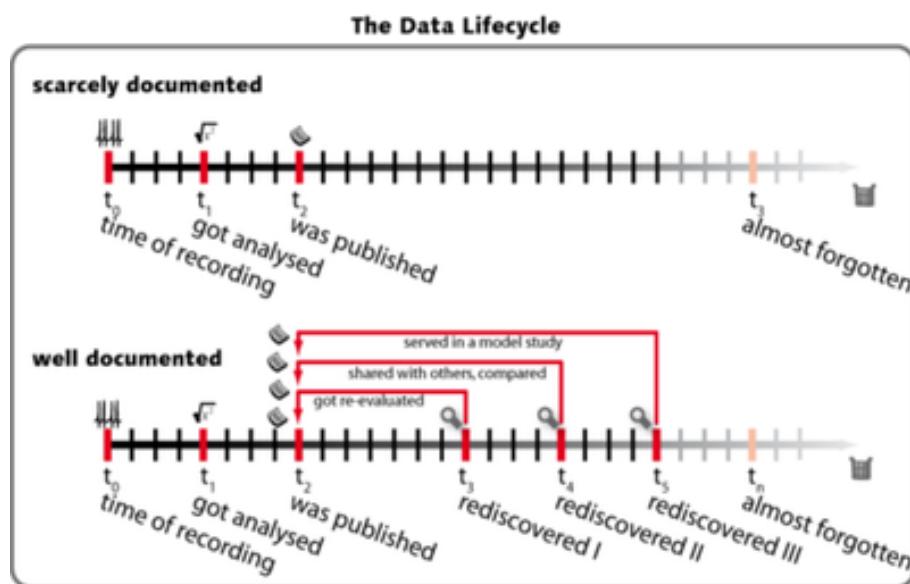
<sup>1</sup>RELACS je projekt Jana Bendy zaměřující se na získávání elektrofyziologických dat. [20]

<sup>2</sup>LabLog ze zabývá projektovou dokumentací a správou dat. Jeho autorem je Jan Grewe. [21]

identifikovat a zpracovat jejich formu, nemá smysl, jsou mnohem rychleji zapomenuta. Rozdíl mezi daty s kvalitními a nekvalitními metadaty ilustruje obrázek 3.4. [17]

Formát vhodný pro anotaci a sdílení dat musí splňovat tyto požadavky:

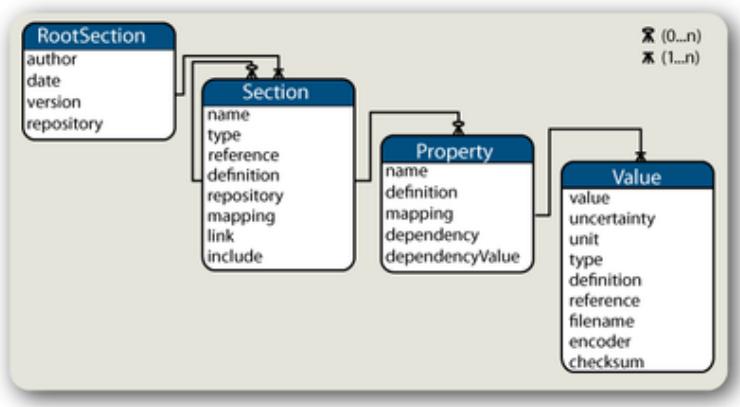
- Je snadno použitelný a jasně čitelný.
- Lze ho implementovat do jakékoli záznamu dat, analýzy a nástroje pro správu.
- Je otevřený a volně dostupný.
- Je snadno rozšiřitelný a flexibilní pro změny.
- V ideálním případě není omezený uživateli či zadáním experimentu.



Obrázek 3.4: Životní cyklus dat. Zdroj: [17]

Kromě jednotného formátu dat a metadat je potřeba zavést i jednotnou terminologii. Terminologie obsahující jména a definice položek metadat a návod, jak je využívat, jsou uvedené na webových stránkách G-Node (viz [18]).

Datový model odML (viz obrázek 3.5) definuje 4 entity - RootSection, Section, Property a Value a je navržen tak, aby byl co nejjednodušší a snadno přenositelný a přizpůsobitelný. Jádrem modelu jsou entity Section a Property.



Obrázek 3.5: Datový model odML. Zdroj: [19]

## 3.4 Zpracování dat

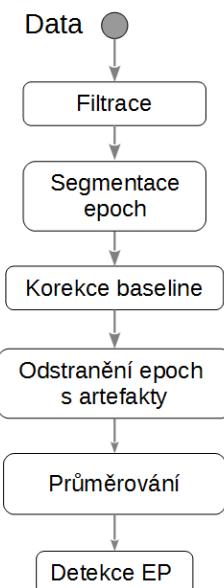
Surová elektroencefalografická data se zpracovávají v několika krocích. Celý proces můžeme vidět na obrázku 3.6 na straně 16. Tyto kroky mají za úkol zbavit signál nežádoucích frekvencí, šumů, artefaktů a nežádoucích individuálních výkyvů signálu a rozdělit signál na jednotlivé epochy. Dále se z něj získává ERP a EP. Teprve zpracované signály jsou porovnatelné mezi sebou (např. mají jednotný formát, značení a velikosti epoch, neobsahují nežádoucí frekvence) a je možné je vyhodnocovat, tak aby výsledek experimentu nebyl ovlivněn nežádoucími vlivy. [3]

### 3.4.1 Filtrace

Filtrací se ze signálu odstraní nežádoucí frekvence. Například pokud nás zajímá ERP potřebujeme z celého spektra EEG signálu pouze dílčí vlny a igno-

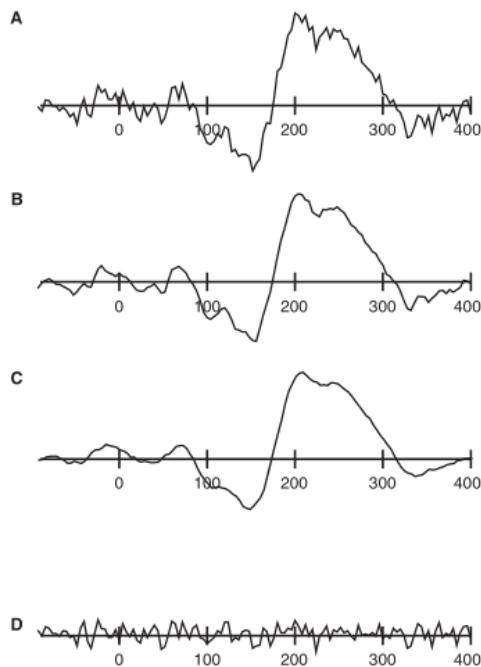
rujeme např. základní aktivity mozku (alfa a beta vlny). Nejčastěji používané filtry:

- low-pass filtr - odstraní vysoké frekvence, ponechá nízké frekvence
- high-pass filtr - odstraní nízké frekvence, ponechá vysoké frekvence
- band-pass - odstraní vysoké a nízké frekvence, ponechá střed, tzv. pásmová propust'
- notch filtr - odstraní frekvence zadaného rozsahu, ponechá vysoké a nízké frkvence



Obrázek 3.6: Schéma procesu zpracování dat. Zdroj: [3]

Příklad aplikace některých filtrů je zobrazen na obrázku 3.7. Křivka A je naměřený signál před použitím filtrů. B zobrazuje signál A filtrovaný pomocí průměrování napětí v jednotlivých časových bodech signálu s napětím v sousedících bodech. Křivka C je také výsledek filtrace signálu A pomocí průměrování napětí v jednotlivých bodech, tentokrát však s napětím ve třech následujících a třech předchozích bodech. Křivka D byla vytvořena použitím high-pass filtru, konstruovaného odečtením filtrované křivky C od nefiltrované křivky A. Podrobný popis jednotlivých filtrů a jejich aplikace je popsán v publikaci [1].



Obrázek 3.7: Příklad aplikace filtrů. Zdroj: [1]

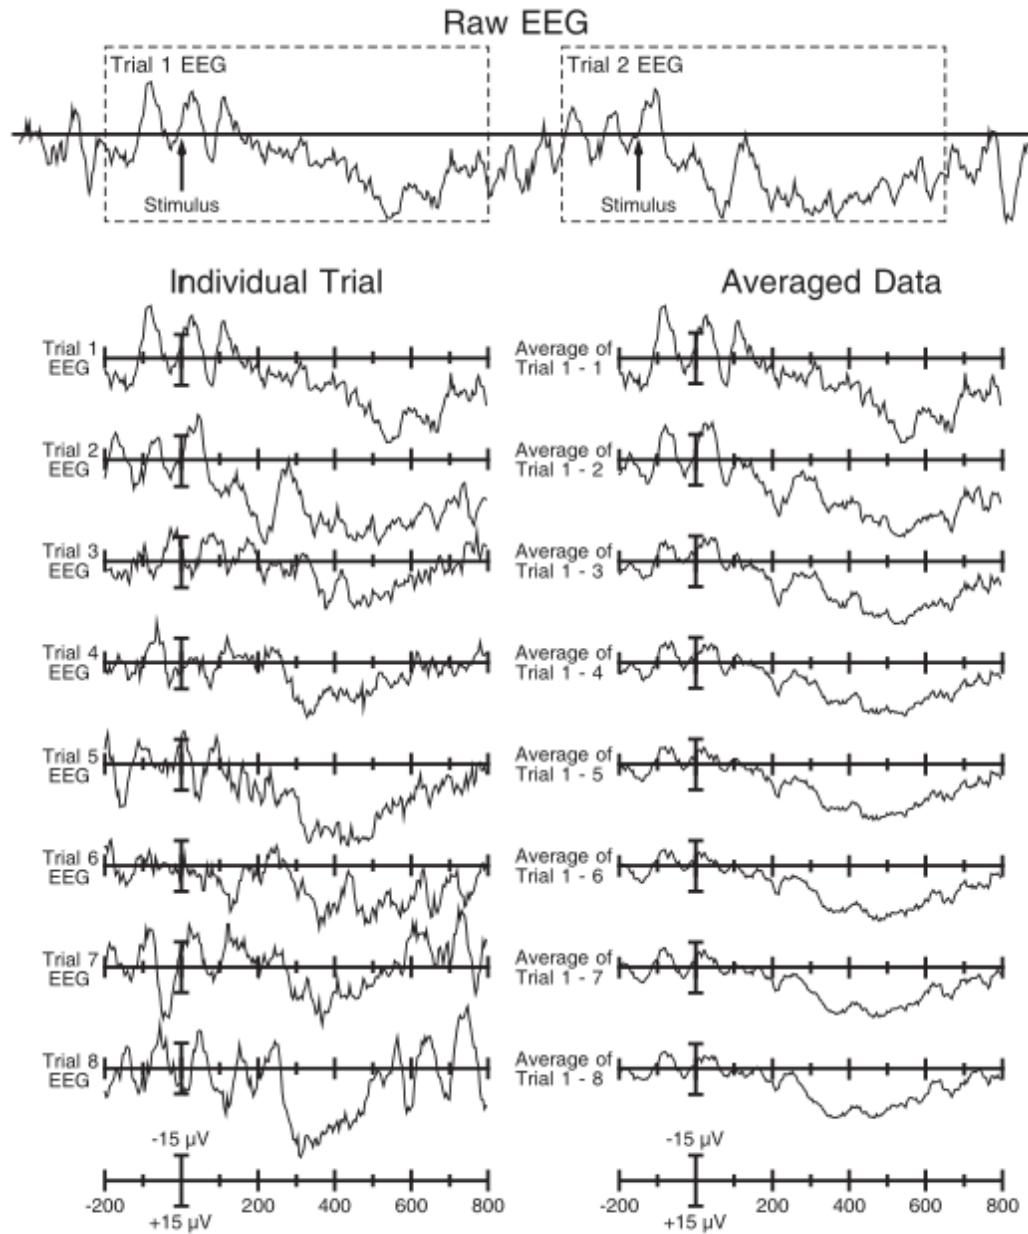
### 3.4.2 Segmentace epoch

Segmentace je rozdělení EEG signálu na stejně dlouhé celky tzv. epochy. Signál se dělí na základě synchronizačních impulsů generovaných při výskytu stimulů. Jako synchronizační impulsy slouží časové značky, které jsme zaznamenávali během měření. Velikost epochy je přímo úměrná délce stimulu a odstupu mezi jednotlivými stimuly. Počátek epochy je například určen 100ms před stimulem a končí 900ms za výskytem stimulu. Všechny epochy pak mají délku 1000ms a mohou se mezi sebou porovnávat (viz Trial 1 a Trial 2 na obrázku 3.8). Jednotlivé epochy se tak mohou průměrovat, čímž z nich extrahuje komponenty.

### 3.4.3 Korekce baseline

Tato korekce odstraňuje nežádoucí změny signálu způsobené např. prostředím při měření (změna teploty nebo vlhkosti vzduchu v průběhu měření), počením subjektu nebo zhoršením přilnavosti elektrod. Pro korekci se používá

např. metoda interpolace, digitální filtrace, nebo waveletová transformace.



Obrázek 3.8: Průměrování. Zdroj: [1]

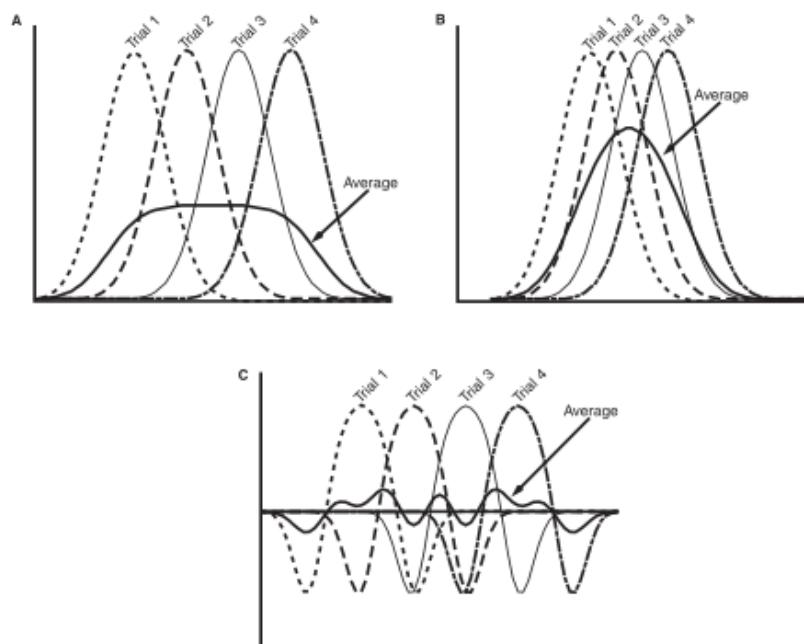
### 3.4.4 Odstranění epoch s artefakty

Ze signálu se odstraní epochy s artefakty. Artefakty se detekují se jako výrazné výkyvy signálu. Artefakty můžeme detektovat pomocí k tomu určených nástrojů (vyhledávání příliš velkých rozdílů frekvencí na daném intervalu) nebo manuálním procházením signálu a hledáním jeho výrazných výkyvů. K manuální detekci je vhodné využít i video nebo audio záznam, ze kterého lze vyčíst některé biologické artefakty (svalová činnost, mrkání, pohyb očí).

### 3.4.5 Průměrování

Pomocí průměrování se odliší ERP signál od základního EEG a od šumu v signálu. Při průměrování se epochy zarovnají podle časových bodů označujících počátek stimulu a postupně se průměrují. Toto schéma je zobrazené na obrázku 3.8. V horní části tohoto obrázku je vidět rozdělení signálu na jednotlivé epochy, v levém sloupci jsou zobrazeny křivky 8-mi epoch signálu srovnанé podle časové značky a pravý sloupec ukazuje efekt průměrování různých počtů těchto epoch. Tato operace vychází z předpokladu, že v každé epoše je určitá míra šumu a signál, který je identický pro všechny epochy. Průměrování odstraní výkyvy způsobené šumem.

Kromě šumů se v této fázi řeší problémy zpoždění latencí komponent, která při průměrování způsobuje zásadní změnu signálu. Po průměrování nejsou odlišnosti jednotlivých latencí komponent na pohled znatelné, i když způsobují jeho zásadní změnu. Průměrné velikosti amplitud, které mají různou latenci a stejný nebo velice podobný průběh se oproti jednotlivým originálním amplitudám zmenší a naopak délka vlny se zvětší. Vliv rozdílu velikostí jednotlivých latencí na výslednou křivku je zobrazen na obrázcích 3.9 A a 3.9 B. Příliš velké rozdíly latence mohou vést i ke ztrátě původního signálu (viz obrázek 3.9 C). Samozřejmě existují metody, které nejsou ovlivňované latencí, popř. přímo slouží ke zmírnění jejich negativních vlivů na tvar výsledné křivky. Patří mezi ně například měření plochy pod křivkou, Woodyho technika filtrování nebo technika Time-locked spectral averaging. Všechny tyto metody jsou blíže popsány v publikaci [1].



Obrázek 3.9: Problémy proměnlivosti latence. Zdroj: [1]

Další problém může nastat, pokud dojde k překryvání po sobě jdoucích stimulů, čímž je signál znehodnocen. Prakticky dochází k tomu, že subjekt reaguje na nový stimul v okamžiku, kdy nebyla dokončena reakce na předcházející stimul. Pro minimalizaci zkreslení dat je nutné tomuto jevu předcházet volbou vhodného intervalu mezi jednotlivými stimuly a volbou jednoznačných a výrazných stimulů. Zkreslení dat pomáhá zvrátit nízkofrekvenční filtr.

Metod průměrování existuje velké množství. Nejjednodušší metody pracují s aritmetickým průměrem zkoumaných signálů. Další metody využívají vážené průměry lišící se způsobem přiřazování váhových koeficientů dílčím prvkům epoch (vážený průměr, blokově vážený průměr), řazení epoch dle znečištění signálů šumem (průměrování řazením) popř. dle rozmezí mezi minimem a maximem vzorku (průměrování s použitím kritického artefaktu).

Nejběžnější metodou je tzv. Grand average. Tento průměr se používá k průměrování dat z různých ERP souborů. To znamená, že data z jednoho ERP souboru se průměrují s daty z jednoho nebo více jinými ERP soubory ze stejné skupiny měření. Nejčastěji se tento průměr používá k vytvoření celkového průměru ze všech měření, popř. z epoch s jednotlivými stimuly. Také může být použit v případě, že EEG data pro daný subjekt byla roz-

dělena mezi různé EEG soubory (například proto, že byla sbírány během více měření) a pak zpracovávaná odděleně do více ERP soubory. Tato metoda průměrování nelze použít, pokud mají průměrované ERP soubory různé počty epoch a kanálů.

### **3.4.6 Detekce komponent a EP**

K detekci a klasifikaci jednotlivých komponent a EP se nejčastěji používají transformační metody, konkrétně Vlnková transformace (Wavelet transformation) a Huang-Hilbertova transformace, metoda Matching pursuit nebo neuronové síťě.

Vlnková transformace je metoda umožňující získat časový a frekvenční popis signálu a rozklad signálu na nezávislé části. Nejčastěji se aplikuje pro zjištění polohy a délky trvání určitého jevu, konkrétně evokovaného potenciálu [22]. Huang-Hilebrtova transformace rozkládá signál na jednotlivé komponenty. Je navržena tak, aby fungovala pro nestacionární a nelineární data a díky své adaptivnosti se dá snáze aplikovat na složitější soubory dat [23].

Matching pursuit je algoritmus, který libovolný signál rozdělí na součet bázových funkcí. Tyto funkce jsou vybírané z tzv. redundančního slovníku funkcí, dle toho jakou charakteristiku má signál v daném úseku signálu. Využití této metody je popsána v [24].

Hledání komponent pomocí neuronové sítě spočívá v převedení signálu na neuronovou mapu, kde jsou jednotlivé neurony vzájemně propojené. Komponentu pak například detekujeme jako shluk neuronů které jsou si navzájem podobné. [8]

## 3.5 Vyhodnocení dat

Posledním krokem zpracování, nyní již upraveného a vyčištěného ERP signálu, je aplikace statistických metod sloužících k analýze dat, reprezentaci výsledků a jejich následná publikaci. Nejdůležitější statistické metody využívané pro vyhodnocení experimentálních dat jsou metody sloužící k testování statistických hypotéz. Zpravidla porovnáváme dvě skupiny subjektů, jedna skupina byla vystavena zkoumané intervenci (experimentální skupina) a druhá nebyla (kontrolní skupina). Také můžeme skupinu bez intervence vynechat a porovnávat dvě různě ovlivněné skupiny. Statistickou hypotézou rozumíme tvrzení, které se může týkat neznámých parametrů daných funkcí, parametrů a tvaru rozdělení a dalších vlastností souboru dat. Nulová hypotéza vyjadřuje „nulový rozdíl“ mezi testovanými soubory dat, nenulová hypotéza je negací nulové hypotézy.

Cílem většiny experimentů je sledovat účinky daných podnětů na testovaný subjekt. Zajímá nás zda existují rozdíly mezi jednotlivými skupinami subjektů, vytvořenými na základě společných znaků (věk, pohlaví, čas měření..) nebo skupinami podnětů. Tuto problematiku řeší statistické metody porovnávající střední hodnoty signálu<sup>3</sup>, které známe pod názvem analýza rozptylu (zkráceně ANOVA z anglického výrazu Analysis of Variance).

### 3.5.1 ANOVA

Základním úkolem analýzy rozptylu je nalezení hlavních a interakčních účinků jednotlivých faktorů ovlivňujících závisle proměnnou. ANOVA umožňuje separovat zdroje rozptylu v jednotlivých skupinách a dílčí rozptyly vzájemně porovnávat a určovat jejich statistickou významnost. Lze ji použít i opačně, pro zařazení souboru dat do konkrétní skupiny. Předpoklady pro validní použití ANOVA jsou nezávislost jednotlivých měření, normalita dat v každé skupině a homogenita rozptylů uvnitř skupiny.

Existuje řada typů analýzy rozptylu. Nejzákladnější a nejjednodušší je jednofaktorová analýza (anglicky označována jako one-way ANOVA). Používá se v případě, že nás zajímá statistická významnost rozdílu měření, pokud přichází v úvahu pouze jeden faktor (například denní doba měření, analytik).

---

<sup>3</sup>Průměrná hodnota signálu po dobu trvání daného časového intervalu (v našem případě reprezentovaného epochou)

Pokud má tento faktor pouze dvě úrovně je metoda totožná s nepárovým t–testem, který testuje rovnost průměrů ve dvou nezávislých výběrech.

Další typy zahrnují větší počet faktorů (dvoufaktorová ANOVA, multifaktorová ANOVA). Pokud zkoumáme vliv dvou a více faktorů působících na závisle proměnnou rozlišujeme kromě hlavních efektů jednotlivých faktorů i efekty, které jsou způsobeny interakcemi mezi faktory. Implementaci ANOVA pro analýzu EEG dat věnuje ve své publikaci Luck [1] celou kapitolu.

V analýze testujeme nulovou hypotézu o rovnosti středních hodnot ( $H_0 : \mu_1 = \mu_2 = \dots = \mu_n$ <sup>4</sup>) a testování provádíme na základě analýzy vztahů mezi rozptyly jednotlivých skupin měření – pomocí f–testu. F–test porovnává testovací kritérium  $F$  a kritickou hodnotu  $F_{krit}$ . Pokud platí, že testovací kritérium nepřekročí tuto kritickou hodnotu, nulová hypotéza platí.

Testovací kritérium  $F$  počítáme jako podíl výběrových rozptylů. Rozptyl  $s_1^2$  je rozptyl mezi skupinami, tedy rozptyl průměrů jednotlivých skupin kolem celkového průměru. Předpokládáme o něm, že je způsoben jak přirozenou variabilitou, tak působícím faktorem. Rozptyl  $s_2^2$  je rozptyl uvnitř skupin, tedy rozptyl jednotlivých průměrů ve skupině kolem skupinového průměru, který je způsobený přirozenou variabilitou. Výpočty jsou uvedené ve vzorcích 3.1., kde  $n$  je velikost souboru čili počet měření a  $x$  je aritmetický průměr čtverců odchylek jednotlivých hodnot sledované proměnné (viz vzorec 3.1).

$$F = \frac{s_1^2}{s_2^2} \quad s_1^2 = \frac{\sum_{i=1}^n x_i^2 - \frac{\sum_{i=1}^n x_i}{n_1}}{n_1 - 1} \quad s_2^2 = \frac{\sum_{i=1}^n x_i^2 - \frac{\sum_{i=1}^n x_i}{n_2}}{n_2 - 1}$$

(3.1)

Kritická hodnota  $F_{krit}$  je hodnota z tabulky kvantilů Fisher-Snedecorova rozdělení. Tabulkou ve které kritickou hodnotu hledáme určuje zvolená hladina významnosti testu  $\alpha$ . Zpravidla se používá hodnota 0.05 nebo menší. Znamená to, že máme 95% jistotu správného rozhodnutí. Jedná se o pravděpodobnost, že test zamítne nulovou hypotézu, ačkoli je správná (pravděpo-

---

<sup>4</sup> $\mu_1 - \mu_n$  jsou střední hodnoty jednotlivých skupin měření

dobnost chybného závěru je tedy 5%). Kritickou hodnotu pak hledáme v tabulce „Kvantily  $F_{0.975}(\nu_V, \nu_M)$  Fisher-Snedecorova rozdělení“ [26]. Kvantil počítáme jako opačnou hodnotu k  $\frac{\alpha}{2}$  (viz vzorce 3.2).

$$\text{F}_{krit} = F_{1-\frac{\alpha}{2}}(\nu_V; \nu_M) \quad \nu_V = k - 1 \quad \nu_M = n - k \quad (3.2)$$

Pro vyhledání kritické hodnoty pro F-test v tabulce, je nutno stanovit stupně volnosti  $\nu_V$  a  $\nu_M$ . Ty počítáme pomocí počtu skupin měření  $k$  a počtu měření ve skupině  $n$  (viz vzorce 3.2). [25, 27, 28]

### 3.6 Interpretace výsledků

Po provedení analýzy a finálním vyhodnocení dat výsledné závěry publikujeme. Publikační činnost probíhá nejčastěji ve vědeckém časopise, v současné době zejména elektronické podobě, která autora méně omezuje prostorem než papírově vycházející časopis. Součástí vědeckého článku je popis experimentu a jeho záměru, zprávy o použitých metodách a prostředcích, o dosažených výsledcích a jejich interpretace a důsledky. Časopisy se zasadují i o publikaci samotných dat. Některé vyžadují publikaci jak výsledných dat, tak naměřených surových dat. Výsledky výzkumů se pak mohou snáze porovnávat a ověřovat, nebo se dají naměřená data použít pro jiný projekt. To zároveň vyžaduje publikovat i kvalitní metadata, jak je uvedeno v kapitole uchování dat.

Např. Scientific data a Giga Science jsou vědecké časopisy, které se zasadují o uchovávání a publikování dat. Oba autorům článků poskytují datová úložiště pro jejich data a důrazně dbají na kvalitu ukládaných dat a metadat. Tyto časopisy dávají přednost publikaci pouhých dat, jejich analýzu a vyhodnocení nevyžadují.

# 4 Zpracování konkrétních dat

## 4.1 Experimenty neuroinformatické laboratoře

V neuroinformatické laboratoři Západočeské university proběhlo a probíhá množství elektrofyziologických experimentů zaměřených na lidské chování v běžných, stresových i stereotypních situacích nebo na výzkum elektrické aktivity lidského mozku osob se zdravotním postižením. Nejvíce experimentů je zaměřených na sběr a vyhodnocování evokovaných potenciálů (ERP). Vzhledem k tomu, že je v laboratoři k dispozici simulátor automobilu Škoda Octavia, zabývá se velké procento experimentů pozorností řidiče. Níže je uveden stručný popis některých experimentů.

Kromě toho výzkumná skupina poskytuje služby v oblasti sběru, ukládání, popisu, sdílení a vyhodnocování medicínských dat. Jeden z nástrojů k tomu určený je EEG/ERP portál EEGbase, který slouží pro uchovávání, správu a sdílení EEG/ERP dat, metadat, nástrojů a dokumentů vázajících se k elektrofyziologii a experimentátorům poskytuje prostředí pro správu jejich experimentů. [30]

### 4.1.1 Experiment 1

Tento experiment se zabýval výzkumem dyspraxie u dětí, což je porucha motorických dovedností. Experimentální protokol a provedené elektrofyziologické experimenty měli za cíl pokusit se učinit krok směrem k možnosti diagnózy tohoto onemocnění pomocí evokovaných potenciálů (ERP). Druhým cílem experimentu bylo, opatřit získaná nezpracovaná data příslušnými metadaty a podporovat jejich dlouhodobou udržitelnost. Experimentální protokol je založen na zvukové stimulaci za pomocí stimulů představujících zvířata a jejich zvuky. Děti reagovaly na zvukový stimul stisknutím příslušného tlačítka– jedno pro stimul štěkajícího psa nebo mňoukající kočky a druhé pro stimul štěkající kočky nebo mňoukajícího psa. [4]

#### **4.1.2 Experiment 2**

Experiment se zabýval pozorností řidiče s využitím automobilového stimulátoru v závislosti na denní době a spánkové deprivaci. Každý testovaný subjekt absolvoval 4 měření při jízdě v simulátoru. Tato měření probíhala ve dvou dnech, vždy dopoledne a odpoledne. Při prvních měřeních měl subjekt za sebou plnohodnotný spánek (7-8 hodin), druhá sada měření probíhala při spánkové deprivaci, kdy subjekt neměl spát déle než 4 hodiny. Každé měření trvalo 20 minut a řidič reagoval na zvukové stimuly. Cílem experimentu bylo srovnání rozdílů latencí P3 komponenty mezi měřeními se spánkovou deprivací a bez spánkové deprivace a mezi dopoledními a odpoledními měřeními . [5]

#### **4.1.3 Experiment 3**

Práce se také zabývala měřením pozornosti řidiče s využitím automobilového simulátoru. Pro posílení pozornosti řidiče je nutné včas identifikovat ospalost, která je častou příčinou nehod a díky tomu kolizím předcházet. Bylo použito měření EEG/ERP pro detekci ospalosti testovaných subjektů. Scénář experimentu se zaměřil na zvukovou stimulaci řidiče a spolujezdce, během jízdy po monotónní trati v automobilovém simulátoru. [6]

#### **4.1.4 Experiment 4**

Práce zkoumala měření emocí za použití evokovaných potenciálů a navazovala na myšlenku měření pitelnosti piva. Hlavní komponentou obsahující emoční reakce by měl být pozdní pozitivní potenciál, ale dřívější komponenty mohou také obsahovat emoční reakce. Subjektům byly promítány obrázky z mezinárodního emočního obrázkového systému (IAPS), které by u nich měly vyvolat emoce. Obrázky byly rozděleny do 4 kategorií - pozitivní, neutrální, negativní a poslední skupinou byly nezařazené (pivní) obrázky, u kterých se měřily reakce subjektů. [7]

Z těchto prací jsem pro praktickou část, ve které zpracovávám vybraná data, zvolila druhý jmenovaný experiment – práci Vojtěcha Košáre ERP komponenty a pozornost řidiče [5]. Jedná se o práci z roku 2013, takže její podrobnější detaily nemá nikdo v živé paměti, a musím tak vycházet pouze

z textu bakalářské práce a ze samotných dat. To mi poskytuje příležitost ověřit důležitost a kvalitu metadat a možnosti znova-využití dat. Data z tohoto experimentu jsou k dispozici na portálu EEGbase. [30]

## 4.2 Použité nástroje

Pro zpracování signálu jsem použila toolbox MATLABU EEGLAB a jeho plugin ERPLAB. MATLAB je univerzální programové prostředí společnosti MathWorks, které slouží k vědeckotechnickým výpočtům, maticovým počtům nebo např. k analýze, zpracování a prezentaci dat. [31]

### 4.2.1 EEGLAB

EEGLAB je open-source software, který byl vytvořen ve Swartz Center for Computational Neuroscience na The University of California San Diego. Modul obsahuje přehledné GUI, podporuje více formátů importovaných dat, obsahuje funkce pro zpracování signálu zahrnující např. manuální i automatickou detekci artefaktů, rozdělení signálu na epochy, jednoduché filtry a průměrovací metody a zobrazení výsledných dat pomocí interaktivních grafů. Modul je neustále doplňován a obnovován a má rozsáhlou dokumentaci a velké množství návodů, obojí veřejně dostupné na webu. [32]

### 4.2.2 ERPLAB

Plugin ERPLAB je také open-source software, je přímo spjat s EEGLABem a požívá se pro analýzy přímo související s ERP. Jeho vývoj zaštituje The University of California Davis - Center for Mind & Brain s finanční podporou National institut of mental health. Plugin rozšiřuje možnosti EEGLABu o pokročilejší metody filtrování, detekce artefaktů, průměrování a třídění EEG epoch. Vzhledem k tomu, že na zvolených testovacích datech detekují ERP komponentu P3, použila jsem při zpracování signálu především tento modul. [33]

## 4.3 Seznámení se s obsahem souboru dat

Data stažená z EEG/ERP portálu jsou rozdělena do 11 složek, reprezentujících vždy data pro jeden měřený subjekt. Autor data uložil jako jedenáct různých experimentů přiřazených pod výzkumnou skupinou ERP\_Kosar. Každá složka obsahuje složku Data s výstupy jednotlivých měření a soubor metadata.xml obsahující informace o konkrétním experimentu. Z metadat lze vyčíst informace o počátku a konci experimentu (vzhledem k tomu, že měření probíhalo ve dvou dnech soudíme, že se jedná zároveň o konkrétní dny měření), podmínkách měření (teplota, počasí), použitých prostředcích (scénář experimentu, EEG čepice) a informace o měřeném subjektu (věk, pohlaví). Další informace o jednotlivých subjektech a měřeních lze získat pouze z bakalářské práce Vojtěcha Košáře [5].

Složka data obsahuje soubory .avi, .eeg, .vhdr, .vmrk a .fig. Pro zapracování signálu potřebuji soubory .eeg a .vhdr (výstup z měřicího zařízení) a .vhdr, kde jsou zapsány časové značky stimulů. Video soubor slouží pro doplnění informací o měření (např. pro detekci artefaktů jako je mrkání).

Jednotlivé soubory mají názvy ve formátu N\_DD\_M\_RRRR.xxxx, kde N je číslo mezi 1 a 45 a předpokládám, že se jedná o pořadí měření, další část názvu je datum. Vzhledem k tomu, že autor nikde neuvádí hodinu měření, ani zda se jedná o měření s nebo bez spánkové deprivace, mohu při identifikaci měření vycházet pouze z plánu experimentu uvedeného v textu bakalářské práce [5]. Definuji tedy dřívější datum jako měření bez spánkové deprivace a dopoledne a odpoledne rozlišuji dle pořadí měření.

První složka obsahuje pouze měření z jednoho dne, zároveň se jedná o první dvě měření, takže předpokládám, že šlo o otestování scénáře a procesu měření. V textu práce jsou sice uvedeny pro první subjekt výsledky ze 4 měření, ale data k dalšímu dni měření nejsou k dispozici, navíc nemohu s jistotou určit, zda dostupná data reprezentují měření po plnohodnotném spánku, nebo se spánkovou deprivací. Z těchto důvodů jsem tento subjekt do zpracování nezařadila.

## 4.4 Zpracování dat

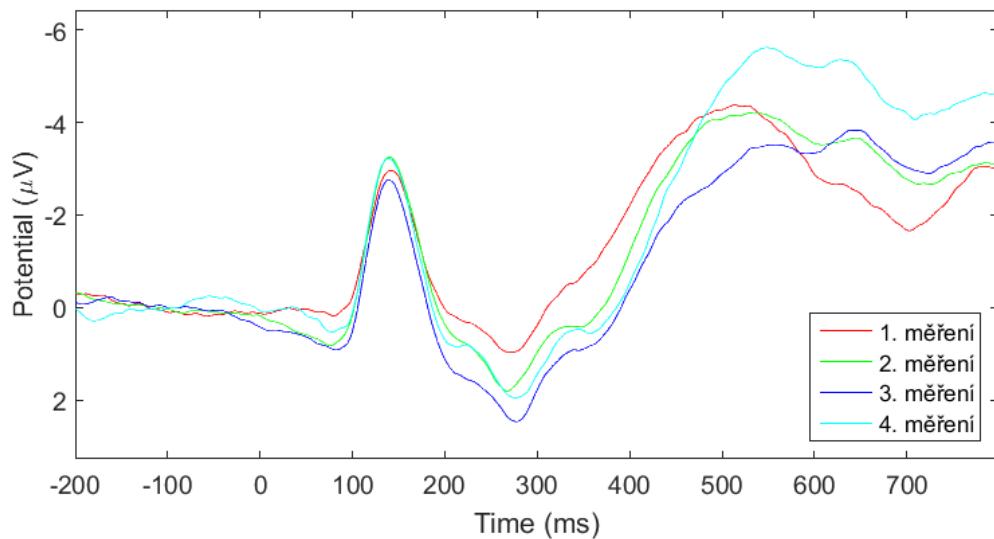
Naměřená data (soubor .vhdr) jsem zpracovávala nástroji poskytovanými EEGLABem a ERPLABem tak, abych se co nejvíce přiblížila teoretickému pracovnímu postupu. První krokem bylo nastavení lokací záznamových elektrod, poněvadž datový soubor EEGLABu musí obsahovat informaci o jejich umístění. Na data byly aplikovány low-pass (20.0 Hz) a high-pass (0.1 Hz) filtry, které odstranily příliš vysoké a příliš nízké frekvence. Dalším krokem byla segmentace epoch, které předcházela tvorba Event listu – souboru, který obsahuje informace o délce jednotlivých epoch a druhu stimulu. Součástí funkce pro extrakci epoch je korekce baseline.

V následujících krocích jsem detekovala artefakty. Použila jsem k tomu jak automatické metody, které vyhledávají a označují výrazné rozdíly a výkyvy v signálu, tak manuální metodu, kdy je nutné vykreslený signál ručně projít a vyznačit segmenty obsahující artefakty. Po tomto procesu je nutné aktualizovat Event list – vybraným segmentům se přiřadí značka pro vyřazení. Nakonec byly zbylé segmenty zprůměrovány, čímž byl získán ERP signál z každého měření.

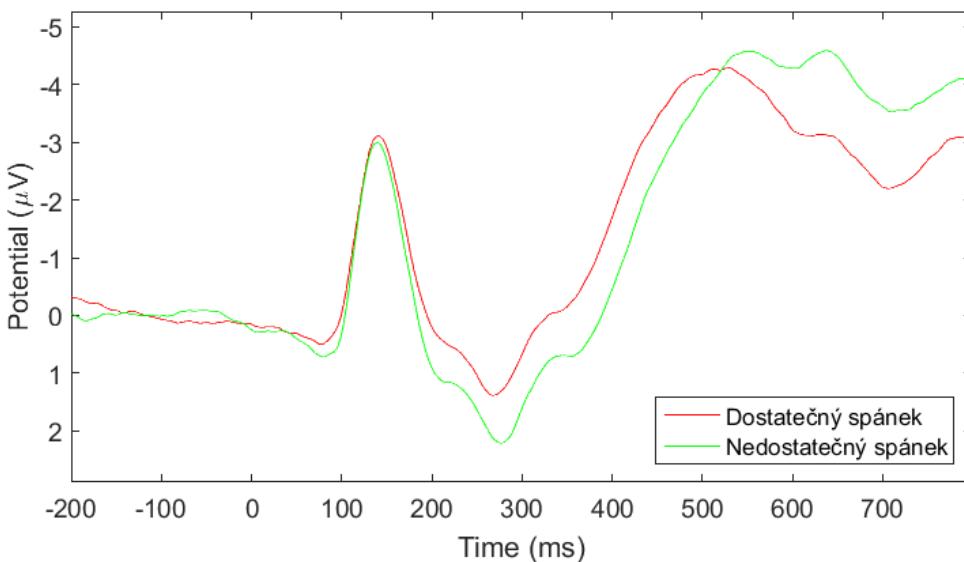
Z těchto ERP signálů byly vytvořeny studie a vypočten grand average pro každé měření a jejich kombinace (viz obrázky 4.1, 4.2 a 4.3). Signál jsem zpracovávala pro všechny elektrody, ale závěrečné průměry a analýzy pouze pro elektrody Fz, Cz a Pz, na kterých je P3 komponenta nejlépe rozeznatelná. Zobrazení výsledných křivek signálů ze zbylých dvou elektrod (Cz a Pz) jsou uvedeny v příloze A.

## 4.5 Detekce P3 komponenty a určení latence

Nejjednodušší způsob detekce P3 komponenty a určení její latence je nalezení jejího maxima a jejich porovnání. Tento způsob detekce je vhodný hlavně pro komponenty, které mají snadno určitelné maximum (resp. minimum), což P3 komponenta ve většině případech splňuje. Tuto metodu nazýváme peak latency. Další metody vyhledávají pomocí výpočtu plochy pod křivkou na intervalu, kde se vyskytuje komponenta, nebo detekují latenci v bodě definovaném jeho poměrem k maximu intervalu.

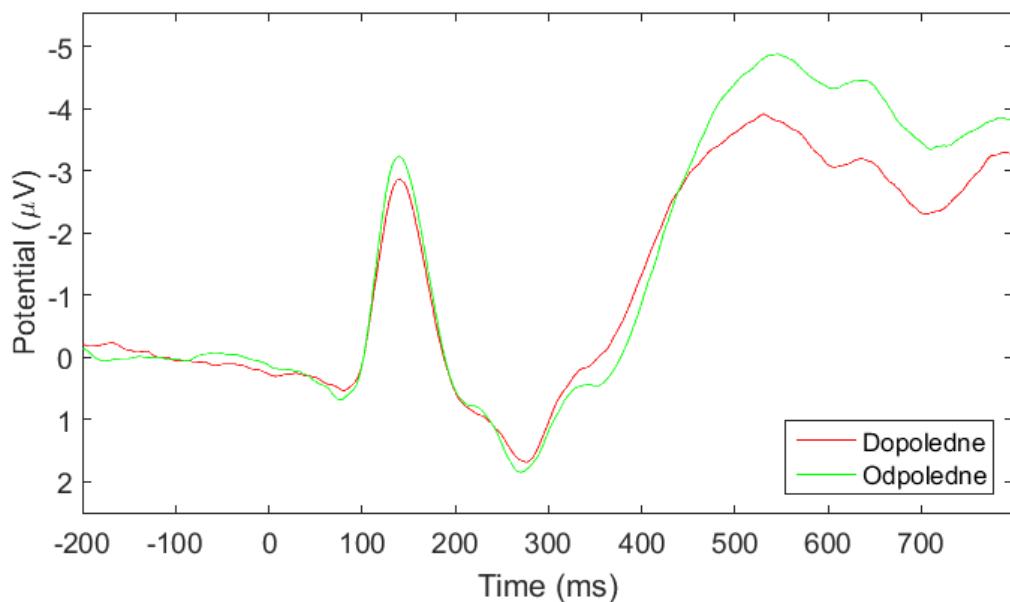


Obrázek 4.1: Grand average jednotlivých měření na elektrodě Fz.



Obrázek 4.2: Grand average měření bez spánkové deprivace (1. a 2. měření) a se spánkovou deprivací (3. a 4. měření) na elektrodě Fz.

ERPLAB obsahuje funkci pro detekci peak latency v ERP Measurements Tool. P3 komponenta se obvykle vyskytuje 250-500ms po stimulu, interval pro jejich detekci jsem zvolila mezi 240 a 400ms. Do šetření jsem zahrnula pouze singály naměřené na elektrodách Fz, Cz a Pz a pouze epochy s target stimuly.



Obrázek 4.3: Grand average dopoledních (1. a 3. měření) a odpoledních (2. a 4. měření) na elektrodě Fz.

Všechny tyto proměnné jsou v ERP Measurements Tool libovolně nastavitelné a kombinovatelné. Výsledky program exportuje jako textový soubor a umožňuje i náhled a uložení grafického zobrazení. Výsledky detekce jsou prezentovány v tabulce 4.1 na straně 32. Tabulka obsahuje i průměrné hodnoty z jednotlivých měření.

Subjekt	1. Měření			2. Měření			3. Měření			4. Měření		
	Fz	Cz	Pz	Fz	Cz	Pz	Fz	Cz	Pz	Fz	Cz	Pz
2	337	322	361	333	348	371	366	362	384	365	361	386
3	335	332	361	340	341	369	332	361	372	357	359	381
4	343	346	356	348	342	334	343	346	356	358	283	355
5	343	313	311	348	342	334	282	283	350	358	283	355
6	343	313	311	328	310	311	370	314	314	366	302	303
7	303	298	303	306	301	321	301	292	322	295	292	307
8	315	314	363	290	291	354	300	293	378	293	286	288
9	355	313	383	367	360	375	372	352	374	371	339	338
10	338	325	346	330	324	327	346	349	355	328	323	331
11	347	339	341	342	335	346	344	340	342	350	351	358
Průměr	335,9	321,5	343,6	333,2	329,4	344,2	335,6	329,2	354,7	344,1	317,9	340,2
Rozptyl	240,5	206,1	719,4	483,1	494,7	502,8	1001,8	939,7	553,8	834,3	1054,5	1090,8

Tabulka 4.1: Průměrné a rozptyl průměrných hodnot Peak latence.

# 5 Interpretace výsledků

## 5.1 Analýza rozptylu

Získané latence P3 komponenty jsem použila k analýze rozptylu. Protože jednotlivá měření probíhala za různých podmínek, nelze použít jednofaktorovou ANOVU. Metoda zjišťující, zda jsou statisticky významné rozdíly středních hodnot náhodné veličiny měřené na stejných subjektech za různých podmínek se nazývá ANOVA s opakoványmi měřeními (Repeated Measures ANOVA).

Podmínky ovlivňující měření jsou reprezentovány nezávislou kategoriální proměnnou tzv. faktorem, které jsou v tomto případě dva - faktor spánkové deprivace (bez spánkové deprivace/spánková deprivace) a faktor denní doby měření (dopoledne/odpoledne). Ta rozděluje a kombinuje naměřené hodnoty do čtyř skupin. Náhodná veličina je v našem případě latence P3 komponenty.

Pro výpočet ANOVY jsem zvolila statistické funkce programu Microsoft Office Excel 2007. V Excelu jsou k dispozici 3 druhy ANOVA - jednofaktorová, dvoufaktrová bez opakování a dvoufaktrová s opakováním. Pro mé účely posloužila třetí jmenovaná, která napřed vypočítala průměry a rozptyly jednotlivých skupin měření i jejich kombinací a pro tyto kombinace poté vygenerovala tabulku s hodnotami analýzy rozptylu. Výsledky ANOVY pro jednotlivé elektrody jsou uvedeny v tabulce 5.1 na straně 34.

Před vyhodnocením výsledků výpočtů je nutné stanovit hypotézy. Hypotéza  $H_0$  říká, že střední hodnoty sledované náhodné veličiny jsou ve všech skupinách stejné (tj. bez statisticky významných rozdílů), další hypotézy  $H_n$  říkají, že střední hodnoty sledované náhodné veličiny jsou v některých skupinách rozdílné.

Elektroda	Zdroj variability	Rozdíl <sup>a</sup>	MS <sup>b</sup>	F <sup>c</sup>	Hodnota p <sup>d</sup>
<b>Fz</b>	Spánková deprivace	1	280,9	0,439	0,512
	Denní doba	1	84,1	0,131	0,719
	Interakce	1	313,6	0,490	0,488
	Dohromady	36	639,9		
	Celkem	39			
<b>Cz</b>	Spánková deprivace	1	36,1	0,054	0,818
	Denní doba	1	28,9	0,043	0,837
	Interakce	1	921,6	1,368	0,250
	Dohromady	36	673,8		
	Celkem	39			
<b>Pz</b>	Spánková deprivace	1	126,0	0,176	0,677
	Denní doba	1	483,0	0,674	0,417
	Interakce	1	570,60	0,795	0,378
	Dohromady	36	716,7		
	Celkem	39			

<sup>a</sup>počet stupňů volnosti<sup>b</sup>vypočítané rozptyly<sup>c</sup>testové kritérium<sup>d</sup>vypočítaná pravděpodobnost p

Tabulka 5.1: Výsledky výpočtu dvoufaktorové ANOVA s opakováním.

Mým cílem je odpovědět na tři otázky. Za prvé, zda existuje významný rozdíl mezi měřením se spánkovou deprivací a bez spánkové deprivace. Každý subjekt podstoupil dvě měření bez deprivace (1. a 2. měření) a dvě měření s deprivací (3. a 4. měření). Za druhé zda existuje významný rozdíl na základě denní doby měření. Každý subjekt podstoupil dvě měření dopoledne (1. a 3. měření) a odpoledne (2. a 4. měření). A za třetí, zda se tento rozdíl projeví pro všechna měření, tj. zda existuje nebo neexistuje interakce mezi spánkovou deprivací a denní dobou.

ANOVA se vyhodnocuje dvěma způsoby:

- Porovnáním testového kritéria  $F$  a kritické hodnoty  $F_{krit}$ .
  - Hodnota  $F_{krit}$  byla vypočítána při výpočtu ANOVA. ( $F_{krit} = 4,113$ )
  - $F < F_{krit}$  – nulovou hypotézu nezamítneme. Předpokládáme shodnost středních všech porovnávaných skupin dat.
  - $F > F_{krit}$  – nulovou hypotézu zamítáme. Alespoň jedna střední hodnota se liší od ostatních.
- Porovnáním hodnoty  $p$  a hodnoty  $\alpha$ .
  - Hodnotu  $\alpha$  volíme předem a je to z pravidla 5% ( $\alpha = 0,05$ ).
  - $p < \alpha$  – nulovou hypotézu zamítáme. Alespoň jedna střední hodnota se liší od ostatních.
  - $p > \alpha$  – nulovou hypotézu nezamítáme. Předpokládáme shodnost středních hodnot všech porovnávaných skupin dat.

### 5.1.1 Výsledky

Všechny testy skončily nezamítnutím nulové hypotézy o nezávislosti na zvolené hladině významnosti 5%. Z tohoto výsledku vyplývá, že mezi danými dvěma faktory neexistuje statisticky významná souvislost.

První řešenou nulovou hypotézou byla hypotéza o vlivu spánkové deprivace na výsledky měření:

$$\begin{aligned} H_0: & \text{Spánková deprivace nemá statistickou významnost} \\ H_1: & \text{Spánková deprivace má statistickou významnost} \end{aligned}$$

Testová kritéria pro jednotlivé elektrody  $F_{Fz} = 0,439$ ,  $F_{Cz} = 0,054$ ,  $F_{Pz} = 0,179$  jsou menší než kritická hodnota  $F_{krit} = 4,113$ . Stejně tak hodnoty pravděpodobnosti  $p_{Fz} = 0,511$ ,  $p_{Cz} = 0,818$ ,  $p_{Pz} = 0,677$  jsou větší než  $\alpha$  s hodnotou 5%. Musíme tedy konstatovat, že výsledek testu je, že Hypotézu  $H_0$  nezamítáme. Tento výsledek potvrzuje i obrázek 4 na straně 46, kde je zřejmé, že amplituda křivky se sice změnila, ale latence zůstává přibližně stejná.

Dalsí řešenou nulovou hypotézou byla hypotéza vlivu denní doby na výsledky měření:

**$H_0$ : Denní doba měření nemá statistickou významnost**

**$H_1$ : Denní doba měření má statistickou významnost**

Testová kritéria pro jednotlivé elektrody  $F_{Fz} = 0,131$ ,  $F_{Cz} = 0,043$ ,  $F_{Pz} = 0,674$  jsou menší než kritická hodnota  $F_{krit} = 4,113$ . Stejně tak hodnoty pravděpodobnosti  $p_{Fz} = 0,719$ ,  $p_{Cz} = 0,837$ ,  $p_{Pz} = 0,417$  jsou větší než  $\alpha = 0,05$ . V tomto případě Hypotézu  $H_0$  také nezamítáme. Tento výsledek potvrzuje i obrázek 6 na straně 47, kde jsou výsledné křivky signálu téměř totožné.

Poslední řešenou nulovou hypotézou byla hypotéza o vlivu spánkové deprivace:

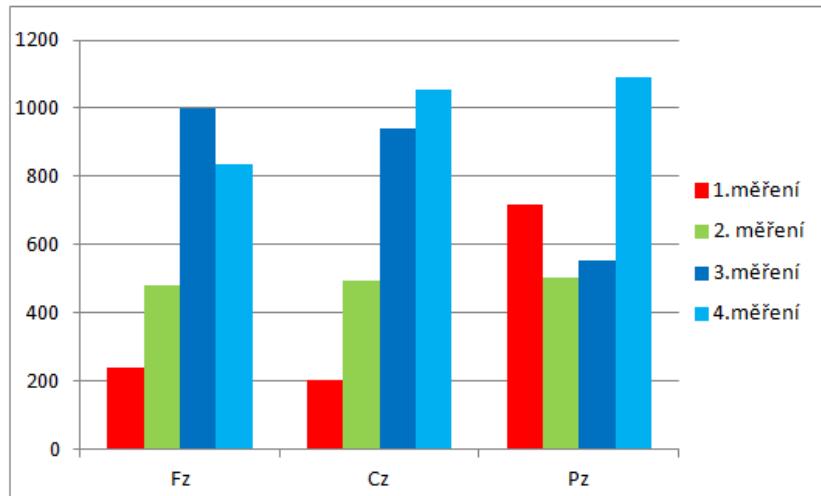
**$H_0$ : Iterace spánkové deprivace a denní doby nemá statistickou významnost**

**$H_1$ : Iterace spánkové deprivace a denní doby má statistickou významnost**

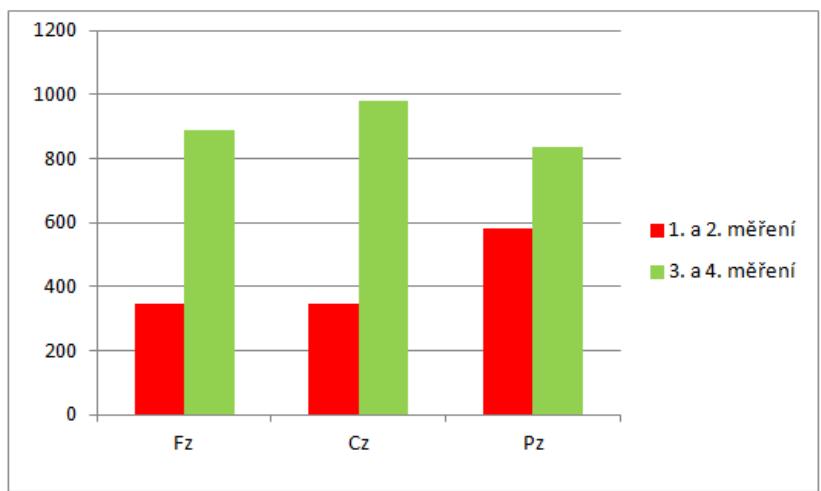
Testová kritéria pro jednotlivé elektrody  $F_{Fz} = 0,490$ ,  $F_{Cz} = 1,368$ ,  $F_{Pz} = 0,795$  jsou menší než kritická hodnota  $F_{krit} = 4,113$ . Stejně tak hodnoty pravděpodobnosti  $p_{Fz} = 0,488$ ,  $p_{Cz} = 0,250$ ,  $p_{Pz} = 0,378$  jsou větší než  $\alpha$  s hodnotou 5%. Závěr tohoto testu je také nezamítnutí Hypotézy  $H_0$ . Na obrázku 2 na straně 45 je zřejmé, že největší rozdíl je mezi 1. a 3. měřením, ale opět se jedná pouze o velikost amplitudy, latence zůstává přibližně stejná. Pro všechny tři testy jsem porovnávala rozptyly (viz obr. 5.1, 5.2, 5.3).

Z prvního grafu (obrázek 5.1) je patrné, že rozptyl je u 1. měření většinou menší než u měření následujících. Výjimkou je měření na elektrodě Pz, tento výkyv mohla způsobit chyba při měření nebo špatně detekovaný artefakt. Nejmarkantnější je rozdíl mezi měřeními ovlivněnými faktorem spánkového deficitu (obrázek 5.2). Naopak rozdíl rozptylů pro faktor denní doby je minimální (obrázek 5.3).

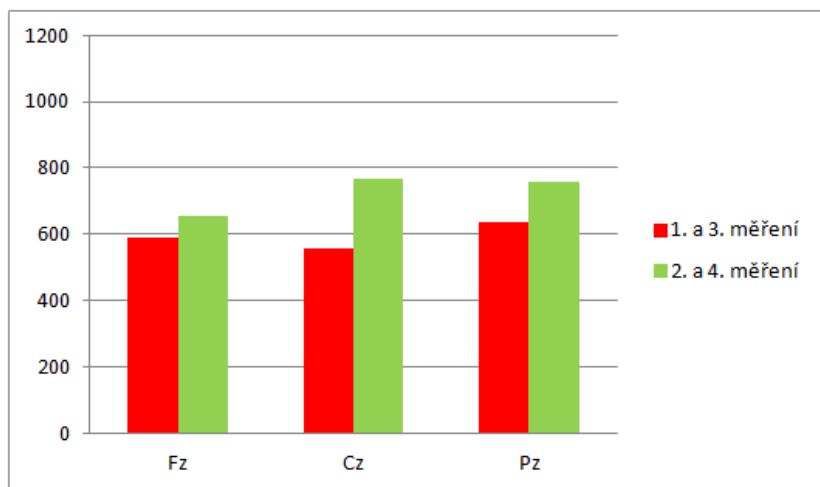
Jedna z možných příčin těchto výsledků je, že byl ERP signál průměrován z nedostatečného množství segmentů (cca 40 segmentů u jednoho měření), a průměrování tak neodstranilo všechny šumy. Dalsí příčinou mohlo být přehlédnutí a nevyložení některých artefaktů.



Obrázek 5.1: Rozptyl jednotlivých měření na elektrodách Fz, Cz a Pz.



Obrázek 5.2: Rozptyl měření bez spánkové deprivace (1. a 2. měření) a se spánkovou deprivací (3. a 4. měření) na elektrodách Fz, Cz a Pz.



Obrázek 5.3: Rozptyl dopoledních (1. a 3. měření) a odpoledních (2. a 4. měření) na elektrodách Fz, Cz a Pz.

## 6 Závěr

Bakalářská práce se zabývá zpracováním elektrofyziológických dat – celým jejich životním cyklem včetně plánování experimentu, jejich získáváním, zpracováním a uchováváním s ohledem na jejich další použití.

V rámci práce jsem se seznámila s problematikou měření elektrofyziológických dat. Prostudovala jsem si základní pojmy týkající se elektroencefalografie – centrální nervovou soustavu, EEG, artefakty ovlivňující výsledky měření a zejména evokované potenciály a jejich části, na které se zaměřuje většina experimentů.

Dále byly v práci popsány jednotlivé části životního cyklu dat. Velký prostor byl věnován způsobům a zásadám pro uchovávání dat, které jsou důležitou složkou životního cyklu dat, protože umožňují znova použít již naměřená data, což šetří čas i peníze nově vzniklým projektům. Navíc je možné doplňovat starší experimenty o nově vzniklé poznatky či metody a porovnávat výsledky výzkumu.

Další velkou kapitolou je zpracování dat, na kterou navazuje praktická část. V praktické části jsem si ověřila důležitost kvalitně zpracovaných metadat, jeden datový soubor jsem musela vyloučit, protože nebylo možné definovat přesné podmínky měření. U ostatních měření se tyto podmínky určit podařilo, ale pouze na základě předpokladu, že autor předchozího experimentu postupoval přesně dle scénáře experimentu popsaného v jeho práci (1. den měření byly subjekty odpočaté, 2. den probíhalo měření při spánkové deprivaci).

Výstupy z použitých metod a výpočtů nepotvrídily předpoklad, že se latence P3 komponenty mění pod vlivem spánkové deprivace a denní doby. Nejvýraznější změna latence byla patrná na elektrodě Cz při porovnání celkového rozptylu měření se spánkovou deprivací a bez spánkové deprivace.

Zpracovávaná data jsou k dispozici na portálu EEGbase, jsou uložena pod názvem Driver's\_attention\_and\_sleep\_deprivation. Vlastní zpracování i statistické výpočty jsou k dispozici na přiloženém DVD.

# Literatura

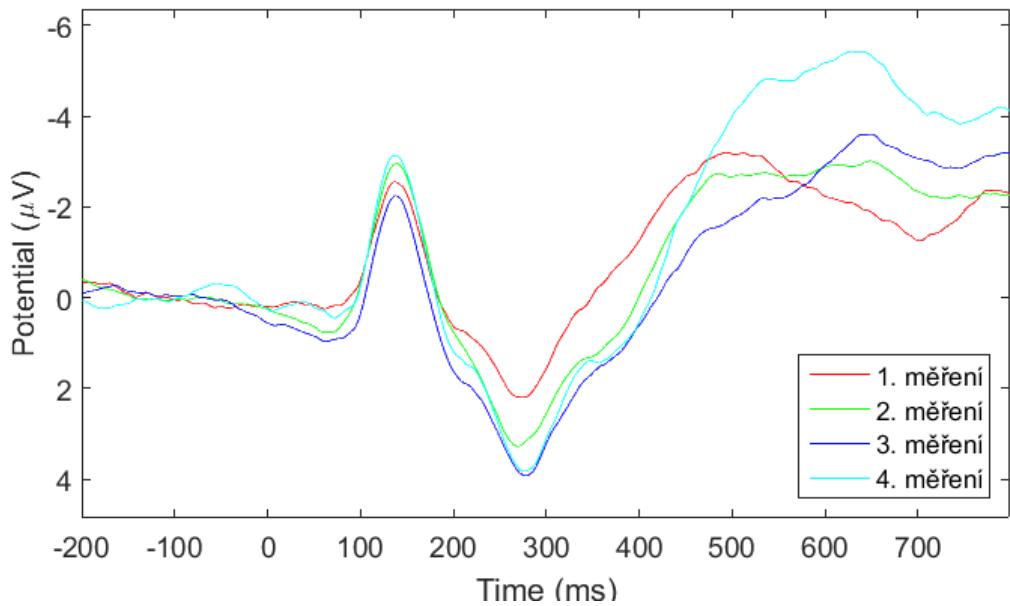
- [1] LUCK, STEVEN J. *An introduction to the event-related potential technique*. The MIT Press, London, 2005. ISBN 0-262-12277-4
- [2] SANEI, SAEID – CHAMBERS, JONATHON A. *EEG signal processing*. John Wiley and Sons, 2007. ISBN-13 978-0-470-02581-9
- [3] VENCÚRIKOVÁ, V. *Metody zpracování EEG/ERP signálů*. Plzeň, 2014. 57 s. Diplomová práce. Západočeská univerzita v Plzni. Fakulta aplikovaných věd.
- [4] MOUČEK, R., MAUTNER, P., BRŮHA, P., VAŘEKA, L., ČEPIČKA, L., HOLEČKOVÁ, I. *Developmental coordination disorder in children – experimental work and data annotation*. Leden, 2014.
- [5] KOŠAŘ, V. *ERP komponenty a pozornost řidiče*. Plzeň, 2013. 62 s. Bakalářská práce. Západočeská univerzita v Plzni. Fakulta aplikovaných věd.
- [6] FORŤ, K. *Metody zjištování pozornosti člověka s využitím automobilového simulátoru*. Plzeň, 2014. 65 s. Bakalářská práce. Západočeská univerzita v Plzni. Fakulta aplikovaných věd.
- [7] HUDA, T. *Detection of emotions in event related potentials*. Plzeň, 2014. 67 s. Diplomová práce. Západočeská univerzita v Plzni. Fakulta aplikovaných věd.
- [8] Strejc, J. *Klasifikace ERP komponent Kohonenovou neuronovou sítí*. Plzeň, 2012. 46 s. Bakalářská práce. Západočeská univerzita v Plzni. Fakulta aplikovaných věd.
- [9] TROJAN, S. *Lékařská fyziologie*. Grada publishing, a. s., 2003. ISBN 80-247-0512-5.

- [10] HOVORKA, J. – NEŽÁDAL, T. – BAJAČEK, M. *EEG abnormita*. Praha, 2006. ISBN 80-7345-093-3.
- [11] KREJČÍ J. *Management sociálněvědních dat a cyklos života dat* Socioweb [online] 2011. Dostupné z: <http://www.socioweb.cz/index.php?disp=teorie&shw=486&lst=117> [cit. 2016-01-01]
- [12] Action potential. Wikipedia: The free encyklopedia [online] 2015. Dostupné z: [https://en.wikipedia.org/wiki/Action\\_potential?oldid=596508600](https://en.wikipedia.org/wiki/Action_potential?oldid=596508600) [cit. 2016-1-02]
- [13] Management dat: koncepce správy dat a výzkumný projekt. ČSDA [online]. Dostupné z: <http://archiv.soc.cas.cz/management-dat-koncepce-spravy-dat-vyzkumny-projekt> [cit. 2016-1-02]
- [14] prof. MUDr. BAREŠ, M. Ph.D. *Kognitivní evokované potenciály*. I. neurologická klinika, LF MU a FN u sv. Anny v Brně. 2013. Dostupné z: [http://www.csnn.eu/ceska-slovenska-neurologie-clanek/kognitivni-evokovane-potencialy-36052?confirm\\_rules=1](http://www.csnn.eu/ceska-slovenska-neurologie-clanek/kognitivni-evokovane-potencialy-36052?confirm_rules=1) [cit. 2016-02-01]
- [15] 10-20 system (EEG). Wikipedia: The free encyklopedia [online] 2015. Dostupné z: [https://en.wikipedia.org/wiki/10-20\\_system\\_\(EEG\)](https://en.wikipedia.org/wiki/10-20_system_(EEG)) [cit.2016-1-4]
- [16] G-Node [online]. 2016. Dostupné z: <http://www.g-node.org/about> [cit.2016-1-4]
- [17] G-Node - odML [online]. 2016. Dostupné z: <http://www.g-node.org/projects/odml> [cit. 2016-1-4]
- [18] G-Node - Terminologies [online]. 2016. Dostupné z: <http://www.g-node.org/projects/odml/terminologies> [cit.2016-3-4]
- [19] G-Node - odML data model [online]. 2016. Dostupné z: <http://www.g-node.org/projects/odml/structure> [cit.2016-1-4]
- [20] Relaxed Electrophysiological Data Acquisition, Control, and Stimulation [online]. Dostupné z: <http://relacs.sourceforge.net> [cit.2016-1-4]
- [21] Laboratory Logbook [online]. Dostupné z: <http://lablog.sourceforge.net> [cit.2016-4-3]

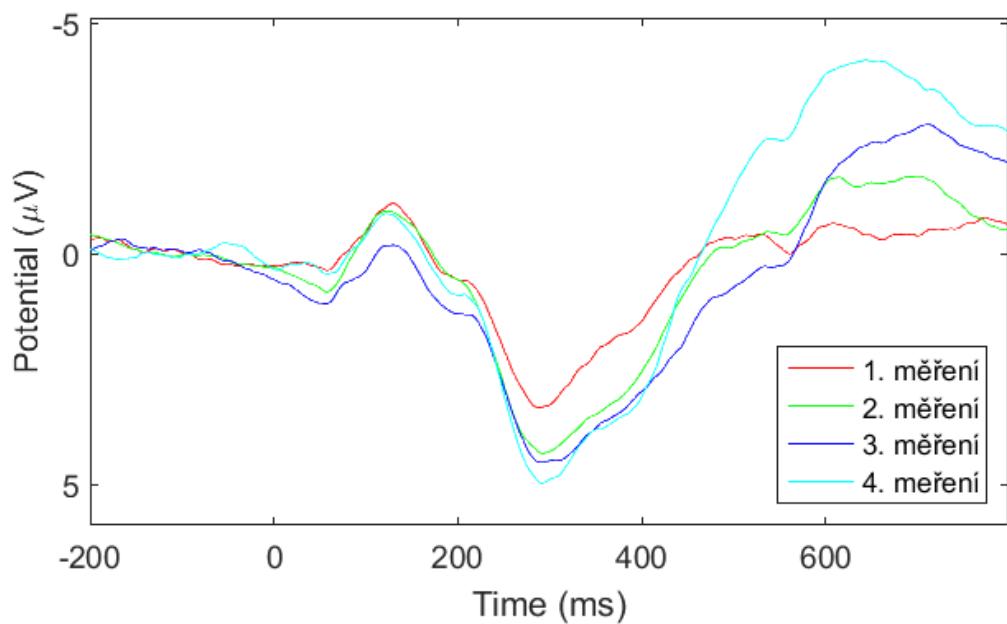
- [22] Wavelet transform. Wikipedie: Otevřená encyklopédie [online]. Dostupné z: <[https://en.wikipedia.org/wiki/Wavelet\\_transform](https://en.wikipedia.org/wiki/Wavelet_transform) [cit. 2016-4-2]
- [23] Hilbert-Huang transformation. Wikipedie: Otevřená encyklopédie [online]. Dostupné z : [https://en.wikipedia.org/wiki/Hilbert%E2%80%93Huang\\_transform#Comparison\\_with\\_Other\\_Transform](https://en.wikipedia.org/wiki/Hilbert%E2%80%93Huang_transform#Comparison_with_Other_Transform) [cit. 2016-4-2]
- [24] Pavel Mautner, Roman Mouček Matching pursuit. [online]. 2009. Dostupné z : <http://dai.fmph.uniba.sk/events/kuz2009/prispevky-pdf/mautner.pdf> [cit. 2016-4-2].
- [25] Analýza rozptylu (ANOVA) [online]. Dostupné z : <http://cit.vfu.cz/statpotr/POTR/Teorie/Predn3/ANOVA.htm> [cit. 2016-4-2]
- [26] Kvantity  $F_{0.975}$  ( $\nu_V$ ,  $\nu_M$ ) Fisher-Snedecorova rozdělení [online]. Dostupné z : <http://cit.vfu.cz/statpotr/POTR/Teorie/tabulky.htmFtest> [cit. 2016-4-2]
- [27] ANALYSA ROZPTYLU – ANOVA. Luděk Dohnal [online]. 2007. Dostupné z : [http://www1.lf1.cuni.cz/~ldohna/publik/Kap\\_7\\_ANOVA.pdf](http://www1.lf1.cuni.cz/~ldohna/publik/Kap_7_ANOVA.pdf) [cit. 2016-4-2]
- [28] Vícerozměrné statistické metody – ANOVA. Martin Sebera [online]. 2012. Dostupné z : [http://www.fsp.s.muni.cz/sebera/vicerozmerna\\_statistika/anova.html](http://www.fsp.s.muni.cz/sebera/vicerozmerna_statistika/anova.html) [cit. 2016-6-2]
- [29] The HDF Group [online]. 2011. Dostupné z : [https://www.hdfgroup.org/about/hdf\\_technologies.html](https://www.hdfgroup.org/about/hdf_technologies.html) [cit. 2016-4-12]
- [30] EEG/ERP portál. [online] 2016. Dostupné z: <http://eegdatabase.kiv.zcu.cz/> [cit. 2016-6-9]
- [31] MathWorks. [online] 2016. Dostupné z: <http://www.mathworks.com/products/matlab> [cit. 2016-6-9]
- [32] Swartz Center for Computational Neuroscience - EEGLAB. [online] 2016. Dostupné z: <http://sccn.ucsd.edu/eeglab> [cit. 2016-6-9].
- [33] ERPinfo - ERPLAB Toolbox. [online] 2016. Dostupné z: <http://erpinfo.org/erplab> [cit. 2016-6-9]

# Přílohy

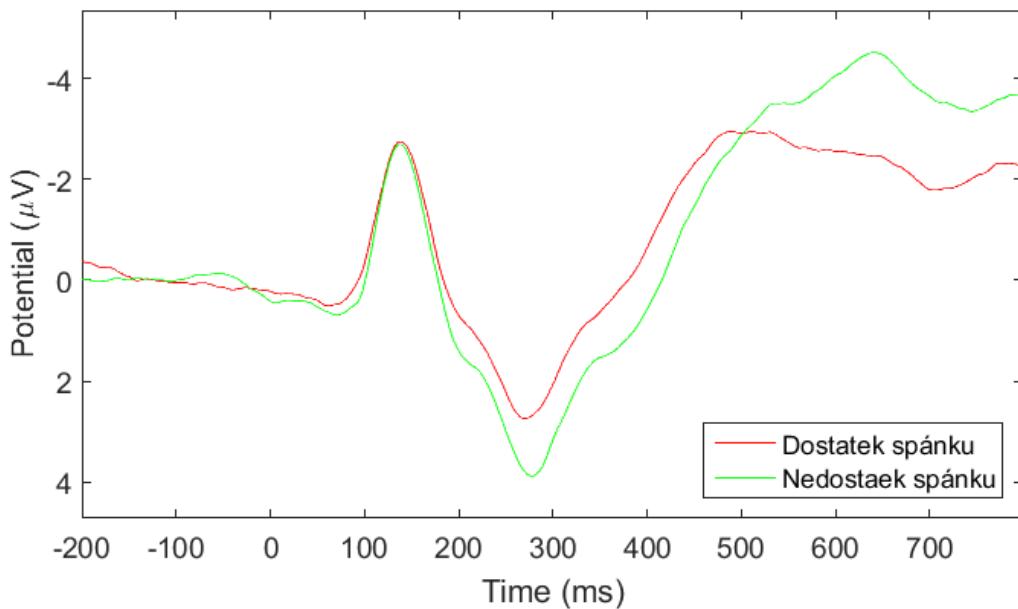
## A Výsledné křivky signálu



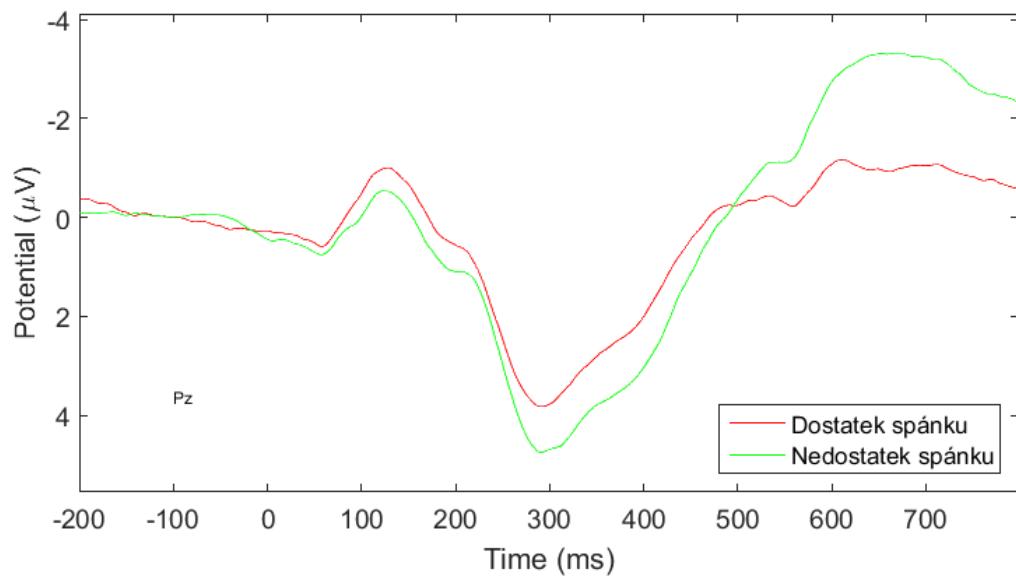
Obrázek 1: Grand average jednotlivých měření na elektrodě Cz.



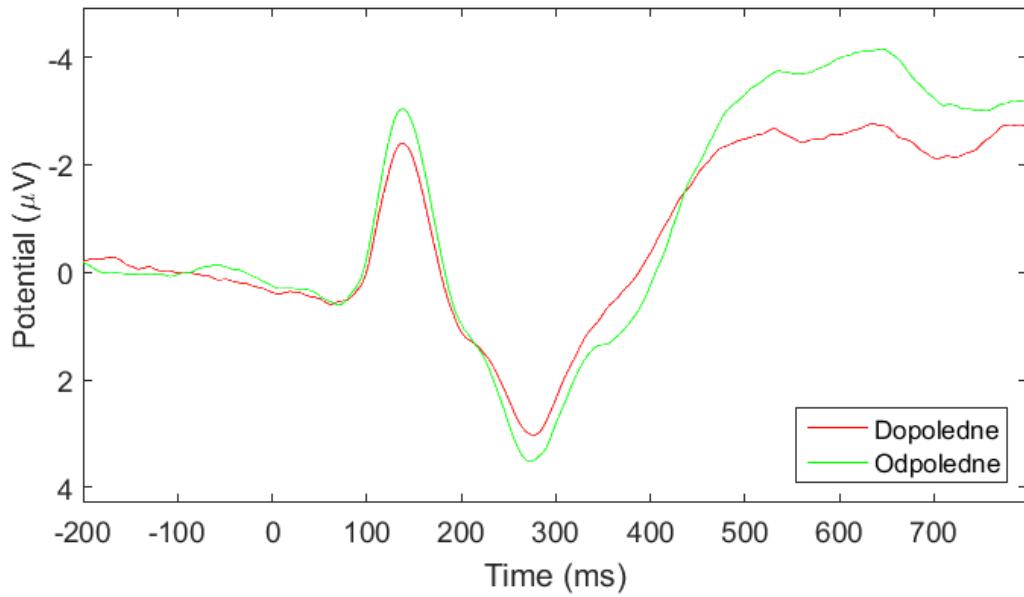
Obrázek 2: Grand average jednotlivých měření na elektrodě Pz.



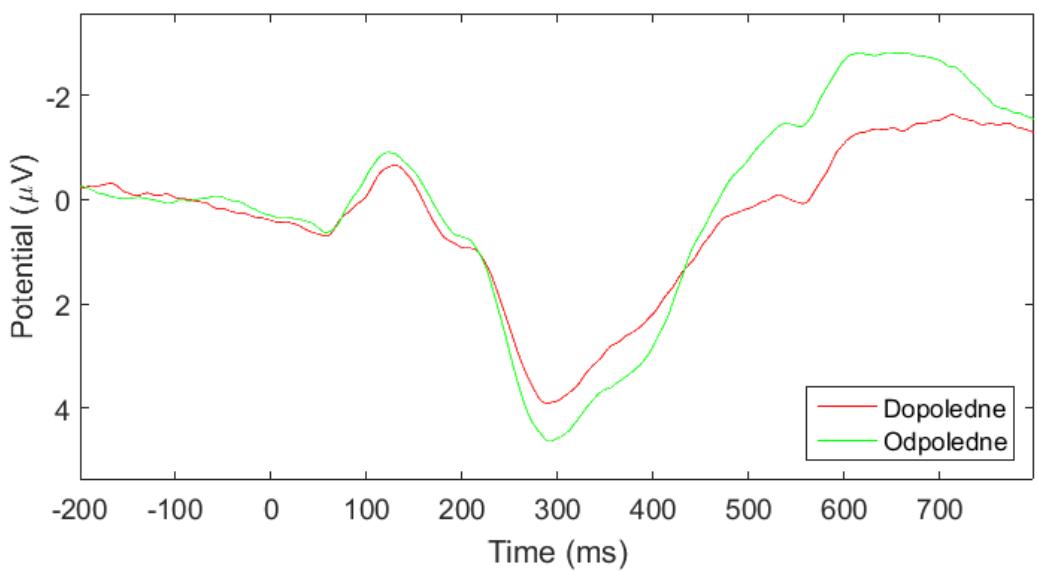
Obrázek 3: Grand average měření bez spánkové deprivace (1. a 2. měření) a se spánkovou deprivací (3. a 4. měření) na elektrodě Cz.



Obrázek 4: Grand average měření bez spánkové deprivace (1. a 2. měření) a se spánkovou deprivací (3. a 4. měření) na elektrodě Pz.



Obrázek 5: Grand average dopoledních (1. a 3. měření) a odpoledních (2. a 4. měření) na elektrodě Cz.



Obrázek 6: Grand average dopoledních (1. a 3. měření) a odpoledních (2. a 4. měření) na elektrodě Pz.

## B Obsah přiloženého DVD

- Data processing
  - Subjekt – zpracovaná data z jednotlivých EEG měření, po jednotlivých subjektech
  - ERP Study - studie nad jednotlivými skupinami měření, obrázky výsledných křivek signálu, soubor s výslednými peak latencemi
  - Statistické zpracování výsledků
- Dokumentace
  - Vygenerovaný PDF soubor s textem bakalářské práce
  - Zdrojové soubory - zdrojové soubory bakalářské práce a obrázky