

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

Diplomová práce

Metody zpracování EEG/ERP signálů

Prohlášení

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

V Plzni dne 26. června 2014

Veronika Vencúriková

Abstract

Methods of EEG/ERP signals

This master's thesis addresses the topic of recorded event-related potentials (ERP) processing and problems related to it. The first part is devoted to a biological introduction, which describes functions and the structure of the central nervous system. It explains the process of invocation and spread of electrical signal through the system. The second part brings an introduction to electroencephalography with focus to evoked potentials. The practical part describes the abilities of well known tools for processing EEG/ERP signals such as EEGLAB (MATLAB toolbox) and its plugin ERPLAB. Next chapter presents methods for processing of ERP and describes the importance and the purpose of data preprocessing. Thesis includes detailed description of characteristics and implementation of five appropriately selected ERP averaging methods, which are not included in the available software tools. The last section is devoted to the results obtained in a practical test and their evaluation. Additionally, this thesis contains user manual describing the installation and the operation of the module.

Abstrakt

Tato diplomová práce se zabývá tématem zpracování záznamu kognitivních evokovaných potenciálů (ERP) a jeho problematikou. První část je věnována biologickému úvodu, ve kterém je popsána funkce centrální nervové soustavy a její struktura. Je zde také objasněn vznik a šířením elektrického signálu touto soustavou. Další část se zabývá úvodem do elektroencefalografie, konkrétně evokovanými potenciály. Praktická část popisuje možnosti dostupných nástrojů pro zpracování EEG/ERP signálů, těmi jsou EEGLAB (toolbox MATLABu) a jeho plugin ERPLAB. Dále navazují metody zpracování ERP, kde je detailně popsán způsob a účel úpravy dat. Součástí práce je charakteristika a implementace pěti vhodně zvolených metod průměrování ERP, které nejsou součástí dostupných programových nástrojů. Poslední část je věnována dosaženým výsledkům a jejich vyhodnocení. Tato práce dále obsahuje uživatelský manuál s popisem instalace a ovládání modulu s funkcemi.

Poděkování

Ráda bych poděkovala Ing. Pavlu Mautnerovi, Ph.D., vedoucímu své diplomové práce, za poskytnutí odborných rad, věcné připomínky a čas strávený při konzultacích.

Velké poděkování náleží také celé mé rodině a blízkým přátelům za pomoc a podporu během studia.

Obsah

1	Úvod	1
2	Biologický úvod	2
2.1	Centrální nervová soustava	2
2.1.1	Struktura CNS	2
2.1.2	Neuron	4
2.2	Šíření signálu	5
3	Úvod do elektroencefalografie	10
3.1	Evokované potenciály (EP)	10
3.1.1	Zrakové EP (VEP - Visual EP)	12
3.1.2	Sluchové kmenové EP (BAEP - Brainstem auditory EP)	12
3.1.3	Somatosenzorické EP (SEP - Somatosensoric EP)	13
3.1.4	Motorické EP (MEP - Motoric EP)	15
3.2	Kognitivní evokované potenciály (ERP)	15
3.2.1	Kontingentní negativní variace (CNV)	16
3.2.2	Přípravný motorický potenciál (BP)	16
3.2.3	Potenciál doprovázející pohyb (MAP)	17
3.2.4	Vlna P300 (P3)	18
4	Nástroje pro úpravu ERP	21
4.1	EEGLAB	21
4.2	ERPLAB	22
5	Metody zpracování ERP	23
5.1	Filtrování vstupních dat	24
5.2	Segmentace epoch	26
5.3	Korekce baseline	26
5.4	Průměrování	27
5.4.1	Problémy latence	28
5.4.2	Průměrování s použitím kritéria artefaktu	34

5.4.3	Průměrování řazením	34
5.4.4	Vážený průměr	36
5.4.5	Blokově vážený průměr	36
5.5	Odhad zbytkového šumu	37
5.6	Iterativní průměrování	38
6	Realizační část	41
6.1	Toolbox do programu EEGLAB	41
6.1.1	Implementační popis metod	41
6.1.2	Rychlost výpočtu metod	41
7	Zpracování a vyhodnocení dat	44
7.1	Úprava dat	45
7.2	Analýza dat	46
7.2.1	Metody průměrování	46
7.2.2	Blokově vážený průměr	50
7.2.3	Iterativní metody	51
8	Závěr	57

1 Úvod

Centrální nervová soustava (CNS) je hlavním řídicím orgánem lidského těla. Má schopnost získávat informace z vnějšího prostředí a předávat je do organismu. Ovládá tělesné funkce, jako je činnost všech orgánů, kosterního svalstva, ale také vytváří chování člověka a komunikuje s okolím. Nervová aktivita lidského mozku a elektrické signály, které jím jsou generovány, mají pod kontrolou stav celého těla. Tento předpoklad je motivací pro zpracování elektrické aktivity mozku pomocí elektroencefalogramu (EEG). Prolnutím neurovědy a neuroinformatiky s novými technologiemi se postupně odhalují další funkce částí lidského mozku.

Evokované potenciály (EP) jsou změny elektrické aktivity mozku, ale také jiných částí nervové soustavy vznikající po působení specifického podnětu nebo událostí z vnějšího prostředí. Jsou součástí EEG a vyznačují se velmi nízkou amplitudou s hodnotami $0,1 - 20\mu V$. Měření těchto potenciálů je důležité a využívá se především v diagnostice onemocnění mozku, například v problematice epilepsie, Parkinsonovy nemoci a jiných záchvatových onemocnění. Vyšetření v dnešní době nedokáže samo o sobě stanovit diagnózu, avšak společně se závěry dalších vyšetření lze odhalit charakter a příčiny onemocnění.

Pro správnou detekci evokovaných potenciálů je potřeba nejprve data vhodným způsobem upravit. K získání EP ze základního EEG signálu je zapotřebí data filtrovat, odstranit nežádoucí artefakty (např. ručním nebo automatickým odstraněním artefaktů mrkání) a poté zprůměrovat. Průměrováním se potlačuje základní EEG aktivita, která se v signálu chová jako náhodný signál. Lékaři obvykle používají konvenční průměr, u kterého není potřeba nastavovat žádné další parametry. Je však zapotřebí mít pořízená velmi kvalitní data, což je v praxi nesnadný úkol.

Cíl této diplomové práce je vybrat a implementovat několik průměrovacích metod pro zpracování EEG/ERP signálů, které nejsou v programu EEGLAB (toolbox MATLABu) a jeho pluginu ERPLAB dostupné. Dále pak ověřit jejich správnost a získat informace o tom, zda se výsledky, zpracované nad daty s artefakty, budou přibližovat vyčištěným zprůměrovaným datům pořízeným konvenční metodou.

2 Biologický úvod

2.1 Centrální nervová soustava

Centrální nervová soustava (CNS) představuje hlavní řídicí orgán lidského těla. Zajišťuje předávání informace z vnějšího prostředí do organismu a všemi jeho vnitřními částmi. Informace je okamžitě zpracována a je na ni zajištěna odpověď. CNS ovládá přímo či nepřímo činnost všech orgánů, kosterního svalstva, vytváří chování člověka a komunikuje s okolím. Její účinky jsou velmi rychlé a krátkodobé, působí pouze po dobu trvání podnětu. Složitější nervové děje, jako jsou např. instinktivní, emotivní chování, učení, paměť, představují komplexnější ovládání tělesných soustav a označují se jako tzv. vyšší nervové funkce.

Jednou ze specifických vlastností CNS je její identita. Funkce každé CNS je založena na stejných principech, i přesto její výsledná činnost každého jedince je opravdu jedinečná a nezaměnitelná. Další zajímavou vlastností CNS je nemožnost regenerace neuronů. Po narození dochází k vývoji struktury a funkce neuronů, společně s větvením axonů a dendritů. Jejich počet je však konečný. Počet nervových buněk v postnatálním období i za zcela fyziologických podmínek klesá a zaniklé neurony mohou být nahrazeny pouze neuroglíí. Trofika nervového systému je jedním z rozhodujících činitelů pro udržení minimálního poklesu počtu neuronů. [22]

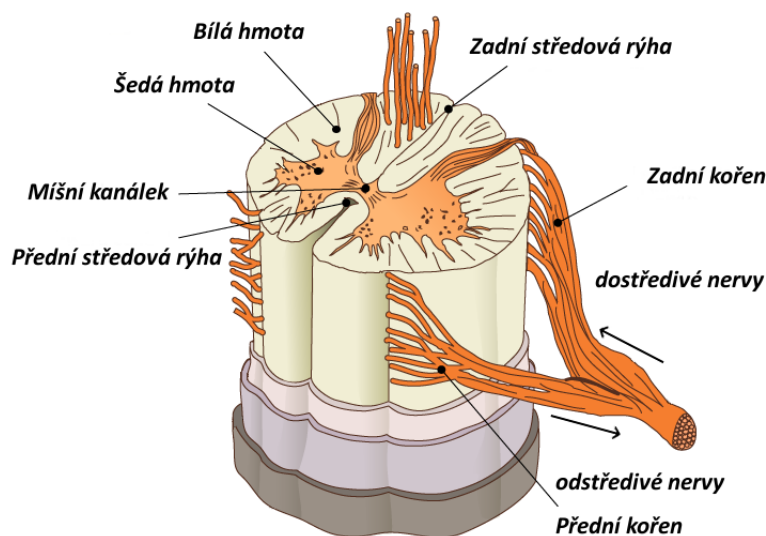
CNS je tvořena nervovou tkání, která se skládá ze dvou typů buněk, z neuronů a neuroglíí. Neuroglie jsou podpůrné buňky zajišťující ochranu a výživu neuronů. V místech, kde převažují těla neuronů se tkáň zbarvuje do tmava, a proto se označuje jako šedá hmota, v místech, kde převažují spoje mezi neurony, je tkáň světlá a je označována jako hmota bílá. [16]

2.1.1 Struktura CNS

Mícha

Mícha je hlavním zprostředkovatelem nervového spojení mezi mozkem a celým tělem. Je to nervová trubice uvnitř páteře, která navazuje na prodlouženou míchu v mozku a končí pod prvním bederním obratlem, kde se rozděluje na jednotlivé míšní nervy. Její délka dosahuje 40 až 45 cm (viz obrázek 2.1). Má za úkol vést a zpracovávat jednoduché míšní reflexy. Předává informace o dotecích na kůži, teplotě, bolesti, chladu, vibracích nebo o poloze končetin či stavech vnitřních orgánů. Zpětně dokáže reagovat např. zatnutím svalu nebo snížením prokrvení orgánu. V míše zároveň probíhají složitější

vícesegmentové reflexy. Díky nim je možné správně koordinovat např. pohyb končetin.



Obrázek 2.1: Struktura míchy

Mozkový kmen

Mozkový kmen je tvořen z míchy, Varolova mostu a středního mozku (viz obr. 2.2). Zde se nacházejí složitější reflexy, jako je např. centrum srdeční činnosti, regulace krevního tlaku a dýchání. Vyskytují se zde 10ti a 12ti hlavové nervy, které mají na starost pohyb očí, velikost zorniček, vnímání chuti, pohyby mimických svalů obličeje, polykání, rovnováhu, atd. Tato část CNS je zodpovědná za vědomí, konkrétně za stav, kdy jsme bdělí. Ve fyziologii je definováno vědomí jako stav, při němž je člověk schopen sebeuvědomování, orientované pozornosti, záměrného jednání a myšlení na základě souboru smyslových a paměťových informací. [22]

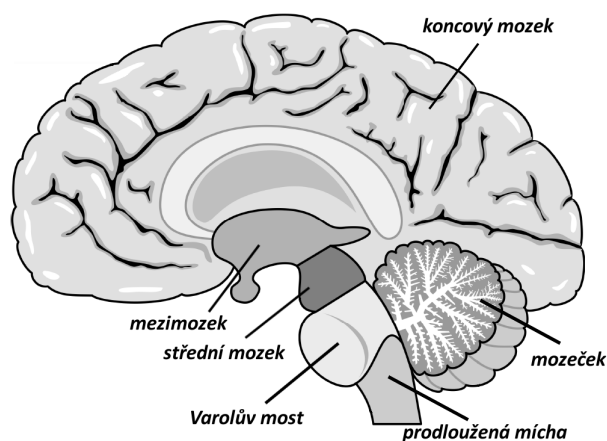
Mozeček

Hlavním úkolem mozečku je postarat se o správnou koordinaci pohybu, činnost svalů a udržování rovnováhy. Jeho funkce běhu je podvědomá. Umístění v mozku můžeme pozorovat na obrázku č. 2.2. Je také centrem pro řízení tělesné teploty, látkového metabolismu, reguluje spánek a bdění. Nesmíme zapomenout, že je zde uloženo centrum pro vnímání žízně a ochrany těla před

přehrátím. Podle nových výzkumů má mozeček roli v poznávacích a řídicích funkcích mozku a v emotivitě. [6]

Koncový mozek

Tato část mozku je největší součástí CNS. U člověka je nejvíce rozvinuta na rozdíl od všech savců. V této oblasti probíhá tzv. vyšší nervová činnost, kterou řídíme svou vůlí. Koncový mozek se skládá ze dvou hemisfér, ty jsou od sebe odděleny hlubokou štěrbinou. Hemisféry jsou spojeny pruhem bílé hmoty tzv. vazníkem. U člověka bývá jedna hemisféra vždy dominantnější. Nejznámějším projevem této vlastnosti je pravo nebo levorukost. Povrch obou hemisfér pokrývá šedá kůra mozková. [16]



Obrázek 2.2: Mozek

2.1.2 Neuron

Neuron je základní stavební a funkční jednotkou CNS, která zajišťuje tvorbu a přenos nervového signálu. Popsal jej poprvé J.E. Purkyně v roce 1835. Tělo neuronu (perikaryon, soma) obsahuje buněčné jádro a výběžky. Jeho velikost se pohybuje od $6\mu\text{m}$ do $100\mu\text{m}$. Každé tělo buňky neuronu je ohraničené plazmatickou membránou, jenž podmiňuje vznik a šíření vzruchů. Nervové buňky vytvářejí společně trojrozměrnou prostorovou síť, kde každá nervová buňka zůstává oddělenou jednotkou, která vzruchy přijímá a následně je posílá dalším buňkám pomocí **synapsí**. Přenos informací na druhou buňku probíhá vyloučením speciální látky, označované jako **mediátor**, do mezibuněčné (synaptické) štěrbiny. Mediátor působí na membránu další

buňky a elektrochemickým procesem je nervový vzruch přenesen. Celá neuronová síť je nositelem funkcí CNS. Tyto celky jsou velmi složité. Například v lidské kůře koncového mozku je skoro 10^{10} nervových buněk a na každou z nich je napojeno až 17 000 synapsí. Struktura neuronů a propojení pomocí synapse jsou zobrazeny na obrázku 2.3.

Jádro

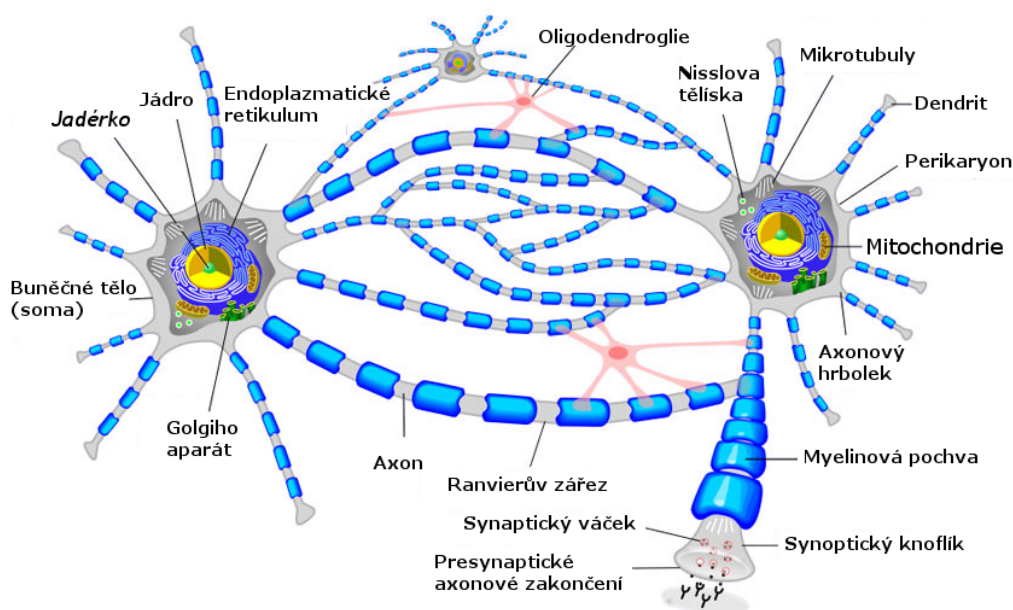
Jádro je obsaženo ve všech buňkách, které jsou schopny reprodukce. V této části buňky je ukryta většina genetického materiálu (DNA). Je poměrně velkého kulovitého tvaru, vyplněného neuroplazmou, ve které se nachází jádro a jadérko. V neuroplazmě se nacházejí mitochondrie, ribosomy a silně vyvinuté hladké a granulární endoplazmatické retikulum. Celé tělo je obaleno plazmatickou membránou.

Výběžky

Výběžky jsou rozděleny do dvou skupin v závislosti na směru vedení vzruchů. **Dendrity** jsou krátké dostředivé výběžky, přijímající a vedoucí vzruchy směrem do těla buňky. Buňka jich má obvykle větší počet, bývají kratší a bohatě se větví. **Neurit(axon)** je dlouhý odstředivý výběžek, který je vždy jenom jeden, vede vzruchy z buňky k další struktuře, jež je pak tímto vzruchem ovlivňována. Může to být například další nervová buňka, svalové vlákno, apod. Místo, kde vychází axon z buněčného těla je označován jako **axonový hrbolek**. První oddíl axonu se nazývá iniciální segment. Tyto dvě části mají rozhodující význam pro vznik vzruchu v neuronu. Ve většině případů jsou axony celé obaleny **myelinovou pochvou**. Ta se také významně podílí na přenosu vzruchu. Čím více je nervové vlákno a myelinová pochva silnější, tím je přenos vzruchu rychlejší. Myelinová pochva nepokrývá axon souvisle, je přerušována **Ranvierovými zářezy**, které můžeme pozorovat na obrázku 2.3. [22]

2.2 Šíření signálu

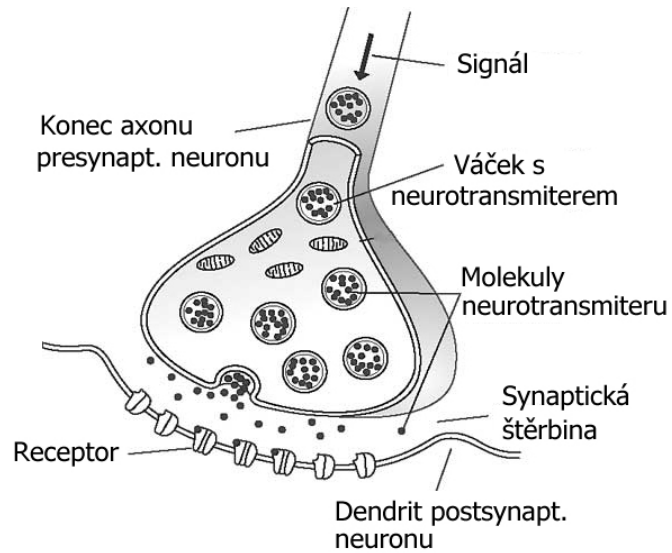
Základní funkcí neuronů je přenášení informací(vzruchů). K těmto přenosům dochází většinou z axonu na dendrit dalšího neuronu nebo přímo na jeho tělo. Samotné šíření signálu se děje na základě změn elektrického napětí na jejich membránách spojených s přečerpáváním elektricky nabitých částic. Celý tento děj umožňují **synapse**, viz obr. 2.4. Dostane-li se do synapse podráždění, vylijí se ze synaptického výběžku váčky s neurotransmiterem (mediátorem), který je uvolněn do štěrbin mezi buňkami. V místě,



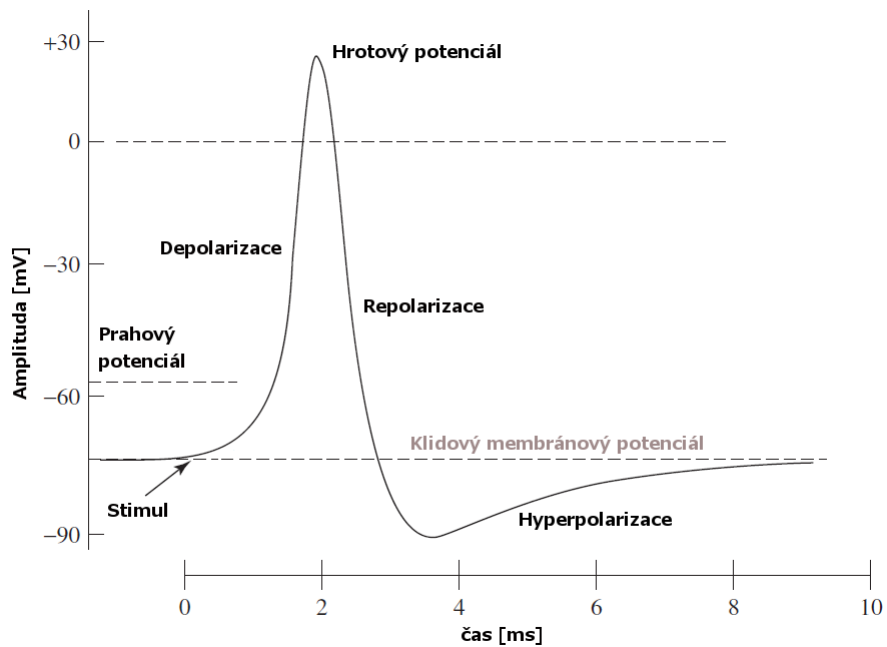
Obrázek 2.3: Neuronové mozkové buňky [14]

kde došlo k podráždění, vznikne krátkodobé zvýšení propustnosti membrány pro ionty sodíku (Na^+) a draslíku (K^+). Při otevření iontových kanálků pronikne ve vysoké rychlosti velké množství Na do axonu. Díky zápornému potenciálu uvnitř neuronu se mění rozložení náboje na membráně. Ve fázi klidového membránového potenciálu existuje mezi vnitřkem buňky a okolním prostředím rozdíl v koncentraci iontů. Tento rozdíl elektrického potenciálu se pohybuje mezi -50 až $-70mV$. Změnou klidového membránového potenciálu k pozitivnějším hodnotám o $+30mV$ až $+40mV$ vzniká **depolarizace** a tím je vytvořen **akční potenciál**, viz obr. 2.5. Po proběhnutí akčního potenciálu zde začíná pracovat mechanismus **sodíko-draslíkové pumpy**. Výsledkem je obnova rozložení náboje po obou stranách membrány (**repolarizace membrány**).

Principem sodíko-draslíkové pumpy je cyklus, trvající přibližně $10ms$. Na vnitřní straně membrány jsou nejprve navázány tři ionty sodíku, dále pak dojde k aktivaci ATPázové činnosti enzymu. **ATPáza neboli adenosin trifosfáza** je enzym, který katalyzuje hydrolýzou ATP na ADP a fosfát. Takto vzniká energie pro pohánění chemických reakcí, které jsou potřeba pro přesun iontů v pumpě. Tím dojde k fosforylaci pumpy za spotřeby ATP. Po té celá molekula změní konformaci a uvolní sodík ven z buňky na opačné straně membrány. Díky tomu se vytvoří místo pro dva ionty draslíku, které se na-




Obrázek 2.4: Synapse [15]



Obrázek 2.5: Průběh akčního potenciálu [20]

váží na sodno-draslíkovou pumpu a proběhne defosforylace. Při defosforylaci se fosfát odloučí od ATP a vzniká ADP a samostatný P_i . Po této akci se draslík uvolní do vnitřního prostoru buňky, čímž je umožněno znovu započít další cyklus navázání třech nových iontů sodíku. Mechanismus sodíko-draslíkové pumpy je znázorněn na obr. 2.6.



Obrázek 2.6: Sodíko-draselná pumpa

Ve štěrbině je neurotransmitter po přenosu rozložen speciálními enzymy, aby nepůsobil velmi dlouho. Mezi nejvýznamnější neurotransmitery patří serotonin, dopamin, noradrenalin, adrenalin, kyselina gama-aminomáselná, aj.

Existují ještě speciální tlumivé synapse, které obsahují odlišný neurotransmitter. Při jejich činnosti dochází ke snížení klidového potenciálu na více než $-90mV$, tím vzniká tzv. **hyperpolarizace** (útlum). U sousední buňky tato látka nevyvolá vzruch, ale naopak zvýší polaritu membrány a tím zesílí její odolnost vůči podráždění budivou synapsí. Tlumivé synapse tvoří třetinu všech synapsí v těle a jsou důležité jako „vypínače“ budivých synapsí. [22]

Podnět (Stimul)

Nervový vzruch musí být vytvořen dostatečně intenzivním podrážděním, aby se mohl šířit buňkami dále. Vzniká každou změnou zevního nebo vnitřního prostředí, která působí na buňku neuronu. O účinnosti podnětu rozhoduje jeho kvalita (druh působící energie), kvantita (v závislosti na dosažení

určitého prahu intenzity), doba trvání a rychlost změny intenzity podnětu. Amplituda akčního potenciálu není závislá na počtu impulsů, kterými byla vyvolána. Tyto signály pracují na principu „všechno nebo nic“, tzn. že reaguje vzruchem, nebo vůbec ne. Pokud reaguje, tak jen s maximální možnou intenzitou.

Při malém podráždění označujeme podnět jako **podprahový**. Má velmi malou intenzitu o 10–15mV. Vzruch se nešíří a velmi rychle zaniká. **Nadprahové podněty**, které dosahují vyšší intenzity než je intenzita maximálního podnětu, nevedou ke zvýšení odezvy.

3 Úvod do elektroencefalografie

Nervová aktivita lidského mozku se objevuje mezi 17. a 23. týdnem prenatálního vývoje. V této vývojové fázi se předpokládá, že elektrické signály, které jsou generovány mozkem, mají pod kontrolou stav celého těla. Tento předpoklad je základem motivace pro zpracování elektrické aktivity mozku za pomoci elektroencefalogramu (EEG). Elektrické výboje (změny polarizace neuronů), vytvořené neurony v mozku, jsou následně zachycovány jako směsice signálů pomocí speciálních elektrod z povrchu hlavy (standardním systémem rozložením měřících prvků 10/20) a zaznamenávány elektroencefalogramem v desítkách μV . Metoda měření mozkové aktivity je důležitá a využívána v diagnostice onemocnění mozku, zvláště v problematice epilepsie nebo jiných záchvatových onemocnění.

Kromě využití v klinické praxi se v posledních letech stále více těší oblibě experimenty s měřením mozkové aktivity v pozornosti či bdělosti, také ale v oblasti zábavního průmyslu jako jsou například herní konzole založené na technologii snímání EEG.

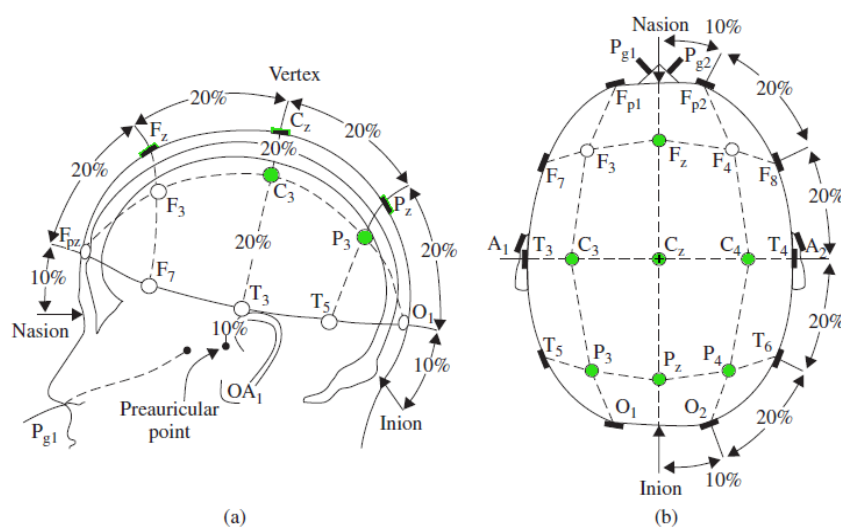
Neuroinformatika prolnutá s neurovědou se za pomoci moderních technologií snaží odhalit funkci některých částí lidského mozku. Při vstupu počítačů do lékařského odvětví se otevřely dveře pro zkoumání, analýzu a interpretaci měřených dat mozkové aktivity.

3.1 Evokované potenciály (EP)

Evokované potenciály jsou změny elektrické aktivity mozku, ale také jiných částí nervové soustavy, vznikající po působení specifického podnětu nebo události z vnějšího prostředí. Abychom je mohly správně zaznamenat, je potřeba tyto elektrické aktivity mnohonásobně zopakovat. Doporučené minimální množství je asi 40 – 60 průběhů opakování. Všechny signály tohoto typu mají společnou charakteristiku. Vyznačují se změnou elektrického napětí v nervové tkáni a svou nízkou amplitudou s hodnotami 0,1 – 20 μV . Nejčastějším místem registrace evokovaných potenciálů je vertex (elektroda CZ), dále pak C3, C4, Fz, Pz, P3 a P4 (obr. 3.1). Doba latence bývá obecně kratší než 50ms u krátkolatenčních EP (např. BAEP, SEP), u dlouholatenčních delší než 100ms (např. ERP).

Prvním významným objevitelem EP se stal G. D. Dawson, který zaznamenal klasickým elektroencefalografem odpověď na nervový stimul u pacienta s epilepsií. [1, 17]

Po této události, více jak dvacet let, se EP využívaly jen v experimentál-



Obrázek 3.1: Rozmístění elektrod [20]

ních oblastech. Zaznamenávání a vyhodnocení dat bylo velmi obtížné. Průměrování bylo potřeba provádět manuálně, nemluvě o vyčleňování nevhodných artefaktů. Teprve rozvoj v oblasti přístrojové techniky a využití počítačového průměrování umožnil vlastní uplatnění této metody i v klinické oblasti. Zaznamenávání EP je nyní díky dostupnosti nové generace kvalitních přístrojů s multimodálními stimulátory relativně snadné. Interpretace výsledků je naopak složitější. Ta vyžaduje důkladnou teoretickou znalost problematiky. Je zde nutné upozornit na vlastní tvorbu norem. I přes vyspělost dnešní techniky je dobré vědět, že podmínky v laboratořích si nejsou často rovny. Z toho můžeme usoudit, že i zhodnocení výsledků může být mnohdy odlišné. [11]

Sledované parametry dat z experimentů testujících EP [19]:


- přítomnost nebo absence jednotlivých komponent
- amplituda - jde o velikost napětí snímaného signálu, dělí se na nízkou (pod $20\mu V$), střední ($20 - 50\mu V$) a vysokou (nad $50\mu V$)
 - měřená od základní linie (baseline)
 - mezivrcholová amplituda (peak-to-peak)
- area - plocha pod křivkou
- polarita registrovaných komponent (negativní, pozitivní)
- trvání jednotlivých komponent

- latence - nulou se označuje okamžik zevního stimulu nebo zahájení motorické aktivity
- reakční čas

Dělení evokovaných potenciálů:

3.1.1 Zrakové EP (VEP - Visual EP)

VEP slouží k vyšetření zrakové dráhy, od sítnice až k okcipitálnímu kortexu. VEP se obvykle vyvolávají pomocí černobílé šachovnice, která je promítána na monitoru počítače. V průběhu testu dochází k pravidelnému přerazení černých a bílých polí, které představují zrakový stimul. Při vyšetření se pacient musí fixovat na střed obrazovky označený bodem, nikoli na měnící se černobílá pole. Snímání evokované odpovědi se provádí nad okcipitálním zrakovým kortexem pomocí elektrody Oz. Výsledný potenciál je hodnocen na tzv. vlně trifázického tvaru - komplex N-P-N, viz obr.3.2. Latence první negativní vlny bývá kolem $70 - 75ms$, vlna se nazývá N70 nebo N75. Pozitivní vlna má latenci $100 - 150ms$ a představuje konstantní část záznamu. Jednotně je nazývána P100. Latence druhé negativní vlny kolísá, proto může být pojmenována N135, N140 nebo N145 s latencemi kolem $130 - 150ms$.



Obrázek 3.2: Vykreslení komponent VEP [13]

3.1.2 Sluchové kmenové EP (BAEP - Brainstem auditory EP)

BAEP slouží k vyšetření sluchové dráhy od periferie (sluchového nervu) až do úrovně mozku kmene. Ke stimulaci se využívá jednoduchý slu-

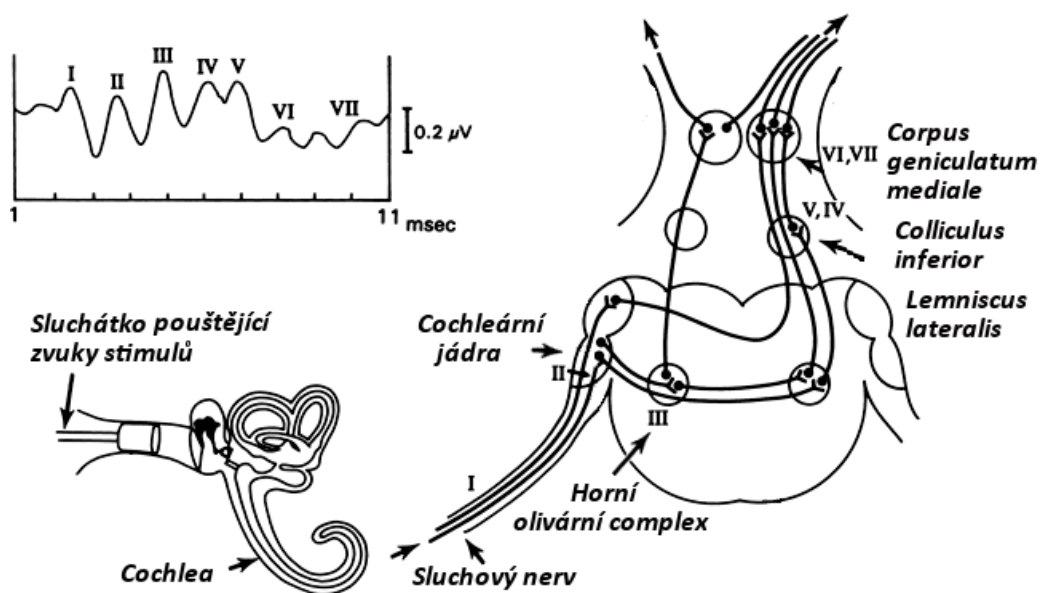
chový podnět, tzv. klik. Jedná se o krátký zvuk, který je opakovaně pouštěn do sluchátek o určité intenzitě a frekvenci. Při vyšetření se testuje každé ucho zvlášť. Do sluchátka u netestovaného ucha je aplikován maskovací šum. Snímací elektrody jsou umístěny nad temenem hlavy a na ušních boltcích se umísťují referenční elektrody. Výsledná data pozorujeme na elektrodě Cz, kde vzniká záznam sestávající z 5 - 7 vln během 10ms (viz obr.3.3). Ty se označují římskými číslicemi jako I - VII a jsou generovány v odlišných úrovních sluchové dráhy:

- vlna I v periferní části sluchového nervu
- vlna II v proximální části sluchového nervu nebo kochleárních jádrech
- vlna III v horním olivárním komplexu
- vlna IV v lemniscus lateralis a jeho jádrech
- vlna V v oblasti colliculus inferior


Vlny II-V pocházejí ze struktury mozkového kmene, vlny II-III z jeho dolní části, vlny IV a V ze střední či proximální části. Vznik vln VI a VII je připisován do corpus geniculatum mediale nebo do sluchové radiace. Standardní záznam je ovlivněn biologickými parametry jako je věk, pohlaví i tělesná teplota.

3.1.3 Somatosenzorické EP (SEP - Somatosensoric EP)

Za pomoci SEP je možné testovat funkce somatosenzorické dráhy, převážně periferní části nervové soustavy, a zjišťovat mozkové a míšní poškození. Standardní vyšetření je prováděno elektrickým stimulátorem generujícím krátké elektrické výboje. Stimul může být vyvolán například i laserem nebo krátkým proudem vzduchu. Obvykle je aplikován na zvlhčenou kůži na zápěstí, těsně za karpálním tunelem (SEP nervus medianus) nebo za vnitřním kotníkem nohy (SEP nervus tibialis). Elektrický stimulem by měl být pravouhlý impuls, jehož trvání může být různé. Běžně se používá hodnota 0,1ms. Intenzita by měla být taková, aby vyvolala šubnutí prstu (palce) stimulované končetiny, což může být u různých jedinců individuální. U lidí, kteří netrpí žádnou poruchou periferních nervů se intenzita pohybuje v mezích 2 – 8mA. Ukázka výsledných vln při měření SEP na zápěstí je zobrazena na obrázku 3.4.



Obrázek 3.3: Schéma sluchové nervové dráhy [12]



Obrázek 3.4: SEP nervus medianus [10]

3.1.4 Motorické EP (MEP - Motoric EP)

MEP jsou odezvou na elektrickou či magnetickou stimulaci mozku nebo míchy a užívají se pro testování funkční integrity motorických drah. Elektrická stimulace je poměrně bolestivá metoda a často bývá pacienty špatně snášena.

Mozek a míchu můžeme stimulovat dvěma různými způsoby. První skupina je **neinvazivní**, kam patří magnetická a elektrická transkraniální stimulace.

Magnetická stimulace je indukce proudu ve vodivé tkáni časově proměnlivým magnetickým polem. Stimátorem je plochá spirálovitá smyčka, která je přiložena na skalp ve stimulované oblasti. Elektrická stimulace využívá bipolární a monopolární způsob stimulace. Je výhodnější pro vyšetření míchy, kde je rychlejší a má menší rozptyl podnětu.

Další možností stimulace je **invazivní**. Elektrody stimulace se přikládají během operace přímo na povrch mozku v zadní jámě lební. Evokované potenciály se snímají z míchy, periferních nervů nebo svalů.

Díky magnetické stimulaci lze přispět k diagnostice neurologických onemocnění (např. roztroušená skleróza, Parkinsonova choroba, cévní onemocnění mozku, aj.). [11]

3.2 Kognitivní evokované potenciály (ERP)

Další skupinou evokovaných potenciálů jsou tzv. **kognitivní evokované potenciály** neboli potenciály vázané na událost. Budou zde popsány podrobněji, protože jsou objektem zkoumání diplomové práce.


Tyto EP jsou pro lékaře a neuroinformatiky obzvláště zajímavým cílem. Vzhledem k tomu, že stimulace při vyšetření ERP je velmi individuální, spadají převážně do světa experimentálního využití. Řadí se do skupiny dlouholatentních a pomalých kognitivních potenciálů. Jsou považovány za odraz aktivity komplexních neuronálních sítí, odpovídajících za detekci nových podnětů a za rozlišovací chování osob, což znamená, že jedinec dokáže rozlišit pro něj důležité podněty od těch méně podstatných.

Pomalé mozkové potenciály jsou ovlivněné vědomou i nevědomou kognitivní aktivitou. Vznikají v souvislosti se zapojením jedince do daného úkolu. Proto vyšetření obvykle probíhá formou zadávání různých úloh pacientovi. Ten při vyšetření pohodlně sedí nebo leží.

3.2.1 Kontingentní negativní variace (CNV)

Kontingentní negativní variace (v angličtině **contingent negative variation**) je elektrický fenomén, který byl poprvé popsán v roce 1964 W. Greyem Walterem a jeho spolupracovníky. Je zobrazen jako pomalá negativní výchylka EEG aktivity na povrchu hlavy, která se objevuje v intervalu mezi přípravným, varovným podnětem a následným vykonávajícím podnětem, po němž následuje mentální či motorická odpověď. Hodnota reakčního času se pohybuje v rozmezí 300–600ms. Tento dlouholatentní potenciál (obr. 3.5) se ukázal jako vhodný pro studium mozkových funkcí se vztahem k chování.

CNV je komplexní endogenní potenciál, který odráží mnoho mentálních a kognitivních procesů a aktivit, např. úroveň bdělosti, vnímání, pozornosti, očekávání, rozlišování, stresu, přípravu odpovědi, časový odhad a přípravu motorické odpovědi. U starších osob dochází k poklesu amplitudy CNV ve frontální oblasti. Je zajímavé, že u neurotiků byla prokázána nižší amplituda CNV a extroverti mají vyšší amplitudu než introverti.



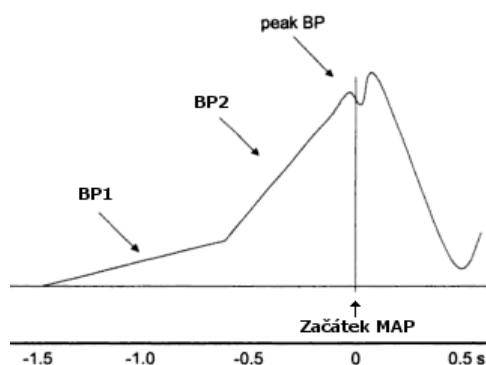
Obrázek 3.5: Vlna CNV

3.2.2 Přípravný motorický potenciál (BP)

BP (jinými názvy také: **Bereitschaftspotential**, **Readiness Potential** nebo **Movement Related Cortical Potential**) byl poprvé zaznamenán a popsán na jaře v roce 1964 Hansem Helmutem Kornhuberem a Lüderem Deeckem na Freiburské univerzitě v Německu. Tento fenomén se řadí do souboru pomalých negativních potenciálů, který předchází 1-2 sekundy volnímu pohybu. Začíná zhruba o 1 s dříve než si vyšetřovaná osoba uvědomí, že chce provést nějaký pohyb. BP souvisí s vědomými i nevědomými aktivitami. Ovlivňuje ho řada fyzikálních i psychologických parametrů. Předchází pouze

pohybu, který byl nebo nemusel být vykonán. Tento potenciál je úzce spjat s kognitivní aktivitou vázanou na pohyb. Z EEG je zpětně získáván zprůměrováním EEG signálu, který je vytvářen opakovaným volným, jednoduchým, pohybem. Což může být například pohyb prstu, ruky, ale také komplexnější pohyb jako jen například psaní nebo otáčení stránky v knize.

Pohyb musí vycházet z vůle člověka a není nastartován žádným signálem, počítáním apod. (v literatuře označováno jako **non-cued**, naproti potenciálům vázaných na určitý signál **cued**). Výsledkem měření je křivka obsahující několik komponent. První komponentou je postupně vzrůstající negativita BP1, která začíná 1500 – 800ms a končí přibližně 500ms před začátkem pohybu. Druhá strměji narůstající komponenta označovaná jako BP2 je napojena na BP1 a končí cca 50ms za počátkem pohybu (viz obr. 3.6). Nejlépe rozeznatelný je BP na elektrodě CZ, tedy nad vertexem, kde dosahuje nejvyšší amplitudy.



Obrázek 3.6: Schéma znázorňuje časový průběh a komponenty BP před začátkem potenciálu doprovázející pohyb [8]

Experimenty vyšetřující BP mají stále jen vědecký význam ke studiu fyziologie a patofyziologie motoriky. Abnormality BP byly nalezeny u jedinců s Parkinsonovou nemocí a esenciálním třesem, u nichž se křivka potenciálu snížila nebo úplně vymizela.

3.2.3 Potenciál doprovázející pohyb (MAP)

MAP (anglicky **Movement accompanying potential**) je potenciál identifikovatelný v době, kdy probíhá pohyb. Umístění MAP se liší v kortikálních oblastech podle toho, zda se pohyb spouští volně (což by probíhalo podle Bereitschaftspotential paradigmatu) nebo na základě vnějšího podnětu, což by odpovídalo contingent negative variation paradigmatu. Význam výzkumu je také stále čistě vědecký.

3.2.4 Vlna P300 (P3)

Nejčastěji pozorovanou a nejvíce probádanou komponentou ERP je vlna P300. Poprvé byla popsána v experimentu se sluchovou stimulací Desmedtem a Suttonem v roce 1965.

U zdravých osob při sluchové stimulaci se vlna P300 objevuje s latencí 300 milisekund (od toho odvození názvu P300). V případě využití vizuální stimulace je vrcholová latence prodloužena na 400 – 550 milisekund. V tomto případě je vhodnější použít označení P3.


Experiment je postaven na reprezentaci dvou podnětu vzácnější terčový (terčový) a častý nontargetový (standardní) stimul. Poměr by měl být nastaven zpravidla 1:5 (terčový:standardní). Po zprůměrování několika desítek průběhů jsou patrné na EEG záznamu série potenciálů, v nichž dominuje vlna P300. Tato vlna představuje aktivaci mnoha oblastí v neokortexu a limbickém systému v závislosti na stupni volní a mimovolní pozornosti věnované podnětům.

Experiment lze založit na několika modelových situacích a to s použitím různých druhů stimulů. Nejčastěji používané jsou „odd-ball“, „go-no go“ a „mismatch“. Příkladem při testování sluchového paradigmatu „**odd-ball**“ jde o detekci dvou druhů tónů. Jednoho targetového a druhého nontargetového. Podněty jsou přenášeny do obou uší. Testovaný jedinec je před zahájením instruován, které stimuly jsou terčové, aby je očekával, rozeznal a postupně počítal, kolik jich proběhlo. Další způsob stimulace je paradigma „**go-no go**“. Testovaný jedinec při detekci targetového stimulu nepočítá, ale vykonává nějakou činnost, například stiskne tlačítko. Tato metoda stimulace je vhodná pro testování kognitivní výkonnosti a reakční doby. Posledním zmíněným způsobem je tzv. „**mismatch**“, který vznikne na základě propojení paradigmatu „go-no go“ a sčítání terčových podnětů.

Výsledkem testování jsou dvě křivky. Jedna odpovídá maskovacím a druhá terčovým podnětům. K registraci jsou užívány elektrody Fz, Cz, Pz a Oz, minimálně na elektrodách Cz a Pz u zjednodušených vyšetření.

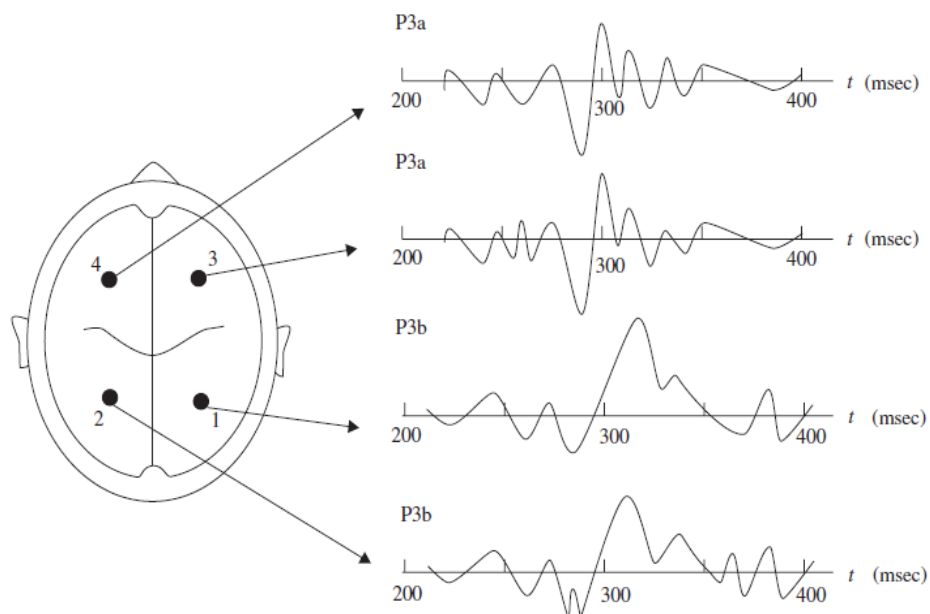
Křivka, kde je nejvýraznější vlna P3, se skládá z několika komponent: P1, N1, P2 a N2 (obr. 3.7). Vrchol P1 značí první pozitivní vlnu pozdního zrakového potenciálu s latencí přibližně 100ms. Stejnou komponentu s názvem P100 registrujeme při snímání VEP. Vrchol N1 znázorňuje pozdní sluchový potenciál s latencí 100ms. Tyto první dva potenciály nemají žádnou spojitost se zpracováním stimulu nebo informace. Další komponenty vlna P2 s latencí 180 – 250ms a vlna N2 s latencí přibližně 200 – 450ms reprezentují skutečně endogenní potenciály vázané na posouzení podnětu a zaměření pozornosti. Rozptyl latencí komponent se odvíjí od charakteru podnětu.

Samotná komponenta P3 je označována jako **P3a** nebo **P3b** podle délky



Obrázek 3.7: Vlna P300

latence. Obě subkomponenty mají pravděpodobně odlišné spouštěče na různých místech skalpu. P3a je registrována ve frontální části, zatímco P3b je registrována v temenní části hlavy (viz obr. 3.8).



Obrázek 3.8: Vlna P3a a P3b [20]

Výzkumem bylo dokázáno, že vlna P3 bývá abnormální u různých druhů neurologických onemocnění, především demencí, např. Parkinsonova nemoc, Alzheimerova demence. Projevuje se prodloužením latence nebo úplným vymizením komponenty P3. Vzhledem k tomu, že se vlna P3 prodlužuje pro-

cesem stárnutí, je potřeba použití norem vázaných věkovými hranicemi. Nesmíme zapomenout, že na výsledky má také vliv okamžitý stav testovaného subjektu. Zvažujeme jeho pozornost, únavu a ospalost.

Materiály v této kapitole byly čerpány především z odborné knihy [11] a z vědeckého článku [19].

4 Nástroje pro úpravu ERP

MATLAB, jako univerzální prostředek pro vědeckotechnické výpočty, zpracování, modelování, analýzu a prezentaci dat, je jedním z nejefektivnějších prostředí také pro zpracování signálů EEG. Lze zde pohodlně vytvářet široké množství aplikací. V posledních letech se stal celosvětovým standardem v oblasti technických výpočtů, simulací, výzkumu i v oblasti vzdělávání. Jeho výhoda spočívá v rozsáhlých knihovních funkcích, které se dají použít ve všech oblastech lidské činnosti. Mimořádně rychlé výpočetní jádro s optimalizovanými algoritmy je připravené na řešení početně náročných úloh. Jednoduchým způsobem dovoluje vytvořit dvojrozměrné nebo trojrozměrné grafy s libovolným vzhledem. Dalším velkým pozitivem je otevřená architektura, díky níž lze využívat funkce MALABu i v externích aplikacích, které si uživatel může sám vytvořit v jeho oblíbeném programovacím jazyce. Vzniklo tak spoustu nových knihoven, nazývaných *toolboxy*, obsahující specializovaná funkce, které je možné dále rozšiřovat a modifikovat. Samozřejmostí je srozumitelná, dostupná dokumentace a návody jak program či funkci používat krok za krokem. [9]

4.1 EEGLAB

Jedním z toolboxů je EEGLAB, který byl vytvořen a je neustále vyvíjen jako open-source software ve Swartz Center for Computational Neuroscience na Kalifornské univerzitě v San Diegu. Je to zdarma dostupný modul, který lze jednoduše nahrát a spustit v prostředí MATLAB. Tento program je velmi dobrým nástrojem pro zpracování nejen EEG, MEG, ale i dalších elektrofyziologických dat za pomoci časových nebo frekvenčních analýz a poskytuje mnoho dalších metod, včetně nástrojů na vyčištění dat od artefaktů. Má rozsáhlou podporu dostupných modulů a detailní dokumentaci s množstvím tutoriálů. [21]

V rámci zadání diplomové práce byl EEGLAB nainstalován a otestován s naměřenými EEG daty. Analýza dostupných zdrojových kódů EEGLABu ukázala, že data jsou v rámci tohoto modulu zpracovávána jednoduchou průměrovací metodou.¹

¹Ve funkci *pop_timoto.m* lze nalézt volání procedury MATLABu *mean()* s parametry *mean(SIGTMP(:,posi : posf,:), 3)*, kde *SIGTMP* obsahuje naměřená EEG data, uložená v trojrozměrném poli (kanály, vzorky, epochy).

4.2 ERPLAB

Dalším zajímavým open-source toolboxem pro zpracování EEG dat je *ERPLAB*. Tento modul je těsně spjat s *EEGLABem* a je také zdarma. Používá se pro analýzu souvisejících přímo s ERP. Vývoj toolboxu je koordinován vědci Janvierem Lopez-Calderonem a Stevenem J. Luckem na oddělení psychologie v Center for Mind and Brain na Kalifornské univerzitě ve městě Davis v USA. Rozšiřuje možnosti *EEGLABu* a poskytuje další nástroje pro filtrování, detekci artefaktů, lepší manipulaci s daty, třídění EEG epoch a jejich vzájemné průměrování.

Podobně jako v případě *EEGLABu* byly i zdrojové kódy *ERPLABu* podrobeny analýze, z níž vyplynulo, že tento modul využívá k výpočtu průměrovací metodu s kritériem artefaktu, viz kapitola č. 5. Toto zjištění je ve shodě s popisem uvedeným v dokumentaci. [2]

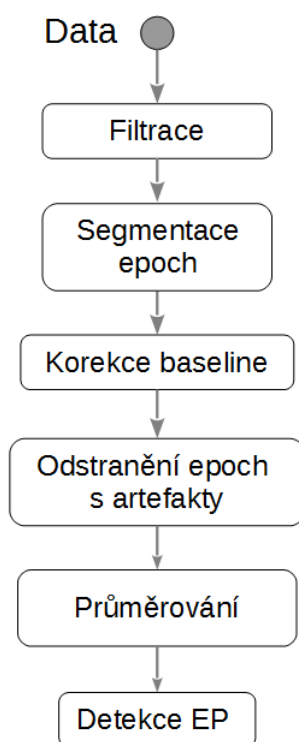
5 Metody zpracování ERP

Pro správnou detekci evokovaných potenciálů v EEG záznamech je potřeba data vhodně zpracovat. Toho je možné dosáhnout pomocí filtrů a průměrování.

Během měření mozkové aktivity dochází k jevům, které je nutné co nejvíce eliminovat. Záznam ovlivňují tzv. rušivé artefakty. Dělí se podle způsobu jejich vzniku:

- Biologické artefakty - vznikají při mrkání a pohybu očí, pohybu těla a svalové aktivitě. Pohyb očí lze zaznamenat tzv. elektrookulogramem. Bohužel tyto artefakty nelze nikdy zcela odstranit.
- Artefakty z EEG přístroje - objevují se např. ve svodech elektrod nebo při jejich špatném kontaktu, na vině mohou být kabely, ale i elektrické rozvodné sítě.
- Interferenční artefakty - vznikají ze zvonění mobilních telefonů, klimatizace, osvětlení a jiných elektronických přístrojů v provozu.

Hladina šumu dokáže nevhodným způsobem pozměnit naměřené výsledky. Je možné ji ovlivnit za pomoci průměrování signálu, proto je zapotřebí získávat data s velkým počtem opakování stimulu a reakcí na něj.



Obrázek 5.1: Průběh zpracování EEG dat

Na obrázku 5.1 je zachyceno obecně platné schéma pro zpracování EEG signálu. Data jsou nejprve filtrována od nežádoucích frekvencí. Potom je provedena segmentace epoch, korekce baseline a odstranění epoch s artefakty. V dalším kroku jsou data zprůměrována a následně je detekován evokovaný potenciál.


5.1 Filtrování vstupních dat

Filtrování je nezbytné pro odstranění nežádoucích frekvencí z naměřených dat (např. interferenční jevy). Podrobný popis aplikace filtrů je popsán v publikaci [7]. K zobrazení ERP komponent je nutné potlačení základní EEG aktivity, který se skládá především z alfa a beta vln.

Přehled dalších frekvencí obsažených v EEG signálu [23]:

- DELTA - 3 Hz a méně s amplitudou $80\text{--}210\mu\text{V}$ (hluboký spánek, v bdělosti patologické)


- THETA - 3,5 až 7,5Hz s amplitudou 5 – 20 μV (kreativita, usínání, meditace, hluboká relaxace)
- ALPHA - 8 až 13Hz s amplitudou 30 – 80 μV (relaxace, zavřené oči)
- BETA - 14 až 30Hz s amplitudou 10 – 20 μV někdy 20 – 30 μV (koncentrace, logicko-analytické myšlení, neklid, úzkost, stres)
- GAMA - 30Hz a více (toto pásmo se v souvislosti s EEG někdy neuvádí, není tolik prozkoumáno, obvykle spojováno např. s extrémní koncentrací)



Obrázek 5.2: Frekvence v EEG signálu [23]

Mezi nejčastější typy filtrů patří:


- low-pass filtr - tlumí vysoké frekvence, nechává procházet nízké frekvence
- high-pass filtr - zadržuje nízké frekvence a propouští vysoké frekvence
- bandpass filtr - pásmová propust tlumí vysoké a nízké frekvence, propouští pouze střední rozsah frekvencí
- notch filtr - úzkopásmové filtry zadržují daný rozsah frekvencí a propouští zbylé



Obrázek 5.3: Ukázka použití filtrů, A) bez filtru, B) s filtrem [7]

5.2 Segmentace epoch

Segmentace je technika rozdělení kontinuálního EEG signálu do stejně dlouhých úseků tzv. epoch. Provádí se na základě synchronizačních impulsů, které jsou generovány u výskytu stimulů. Počátek je určen např. 100ms před a končí 900ms za výskytem stimulu, s cílem zachytit hledanou komponentu v epoše. Z naměřených dat jsou vyextrahovány epochy, které jsou zarovnané na základě jejich časového průběhu. Z časově odpovídajících si vzorků epoch se následně vytvoří průměrná hodnota, viz obr. 5.4.




Obrázek 5.4: Princip průměrování [5]

5.3 Korekce baseline

Při snímání EEG aktivity pomocí elektrod umístěných na povrchu hlavy dochází převážně vlivem pocení u měřeného subjektu ke kolísání nulové izo-

linie neboli ke změně baseline. Tento jev vytváří nežádoucí rušení v EEG signálu. Je ho potřeba dostatečně redukovat, aby nedošlo ke zkreslení výsledných dat. Pro korekci baseline lze použít např. metodu interpolace, digitální filtraci nebo waveletovou transformaci. [3]



Obrázek 5.5: Originální signál (černá) se změnou baseline a signál po úpravě (červená) [3]

5.4 Průměrování

Vzhledem k tomu, že ERP je součástí silnějšího základního signálu EEG, je nutné použít k jeho extrakci metody, které je dokáží odlišit od přítomného šumu v EEG signálu. Tento proces je obvykle založen na eliminaci nebo korekci epoch obsahujících artefakty.

Obrázek 5.6 ilustruje ustálené schéma průměrování ERP. Prvním krokem je zarovnání epoch podle časové značky (obvykle stimulu) reprezentující zahájení sledované aktivity v EEG signálu. Následně jsou tyto epochy zprůměrovány prvek po prvku. Za touto procedurou se skrývá jednoduchá myšlenka. Předpokladem je, že zaznamenaná data v rámci jedné epochy obsahují určitou míru náhodného šumu a ERP signál, který by měl být ve všech epochách identický. Kdyby se nám nějakým způsobem podařilo extrahovat tento náhodný šum z každé epochy, a pak jej zprůměrovat, obdrželi bychom šum s nulovou hodnotou. Proto zprůměrování všech epoch povede k odstranění šumu a odhalení ERP signálu. V případě, že se počet průměrovaných epoch bude zvětšovat, míra šumu se naopak bude stávat postupně menší.

Matematicky to lze vyjádřit takto: velikost šumu v průměrovaném signálu o N epochách je rovna $(1/\sqrt{N}) * R$, kde R je míra šumu. Jelikož signál není v tomto procesu ovlivněn, odstup signálu od šumu (S/N) se zvyšuje jako funkce druhé odmocniny počtu epoch. Tzn. ke zdvojnásobení S/N je zapotřebí použít čtyřnásobné množství epoch. Z tohoto faktu vyplývá, že k vylepšení kvality dat je častokrát snadnější redukovat zdroj šumu než zvyšovat počet epoch.

Metody, které zde budou zmíněny lze charakterizovat, jako procesy získání odhadu signálu $s(t)$ vytvořením váženého průměru z (filtrovaných) J epoch $x(t)$, kde $x_j(t)$ představuje prvek signálu a t označuje čas. Metody vychází převážně ze základního vzorce 5.1.

$$s(t) = \frac{\sum_{j=1}^J w_j x_j(t)}{\sum_{j=1}^J w_j} \quad (5.1)$$


Jednotlivé postupy průměrování se liší způsobem přiřazování vah w_j dílčím prvkům epoch $x_j(t)$. Nejjednodušší způsob výpočtu průměru je nastavit všem epochám váhu $w_j = 1$. Tento běžný průměr se nazývá anglicky **conventional average** $s_c(t)$, rovnice 5.2.

$$s_c(t) = \frac{1}{J} \sum_{j=1}^J x_j(t) \quad (5.2)$$

V praxi se tato průměrovací metoda používá nejčastěji vzhledem k faktu, že nevyžaduje žádné speciální nastavení dodatečných parametrů a její výpočet je triviální.

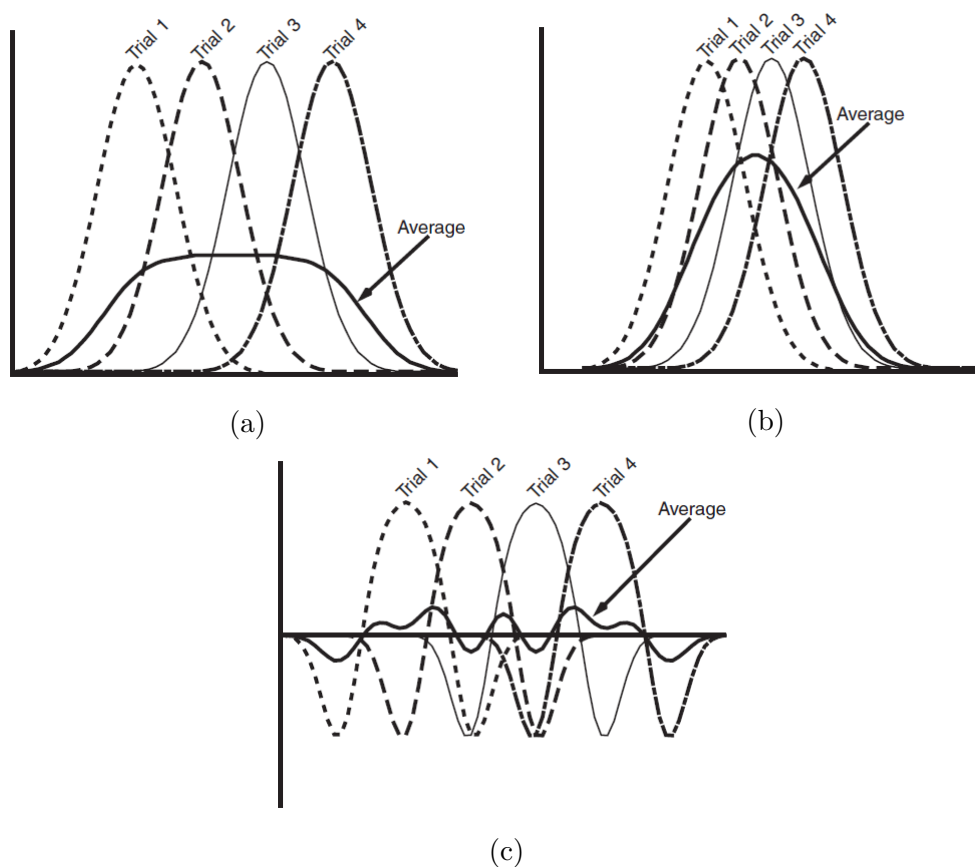
5.4.1 Problémy latence

Ačkoliv proměnlivost amplitudy ERP signálu v jednotlivých epochách není obvykle problémem, tak odlišnost jejich latencí má poměrně negativní dopad na výsledná zprůměrovaná data. Tato situace je zobrazena na obrázku 5.7a. Jsou zde zobrazeny čtyři samostatné epochy s P3 komponentou a odlišnou latencí. Velikost amplitudy průměru těchto epoch je mnohem menší než velikost amplitudy každé z nich, přičemž šířka vlny se naopak zvětší. Obrázek 5.7b demonstruje, že snížení proměnlivosti latence vede ke zvýšení amplitudy zprůměrovaného signálu. V nejhorším případě může nastat situace, ve které



Obrázek 5.6: Příklad aplikace průměrovací metody. Horní křivka ukazuje dvě epochy EEG signálu s vyznačenými stimuly. V levém sloupci je zobrazeno 8 epoch, které jsou v pravém sloupci postupně průměrovány. [7]

se latence liší natolik, že ve výsledném průměru nelze nalézt hledanou vlnu ERP. Zmíněný jev je ilustrován na obrázku 5.7c. Ke zmírnění negativních účinků latence na tvar výsledné vlny může být použito několik technik. Některé z nich popíší v následujících odstavcích.



Obrázek 5.7: Příklady problémů latence u průměrování

Měření plochy pod křivkou

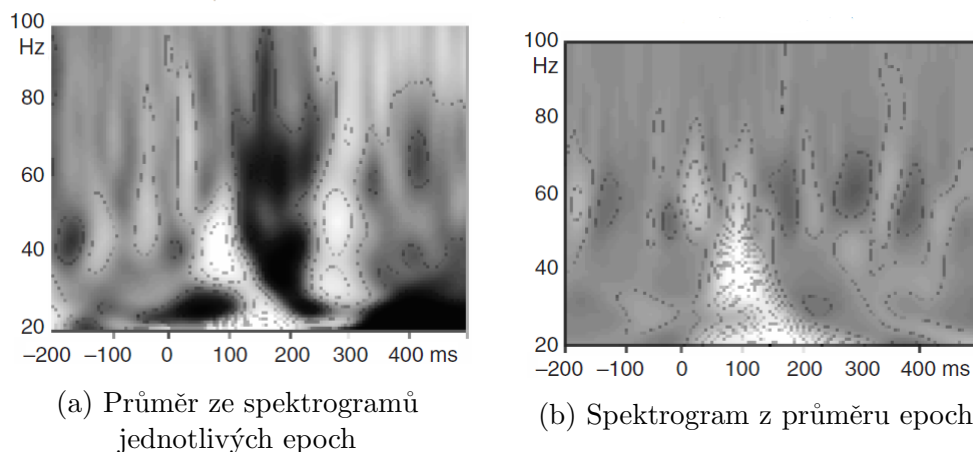
Tato metoda je založena na určení bodu, podle kterého jsou následně epochy zarovnány tak, aby se co nejméně zkreslila velikost výsledné ERP komponenty. Vychází z předpokladu, že plochy pod křivkami epoch jsou rovny ploše pod křivkou jejich průměru, a to i při lišící se latenci. Tento faktor tedy není latencemi ovlivněn. Detailně je metoda popsána v publikaci [7].

Woodyho technika filtrování

Woodyho adaptivní filtr je založen na myšlence extrakce komponenty EEG na základě jejího porovnání se vzorem. Jde o iterativní metodu, v níž se v každém kroku hledaný vzor zpřesňuje. Filtr začíná svou práci se vzorem, který je obvykle polovina vlny *sinu* nebo trojúhelníková vlna. Mezi každou epochou a vzorem je pro určité množství vzájemně posunutých vzorků vypočtená korelace. Epochy jsou na základě maximální korelace zarovnané a z jejich průměru vznikne nový vzor, který bude použit v následující iteraci. Vlastnosti metody jsou podrobně prezentovány v článcích [18, 24].

Technika Time-locked spectral averaging

Tato technika je způsob, jak správně zacházet s fázově posunutými signály. Na rozdíl od běžného průměru, který informace o fázovém posunu v průběhu zpracování zničí, je metoda založená na spektrální analýze schopná s touto informací pracovat. Data z epoch se převedou pomocí *Fourierovy transformace* do spektrální oblasti, kde se přes všechny epochy zprůměrují. V obrázku 5.8a byla použita spektrální transformace na epochy, které byly následně zprůměrovány. Obrázek 5.8b demonstruje spektrální transformaci již zprůměrovaných epoch. Je patrné, že některé frekvence byly úplně eliminovány, což vede ke zkresleným výsledkům.



Obrázek 5.8: Příklad time-locked spectral averaging [7]

Překrývání po sobě jdoucích stimulů

Při překrývání po sobě navazujících stimulů dochází ke znehodnocení průměru ERP. V některých případech se tento jev nemusí projevit, v některých je zřejmý. Proto je důležité porozumět, jak vzniká, a kdy by mohl vést k nesprávné detekci ERP komponenty. Překrytí se objeví, když odpověď na předchozí stimul nebyla dokončena před začátkem následujícího stimulu. Problém je obzvláště patrný u experimentů, ve kterých jsou podněty prezentovány příliš rychle za sebou. Nicméně i při dlouhých intervalech mezi nimi může překrývání významně narušit výsledná data, protože ERP křivka může trvat několik sekund.


Obrázek 5.9 ilustruje problém překrytí pro teoretický experiment, kde byly stimuly prezentovány každých 300 – 500ms. V části A je zobrazen průběh originální křivky bez překryvu. Obrázek 5.9 B uvádí vlny toho samého stimulu, které vznikly v časových záznamech 300, 400 a 500ms před aktuálním stimulem (originální vlna byla posunuta vlevo podle daných hodnot). Vlna v části C je průměrem vln obrázku B. Část D zobrazuje vlny stimulu v 300, 400 a 500ms po aktuálním stimulu a v části E vidíme zase jejich průměr. Při průměrování překrývajících se vln dochází k tzv. *rozmazání* a vyhlazení výrazných prvků v signálu.

Část F obr. 5.9 prezentuje složení originálního signálu a překryvů C a E. Výsledná křivka odpovídá produktu konvenčního průměrování všech odpovědí na stimuly z daného časového rozsahu. Dosažené zkruslení je kvůli přítomným překryvům poměrně závažné.

Existuje několik možných principů, jak tomuto nežádoucímu efektu zabránit a tím minimalizovat zkruslení výsledných dat. Jednou z metod je zvětšení intervalu mezi stimuly. V obrázku 5.9 G byla hodnota změněna na 300 – 1000ms. Můžeme v něm pozorovat výraznou změnu (oproti části F) a podobnost s originálním signálem (A). Obdobného výsledku můžeme docílit i použitím nízkofrekvenčního filtru, kdy se nízké frekvence vzniklé vlivem *rozmazání* z výsledného signálu odstraní. Této techniky bylo využito při úpravě dat, viz kapitola 7.1.

Další metoda staví na empirickém zjištění míry překryvu v naměřených datech. Testovaný subjekt je vystaven řadě po sobě jdoucích stimulů, přičemž několikrát v průběhu experimentu jsou určité stimuly vynechány. Z těchto "prázdných epoch", v nichž se měl stimul objevit, se vypočítá model, který se použije k odstranění překryvu z průměru ERP.

Poslední princip je založený na odhadu překrytí stimulů z naměřených dat. Tato technika byla vytvořena Martym G. Woldorffem v roce 1988 a byla pojmenována *ADJAR* (*adjacent response*). Více informací lze nalézt v publikaci [7].



Obrázek 5.9: Ukázka problému překrývajících se stimulů [7]

Na základě zjištěných vlastností nástrojů pro úpravu ERP dat (EEGLAB, ERPLAB), popsaných v předchozí kapitole, byla vybrána sada průměrovacích metod, jejichž implementace není v těchto programech dostupná. V této kapitole budou jednotlivé metody podrobně rozebrány.

5.4.2 Průměrování s použitím kritéria artefaktu

V metodě průměrování s použitím kritéria artefaktu, anglickým názvem **averaging using an artifact criterion**, jsou vyřazeny z výpočtu epochy, ve kterých je rozmezí mezi minimálním a maximálním vzorkem napětí A_j (peak-to-peak) větší než prahová hodnota A . Těmto epochám je přiřazena váha $w_j = 0$, zbývající $J_a \leq J$ obdrží váhu $w_j = 1$. Množství započtených epoch J_a a průměr (rovnice 5.3) samotný je silně závislý na volbě prahu artefaktu A .

$$s_a(t) = \frac{1}{J_a} \sum_{j=1}^{J_a} x_{j,A_j \leq A}(t) \quad (5.3)$$

Tato strategie průměrování má jednu zřetelnou nevýhodu. Prahová hodnota kritéria musí být známa ještě před výpočtem průměrování. V praxi se lékaři a výzkumníci spoléhají na své zkušenosti. Volí hodnotu, která se pro ně jevila nejvýhodněji podle předchozích testování. Vzhledem k tomu, že se prostředí při měření liší, není vždy možné použít pevnou hodnotu artefaktu. Hodnota je nastavena podle potřeby v rámci jedné studie a je nutné ji podle potřeby upravovat.

5.4.3 Průměrování řazením

V roce 1999 vědci Roland Mühler a Hellmut von Specht navrhli metodu řazení průměrováním (**sorted averaging**). Epochy jsou před samotným průměrováním seřazeny podle jejich znečištění šumem a rozděleny do dvou skupin. Epochám obsahujícím malé množství šumu je přidělena váha ($w_j = 1$). Zbytek epoch je z průměru vyřazen ($w_j = 0$). Kritická hodnota šumu, která odděluje přijaté a odmítnuté epochy je odvozena od následujících úvah. Naměřený signál EEG je složen z čistého signálu, což je pro nás zprůměrovaný signál ($S(t)$), a šumu (N_j). Ve studii [4] bylo zjištěno, že SNR nabývá hodnot $-20, -30dB$. Podle toho docházíme k závěru, že podíl šumu je natolik vysoký, že má následek úplné převýšení signálu. Potom můžeme prohlásit veškerý signál za šum (viz rovnice 5.4).

$$x_j(t) = S(t) + N_j(t) \approx N_j(t), \quad j = 1 \dots J \quad (5.4)$$

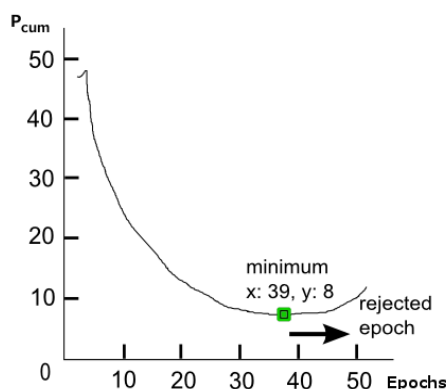
Výpočet hodnoty energie P každého diskrétního signálu $x(t)$ v jedné epoše o délce T je definován podle následující rovnice 5.5.

$$P(x) = \frac{1}{T} \sum_{t=1}^T (x(t))^2 \quad (5.5)$$

Epochy jsou nyní seřazeny vzestupně podle jejich energie $P(x_j(t)) \equiv P'_j$. Hodnota šumu dělicí akceptované a zamítnuté epochy je stanovena minimální energií ze středního kumulativního normalizovaného šumu, kde j' značí indexy seřazených epoch. Prahová hodnota je vypočítána podle rovnice 5.6.

$$P_{cum}(J') = \frac{1}{J'(J' - 1)} \sum_{j'=1}^{J'} P(N_{j'}) \approx \frac{1}{J'(J' - 1)} \sum_{j'=1}^{J'} P_{j'} \quad (5.6)$$

Pokud všechny hodnoty J' ze sumy budou mít stejnou velikost, bude číselník zvýšen v poměru k J' , zatímco jmenovatel se zvyšuje s J'^2 . Díky tomu je suma snižována v poměru $1/J'$. V případě nestacionárního šumu nemají všechny epochy v součtu rovnice 5.6 stejnou velikost. Pokud kumulativní šum zahrnuje a počítá jednu hodnotu po druhé, tj. je-li J' zvýšena, tak minimum dané funkce může být nalezeno po určitém počtu vzorků. To platí pouze v případě, že nárůst energie šumu v čitateli způsobený zahrnutím dané epochy převáží zvýšení jmenovatele J' o jednu. Ve většině praktických měření ERP, lze takové minimum nalézt.



Obrázek 5.10: Graf kumulativní energie s vyznačeným minimem

Příklad grafu s funkcí P_{cum} je zobrazen na obrázku 5.10. Proto lze stanovit optimální počet epoch J_s a výsledný průměr $s_s(t)$ je následně vypočítán podle rovnice 5.7.

$$s_s(t) = \frac{1}{J_s} \sum_{j'=1}^{J_s} x_{j'}(t) \quad (5.7)$$

5.4.4 Vážený průměr

Metoda váženého průměru, anglicky **weighted averaging**, byla vymyšlena vědci Manfredem Hokem (1984) a Berndem Lütkenhönerem (1985). Způsob výpočtu umožňuje přiřadit váhové koeficienty z oboru reálných čísel každé epoše. Váhy jsou zvoleny podle rozsahu kontaminace jednotlivých vzorků šumem. To by mohlo být užitečné v případech, kdy je pozadí šumu v EEG nestacionární. Například při pohybu a změny svalové aktivity u měřeného subjektu.

Ve studii [4] bylo dokázáno, že nejvyšší poměr signálu k šumu lze získat z výpočtu rovnice 5.8, kde je inverzní energie šumu epochy použita jako váha w_j vzorků $x_j(t)$.

$$w_j = \frac{1}{P(N_j(t))} \approx \frac{1}{P_j} = \frac{T}{\sum_{t=1}^T x_j^2(t)} \quad (5.8)$$

Vážený průměr se vypočítá jako poměr součtů přes všechny epochy J podle rovnice 5.9. Metoda má tu výhodu, že není nutné nastavovat práh artefaktu.

$$s_w(t) = \frac{\sum_{j=1}^J \frac{x_j(t)}{P_j}}{\sum_{j=1}^J \frac{1}{P_j}} \quad (5.9)$$

5.4.5 Blokově vážený průměr

Metoda blokově váženého průměru (**block-weighted averaging**) byla poprvé použita vědci Clausem Elberlingem a O. Wahlgreenem v roce 1985. Ti dokázali, že energie šumu může být lépe odhadnuta pomocí seskupení epoch do bloků oproti výpočtu založeném na jediné epoše.

Výpočet po blocích β vede k získání průměrné hodnoty vzorků $x_{(b\beta)}(t)$ v bloku podle rovnice 5.10.

$$x_{(b\beta)}(t) = \frac{1}{\beta} \sum_{j=(b-1)\beta+1}^{b\beta} x_j(t) \quad (5.10)$$

Epochy v blocích jsou označeny písmenem b , kde $b = 1 \dots B$, a jejich průměrná hodnota energie se stanoví rovnicí 5.11.

$$P_{(b\beta)} = \frac{1}{\beta} \sum_{j=(b-1)\beta+1}^{b\beta} P_j \quad (5.11)$$

Inverzní energie příslušných prvků $x_{(b\beta)}(t)$ slouží jako koeficient jednotlivých bloků. Vážený průměr $s_{(b\beta)}(t)$ lze vypočítat podle rovnice 5.12. Počet epoch vstupujících do průměru získáme součinem počtu bloků s velikostí bloku, tj. $J_b = \beta * B$.

$$s_{(b\beta)}(t) = \frac{\sum_{b=1}^B \frac{x_{(b\beta)}(t)}{P_{(b\beta)}}}{\sum_{b=1}^B \frac{1}{P_{(b\beta)}}} \quad (5.12)$$

5.5 Odhad zbytkového šumu

Zbytkový šum základního průměrování je odhadován směrodatnou odchylkou přes všechny epochy. Výpočet uvádí rovnice 5.13. Tento postup je vhodný pro získání odhadu chyby u průměrovací metody s použitím kritéria a u průměrování pomocí řazení. Odhady chyb $\sigma_a(t)$ a $\sigma_s(t)$ jsou vypočteny podobným způsobem.

$$\sigma_c(t) = \sqrt{\frac{1}{J(J-1)} \sum_{j=1}^J (x_j(t) - s_c(t))^2} \quad (5.13)$$

Směrodatná odchylka u váženého průměru je definována podle následující rovnice 5.14.

$$\sigma_w(t) = \sqrt{\frac{\sum_{j=1}^J \frac{1}{P_j} (x_j(t) - s_w(t))^2}{(J-1) \sum_{j=1}^J \frac{1}{P_j}}} \quad (5.14)$$

Velmi obdobným způsobem je definován výpočet směrodatné odchylky pro blokově vážený průměr (5.15).

$$\sigma_b(t) = \sqrt{\frac{\sum_{b=1}^B \frac{1}{P^{(b_\beta)} \beta} \sum_{j=(b-1)\beta+1}^{b\beta} (x_{(b_\beta)}(t) - s_b(t))^2}{(J_b - 1) \sum_{b=1}^B \frac{1}{P^{(b_\beta)}}}} \quad (5.15)$$

Efektivní hodnoty signálu a odhadu odchylky (s a σ) se používají pro datovou analýzu. Jejich podíl $\gamma = s/\sigma$ slouží jako odhad SNR.

5.6 Iterativní průměrování

Stanovený cíl zlepšit odhad šumu vedl k vytvoření nové techniky tzv. **iterativnímu průměrování**. Základem této metody je odečtení průměrné hodnoty $s_w(t)$ z předchozí iterace od úrovně naměřeného vzorku $x_j(t)$. Výsledný rozdíl představuje šum zohledňovaný v aktuální iteraci. V nultém kroku je odhad stanoven podle rovnice 5.16.

Váha epochy je definována jako inverzní energie jejího šumu. Jde tedy o zjednodušení rovnice 5.4. Nežádoucím efektem je podcenění celkové hodnoty signálu.

$$n_j^{(0)}(t) = x_j(t) \quad (5.16)$$

Iterativní metodu lze použít pro průměrování řazením, pro vážené a blokově vážené průměrování stejně i pro výpočet na základě kritéria artefaktu. Uvádím pouze rovnice pro výpočet váženého průměrování. Pro ostatní metody lze snadno odvodit příslušné vztahy.

Zbytkový šum váženého průměru pro nultý krok je dán rovnicí 5.17.¹

$$\sigma_w^{(0)}(t) = \sqrt{\frac{\sum_{j=1}^J \frac{1}{P_j} (x_j(t))^2}{(J-1) \sum_{j=1}^J \frac{1}{P_j}}} \quad (5.17)$$

Z rovnice 5.16 plyne odhad signálu 5.18 pro nultý krok iterace.

$$s^{(0)}(t) \equiv 0 \quad (5.18)$$

Ve výpočtu jednoduchého váženého průměru byla tato aproximace použita k určení koeficientu váhy (viz rovnice 5.8). Výsledkem výpočtu (viz rovnice 5.9) je odhad signálu $s_w(t) = s_w^{(1)}(t)$ prvního řádu, což lze využít ke zlepšení odhadu šumu v jednotlivých epochách (5.19).

$$n_{j,w}^{(1)}(t) = x_j(t) - s_w^{(1)}(t) \quad (5.19)$$

Při použití vztahu $n_{j,w}^{(1)}(t)$ pro výpočet inverzní energie odhadu šumu se koeficient váhy v první iteraci získá z rovnice (5.20).

$$w_j^{(1)} = \frac{1}{P(n_{j,w}^{(1)}(t))} = \frac{1}{\sum_{t=1}^T (x_j(t) - s_w^{(1)}(t))^2} \quad (5.20)$$

Rovnice 5.21 poskytuje hodnotnější odhad signálu váženého průměru druhého řádu (2. iterace).

$$s_w^{(2)}(t) = \frac{\sum_{j=1}^J w_j^{(1)} x_j(t)}{\sum_{j=1}^J w_j^{(1)}} \quad (5.21)$$

Odhad směrodatné odchylky je analogicky definován rovnicí 5.22.

¹Tato veličina je spíše odhadem měřeného šumu než směrodatnou odchylkou.

$$\sigma_w^{(2)}(t) = \sqrt{\frac{\sum_{j=1}^J w_j^{(1)} (x_j(t) - s_w^{(2)}(t))^2}{(J-1) \sum_{j=1}^J w_j^{(1)}}} \quad (5.22)$$

Proces má smysl opakovat do té doby, snižuje-li se hodnota směrodatné odchylky dvou po sobě jdoucích iterací ($s_w^{(i)}(t)$, $s_w^{(i+1)}(t)$) o stanovenou míru.

Iterativní výpočet může být snadno zobecněn pro blokově vážené průměrování. Stejnou proceduru lze použít i pro průměrování s kritériem artefaktu a průměrováním s řazením, uvědomíme-li si, že pro takové případy lze za koeficient vah w_j dosadit hodnoty $w_j = 0$ nebo $w_j = 1$. U metody průměrování s použitím kritéria odhadujeme šum způsobem $n_{j,a_A}^{(i)}(t) = x_j(t) - s_{j,a_A}^{(i)}(t)$. Během další iterace je třeba přezkoumat kritériem artefaktu A šum $n_{j,a_A}^{(i)}(t)$ místo naměřených hodnot $x_j(t)$. Totéž platí pro metodu s použitím řazení. V případě obecného průměrování nelze tento princip použít, protože v něm žádné vážení (odmítání a přijímání) epoch neprobíhá, tudíž by při průběhu výpočtu iterace nebyly výsledky nijak ovlivněny. [4]

6 Realizační část

Úkolem této diplomové práce bylo vytvoření rozšiřujícího modulu do programu EEGLAB verze 11.0.5.4b. Celý modul je implementovaný pouze prostředky poskytovanými integrovaným vývojovým prostředím MATLAB R2009b.

6.1 Toolbox do programu EEGLAB

EEGLAB byl navržen tak, aby vytváření nových modulů nebylo příliš náročné. Za tímto účelem poskytuje také podporu v oblasti definice grafického rozhraní. Díky tomu získává aplikace ucelený vzhled a stává se uživatelsky přívětivější. Mnou navržený modul daného rozhraní plně využívá, proto ho bylo možné snadno integrovat do GUI EEGLABu.

6.1.1 Implementační popis metod

Toolbox pro svou funkci vyžaduje datovou strukturu *EEG*, která obsahuje všechny informace o aktuálně spuštěné datové sadě. Vytvořené funkce potřebují ke své činnosti, tj. výpočtu a zobrazení grafů, následující prvky ze zmíněné datové struktury:

- EEG.setname - zde je zaznamenán název datasetu
- EEG.data - obsahuje naměřená data
- EEG.times - informuje o časovém průběhu epochy
- EEG.chanlocs(:).labels - udává popisy elektrod

Klíčová data vyprodukovaná funkcemi, uvedenými v tabulce 6.1, jsou ukládána ve formě proměnných do *workspace* MATLABu. Je proto možné s nimi dále pracovat nebo je vizualizovat i mimo prostředí EEGLABu.

Každá z uvedených funkcí obsahuje nápovědu, kterou je možné získat z příkazové řádky MATLABu zadáním klíčového slova *help* následovaného názvem hledané funkce.

6.1.2 Rychlost výpočtu metod

Výpočetní složitost implementovaných metod je $O(E * n)$, kde E je počet epoch a n je počet prvků v epoše. V první realizované implementaci se

Název funkce	Význam
<i>eegplugin_averagingmethods.m</i>	výchozí metoda, která je volaná při spuštění EEGLABu. Je v ní obsažen panel modulu <i>Averaging tools</i> s nabídkou dostupných metod.
<i>averaging_criterion_gui.m</i> <i>aver_weighted_gui.m</i> <i>block_weighted_aver_gui.m</i> <i>conventional_aver_gui.m</i> <i>sorted_aver_gui.m</i>	metody jsou volány z hlavního panelu, vytváří GUI a následně spouští funkce výpočtů průměrů se zadanými parametry
<i>averaging_w.m</i> <i>aver_weighted_w.m</i> <i>aver_sort_w.m</i> <i>aver_crit_w.m</i> <i>aver_block_weighted_w.m</i>	pracují s daty ze struktury <i>EEG</i> a počítají požadovaný průměr a směrodatnou odchylku
<i>viewer_averages.m</i>	metoda obsahuje řídicí strukturu grafického rozhraní <i>Viewer averages</i> , umí vykreslit všechna zprůměrovaná data do jednoho grafu
<i>viewer_averages.fig</i>	obsahuje grafické prvky <i>Viewer averages</i>
<i>draw_epochs_gui.m</i>	tvoří GUI <i>Draw epochs</i>
<i>draw_epochs_gui.fig</i>	obsahuje grafické prvky <i>Draw epochs</i>
<i>draw_epochs.m</i>	metoda volaná z GUI <i>draw_epochs_gui.m</i> , vykreslí požadovaný počet epoch podle zadaných parametrů
<i>draw_averaging_data_w.m</i>	vykreslí zprůměrovaná data, je volaná z každé funkce výpočtu průměru
<i>help_averaging.m</i>	pomocná metoda obsahující nápovědu k vytvořenému modulu funkcí

Tabulka 6.1: Přehled vytvořených funkcí

k přístupu do polí využívalo adresování pomocí indexů. Z pohledu interpretu bylo pro práci s každou buňkou nutné vypočítat adresu daného prvku v paměti. Vzhledem k rozměru polí bylo vyhodnocování funkcí relativně pomalé. Vhodně zvolenou formou zápisu algoritmů bylo možné zužítkovat optimalizované metody MATLABu pro práce s maticemi, díky nimž se výpočet výrazně zrychlil.

Měření časové náročnosti bylo provedeno pro 1. iteraci u všech metod na datové sadě *dataset1* (popis datasetu v následující kapitole). Práh kritéria A pro s_a byl nastaven na hodnotu 100 a velikost bloku β pro průměr $s_{b,\beta}$ na 5 epoch. Výsledky jsou uvedeny v následující tabulce 6.2.

Metoda	Rychlost výpočtu v s	
	Před úpravou	Po úpravě
Běžný průměr (s_c)	15,58	0,89
Průměr s použitím kritéria artefaktu (s_a)	0,09	0,07
Průměrování řazením (s_s)	20,40	0,77
Vážený průměr (s_w)	36,74	0,85
Blokově vážený průměr ($s_{(b\beta)}$)	38,81	11,57

Tabulka 6.2: Přehled rychlosti výpočtu funkcí

7 Zpracování a vyhodnocení dat

Implementované metody byly otestovány na čtyřech datasetech. Konkrétní informace o nich nalezneme v tabulce 7.1.

Dataset1 a *Dataset2* byly získány z experimentu *vyvolání evokovaného potenciálu P3* [23]. Měření dat bylo provedeno ve dvou fázích. Měřené osoby se soustředily na dvě diody blikající v daných intervalech.

V první fázi si v duchu počítaly množství bliknutí targetové diody, která se rozsvítila přibližně 100krát. Záznamy z této fáze byly uloženy do datasetů s názvy *Dataset1a* a *Dataset2a*. Ve druhé fázi se osoby soustředily na obě diody, v tomto případě již bez počítání.

Třetí a čtvrtý dataset byl pořízen v experimentu, který proběhl za účelem evokování subkomponenty P3a (*Dataset3a*, *Dataset4a*) a subkomponenty P3b (*Dataset3b*, *Dataset4b*).

Název datasetu	Počet			Měřená osoba	
	Elektrody	Epochy	Vzorky v epoše	Pohlaví	Věk
<i>Dataset1a</i>	8	100	1100	žena	21 let
<i>Dataset1b</i>	8	100	1100		
<i>Dataset2a</i>	8	74	1100	muž	24 let
<i>Dataset2b</i>	8	52	1100		
<i>Dataset3a</i>	19	74	1100	žena	neznámý
<i>Dataset3b</i>	19	21	1100		
<i>Dataset4a</i>	19	18	1100	žena	neznámý
<i>Dataset4b</i>	19	63	1100		

Tabulka 7.1: Přehled testovaných datasetů


7.1 Úprava dat

EEG dataset jedné testované osoby sestává z následujících souborů:

- *.EEG - obsahuje elektroencefalografická data
- *.VMRK - získáme z něj typy a časy jednotlivých stimulů
- *.VHDR - informuje o jednotlivých elektrodách, podmínkách měření, atd.

Těžištěm této práce bylo implementovat metody pro zpracování EEG/ERP signálů s artefakty (*Dataset_bez_korekce*) a dokázat, že kvalita jimi produkováných dat bude srovnatelná s výstupem, který byl vytvořen konvenčním průměrem nad daty bez artefaktů (*Dataset_s_korekci*). Korekce skupiny *Dataset_s_korekci* byla provedena ručně v EEGLABu. Příklad odstraňování artefaktů je ilustrován na obr. 7.1.

Od tohoto bodu dále prošly obě skupiny dat stejným procesem zpracování. Data byla upravena filtrem EEGLABU *Basic FIR filter* s dolní propustí 20Hz . Dalším krokem bylo extrahování epoch se segmentací s dobou trvání 1s , které začínaly 100ms před výskytem stimulu a končily 900ms po jeho výskytu. Následovalo provedení automatické korekce baseline, která byla stanovena z intervalu 100ms před příchodem stimulu.



Obrázek 7.1: Ukázka ruční korekce artefaktů v EEGLABu. Jsou zde znázorněné synchronizační značky odpovídající výskytům stimulů¹.

¹Červeně označený stimul *S2* je targetový a zelený stimul *S4* netargetový.

7.2 Analýza dat

Rozbor datasetů byl proveden v několika fázích, aby se ukázalo, jakým způsobem se jednotlivé metody chovají. Testování bylo provedeno u všech dat se stejnými podmínkami:

- průměr s použitím kritéria artefaktu - $A = 100$
- blokově vážený průměr - $\beta = 5$

Nejvhodnější metoda je vždy volena s ohledem na charakter vstupních dat. Abychom lépe porozuměli všem vybraným metodám, musíme mít přehled jejich vlastností (rychlost výpočtu, iterace, redukce šumu). Pro tento účel jsem vytvořila následující grafy a tabulky, které by měly tyto vlastnosti osvětlit.

7.2.1 Metody průměrování

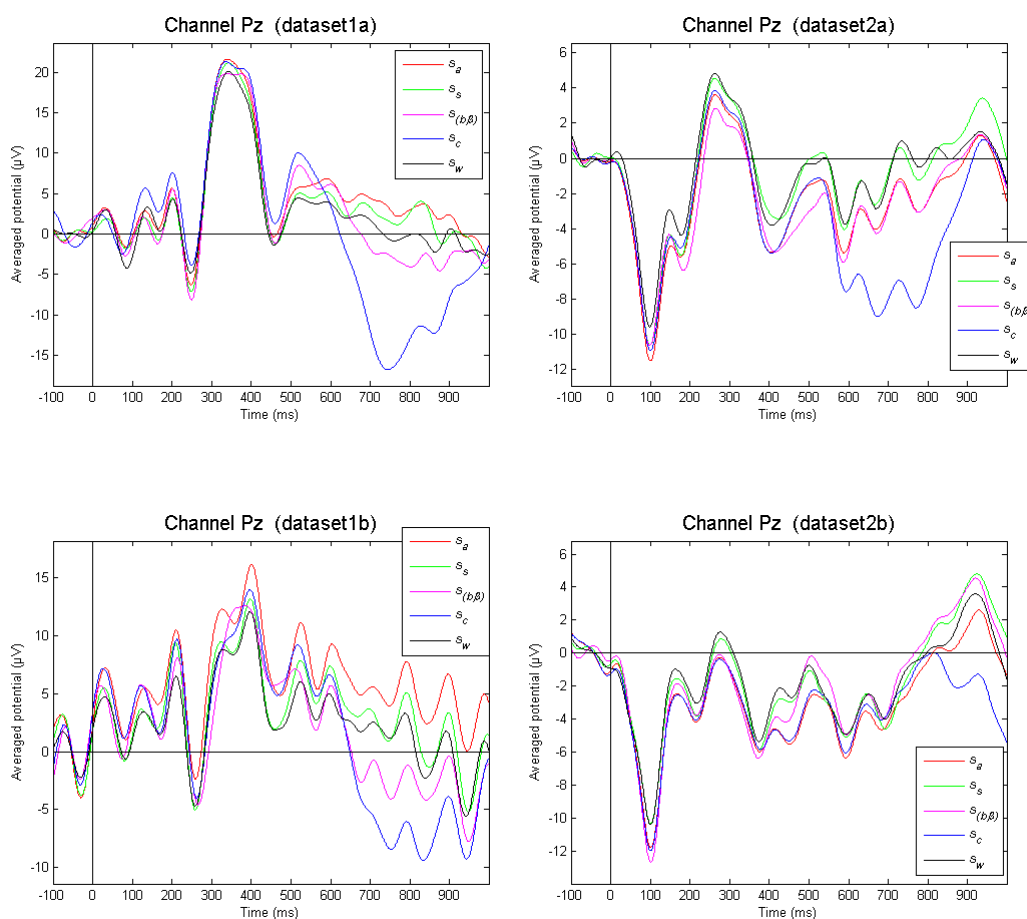
V první fázi testování jsou metody zobrazeny v jednom grafu, aby byly jasně patrné jejich odlišné výsledky. Pro zobrazení jsem využila hodnoty elektrody PZ , která je svými daty nejzajímavější. Na obrázku 7.2 vidíme grafy metod, které byly vytvořeny z *Datasetu1* a *Datasetu2*. Vlna $P3$ je zde krásně viditelná. V tomto setu obrázků je dobře patrné, že v poslední části grafu (zhruba ve 2/3) jsou hodnoty *běžného průměru* (vyznačeny modře) mnohem nižší oproti ostatním křivkám. To způsobila přítomnost epoch s artefakty, které jsou v jiných metodách redukovány.

V další sadě grafů (viz obr. 7.3) jsou vykreslena zprůměrovaná data z kolekcí *Dataset3* a *Dataset4*. Jedná se o záznamy porízené z jiného experimentu. Díky tomuto faktu, byly metody otestovány rozmanitější skupinou dat – tj. vzorky od mužských i ženských subjektů. Výsledky zpracování jsou k nahlédnutí v příložených grafech s označením 7.3. Je z nich patrné, že v některých místech jsou hodnoty z *blokově vážené metody* podobné *běžnému průměru*. Není vyloučeno, že by se změnou nastavení parametru β mohly výsledky přibližovat k hodnotám ostatních průměrů.

Dalším krokem testování bylo získat informace o tom, jakých výsledků budou metody dosahovat při průměrování jednoho datasetu (konkrétně *dataset1a*) ve dvou různých podobách. V první byla použita ručně vyčištěná data od artefaktů a ve druhé stejná data s artefakty. Rozdíly mezi nimi můžeme vidět v grafech 7.4. Nejlepších výsledků dosáhla metoda *průměrování s řazením a váženého průměru*. Zde lze pozorovat vizuální podobnost mezi

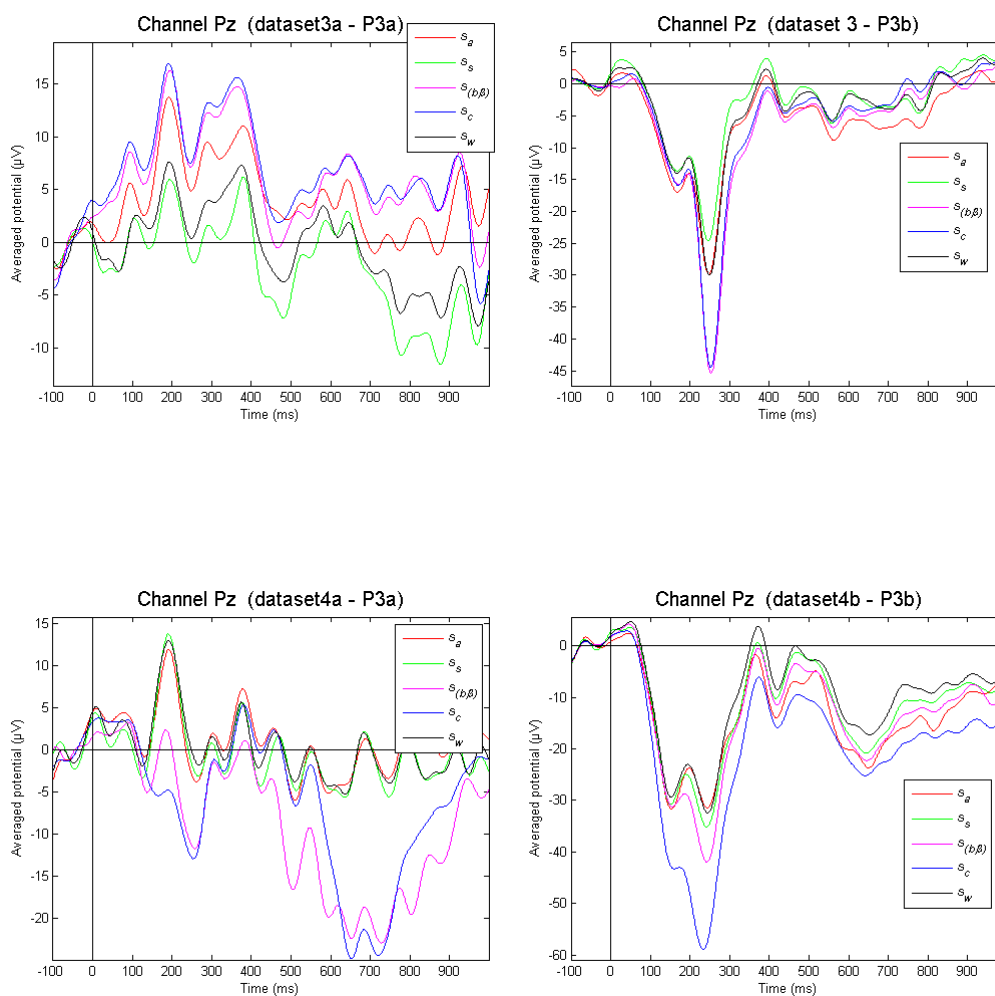
skupinami křivek *Datasety_s_korekci* (vykresleno červenou barvou) a *Datasety_bez_korekce* (vykresleno černě). U metod *průměrování s použitím kritéria artefaktu* a *blokově váženého průměru* se vyskytují zřetelně větší rozdíly mezi křivkami. To bylo pravděpodobně způsobeno tím, že jsou tyto funkce závislé na ručním nastavení parametrů specifických pro daný experiment².

Po porovnání křivky *konvenčního průměru* bez artefaktů, který se v praxi běžně využívá, a ostatních křivek průměrů s artefakty i bez artefaktů, jsem dospěla k závěru, že jsou si všechny velmi podobné. To dokazuje, že není potřeba použití speciální korekce artefaktů z naměřených dat, protože metody si je samy dokáží poměrně dobře redukovat.

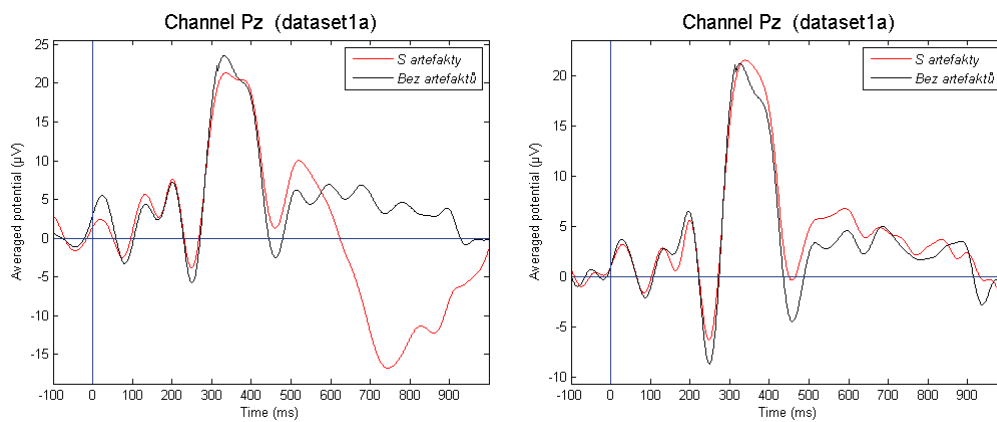


Obrázek 7.2: Přehled průměrů Datasetu1 a Datasetu2 z prvního experimentu

²Hodnoty parametrů jsou voleny na základě potřeby výzkumníka a výsledků předchozích experimentů.




Obrázek 7.3: Přehled průměrů Datasetu3 a Datasetu4 z druhého experimentu



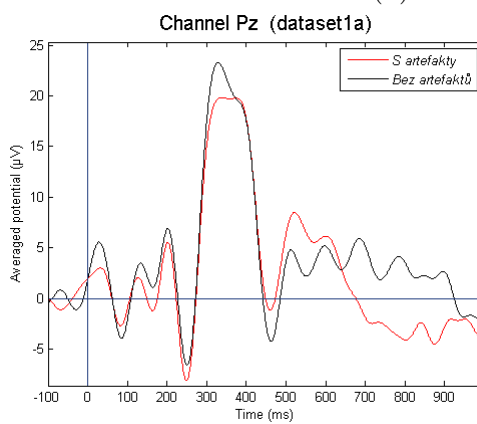
(a) Běžný průměr

(b) Průměr s kritériem artefaktu



(c) Průměr řazením

(d) Vážený průměr

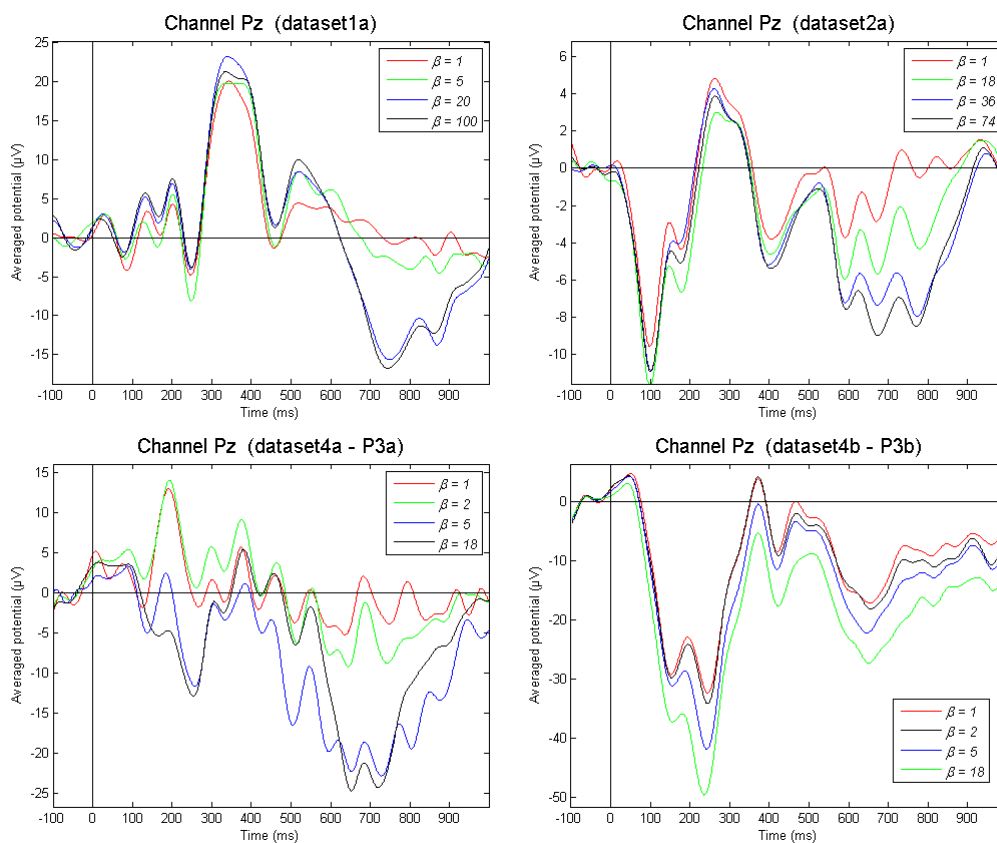
(e) Blokově vážený průměr
s parametrem $\beta = 1$

Obrázek 7.4: Přehled metod se zprůměrovanými daty s korekcí a bez korekce artefaktů

7.2.2 Blokově vážený průměr

V této podkapitole bych chtěla ukázat odlišnost výsledných dat s různým nastavením parametru β . V ukázce byly použity tři testovací množiny dat. Pro každé měření byla stanovena čtveřice hodnot koeficientu β . Základní myšlenkou bylo sledovat chování testované průměrovací metody při použití krajních hodnot ($\beta = 1$ a $\beta = \text{počet epoch kanálu}$) a dvou náhodně zvolených hodnot z tohoto rozsahu.

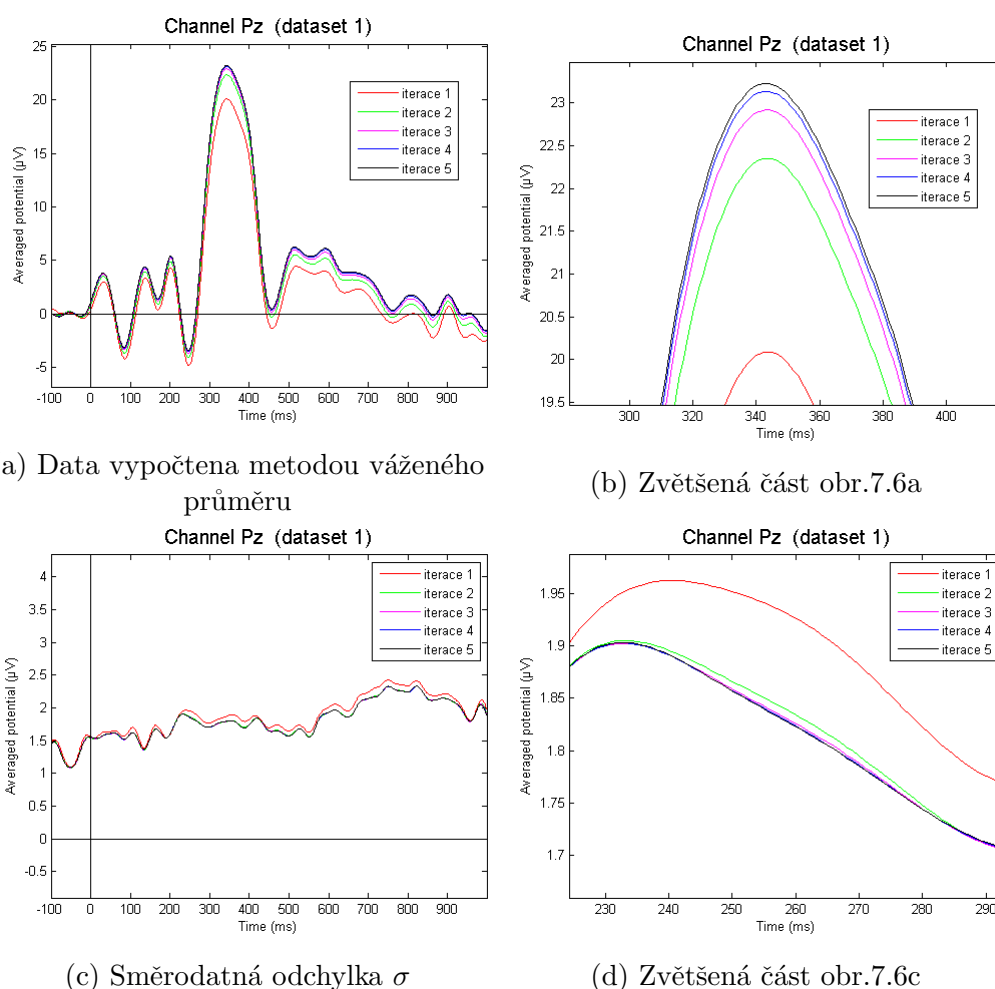
V grafech 7.5 je očividné, že při nastavení parametru na nejmenší hodnotu ($\beta = 1$) je křivka mnohem více odfiltrována od nežádoucích epoch s artefakty a reprezentuje *metodu váženého průměru*. V opačném případě při nastavení $\beta = 100$, jsou hodnoty shodné s běžným průměrem.



Obrázek 7.5: Přehled blokově vážené metody s různým nastavením parametru β pro Dataset1a, Dataset2a, Dataset4a - P3a a Dataset4b - P3b

7.2.3 Iterativní metody

Zavedením iterativního způsobu výpočtu chceme dosáhnout postupného zpřesňování zprůměrovaných dat a snižování směrodatné odchylky σ . Jako příklad posloužil *Dataset1a*, který byl zpracován *váženou průměrovací metodou* v pěti iteracích. Dvojice grafů 7.6a, 7.6b zachycuje vývoj váženého průměru s_w . Je z nich patrné ustalování hodnot s_w pro rostoucí iterace. Na dalším páru grafů 7.6c, 7.6d je vykreslena směrodatná odchylka σ_w . Jejich význam je obdobný jako u grafů popisujících vývoj s_w .



Obrázek 7.6: Zprůměrovaná data Datasetu1a a jejich směrodatná odchylka σ v pěti iteracích

Další dvě podkapitoly popisují rychlost konvergence zprůměrovaných dat. Každou následující iterací $n - 1$ a n se hodnoty vypočteného průměru ustálují. Rychlost konvergence je pro každou metodu jiná. Na data z kanálu *PZ* kolekcí *Dataset1a* a *Dataset2b* byly aplikovány všechny metody v devíti iteracích. Pro každou iteraci byly zaznamenány údaje o průměru, směrodatné odchylce a času výpočtu. Číselné hodnoty v tabulkách (7.2, 7.3 - data, 7.4, 7.5 - směrodatná odchylka) jsou vypočteny podle následující rovnice 7.1, kde N je počet prvků epochy.

$$\alpha = \sum_{n=1}^N |\text{iter}_{i-1}(x_n) - \text{iter}_i(x_n)| \quad (7.1)$$

Konvergence zprůměrovaných dat

Tabulky 7.2, 7.3 uvádějí konvergenci metod na *Datasetu1a*, resp. *Datasetu2a*. Při testování metody s použitím kritéria artefaktu s_a byly vyřazeny nevhodné epochy, které přesáhly svými hodnotami hladinu kritéria, již v první iteraci. V následujících iteracích nebyla viditelná žádná změna.

Druhá metoda s řazením s_s vykazala odlišné výsledky u obou datasetů. Výpočet na datech *Datasetu1a* se stabilizoval už při 3. kroku iterace. *Dataset2a* konvergoval dvakrát pomaleji, tam nastala stabilita až u 5. iterace.

Konvergence metody váženého průměru se prokazatelně projevila jako nej-pomalejší a to na obou testovacích datasetech. Vidíme, že například v *Datasetu1a* jsme dosáhli v iteraci č. 9 přibližně stejného výsledku jako v iteraci č. 7 u *Datasetu2a*.

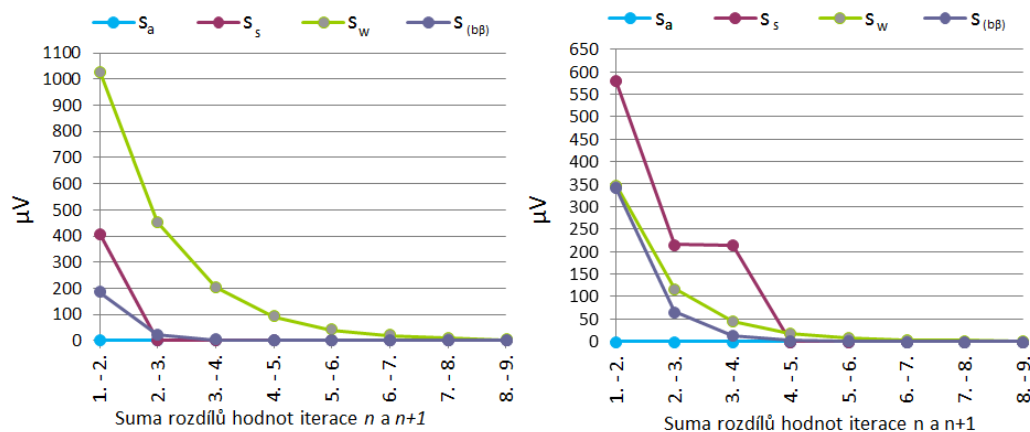
Poslední testovaná metoda byla *blokově vážená* $s_{(b\beta)}$. Ta konverguje obdobně nebo rychleji než metoda váženého průměru v závislosti na zvoleném parametru β . Na obrázku 7.7 vidíme dva grafy, ze kterých lze získat představu o rychlosti konvergence jednotlivých metod.

Průměr	Suma rozdílů hodnot iterace n a $n+1$							
	1.-2.	2.-3.	3.-4.	4.-5.	5.-6.	6.-7.	7.-8.	8.-9.
s_a	0	0	0	0	0	0	0	0
s_s	404,87	$3,2E-4$	0	0	0	0	0	0
s_w	1025,05	451,12	202,88	91,76	41,58	18,85	8,55	3,88
$s_{(b\beta)}$	183,39	21,13	3,08	0,47	0,07	0,01	$1,3E-3$	$2,2E-4$

Tabulka 7.2: Dataset1a, elektroda PZ - zprůměrovaná data

Průměr	Suma rozdílů hodnot iterace n a $n+1$							
	1.-2.	2.-3.	3.-4.	4.-5.	5.-6.	6.-7.	7.-8.	8.-9.
s_a	0	0	0	0	0	0	0	0
s_s	580,45	216,02	214,76	$1,4E-4$	0	0	0	0
s_w	348,21	117,87	44,83	18,49	8,04	3,52	1,55	0,68
$s_{(b\beta)}$	342,07	65,50	12,89	2,55	0,51	0,10	0,02	$3,79E-3$

Tabulka 7.3: Dataset2a, elektroda PZ - zprůměrovaná data



(a) Dataset1a - zprůměrovaná data

(b) Dataset2a - zprůměrovaná data

Obrázek 7.7: Grafy znázorňující rychlosti konvergence

Konvergence směrodatné odchytky

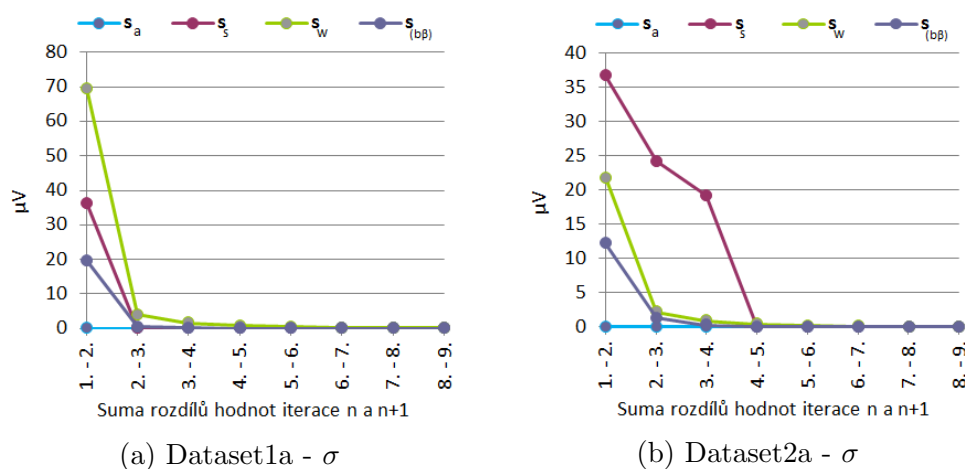
Rozdíly mezi křivkami směrodatné odchytky σ dvou po sobě jdoucích iterací jsou uvedeny v tabulkách 7.4 a 7.5. V mnoha případech se chovají stejně jako u zprůměrovaných dat. Výsledky jsou zobrazeny v grafech 7.8.

Průměr	Suma rozdílů hodnot iterace n a $n+1$							
	1.-2.	2.-3.	3.-4.	4.-5.	5.-6.	6.-7.	7.-8.	8.-9.
s_a	0	0	0	0	0	0	0	0
s_s	36,20	$4,62E-5$	0	0	0	0	0	0
s_w	69,56	3,88	1,61	0,78	0,37	0,17	0,08	0,04
$s_{(b\beta)}$	19,70	0,51	0,07	0,01	$1,7E-3$	$2,7E-4$	$3,7E-5$	$1,1E-5$

Tabulka 7.4: Dataset1a, elektroda PZ - σ

Průměr	Suma rozdílů hodnot iterace n a $n+1$							
	1.-2.	2.-3.	3.-4.	4.-5.	5.-6.	6.-7.	7.-8.	8.-9.
s_a	0	0	0	0	0	0	0	0
s_s	36,69	24,15	19,17	$2,57E-5$	0	0	0	0
s_w	21,79	2,18	0,91	0,41	0,18	0,08	0,03	0,01
$s_{(b\beta)}$	12,17	1,28	0,25	0,05	0,01	$1,9E-3$	$4,07E-4$	$8,16E-5$

Tabulka 7.5: Dataset2a, elektroda PZ - σ



Obrázek 7.8: Grafy znázorňují rychlosti konvergence

Čas výpočtu iterací

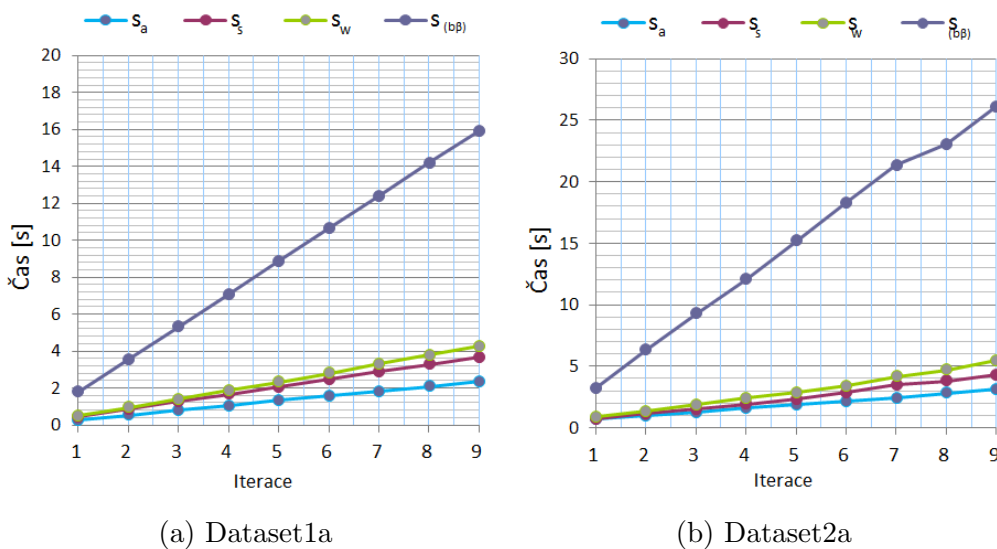
Časová náročnost je závislá na složitosti výpočtu metody (viz kapitola 6.1.2). Zvyšující se počet iterací úměrně prodlužuje dobu výpočtu. Tabulka 7.6 uvádí naměřené časy zpracování iterací 1 - 9 pro *Dataset1a* a tabulka 7.7 pro *Dataset2b*. Získaná data 7.6, 7.7 potvrzují domněnku lineární složitosti výpočtu metod. Pro ilustraci je uveden graf 7.9.

Průměr	Čas výpočtu iterace v s								
	1	2	3	4	5	6	7	8	9
s_a	0,68	0,95	1,27	1,58	1,85	2,17	2,42	2,82	3,11
s_s	0,72	1,16	1,51	1,93	2,35	2,85	3,46	3,80	4,30
s_w	0,89	1,32	1,84	2,42	2,88	3,43	4,17	4,71	5,45
$s_{(b\beta)}$	3,21	6,31	9,28	12,07	15,20	18,31	21,32	23,06	26,10

Tabulka 7.6: Dataset1a, elektroda PZ - čas

Průměr	Čas výpočtu iterace v s								
	1	2	3	4	5	6	7	8	9
s_a	0,26	0,53	0,79	1,05	1,31	1,57	1,83	2,08	2,33
s_s	0,45	0,86	1,26	1,67	2,07	2,46	2,87	3,27	3,67
s_w	0,49	0,95	1,41	1,86	2,33	2,81	3,28	3,78	4,26
$s_{(b\beta)}$	1,78	3,53	5,31	7,08	8,86	10,64	12,41	14,17	15,93

Tabulka 7.7: Dataset2a, elektroda PZ - čas



Obrázek 7.9: Grafy znázorňují čas výpočtu iterací

Z naměřených dat je viditelné, že nejnáročnější metodou se stala *blokově vážená* $s_{(b\beta)}$, ačkoliv všechny metody mají stejnou složitost. Rozdílné rychlosti jejich výpočtu jsou zapříčiněny volbou odlišné optimalizační strategie interpretu MATLABu při používání funkcí pro práci s maticemi.

8 Závěr

Diplomová práce se zabývá problematikou průměrování EEG/ERP signálů. Po provedené analýze EEGLABu (toolbox MATLABu) a jeho pluginu ERPLABu byla vybrána k implementaci *metoda s použitím kritéria artefaktu* (s_a), *průměrování řazením* (s_s), *vážený průměr* (s_w) a v poslední řadě *metoda blokově váženého průměru* ($s_{(b\beta)}$). Pro porovnání výsledných dat byla doplněna v praxi užívaná *metoda konvenčního průměru* (s_c). Funkce byly zpracovány do modulu s názvem *Averaging Tools*, který lze snadno nainstalovat do prostředí EEGLAB. Všechny funkce byly podrobně popsány v kapitole 5 *Metody zpracování ERP*, kde jsou objasněny i některé další postupy pro zlepšení kvality výpočtu průměru. Navíc byla vytvořena sada nástrojů pro zobrazení EEG dat. Funkce *Drawing Epochs* vykresluje jednotlivé epochy z aktuálního datasetu a ulehčuje např. určení hodnoty prahu u metody s použitím kritéria artefaktu. Další přidanou funkcí je *Viewer Averages* umožňující zobrazit zprůměrovaná data všech vytvořených metod do jednoho grafu.

V rámci diplomové práce bylo zpracováno 23 EEG datových sad od 14 měřených osob ze dvou experimentů. Ve výsledcích jsou uvedena data od čtyř subjektů (8 datasetů), která se jeví jako dostatečně reprezentativní. Ostatní datasety byly ze zpracování vyloučeny. Testování prokázalo, že nové metody produkují výsledky, které se svou kvalitou přibližují zprůměrovaným datům z *konvenčního průměru*, u nichž bylo provedeno odstranění artefaktů. Není tedy nezbytně nutné ručně nebo automaticky ošetřovat vstupní EEG záznam od artefaktů, protože nové metody dokáží zpracovat i méně kvalitní vstupní data.

Nejblíže se k výsledkům *konvenčního průměru* přiblížila *metoda váženého průměru* a *metoda průměrování řazením*. Metody *blokově vážená* a *s použitím kritéria artefaktu* jsou závislé na ručním nastavení parametrů, které však mohou značně ovlivnit výsledky, a proto záleží hlavně na zkušenostech, jaké s metodou výzkumník má.

Současná implementace programu splňuje všechny stanovené cíle. Ideou do budoucna by mohlo být integrování vytvořeného modulu do toolboxu ERPLAB a obohacení grafického prostředí o další prvky pro přehlednější prezentaci naměřených ERP dat.

Slovník pojmů

ADP	adenosindifosfát
AEP	auditory evoked potentials
ATPáza	adenosin trifosfatáza
CNS	centrální nervová soustava
Colliculus inferior	spodní párový hrbolek, součást sluchové dráhy
Corpus geniculatum mediale	oblá vyvýšenina v mozku, je součástí sluchové dráhy
DNA	deoxyribonukleová kyselina
EEG	elektroencefalograf
ERP	evokovaný potenciál
EEGLab	open-source vyvíjený jako doplněk softwaru MATLAB firmy Mathworks sloužící pro zaznamenávání a zpracování mozkových vln
GUI	(graphical user interface) grafické uživatelské rozhraní
Intenzivní medicína	představuje vysoce specializovanou medicínskou činnost jak z odborného, tak z formálního hlediska
K	draslík
Kognitivní	rozpoznávací, týkající se vnímání a myšlení
Kochleární	týkající se hlemýždě vnitřního ucha
Konformace	prostorové uspořádání atomů v molekule sloučenin

MEG	magnetoencefalografie - metoda, díky které lze sledovat elektrické proudy v mozku za pomoci jimi vygenerovaných velmi slabých změn magnetického pole, tímto způsobem lze lokalizovat místa elektrické aktivity mozku při různých podnětech nebo zadaných kognitivních úlohách
Lemniscus lateralis	vlákna, která jsou součástí sluchové dráhy
Na	sodík
Perikaryon	oblast buňky přiléhající k jádru
Proximální	blíže k centru, středu hlavy
Referenční elektroda	při záznamu EEG se porovnává potenciál dvou bodů na kůži lebky (bipolární záznam), nebo rozdíl elektrického potenciálu mezi aktivním bodem mozkové tkáně proti bodu s nulovým potenciálem (pod neaktivní, referenční elektrodou - např. ušní boltec, kořen nosu), což je označováno jako unipolární záznam
SEP	somatosensory evoked potentials
Sluchová radiace	vlákna posledního neuronu sluchové dráhy
SNR	signal-to-noise ratio - poměr signál-šum
Soma	tělo buňky
Olivární komplex	je součástí mozkového kmene, konkrétně prodloužené míchy, v něm se nacházejí olivární jádra, která jsou důležitou součástí sluchových drah
P_i	iontová forma fosfátu
Transkraniální	přes lebku
Trofika	funkce nervových vláken regulujících výživu a přeměnu látek tkání
VEP	visual evoked potentials
Vertex	temeno, vrchol hlavy

Použité prameny

- [1] G. D. Dawson. *Investigations on a patient subject to myoclonic seizures after sensory stimulation*, J. Neurol Neurosurg Psychiatry 1947.
- [2] ERPinfo. *Manuál pro ERPLAB [online]*, 2011. <http://www.erpinfo.org/erplab>.
- [3] Adam Hanzelka. *Korekce kolísání nulové izolinie*. Bakalářská práce, Vysoké učení technické v Brně, 2011.
- [4] Birger Kollmeier Helmut Riedel, Michael Granzow. *Single-sweep-based methods to improve the quality of auditory brain stem responses Part II: Averaging methods*, 2001.
- [5] Ing. Elena Cocherová PhD. Ing. Jozef Púčik, PhD. *Analýza biosignálov*. Slovenská technická univerzita v Bratislave, 2008. ISBN 978-80-227-2833-1.
- [6] František Koukolík. *Já - O vztahu mozku, vědomí a sebeuvědomování*. Praha: Karolinum 2003.
- [7] Steven Luck. *An Introduction to Event-Related Potential*. Massachusetts Institute of Technology, The MIT Press London 2005. ISBN 0-262-12277-4.
- [8] Mark Hallett Marjan Jahanshahi, editor. *The Bereitschaftspotential: Movement-Related Cortical Potentials*. 2003. ISBN 0-306-47407-7.
- [9] MathWorks. *Manuál pro Matlab [online]*, 2014. <http://www.mathworks.com/help/matlab/index.html>.
- [10] MSc Mohamed Fath EL-Bab, MB B Ch. *Cognitive event related potentials during a learning task*, 2001, University of Southampton, United Kingdom.

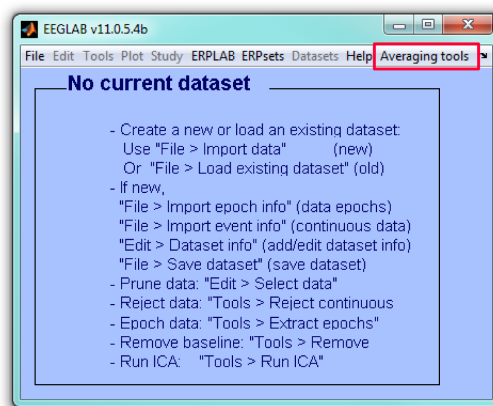
- [11] MUDr. Jaroslav Dufek MUDr. Petr Kaňovský, CSc. *Evokované potenciály v klinické praxi*. Brno 2000. ISBN 80-7013-306-6.
- [12] Churchill Livingstone [online]. *Brain-stem auditory evoked potentials*, 2000. http://web.squ.edu.om/med-Lib/MED_CD/E_CDs/anesthesia/site/content/v03/030453r00.HTM.
- [13] Donnel J. Creel [online]. *Visually evoked potentials*, 2014. <http://webvision.med.utah.edu/book/electrophysiology/visually-evoked-potentials/>.
- [14] Mark Kelly [online]. *Brain Neuron Diagram*, Heartspring.net 2012. http://www.heartspring.net/art_brain_cell_neuron.html.
- [15] MUDr. Ladislav Polách [online]. *Neurony, neurotransmitery a synapse*, 2012. <http://www.upsychiatra.cz/srozumitelne/neurony-neurotransmitery-a-synapse/>.
- [16] Sdružení CEREBRUM [online]. *Centrální nervová soustava*, 2013. <http://www.poranenimozku.cz/fakta-o-mozku/nervova-soustava/centralni-nervova-soustava.html>.
- [17] S. Butler P. Walsh, N. Kane. *The clinical role of evoked potentials*, 2005. http://jnp.bmj.com/content/76/suppl_2/ii16.full.
- [18] John J.B. Allen Ph.D. *Advanced Signal Processing II [online]*, University of Arizona, 2011. http://apsychoserver.psychofizz.psych.arizona.edu/JJBAREprints/PSYC501A/pdfs2011/Lecture_14_Advanced_II_2011.pdf.
- [19] prof. MUDr. Martin Bareš Ph.D. *Kognitivní evokované potenciály*, I. neurologická klinika, LF MU a FN u sv. Anny v Brně. 2013. http://www.csnn.eu/ceska-slovenska-neurologie-clanek/kognitivni-evokovane-potencialy-36052?confirm_rules=1.
- [20] Saeid Sanei and J. A. Chambers. *EEG signal processing*. John Wiley & Sons Ltd, 2007. ISBN 978-0-470-02581-9.
- [21] SCCN Software. *Manuál pro EEGLAB [online]*, 2011. <http://sccn.ucsd.edu/wiki/EEGLAB>.
- [22] S. Trojan. *Lékařská fyziologie*. Grada publishing, a. s., 2003. ISBN 80-247-0512-5.

- [23] Veronika Vencúriková. *Evokovaný potenciál P3 a jeho aplikace v neuroinformatice*. Bakalářská práce, Západočeská univerzita v Plzni, 2011.
- [24] Charles D. Woody. *Characterization of an adaptive filter for the analysis of variable latency neuroelectric signals*, Laboratory of Neurophysiology, National Institute of Mental Health, Bethesda, Maryland, 1967.

Uživatelská dokumentace

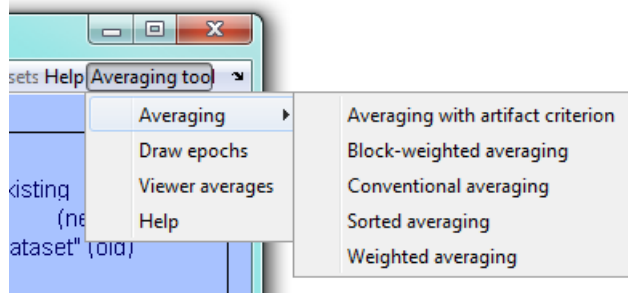
Instalace

Zásuvný modul průměrovacích metod nainstalujeme tak, že vložíme adresář *averagingmethods* s funkcemi do podadresáře *eeglab\plugins*. Po spuštění nebo restartování EEGLABu se objeví v menu *Averaging tools* (obr. 1).



Obrázek 1: Hlavní okno EEGLABu s instalovaným pluginem. Nabídka *Averaging tools* je červeně orámovaná.

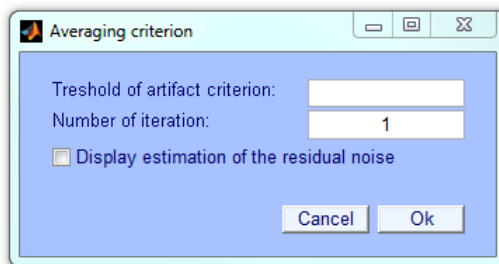
Nabídka zásuvného modulu obsahuje možnosti pro volbu všech průměrovacích metod (*Averaging: Averaging with artifact criterion, Block-weighted averaging, Conventional averaging, Sorted averaging, Weighted averaging*), vykreslení epoch (*Draw epochs*), vykreslení průměrů (*Viewer averages*) a nápovědu (*Help*), viz obr. 2. Vysvětlení významu a způsobu výpočtu průměrů najdeme v kapitole 4 diplomové práce.



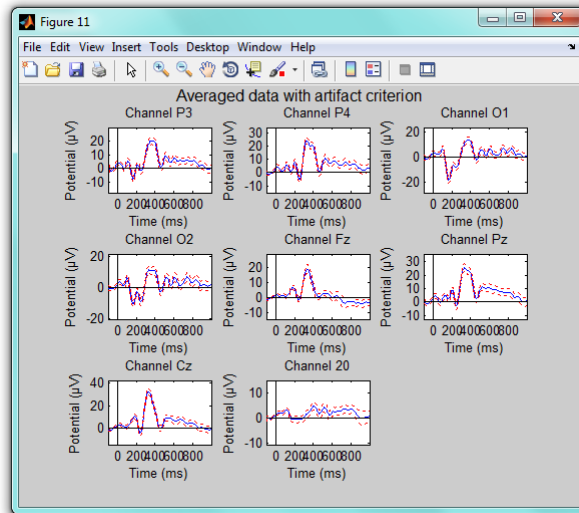
Obrázek 2: Panel *Averaging tools*

Averaging

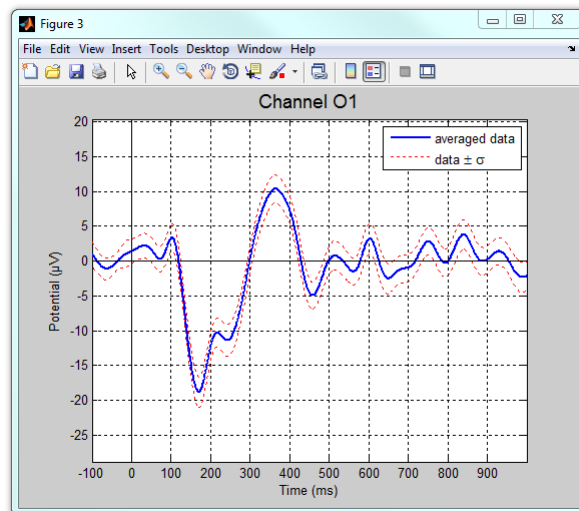
Abychom mohli použít funkce z nabídky, musí být načten nejlépe filtrovaný *dataset* s extrahovanými epochami (počet epoch musí být větší než 1). Metody vždy pracují s aktuálním *datasetem*. Na obrázku 3 je zobrazeno okno s ovládacími prvky metody *Averaging with artifact criterion*. Zde je nutné nastavit velikost prahu a počet iterací. Pokud chceme zobrazit ve výsledcích směrodatnou odchylku výpočtu, zaškrtneme *Display estimation of the residual noise*. Stisknutím tlačítka *Ok* se spustí výpočet funkce. Následně se otevře okno s grafy se zprůměrovanými hodnotami každé elektrody (obr. 4). Pokud si chceme blíže zobrazit graf elektrody, stačí na něj kliknout myší a objeví se nový plot s jedním grafem. Na obrázku 5 je zobrazen průměr elektrody *O2*. Ostatní nabídky metod jsou koncipovány stejným způsobem.



Obrázek 3: Okno metody průměrování s použitím kritéria artefaktu



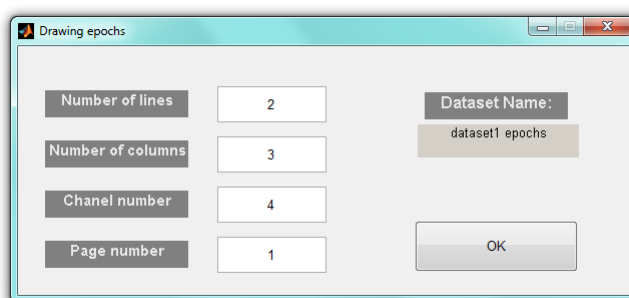
Obrázek 4: Ukázka vykreslení průměru pro každou elektrodu



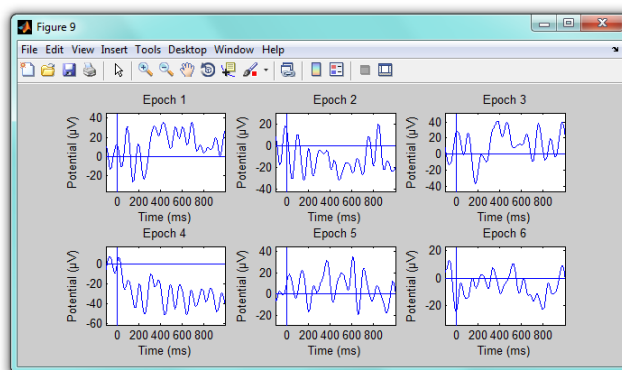
Obrázek 5: Modře je zobrazen průměr elektrody O1, červeně je vykreslena směrodatná odchylka.

Draw epochs

Averaging tools nabízí i pomocnou funkci pro vykreslení jednotlivých epoch (*Drawing epochs*) z aktuálního datasetu. Je vhodná například pro určení prahu u metody s použitím kritéria artefaktu. Před vykreslením je potřeba zvolit vhodný počet epoch v řádku a ve sloupci, číslo kanálu elektrody a číslo strany. Ukázkové vyplnění nabídky zachycuje obrázek 6. Stisknutím tlačítka *Ok* se zobrazí grafy s jednotlivými epochami zvolené elektrody, viz obr. 7.




Obrázek 6: GUI *Drawing epochs*



Obrázek 7: Vykreslené epochy

Viewer averages

Pro přehledné zobrazení všech dostupných průměrů do jednoho plotu byl vytvořen panel *Viewer averages*. GUI máme zobrazeno na obrázku 8. Nabídku lze spustit po načtení minimálně jednoho datasetu. Po spuštění jsou aktivní zaškrťovací políčka pouze pro průměry, které jsou dostupné ve *workspace* MATLABu. Proto je v první řadě potřebné zprůměrovat dostupná data metodami, které chceme vykreslit. Okno obsahuje na levé straně plochu pro vykreslení všech průměrů a po pravé straně nabídku *Setting*, kde je potřeba zvolit číslo elektrody (kanálu) a zobrazení jednotlivých průměrů.



Obrázek 8: GUI *Viewer averages* pro zobrazení průměrů

Help

Poslední možností pluginu je *Help*. Po stisknutí tlačítka se v příkazové řádce MATLABu objeví popis všech funkcí. Kliknutím na modře zvýrazněný název funkce se zobrazí jednoduchá nápověda pro konkrétní metodu.

```
>>
HELP_AVERAGING - Call the help for averaging methods in Averaging tools

Help for averaging methods:

See also:
averaging\_w           - conventional average
aver\_crit\_w          - average using an artifact criterion
aver\_sort\_w          - average with sorting
aver\_weighted\_w      - weighted average
aver\_block\_weighted\_w - block-weighted average
draw\_averaging\_data\_w - draw averaged data
draw\_epochs         - draw individual epochs
```

Obrázek 9: Nápověda v příkazové řádce MATLABu