VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE

Brno, 2021 Tereza Mikešová

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ
FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ
DEPARTMENT OF BIOMEDICAL ENGINEERING

METODY KOMPARACE ZÁZNAMŮ ELEKTROENCEFALOGRAFU
METHODS FOR ELECTROENCEPHALOGRAM RECORDS COMPARISON

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS

AUTOR PRÁCE Tereza Mikešová
AUTHOR

VEDOUCÍ PRÁCE Ing. Oto Janoušek, Ph.D.
SUPERVISOR

BRNO 2021

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Tereza Mikešová ***ID:*** 211207

Ročník: 3 ***Akademický rok:*** 2020/21

NÁZEV TÉMATU:

Metody komparace záznamů elektroencefalografu

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s metodami analýzy elektroencefalogramu. 2) Proveďte literární rešerši těch metod, jejichž výstupy lze použít pro srovnání elektroencefalogramů. 3) Porovnejte vlastnosti těchto metod. Objasněte vliv nastavení parametrů metody na její výsledek, popište závislost na délce signálu, vyjádřete se k robustnosti metody vůči zašuměným a nekompletním záznamům, atd. 4) Vyberte si jednu z metod a zdůvodněte její výběr. 5) Implementujte vybranou metodu. 6) Pomocí navržené metody analyzujte záznamy elektroencefalografické aktivity ze dvou skupin dat vhodné databáze, statisticky zpracujte výsledky a interpretujte jejich význam. 7) Zhodnoťte dosažené výsledky, zhodnoťte schopnost metody rozlišit záznamy ze dvou skupin dat, a srovnejte vlastní dosažené výsledky s teoretickou úspěšností vybrané metody i s teoretickou úspěšností ostatních metod zahrnutých v literární rešerši.

DOPORUČENÁ LITERATURA:

[1] CHANG-HWAN, I. Computational EEG analysis. New York, NY: Springer Berlin Heidelberg, 2018. ISBN 978-9811309076.

[2] SIULY, S. EEG signal analysis and classification. New York, NY: Springer Berlin Heidelberg, 2017. ISBN 978-3319476520.

Termín zadání: 8.2.2021 ***Termín odevzdání:*** 28.5.2021

Vedoucí práce: Ing. Oto Janoušek, Ph.D.

doc. Ing. Jana Kolářová, Ph.D.
předseda rady studijního programu

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

ABSTRAKT

Tato bakalářská práce se zabývá v teoretické části metodami analýzy elektroencefalografických záznamů, které lze využít pro komparaci těchto záznamů. Teoretická část ústí ve výběr jedné metody, konkrétně STFT, která je využita v navazující praktické části. Cílem této části je ověřit schopnost metody STFT rozlišit záznamy ze dvou skupin. Pro tyto účely jsou použity záznamy klidové a zátěžové, přičemž zátěž je navozena počítáním matematických příkladů. Ze zkoumaných výkonových parametrů prokázaly největší statistickou významnost rozdíly parametrů poměru výkonu v beta a alfa pásmu a relativní výkon alfa pásma. Jako nejvýhodnější se ukázalo použití nejkratšího časového okna STFT s délkou 2 sekund.

KLÍČOVÁ SLOVA

Analýza EEG, komparace záznamů, STFT, mentální zátěž, aritmetický test, výkon ve frekvenčních pásmech.

ABSTRACT

This bachelor thesis starts with a theoretical section that explores the methods of electroencephalographic records analysis. The chosen methods are suitable for signal comparison. One of the methods, specifically STFT, is subsequently used in the practical segment. The aim of the practical section is to verify the ability of the proposed method to distinguish between the signals from two groups. For these purposes, rest and mental load records are used, the load being induced by counting mathematical examples. Of the examined power parameters, the differences in the ratio of beta and alfa band power and the relative power of alfa band showed the greatest statistical significance. The most appropriate setup of STFT seems to be with the shortest time window of 2 seconds.

KEYWORDS

EEG analysis, records comparison, STFT, mental workload, arithmetic task, frequency band power.

MIKEŠOVÁ, Tereza. *Metody komparace záznamů elektroencefalografu*. Brno, 2021, 75 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Oto Janoušek, Ph.D.

Vysázeno pomocí balíčku `thesis` verze 4.02; `http://latex.feec.vutbr.cz`

PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma „Metody komparace záznamů elektroencefalografu“ jsem vypracovala samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

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

Brno ....

podpis autorky

PODĚKOVÁNÍ

Ráda bych poděkovala vedoucímu bakalářské práce panu Ing. Otovi Janouškovi, Ph.D. za odborné vedení, trpělivost, vstřícnou komunikaci a podnětné návrhy k práci.

Obsah

Úvod **11**

1 Elektroencefalografie **12**
1.1 Mozková aktivita 12
1.2 Elektrody 12
1.3 Mezinárodní systém 10–20 13
1.4 EEG přístroj 14
1.5 Vlastnosti EEG signálů a EEG pásem 14

2 Analýza EEG **17**
2.1 Analýza ve frekvenční oblasti 17
2.1.1 Welchova metoda 17
2.1.2 Autoregresní lineární model – AR 18
2.2 Časově-frekvenční analýza 19
2.2.1 Krátkodobá Fourierova transformace – STFT 19
2.2.2 Vlnková transformace – WT 20
2.3 Nelineární analýza 21
2.3.1 Aproximativní entropie – ApEn 21
2.3.2 Spektrální entropie – SpEn 22
2.3.3 Higuchiho fraktální dimenze – HFD 22

3 Studie mentální zátěže **24**
3.1 Detekce stresu na základě výkonových příznaků 24
3.2 Identifikace úrovní stresu pomocí výkonů v pásmech alfa a beta . . . 25
3.3 Kvantifikace stresu pomocí vlnkových koeficientů 26
3.4 Analýza EEG během relaxace a stavu mentální zátěže pomocí PSD . 28
3.5 Charakterizace mentální zátěže pomocí entropií 28
3.6 Rozpoznání zátěže pomocí fraktální dimenze, AR modelu a odhadu PSD 30

4 Srovnání analytických metod **31**
4.1 Frekvenční oblast 31
4.1.1 Parametry odvozené z PSD 32
4.2 Časově-frekvenční oblast a její parametry 32
4.3 Nelineární analýza a nelineární parametry 33
4.4 Úspěšnost vybraných metod 33

5 Experimentální část **35**
5.1 Data 35
5.2 Výběr metody a parametrů 36
5.3 Implementace metody 36
5.4 Statistická analýza 38
5.4.1 Popis průběhu analýzy 39

6 Výsledky experimentální části **41**
6.1 Dílčí výsledky pro elektrodu Fp1 41
6.2 Dílčí výsledky pro elektrodu F8 46
6.3 Dílčí výsledky pro elektrodu P4 51
6.4 Dílčí výsledky pro elektrodu O1 56
6.5 Modifikace původní analýzy 61
6.5.1 Analýza energeticky výrazné oblasti spektrogramu 61
6.5.2 Analýza signálů s aditivním šumem 61

7 Diskuze výsledků **64**

Závěr **66**

Literatura **67**

Seznam symbolů, veličin a zkratek **73**

A Obsah přiloženého archivu **75**

Seznam obrázků

1.1 Umístění elektrod podle mezinárodního systému 10-20 [4]. 13
1.2 Jednotlivá standardizovaná frekvenční pásma EEG signálu dle [7]. . . 16
2.1 Schéma kaskády filtrů pro vlnkovou dekompozici [19]. 20
3.1 Průměrná PSD kanálu Fp1 pro jednotlivá frekvenční pásma od všech subjektů dle [33]. 25
3.2 Rozložení průměrného výkonu v alfa pásmu během počítání 3 obtížnostních úrovní matematických příkladu ve stavu klidu a při stresu dle [35]. 27
3.3 Medián ApEn od prvního subjektu z okcipitálního kanálu PO3 při všech 7 úrovních zátěže dle [38]. 29
5.1 Průběh měření EEG záznamů dle [42]. 35
5.2 Blokové schéma programu. 37
5.3 Test normality histogramem s Shapiro-Wilkovým testem pro parametr průměrného výkonu v alfa pásmu v klidu ze záznamů elektrody Fp1. 40
5.4 Test normality histogramem s Shapiro-Wilkovým testem pro parametr průměrného výkonu v delta pásmu v klidu ze záznamů elektrody Fp1. 40
6.1 Rozložení hodnot průměrných výkonů v delta pásmu záznamů z elektrody Fp1. 42
6.2 Rozložení hodnot průměrných výkonů v alfa pásmu záznamů z elektrody Fp1. 43
6.3 Rozložení hodnot průměrných výkonů v beta pásmu záznamů z elektrody Fp1. 43
6.4 Rozložení hodnot poměrů výkonů v beta a alfa pásmu záznamů z elektrody Fp1. 44
6.5 Rozložení hodnot relativních výkonů delta pásma záznamů z elektrody Fp1. 44
6.6 Rozložení hodnot relativních výkonů alfa pásma záznamů z elektrody Fp1. 45
6.7 Rozložení hodnot relativních výkonů beta pásma záznamů z elektrody Fp1. 45
6.8 Rozložení hodnot průměrných výkonů v delta pásmu záznamů z elektrody F8. 47
6.9 Rozložení hodnot průměrných výkonů v alfa pásmu záznamů z elektrody F8. 48

6.10 Rozložení hodnot průměrných výkonů v beta pásmu záznamů z elektrody F8. 48
6.11 Rozložení hodnot poměrů výkonů v beta a alfa pásmu záznamů z elektrody F8. 49
6.12 Rozložení hodnot relativních výkonů delta pásma záznamů z elektrody F8. 49
6.13 Rozložení hodnot relativních výkonů alfa pásma záznamů z elektrody F8. 50
6.14 Rozložení hodnot relativních výkonů beta pásma záznamů z elektrody F8. 50
6.15 Rozložení hodnot průměrných výkonů v delta pásmu záznamů z elektrody P4. 52
6.16 Rozložení hodnot průměrných výkonů v alfa pásmu záznamů z elektrody P4. 53
6.17 Rozložení hodnot průměrných výkonů v beta pásmu záznamů z elektrody P4. 53
6.18 Rozložení hodnot poměrů výkonů v beta a alfa pásmu záznamů z elektrody P4. 54
6.19 Rozložení hodnot relativních výkonů delta pásma záznamů z elektrody P4. 54
6.20 Rozložení hodnot relativních výkonů alfa pásma záznamů z P4. . . . 55
6.21 Rozložení hodnot relativních výkonů beta pásma záznamů z P4. . . . 55
6.22 Rozložení hodnot průměrných výkonů v delta pásmu záznamů z elektrody O1. 57
6.23 Rozložení hodnot průměrných výkonů v alfa pásmu záznamů z elektrody O1. 58
6.24 Rozložení hodnot průměrných výkonů v beta pásmu záznamů z elektrody O1. 58
6.25 Rozložení hodnot poměrů výkonů v beta a alfa pásmu záznamů z elektrody O1. 59
6.26 Rozložení hodnot relativních výkonů delta pásma záznamů z elektrody O1. 59
6.27 Rozložení hodnot relativních výkonů alfa pásma záznamů z O1. . . . 60
6.28 Rozložení hodnot relativních výkonů beta pásma záznamů z O1. . . . 60
6.29 Ukázka spektrogramů klidového (vlevo) a zátěžového (vpravo) záznamu z elektrody P4 od subjektu 33. 61
6.30 Ukázka časového průběhu záznamu (vlevo) a spektrogramu (vpravo) záznamu z elektrody P4 od subjektu 2 s aditivním šumem. 62

Seznam tabulek

4.1 Shrnutí jednotlivých studií. 34
6.1 Shrnutí statistické analýzy záznamů z Fp1. 41
6.2 Shrnutí statistické analýzy záznamů z F8. 46
6.3 Shrnutí statistické analýzy záznamů z P4. 51
6.4 Shrnutí statistické analýzy záznamů z O1. 56
6.5 Statistická analýza záznamů z elektrody P4 s aditivním šumem. . . . 63

Úvod

Elektroencefalografie (EEG) je přední diagnostická neinvazivní metoda, která zaznamenává mozkovou aktivitu. Hraje klíčovou roli v diagnostice především epilepsie, Alzheimerovy choroby, demence či slouží ke studiu spánkových stádií a poruch. Využití najde EEG i na operačních sálech, kde vyhodnocuje míru anestezie. V posledních letech se uplatňuje ve vývoji BCI (Brain-computer interface) technologií propojujících lidský mozek s počítačem a dalším technickým zařízením. Někteří vědci zkoumají možnost využití EEG signálů jako biometrického prvku, který je specifický pro každého člověka stejně tak jako např. otisky prstů.

Rozlišení dvou od sebe různých EEG záznamů se uplatňuje všude tam, kde je potřeba objektivně zhodnotit psychický stav člověka. Hodnotit se může např. únava řidičů za volantem či pozitivní nebo negativní emoce jedinců. Diskriminaci EEG lze uplatnit v rámci předzpracování pro aplikace umělé inteligence, která se učí na základě parametrů, podle kterých lze záznamy rozlišit.

Diferenciace záznamů se využívá i pro hodnocení míry mentálního stresu. Právě na tuto oblast je zaměřena praktická část práce. V té jsou porovnávány záznamy klidové se zátěžovými, přičemž zátěž je navozena počítáním matematických příkladů. Cílem praktické části je ověřit schopnost analytické metody záznamy odlišit. Použitá metoda vychází z teoretické části, ve které jsou vybrané metody a parametry rozebrány a porovnány.

1 Elektroencefalografie

1.1 Mozková aktivita

EEG snímá hodnoty elektrických potenciálů generovaných mozkovými nervovými buňkami tzv. neurony z povrchu lebky. Předpokládá se, že většina měřených potenciálů pochází z mozkové kůry, jež pokrývá koncový mozek a je charakteristická svým zvrásněním, které zvětšuje její povrch. Je tvořena šedou a bílou hmotou. Šedá hmota obsahuje spíše těla neuronů. Pod šedou hmotou se nachází hmota bílá obsahující myelinizovaná nervová vlákna – axony. Na neuronech je velké množství synapsí v řádech deseti až statisíců, díky kterým si neurony mohou předávat informace v podobě změny membránového potenciálu. Příspěvky od jednotlivých synapsí mohou být buď excitační (EPSP), nebo inhibiční (IPSP). Sčítají se a při překročení prahové hodnoty vzniká v iniciálním segmentu neuronu akční napětí, které se pak dále šíří bez útlumu. [1]

Potenciály, které jsou snímány, vznikají sumací právě post-synaptických potenciálů pyramidálních neuronů. Na těchto neuronech vzniká elektrický dipól mezi tělem neuronu a dendrity směřujícími vzhůru. Elektrické pole sahá až na povrch hlavy, odkud jsou tyto potenciály měřeny. Akční napětí, resp. akční potenciál trvá kratší dobu a nemá takový dosah, co se potenciálového pole týče. Proto se akční napětí významně nepodílí na výsledném EEG záznamu. [2]

Snímané potenciály z povrchu skalpu jsou tvořeny velkým množstvím aktivních neuronů. Uvádí se, že za měřitelným potenciálem stojí nejméně 6 cm^2 synchronizovaně aktivní mozkové kůry obsahující zhruba 10^{12} neuronů. [1]

1.2 Elektrody

Nejčastěji využívané jsou skalpové elektrody, které se umísťují na povrch hlavy, jak napovídá jejich název. Méně často se můžeme setkat s invazivní formou snímání elektrických potenciálů z mozku, kdy se elektrody umísťují přímo na mozkovou kůru. Tato metoda se nazývá elektrokortikografie (ECoG). [3]

Skalpové elektrody mají miskovitý tvar o průměru 4–10 mm a pomocí izolovaného vodiče jsou napojeny na EEG přístroj. Před samotným připevněním elektrody ke skalpu je nutno kůži odmastit alkoholem a pomocí abrazivní pasty odstranit zrohovatělou část pokožky. Fixace elektrody se provádí více způsoby. První je využití kolodia na přichycení a následné vyplnění elektrody vodivým gelem. Další možností je použití vodivé pasty, která se nanese na skalp a elektroda se do daného místa vtlačí. [3]

V současnosti se ale vzhledem k množství elektrod, rychlejší manipulaci a přesnému umístění elektrod využívají elektrodové čepice, na kterých jsou na látce přesně umístěny držáky pro jednotlivé elektrody. Ještě novější je provedení, které nahrazuje látku pružnými gumovými pásky, které spojují přímo elektrodové držáky. [3]

Nejčastěji používané elektrody jsou argentchloridové Ag/AgCl. Jedná se o elektrody nepolarizovatelné, což je žádaná vlastnost u elektrod pro měření různých biologických signálů. Jejich výhodou je dlouhodobá elektrická stabilita, jsou hypoalergenní a vykazují stabilní elektrochemické potenciály vůči tkáni. Existuje však celá řada vhodných materiálů pro výrobu elektrod jako např. nerezová ocel, čisté stříbro a zlato, pozlacené stříbro nebo cín. Důležité však je, aby v rámci jednoho měření byly použity elektrody z jednoho materiálu. [1]

1.3 Mezinárodní systém 10–20

Aby byla zajištěna reprodukovatelnost výsledků měření, možnost srovnání, elektrody se nejčastěji zapojují podle mezinárodně uznávaného schématu 10-20. Po povrchu hlavy jsou na základě kostěných výstupků vedeny linie, na které jsou rovnoměrně rozmísťovány elektrody po 10 či 20 % délky linie. Standardní sestava obsahuje celkem 22 elektrod, z nichž 21 je měřících a 1 zemnící. Každá elektroda má pak své označení pomocí písmene a číslice. [3] Schématické zobrazení zapojení ilustruje obrázek 1.1.

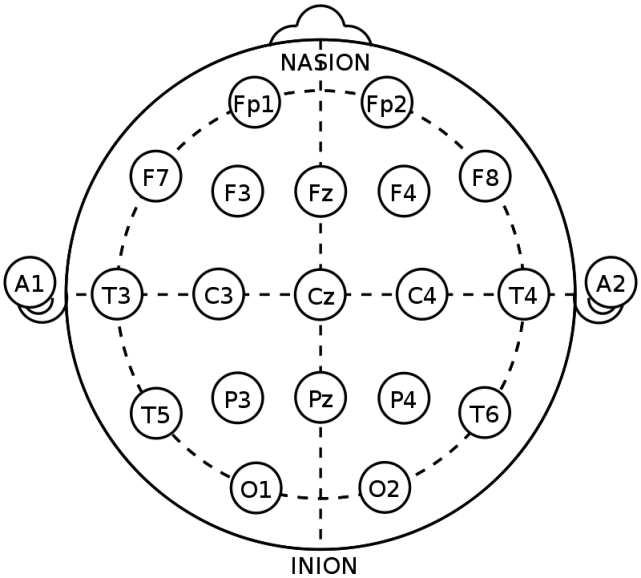

Obr. 1.1: Umístění elektrod podle mezinárodního systému 10-20 [4].

Písmenné označení na obrázku 1.1 odpovídá mozkové oblasti: Fp – frontopolární, F – frontální, C – centrální, P – parientální, O – okcipitální a A – ušní lalůčky [3]. V dnešní době už existuje mnoho druhů elektrodových čepic, které přesahují 10–20

systém a mají dokonce 128 (10–5 systém) či 256 kanálů. Kanál je tvořen aktivní elektrodou, referenční elektrodou (nejčastěji se jako referenční používají elektrody A1/A2 nebo Cz) a zemnící elektrodou. [5]

Elektrody je možné umístit nejen na mozkovou část lebky, ale i na obličejovou část, což může přinést důležité dodatečné informace. Novější čepice mohou mít elektrody ekvidistantně umístěné od sebe, což hraje roli v prostorovém pokrytí spolu s hustotou elektrod. [1]

1.4 EEG přístroj

Vstupním signálem, který vstupuje do EEG přístroje není jenom požadovaná složka mozkové aktivity, ale i další komponenty jako např. ostatní biosignály způsobené svalovou aktivitou nebo dýcháním, síťový brum či zkreslení vlivem nedokonalého přechodu kůže – elektroda a šum. [5]

Klíčovou složkou EEG přístroje je soustava zesilovačů a filtrů. Korové potenciály snímané z povrchu hlavy mají obecně velmi malou amplitudu v intervalu ± 150 µV. Takto malé amplitudy jsou velmi náchylné na rušení, a aby bylo možné s nimi pracovat, je nutné je zesílit. [1] Úkolem vstupních zesilovačů je maximalizovat SNR (poměr signálu k šumu). Čím větší SNR je, tím kvalitnější signál s menším rušením obdržíme. Důraz je kladen na vysokou vstupní impedanci zesilovače. [6]

Na výstupu EEG přístroje pak získáváme digitalizovaný signál, který prošel A/D převodníkem. Jedná se tedy o diskrétní signál, jehož vzorkovací frekvence musí splňovat podmínky vzorkovacího teorému (Nyquistova teorému). Vzorkovací frekvence musí být tedy minimálně dvakrát vyšší, než je nejvyšší frekvence obsažená v signálu. [5]

1.5 Vlastnosti EEG signálů a EEG pásem

EEG signál měřený z povrchu hlavy je dán sumací potenciálů z různých částí mozku. Jedná se o nepredikovatelný, aperiodický signál. Amplituda signálu se pohybuje v intervalu mezi 0,1 až 100 µV. Nejdůležitější frekvence se nachází v intervalu cca 0,1–30 Hz. Tento interval frekvencí se dále dělí do užších standardizovaných pásem, která jsou charakteristická pro dané stavy. Nutné je poznamenat, že jednotlivá pásma nemají pevně danou hranici a jednotlivé publikace pásma definují nepatrně rozdílně. U zdravého člověka se jedná o pásmo delta, theta, alfa, beta a gama. Vyšší frekvence je možné vidět u nefyziologických záznamů EEG např. u epilepsie. [1, 2] Zobrazení jednotlivých frekvenčních pásem je vidět na obrázku 1.2.

Delta pásmo

Delta pásmo se nachází v rozmezí frekvencí 0,5–4 Hz. Pozorovat tento rytmus je možné během hlubokého spánku při amplitudách 75–200 µV [3]. Literatura [7] uvádí, že během výkonu mentálního úkolu roste aktivita v tomto pásmu.

Théta pásmo

Pro théta pásmo jsou typické frekvence 4–8 Hz. Uvádí se, že aktivita v tomto pásmu roste při práci s pamětí, resp. při ukládání nových informací. Rozlišit tento rytmus je obtížné, využívá se porovnávání signálů klidových a testovacích. [7]

Alfa pásmo

Alfa pásmo obsahuje frekvence zhruba v intervalu 8–13 Hz. Pozorovat alfa rytmus je možné převážně v okcipitální či pariento-okcipitální oblasti. Jedná se o rytmus, který se fyziologicky objevuje, pokud je subjekt v relaxovaném bdělém stavu. Alfa rytmus vymizí při otevření očí a při zavření očí se znovu objeví. Kromě otevřených očí může alfa aktivita vymizet nebo snížit svoji amplitudu v závislosti na mentální činnosti, stavu pozornosti či ospalosti. Frekvence alfa rytmu zrcadlí metabolické procesy v mozku např. jeho perfuzi. Průměrná amplituda se nachází v rozmezí 20–80 µV. S přibývajícím věkem může mírně klesat pravděpodobně z důvodu zvyšování impedance struktur mezi mozkovou kůrou a elektrodou. [3]

Beta pásmo

Frekvenčně beta pásmo charakterizují frekvence cca 14–30 Hz. Jedná se o rychlou aktivitu s amplitudou obvykle do 20 µV. Pozorovatelná je nejčastěji nad frontálními až fronto-centrálními a parientálními [7] oblastmi. Beta aktivita mizí s ospalostí a usínáním. S rostoucím věkem roste i četnost výskytu beta aktivity. Zároveň u žen můžeme pozorovat vyšší zastoupení než u mužů. [3] Aktivita se v tomto pásmu zvýší v závislosti na vědomém vnímání podnětů. Beta rytmus je typický hlavně pro stav zvýšené pozornosti a soustředění. [7]

Gama pásmo

Gama pásmo je pásmo s nejvyššími frekvencemi obecně nad 30 Hz, obvykle ale nepřekročí 45 Hz. Aktivita v tomto pásmu je spojena se zpracováním informací ve smyslu rozpoznávání smyslových podnětů, či s nástupem volních pohybů. [7]

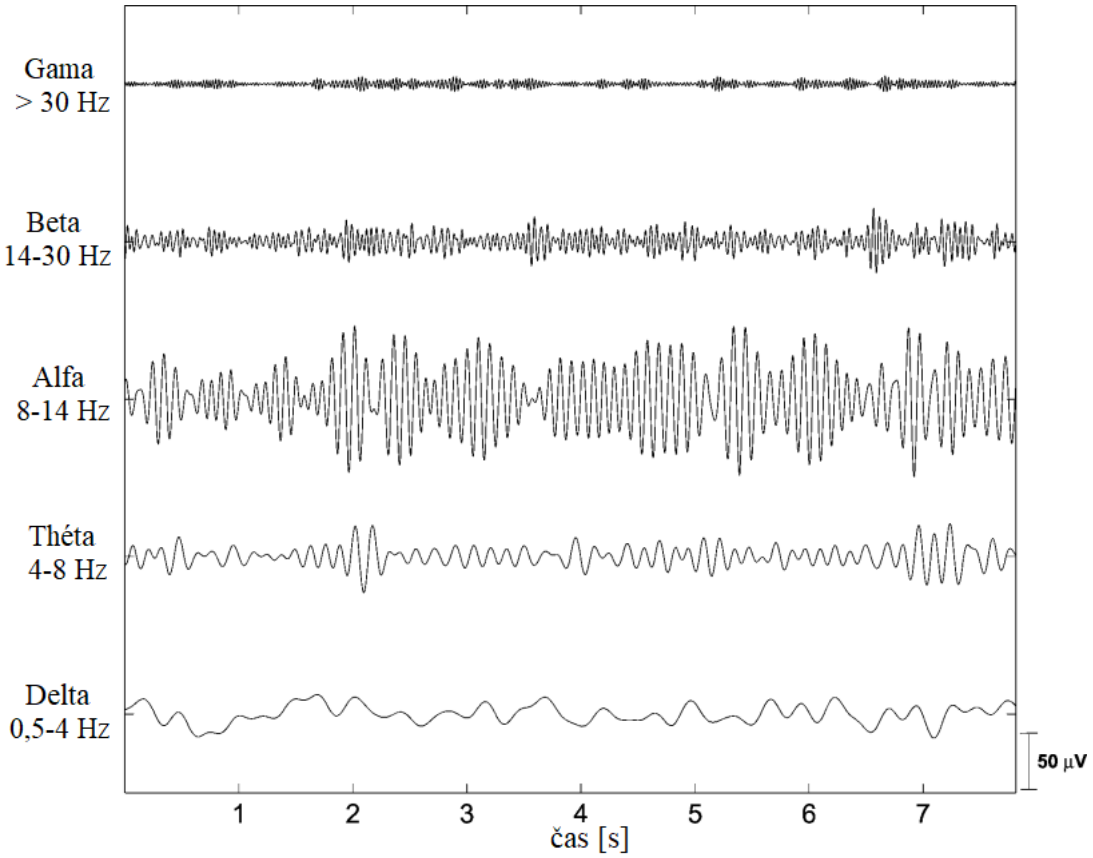

Obr. 1.2: Jednotlivá standardizovaná frekvenční pásma EEG signálu dle [7].

2 Analýza EEG

Číslicové zpracování signálů poskytuje nepřeberné množství různých analytických metod a postupů. V této kapitole jsou stručně teoreticky popsány vybrané metody, pomocí kterých je možné signály porovnávat. Zmíněny jsou jak metody lineární, tak nelineární.

EEG signál lze považovat za náhodný signál, který vznikl stochastickým procesem [1]. Některé analytické metody (např. využívající Fourierovu transformaci) vyžadují, aby analyzovaný signál byl stacionární [8]. Stacionarita je definována jako nezávislost všech pravděpodobnostních charakteristik na čase [9]. Znamená to, že frekvence, amplituda či tvar periodických křivek se nemění během záznamu. EEG záznam však často bývá nestacionární. Z toho důvodu bývá signál rozdělován do kratších segmentů, které následně lze považovat za stacionární. [8]

2.1 Analýza ve frekvenční oblasti

K analýze stochastických signálů ve frekvenční oblasti se obvykle využívá odhad výkonového spektra. Výkonové spektrum, a z něj odvozená výkonová spektrální hustota (PSD), je definováno jako rozložení výkonu signálu jako funkce frekvence. [10] Metod pro výpočet odhadu výkonového spektra je několik. Mezi neparametrické patří metoda periodogramu, korelogramu nebo metoda banky filtrů. Parametrické metody se od neparametrických odlišují tím, že vytváří model vzniku signálu. [11]

2.1.1 Welchova metoda

Základní neparametrickou metodou výpočtu odhadu výkonového spektra je metoda periodogramu. Odhad výkonového spektra je počítán z jednoho dostatečně dlouhého úseku signálu s využitím diskrétní Fourierovy transformace (DFT). [11] Se zvětšením délky signálu, však nedochází ke snížení rozptylu, a tedy odhad výkonového spektra nekonverguje k přesnějším hodnotám [12]. Welchova metoda je metodou modifikovaných periodogramů. Diskrétní signál je nejprve rozdělen do K segmentů o délce M. Každý tento segment je váhován oknem a následně je vypočítán periodogram každého segmentu. Tento princip je popsán následujícím vztahem 2.1

$$S_i(\omega) = \frac{1}{ME} \left| \sum_{n=0}^{M-1} x_i(n) \cdot w(n) \cdot exp(-j\omega n) \right|^2 , \tag{2.1}$$

pro $1 \leq i \leq K$, kde M je délka segmentu, $x_i(n)$ je i-tý segment signálu a $w(n)$ je váhovací okno. Délka okna se volí stejná, jako je délka segmentu. Charakteristické je

50 % překrývaní oken pro Welchovu metodu. [1] Překryvem oken se tato metoda zásadně odlišuje od Bartlettovy, ze které vychází, neboť v rámci Bartlettovy metody se segmenty nepřekrývají [9]. Běžně se pro analýzu EEG používají okna o délce trvání přibližně do 4 s [8, 14]. E v rovnici 2.1 značí normalizační koeficient okna představující průměrný výkon okna. Po vypočtení periodogramů v jednotlivých segmentech dojde k jejich zprůměrování. [1]

Klasické metody (tj. uplatňující FT), včetně Welchovy, jsou vhodné pro delší signály. Zároveň jsou velmi citlivé na přítomnost šumu v signálu. [1] Abychom obdrželi korektní výstup, je nutné dodržet podmínku stacionarity. Zvolená délka segmentů, ve kterých dochází k výpočtu modifikovaných periodogramů, velmi ovlivňuje výsledek. Použitím příliš krátkého segmentu bude frekvenční rozlišení nízké. Použitím dlouhého segmentu se frekvenční rozlišení sice zvýší, avšak hrozí porušení podmínky předpokládané stacionarity. Proto je nutné volit kompromis. [13]

2.1.2 Autoregresní lineární model – AR

Metody, které vytváří model vzniku signálu, jsou označovány jako parametrické. Jsou to např. autoregresní metody, které lze využít pro odhad výkonového spektra. Frekvenční charakteristika modelu vzniku signálu odpovídá odhadu spektra signálu, který analyzujeme. [11] AR model analyzovaného signálu lze získat více způsoby. Těmi jsou Yule-Walkerova, Burgova metoda nebo přístup přes kovarianci nebo modifikovanou kovarianci. [1]

Na počátku stojí generátor bílého šumu. Bílý šum má nulovou střední hodnotu a má rovnoměrně zastoupeny všechny frekvence. [1] Tento bílý šum vstupuje jako signál do lineárního, časově invariantního systému, na jehož výstupu je získán model analyzovaného signálu. V případě AR metody se jedná čistě o rekurzivní filtr. Pro získání parametrů tohoto systému se využívá bělící filtr. Na vstup bělícího filtru je přiveden analyzovaný signál, z kterého bělící filtr vytvoří bílý šum. [11]

AR model je obecně definován jako

$$y(n) = -\sum_{k=1}^{p} a_k \cdot y(n-k) + x(n), \tag{2.2}$$

kde a_k jsou parametry lineárního modelu, p je řád modelu a $x(n)$ je vstupní bílý šum [1]. V případě řešení pomocí Yule-Walkerovy metody, parametry lineárního modelu a_k z rovnice 2.2 jsou získány vyřešením Yule-Walkerovy soustavy rovnic, ve které vystupují koeficienty autokorelační funkce EEG signálu. Yule-Walkerovy rovnice ale nedefinují, jaký řád AR modelu je vhodné použít. Optimální je použít takový řád, který minimalizuje např. Akaikovo informační kritérium (AIC). [1]

AR model se využívá častěji, pokud analyzovaný EEG signál obsahuje spektrální špičky. Pokud signál nemá moc výrazné peaky ve frekvenčním spektru, využívá se spíše autoregresní model s klouzavým průměrem – ARMA. [1]

Výkonové spektrum vzniklé pomocí AR modelu je hladší a má větší frekvenční rozlišení, oproti tomu, které by vzniklo pomocí Welchovy metody. Metoda AR modelu je vhodná pro kratší signály. Klíčovou roli hraje výběr řádu AR modelu. Tento krok hodně závisí na zkušenostech výzkumníka a má velký vliv na výsledek. Čím je řád modelu nižší, tím je odhad spektra hladší. Vyšší řády modelu mohou ve spektru zobrazit falešné peaky, a vést tak k chybné interpretaci. [17]

2.2 Časově-frekvenční analýza

Použití klasické FT v rámci neparametrických metod nebo použití parametrických metod pro analýzu EEG ve frekvenční oblasti má velkou nevýhodu v tom, že neposkytuje časovou informaci o tom, kdy se určitá nestacionarita charakteristická určitou frekvencí v signálu objeví. V případě, že je potřebné tuto časovou informaci znát, uplatňují se časově-frekvenční analytické metody v podobě krátkodobé Fourierovy transfomace nebo vlnkové transformace. Na výstupu těchto metod jsou tedy získány informace nejen o frekvenční, ale i o časové oblasti. [18]

2.2.1 Krátkodobá Fourierova transformace – STFT

Principem STFT (v překladu Short-time Fourier transform) je aplikace DFT na krátké úseky signálu, které vzniknou vymezením pomocí krátkého okna, které se postupně posunuje po signálu [9]. Tyto úseky jsou považovány za stacionární. Samotná STFT je definována následující rovnicí 2.3:

$$STFT\left\{x(n)\right\} = \sum_{m=0}^{N-1} x(n+m) \cdot W(m) \cdot exp(-j\frac{2\pi}{N}km), \tag{2.3}$$

pro $k = 0, 1, 2, ..., N-1$, kde $x(n)$ je diskrétní analyzovaný signál, $W(m)$ je váhovací okno a n a k jsou diskrétní promměné času a frekvence. [1] Velikost okna ovlivňuje rozlišení výsledného spektrogramu. Čím je časové okno kratší, tím je nižší frekvenční rozlišení, ale větší časové rozlišení. Zatímco čím je časové okno delší, tím je frekvenční rozlišení vyšší, a naopak časové rozlišení nižší. [9]

Spektrogram (výstup STFT) je definován jako soubor krátkodobých spekter, čímž zobrazuje spektrální vývoj v čase. Využívá se amplitudové spektrum resp. výkonové v rámci analýzy stochastických signálů a v grafu je zobrazeno jako úzký proužek. Hodnoty spektra jsou charakterizovány pseudobarvením v černobílé (bílá barva zastupuje nejvyšší frekvence, černá naopak nejnižší) nebo barevné škále. [9]

Pokud by v konkrétní aplikaci bylo potřeba zvýšit frekvenční rozlišení, avšak nikoliv za cenu prodloužení časového okna, nabízí se využití vlnkové transformace [18].

2.2.2 Vlnková transformace – WT

Vlnková transformace (v překladu Wavelet transform) je založena na principu toho, že signál vyjádří jako lineární kombinaci jednotlivých bázových funkcí tzv. vlnek. Hlavním rozdílem proti FT je, že vlnka má nenulové hodnoty pouze na určitém časovém intervalu. V případě FT je bázová harmonická funkce nenulová na celé časové ose. Hodnota spektra využívající konkrétní vlnku je tedy ovlivněna pouze omezeným úsekem signálu. Vlnkové funkce pokrývají po částech celý časový rozsah signálu. Výsledek je podobný spektrogramu, který je získán pomocí diskrétní STFT, ale u WT se jedná o tzv. scalogram. [11]

Platí, že základem vlnek je mateřská vlnka (ang. mother wavelet), z které jsou odvozeny všechny další. Spojitá vlnková transformace je definována následovně:

$$S_{CWT}(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t)\psi_{a,b}^{*}(\frac{t-b}{a})dt, \tag{2.4}$$

kde ψ označuje mateřskou vlnku, '*' značí komplexní konjugaci, $x(t)$ je analyzovaný signál, parametr a definuje scale (měřítko) tzn. dilataci či kompresi vlnky podél časové osy a b definuje posunutí po časové ose. [11]

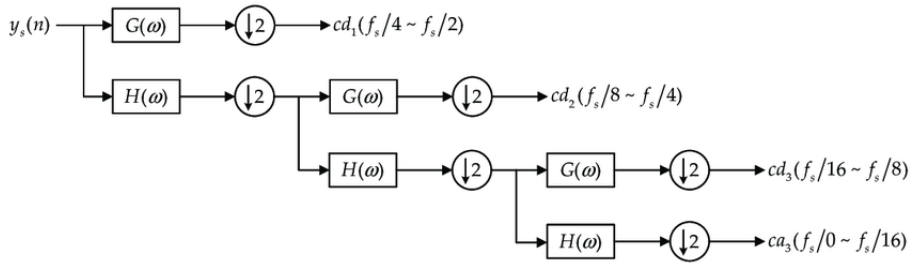

Obr. 2.1: Schéma kaskády filtrů pro vlnkovou dekompozici [19].

V rámci diskrétní WT je signál zpracován sérií filtrů typu dolních a horních propustí, pro nízké a vysoké frekvence. Tímto způsobem je možné oddělit jednotlivá frekvenční pásma EEG. Jedná se o tzv. vlnkovou dekompozici, která se využívá ve fázi předzpracování EEG. Koeficienty této dekompozice lze použít i jako příznaky analyzovaných signálů. [18] Princip je uveden na příkladu 3-úrovňové dekompozici na obrázku 2.1. Horní propust je filtr označený $G(\omega)$ a dolní propust $H(\omega)$. Po průchodu signálu filtrem typu horní propust jsou získány tzv. detailní koeficienty, po průchodu filtrem typu dolní propust tzv. aproximativní koeficienty. Dochází k podvzorkování

signálu. Jaké frekvence budou jednotlivá dekompoziční pásma zahrnovat, definuje vzorkovací frekvence f_s. [19]

Velmi podstatnou výhodou vlnkové transformace je, že dokáže analyzovat nestacionární signály [20]. Důležitý je výběr správných koeficientů a, b a typu vlnky. Mezi nejpoužívanější patří Morletova, Daubechies či Haarova [11].

2.3 Nelineární analýza

EEG signál je komplexní a vykazuje prvky nelinearity. Kromě klasických metod zkoumajících frekvenční spektrum signálu je proto vhodné zkoumat i komplexitu signálu. Použití nelineárních metod tak může přinést informace o signálu, které bychom lineární analýzou nezískali. Komplexitu můžeme zkoumat např. pomocí různých druhů entropií. Další nelineární analýzy aplikovatelné na EEG a vhodné k diferenciaci záznamů jsou např. analýza pomocí Hurstova a Lyapunova exponentu či pomocí fraktální nebo korelační dimenze. [21, 22]

2.3.1 Aproximativní entropie – ApEn

Aproximativní entropii zformuloval Steve Pincus na počátku devadesátých let minulého století za účelem kvantifikace pravidelnosti v časových datových řadách. Metoda odstraňuje nedostatky Kolmorogov-Sinai entropie, která je pro stochastické a zašuměné signály prakticky nepoužitelná. [23]

Časové řadě ApEn připisuje nezáporné číslo. Platí že, čím je menší hodnota parametru ApEn, tím je signál pravidelnější, lépe predikovatelný a s opakujícími se vzory. Naopak vysoké hodnoty ApEn odpovídají větší náhodnosti signálu a nezávislosti mezi jednotlivými vzorky. [23]

Aproximativní entropie je definována následovně:

$$ApEn(m, r, N)(u) = \phi^m(r) - \phi^{m+1}(r), \tag{2.5}$$

pro $m \geq 1$. Jedná se o odhad $ApEn(m, r)$, která vychází z nekonečně dlouhé sekvence. [23] V rovnici 2.5 figurují parametry m a r. Parametr m definuje délku, jak dlouhé budou sekvence vytvořené z původní časové řady u o délce N. Parametr r představuje kritérium podobnosti úseků. [23]

Stejně jako u předchozích metod, i metoda ApEn předpokládá, že signál vznikl stacionárním procesem. To však u EEG neplatí, proto je nutné signál rozdělit do kratších kvazistacionárních subsekvencí. Jednak tyto krátké epochy, tak šum omezují analýzu. Kratší epochy T omezují prostor, ve kterém lze zkoumat dynamiku

signálu. Délka epochy by měla být zvolena jako kompromis, zajišťující jak předpoklad stacionarity, tak zajišťující dostatek informací pro dosažení korektní ApEn. [25]

Správné fungování, hlavně pak správný výstup metody, je velmi ovlivněn nastavovanými parametry. Sám autor aproximativní entropie, Steve Pincus, navrhl optimální nastavení parametrů, při kterém by měla ApEn podávat korektní výsledky. Navrhl, aby $m = 2$ nebo $m = 3$, délka epochy, aby byla 10^m až 20^m vzorků a $r = 20$ % směrodatné odchylky signálu. S rostoucím parametrem m (ang. embedding dimension) klesá pravděpodobnost nalezení podobností (ang. recurrences), klesá tak hodnota ApEn. Zároveň je hodnota ApEn ovlivněna tzv. self-recurrences (podobnosti úseků sami se sebou, které jsou definovány, aby nemohl nastat případ výpočtu logaritmu nuly, který figuruje ve výpočtu ϕ v rovnici 2.5). Je tak méně stabilní. [25]

ApEn je dále ovlivněna vzorkovací frekvencí, tzv. over-sampling vede k linearizaci dynamiky signálu, a tudíž ke snížení ApEn. Je lehčí predikovat následující vzorek, pokud jsou vzorky blízko u sebe. Signál se proto jeví lépe předvídatelný, a tak méně komplexní. [25] Autor článku [25] navrhuje, aby vzorkovací frekvence byla proto nastavena na trojnásobek šířky pásma obsažených frekvencí časové řady.

2.3.2 Spektrální entropie – SpEn

Entropii lze zkoumat nejen jako charakteristiku časové řady, ale i jako charakteristiku spektra signálu. Tou je právě SpEn. Výpočetně se jedná o Shannonovu entropii vypočítanou z normalizovaného výkonového spektra (z normalizované PSD). Fázová a frekvenční informace je při výpočtu vynechána. [26]

Interpretovat ji lze jako neurčitost ve frekvenční oblasti. Pokud spektrum signálu bude mít úzké výrazné peaky, čili bude patrný určitý rytmus, hodnota spektrální entropie bude malá. [27] Naopak hladší, širší peaky spektra tzn. více rovnoměrné spektrum se projeví vyšší hodnotou spektrální entropie [28]. Touto metodou je proto možné kvantifikovat strukturu a distribuci výkonového spektra EEG signálu [27].

Často se spektrální entropie využívá při hodnocení míry anestezie [26]. Dále může sloužit ke klasifikaci kognitivní zátěže. Čím je úroveň kognitivní zátěže vyšší, tím se výkon signálu soustředí do užšího pásma frekvencí, a tím hodnota spektrální entropie klesá. [29]

2.3.3 Higuchiho fraktální dimenze – HFD

Další možností, kterou je možné vyjádřit komplexitu časové řady, je nelineární metoda fraktální dimenze [30]. Existuje více způsobů, jak fraktální dimenzi vypočítat. Jedná se např. o Katzovu či Petrosianovu metodu. Zde je však zmíněna další velmi

častá metoda, a sice Higuchiho, která je pro účely EEG vhodnější a přesnější. Algoritmus výpočtu nejprve rozdělí diskrétní časovou řadu do jednotlivých sub-sekvencí. Následně je vypočítána 'délka' jednotlivých sub-sekvencí, která je dále normalizována a zprůměrována. [31] Výsledná HFD je rovna následujícímu výrazu 2.6 dle [31]:

$$HFD = \frac{ln(L(k))}{\frac{1}{k}}. \tag{2.6}$$

V rovnici 2.6 vystupuje $L(k)$, což je právě zprůměrovaná normalizovaná délka sub-sekvencí pro všechny časové intervaly $k = 1, ..., k_{max}$. Hodnota HFD pak odpovídá sklonu křivky, která nejlépe aproximuje pravou stranu rovnice 2.6. Bylo odhadnuto, že pro lineární křivku platí $HFD \approx 1$. HFD bílého šumu nebo jiné více komplexní křivky odpovídá $HFD \approx 2$. [31]

Použití této metody je vhodné i v případě, že jsou k dispozici pouze krátké signály [30]. V praxi se často signál analyzuje v krátkých oknech ať už s překryvem nebo bez překryvu, a to zejména v případě nestacionárních dat [31].

Důležitým parametrem je k_{max}. Z různých studií vyšlo najevo, že obecné doporučení pro stanovení tohoto parametru neexistuje. Pro každé data je vhodná jiná hodnota tohoto parametru a stejně tak délka jednotlivých sub-sekvencí. Analýza je mnohem více závislá na hodnotě parametru k_{max} než na délce signálu. [31]

Přesnost metody klesá s větším množstvím šumu v signálu. Hodnota HFD se v tomto případě zvětšuje. Nevýhodou této metody může být i to, že HFD nabývá hodnot pouze v malém intervalu, tudíž může být někdy obtížné rozlišit od sebe dva signály jen na základě tohoto parametru. Doporučuje se proto používat HFD v kombinaci s jinými metodami. [31]

3 Studie mentální zátěže

Zpracování EEG záznamů lze rozdělit do několika fází. Po změření záznamů následuje jejich předzpracování. Ve fázi předzpracování dochází obvykle k vyfiltrování záznamu ve snaze získat jen užitečný signál. Zároveň může docházet k extrakci pouze určitých úseků z dlouhodobějších záznamů. S předzpracovaným signálem se pak pracuje ve fázi signálové analýzy, která slouží k získání vhodných příznaků charakterizující signál. Tyto příznaky je vhodné statisticky vyhodnotit např. pomocí statistických testů pro ověření, jestli se příznaky statisticky významně liší mezi různými skupinami, nebo např. mezi různými kanály. Často je možné se setkat s kombinací různých analytických metod, díky které se získá daleko více příznaků, které na signál pohlíží z různých úhlů pohledu, což může pomoci k zvýšení přesnosti případné klasifikace.

V následujících podkapitolách jsou stručně shrnuty vybrané studie, které ve svých bádáních provádí kromě klasifikace i komparaci záznamů EEG. Studie pracují s parametry, pomocí kterých lze záznamy z více skupin srovnat. Zaměřují se na problematiku mentální zátěže způsobené počítáním aritmetických příkladů, která je zároveň zpracovávána v praktické části této práce. Využité analytické metody jsou teoreticky shrnuty v předchozí kapitole 2.

3.1 Detekce stresu na základě výkonových příznaků

Cílem studie "Stress detection from EEG using power ratio" [33] je klasifikace relaxovaného a stresového stavu za použití výkonových poměrů z jednotlivých pásem EEG a samotných výkonů v jednotlivých pásmech, které vstupují jako příznaky do dvou druhů klasifikátorů.

Autoři využívají stejný volně dostupný dataset, který je později využit v praktické části. Detailní popis dat je proto uveden v sekci 5.1. Protože záznam relaxace je výrazně delší, využívají autoři pouze 62 sekund, aby byly obě skupiny vyrovnané. Následně data segmentují po 2^{14} vzorcích s překryvem 25 %.

Analýzu EEG signálů autoři článku prováděli pomocí DFT za účelem zisku PSD signálů. DFT je v programovém prostředí zprostředkována FFT algoritmem. Vypočítanou PSD rozdělili do standardizovaných frekvenčních pásem EEG (viz kapitola 1.5). Pásma alfa, beta a gama navíc rozdělili na poloviny. Celkem měli tedy 8 frekvenčních pásem - delta (0-3,9 Hz), théta (4-7,9 Hz), alfa I (8-9,9 Hz), alfa II (10-13,9 Hz), beta I (14-21,9 Hz), beta II (22-29,9 Hz), gama I (30-46,9 Hz) a gama II (47-65 Hz). Jako základní příznaky zvolili výkony v jednotlivých frekvenčních pásmech, které doplnili o poměry výkonů v těchto pásmech navzájem např. poměr

výkonu v delta pásmu ku výkonu v beta I pásmu. Celkem tedy pracovali s 64 druhy příznaků.

Průměrná PSD od všech subjektů z kanálu Fp1 v různých pásmech je zobrazena na obrázku 3.1. Je vidět, že PSD je vyšší ve stavu stresu než při relaxaci v pásmu delta, théta a gama. V théta pásmu je PSD vyšší zhruba do 6,4 Hz, proto autoři navrhují ještě toto pásmo rozdělit do dvou pro lepší klasifikaci.

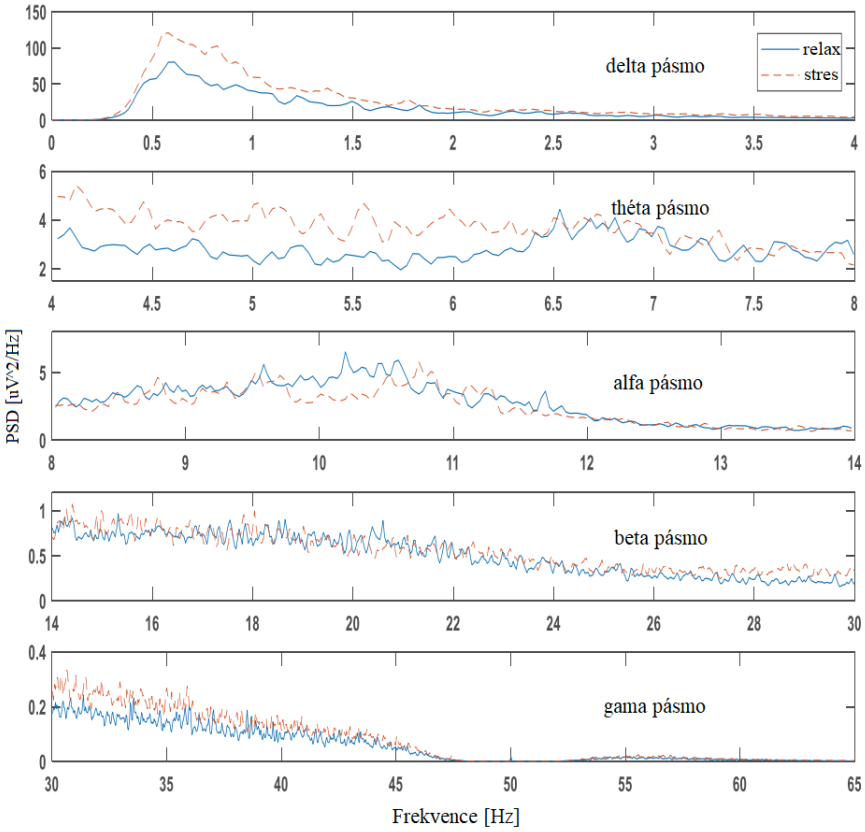

Obr. 3.1: Průměrná PSD kanálu Fp1 pro jednotlivá frekvenční pásma od všech subjektů dle [33].

Ke klasifikaci využívají klasifikátory typu SVM a KNN s různým nastavením. Při klasifikaci pouze dat z jednoho kanálu vychází nejlepší použití KNN klasifikátoru na kanál Fp1 s přesností 99,42 +/- 0,36 %. Při klasifikaci na základě více elektrod dosáhli úspěšnosti s KNN cca 96-98 %. Úspěšnost SVM byla mírně nižší.

3.2 Identifikace úrovní stresu pomocí výkonů v pásmech alfa a beta

Autoři studie "EEG based stress level identification" [34] se snaží detekovat typické vzory v EEG při stavu duševního stresu. Stres navodili použitím Stroopova testu

(kombinace slov a barev) a počítáním příkladů. Celkem rozlišovali mezi třemi úrovněmi - relaxovaným stavem, mírným stavem stresu navozeným Stroopovým testem a stavem s velkou úrovní stresu při počítání příkladů.

Studie se zúčastnilo celkem 10 osob. Experimentální protokol sestával z fáze trénovací a fáze testovací. Trénovací fáze probíhala následujícím způsobem. Nejprve byl subjekt v relaxovaném stavu po dobu 3 minut, následoval 3-minutový Stroop test, 20 sekund pauza (relax), 3 minuty matematického testu a na závěr 20 sekund pauza. Tato data byla použita pro trénovaní klasifikačního modelu. Testovací fáze měření obsahovala pouze 30-sekundová okna relaxovaného stavu, Stroopova testu nebo matematického testu. Během měření se mohly náhodně objevovat. Po každé 30-sekundové sekci následoval 20-sekundový relaxovaný stav. Takto získaná data se použila na nezávislé otestování už naučeného klasifikátoru.

Nahráno bylo 14 kanálů (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, and AF4) podle 10-20 systému se vzorkovací frekvencí 128 Hz v pásmu frekvencí od 0,16 do 43 Hz. Signálové zpracování zahrnuje korekci izolinie, filtrování pásmovou propustí k ponechání pouze frekvenčního pásma zájmu a analýzu pomocí časového okna. Převedení z časové do frekvenční oblasti provedli autoři pomocí FFT algoritmu s využitím vhodně dlouhého Hammingova okna, čili použili STFT. Následně vypočítali PSD pro pásmo théta (4-8 Hz), alfa (8-12 Hz) a beta (12-30 Hz). V každém frekvenčním pásmu spočítali průměrný výkon signálů v jednotlivých stavech.

Na základě analýzy všech kanálů došli na to, že během klidové fáze je přítomen vyšší výkon v alfa pásmu a při vykonávání Stroopova nebo aritmetického testu zase vyšší výkon v beta pásmu. Vhodný příznak pro detekci stresu je tedy indikován poklesem v alfa pásmu a naopak vzrůstem výkonu v beta pásmu. Proto autoři využili příznak rozdílu výkonů v beta a alfa pásmu pro trénování SVM klasifikátoru.

Mimo jiné zkoumali vliv různých délek oken. Použili okna délky 2, 4, 10 sekund s překryvem 1, 3 a 5 sekund. Rozlišení stavu klidu proti stavu počítání matematických příkladů dosáhlo nejlepších výsledků, přesnosti klasifikace 96 %, s využitím 2-sekundového okna s překryvem 1 sekunda. Přesnost klasifikace pro okna trvající 4 a 10 sekund byla shodná - 88 %.

3.3 Kvantifikace stresu pomocí vlnkových koeficientů

Studie [35] s původním názvem "Mental stress quantification using EEG signals" se zabývá rozlišováním klidového a stresového stavu. K indukci stresu využívá počítání aritmetických příkladů. Matematický test provádí ve třech úrovních obtížnosti.

Studie se účastnilo 12 subjektů. Snímali pouze 7 aktivních elektrod z frontální kůry podle 10-20 schématu. Vzorkovací frekvence byla 256 Hz. V rámci kontrolní fáze experimentu nechali subjekty počítat bez časového omezení. Pro navození stresu

snížili čas potřebný k výpočtům o 10 %. Výsledné bloky záznamů obsahují 40 sekund počítání a 30 sekund klidu.

Předzpracování signálu realizovali filtrací Butterworthovým filtrem 3. řádu typu pásmová propust v rozmezí 0.5-30 Hz. Artefakty odstranili technikou ICA. K analýze signálu využili vlnkovou transformaci. Využili ji na dekompozici EEG do 4 dílčích frekvenčních pásem: delta (1 - 4 Hz), théta (4 - 8 Hz), alfa (8 - 12,5 Hz) a beta (12,5 - 30 Hz). Celkově využili dekompozici do 5 úrovní.

Z vlnkových koeficientů určili průměr absolutních hodnot koeficientů v každém pásmu a dále spočítali průměrný výkon a energii. Před vložením příznaků do klasifikátoru provedli normalizaci hodnot do intervalu (0,1). Pro rozlišení stresu a klidu využili jen hodnoty výkonu z pásma alfa.

Při zkoumaní jednotlivých úrovní stresu došli k významným rozdílům, které ověřili párovým t-testem. V analýze využili jen data z alfa pásma, protože vykazují negativní korelaci se stresem a významnou variaci s mentální zátěží, což dokumentuje obrázek 3.2. Pozorovali výrazný pokles výkonu alfa pásma při počítání nejlehčích příkladů ve stresu oproti stavu bez stresu s p-hodnotou 0,03. V rámci druhé úrovně příkladů pozorovali taktéž výrazný rozdíl a pokles v alfa pásmu s p-hodnotou 0,042. V rámci nejtěžší úrovně příkladů rozdíl tak patrný nebyl, a to pouze s p-hodnotou 0,05. Kromě komparace signálů stresových a klidových jejich měření ukázalo závislost aktivity pravé části prefrontální kůry na stresu. Se stresem aktivita v této oblasti klesá.

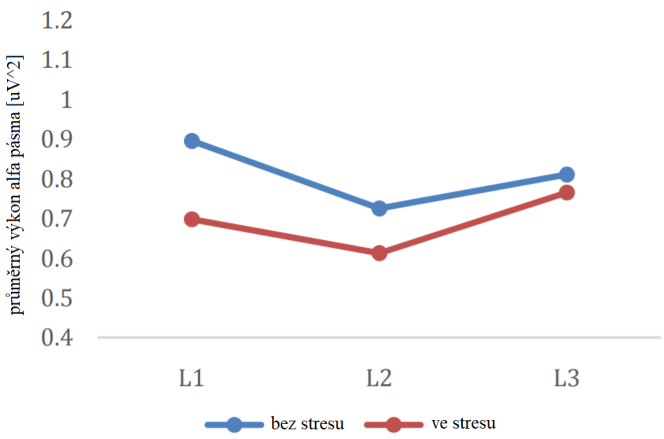

Obr. 3.2: Rozložení průměrného výkonu v alfa pásmu během počítání 3 obtížnostních úrovní matematických příkladu ve stavu klidu a při stresu dle [35].

Jejich klasifikace pomocí SVM dosáhla 94 % úspěšnosti při porovnání kontroly a stresu během první úrovně, 85 % během druhé úrovně a 80 % během třetí úrovně.

3.4 Analýza EEG během relaxace a stavu mentální zátěže pomocí PSD

Hodně studií využívá v EEG analýze PSD. V následující studii [36] "Analysis of EEG signals during relaxation and mental stress condition using AR modeling techniques" autoři porovnávají hodnoty PSD signálů klidových a signálů stresových, přičemž stres byl navozen aritmetickým počítáním.

Studie se zúčastnilo 5 subjektů. Měření probíhalo celkem na 19 elektrodách umístěných podle 10-20 systému (Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 a O2). Vzorkovací frekvence byla 256 Hz. Na obrazovce promítali subjektům příklady, které měly počítat s cílem navození stresu. Relaxovaný, klidový stav zaznamenávali vždy 10 sekund před a po mentální zátěži. V rámci aritmetického testu měly subjekty vypočítat 10 příkladů za 20 sekund.

V rámci předzpracování signálů došlo k vyfiltrování pomocí filtru typu pásmová zádrž s mezní frekvencí 60 Hz. Dále použili eliptické pásmové propusti pro získání jednotlivých pásem - alfa, beta, théta a delta. Eliptický filtr je typický zvlněním přenosové charakteristiky jak v propustném, tak nepropustném pásmu a má pro daný řád nejstrmější přechod mezi těmito pásmy [37].

V rámci analýzy využili Welchovu metodu pro odhad PSD a následně dvě autoregresní modelovací techniky, a sice Yule-Walkerovu metodu a Burgovu metodu. Burgova metoda se hodí pro hodnocení krátkých záznamů s malou úrovní šumu. Přesnost metody klesá s vyšším řádem AR modelu, při hodnocení dlouhých datových sekvencí a s vysokým SNR. [36] Jak pro Yule-Walkerovu, tak pro Burgerovu metodu určili autoři řád modelu takový, který minimalizuje Akaikeho informační kritérium v prvních dvou epochách.

Ke klasifikaci využili dopřednou neuronovou síť. Nejvyšší úspěšnost dosáhla klasifikace na základě Burgovy metody 91,17 %, následovala Welchova metoda s 88,36 % a nejhůře skončila Yule-Walkerova metoda s 85,55 % úspěšností.

3.5 Charakterizace mentální zátěže pomocí entropií

Následující studie [38] s názvem "Characterizing mental load in arithmetic task using entropy based features" navrhuje diferenciaci různých úrovní mentální zátěže na základě příznaků spektrální a aproximativní entropie.

Studie se zúčastnilo 6 subjektů. V rámci experimentu měly za úkol počítat různě obtížné příklady rozdělené dohromady do 7 úrovní. Každá úroveň příkladů trvala 2 minuty, mezi nimi byly 30-sekundové pauzy, kdy mohly subjekty relaxovat. EEG

signály byly zpracovány pásmovým filtrem s mezními frekvencemi 0,1-100 Hz a nahrány s vzorkovací frekvencí 256 Hz. Dohromady zaznamenali 32 kanálů. K analýze SpEn a ApEn však využili jen následující: Fp1, AF3, F7, F3, FC1, FC5, FC6, FC2, F4, F8, AF4, Fp2, PO3, O1, Oz, O2, PO4. Po vizuální inspekci vybrali pro každou úroveň 70-sekundové úseky s minimem EMG artefaktů.

Na dekompozici do celkem 5 frekvenčních pásem využili autoři vlnkovou transformaci. Konkrétně použili Daubechies-4 jako mateřskou vlnku. Spektrální entropii použili jako nástroj pro měření, jak je původní výkon distribuován v jednotlivých pásmech. SpEn klesá, pokud má signálový výkon tendenci se koncentrovat pouze na určité frekvenci. Aproximativní entropie kvantifikuje pravidelnost v časové řadě. [38] Pomocí těchto metod odvozovali příznaky z 5 sekundových segmentů. Pro ApEn zvolili hodnoty parametrů $m = 2$ a $r = 0.2 \cdot SD$.

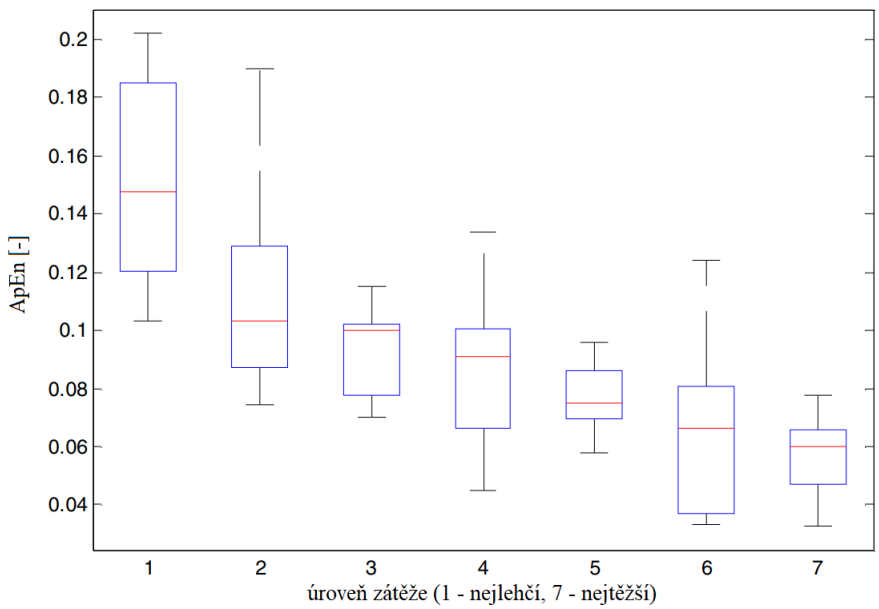

Obr. 3.3: Medián ApEn od prvního subjektu z okcipitálního kanálu PO3 při všech 7 úrovních zátěže dle [38].

Přišli na to, že hlavně frontální a pak i okcipitální regiony byly nejvíce ovlivněny mentální zátěží u všech 6 subjektů. Ukázalo se, že především v pásmu delta byly zaznamenány rozdíly u obou příznaků s rostoucí zátěží. Rozdíly v ApEn ilustruje obrázek 3.3. U obou příznaků došlo k poklesu při zvýšení zátěže. U ApEn to může znamenat, že při plnění náročnějších úkolů se mozková aktivita stává pravidelnější. Rostoucí psychická zátěž se projevuje aktivitou hlavně ve frontální oblasti.

Na základě jejich experimentu autoři uvádí, že využití menšího množství elektrod a analýza v delta pásmu by mohla sloužit pro měření psychické zátěže s využitím entropie. Upozorňují však, že toto tvrzení by bylo vhodné potvrdit na větší databázi.

3.6 Rozpoznání zátěže pomocí fraktální dimenze, AR modelu a odhadu PSD

Autoři studie [21] "Real-time mental arithmetic task recognition from EEG signals" navrhují využití analýzy EEG během počítání aritmetických příkladů u pacientů s ADHD, dyskalkulií nebo s autistickou poruchou jako nástroj, který by mohl pomoct s léčbou těchto poruch.

V experimentu oslovili 10 subjektů, které 2 minuty zůstaly v relaxovaném stavu s otevřenými očima a další 2 minuty počítaly příklady (sčítání trojmístných čísel). K zaznamenání dat využili autoři přístroj Emotiv se vzorkovací frekvencí 128 Hz. Snímali data ze 14 elektrod - AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 podle standardního 10-20 systému. Nejprve data vyfiltrovali FIR pásmovou propustí v rozmezí 2-42 Hz a pásmovou zádrží k vyfiltrování síťového rušení. Následně signály normalizovali na nulovou střední hodnotu a rozptyl roven jedné. Tyto normalizované signály dále rozdělili pomocí 4-sekundových oken s překryvem 3 sekundy.

Prvním druhem příznaků v této studii jsou odhady výkonů ve frekvenčních pásmech, které získali pomocí klasického periodogramu. Dále jako příznaky využili koeficienty AR modelu. Konkrétně zvolili model šestého řádu. Analýzu doplnili o statistické příznaky - průměr, směrodatnou odchylku, absolutní hodnoty první a druhé diference původního signálu a absolutní hodnoty první a druhé diference normalizovaného signálu. Fraktální dimenzi odhadli pomocí zobecněné Higuchiho metody, aby kvantifikovali komplexitu a multifrakcionalitu epochy EEG. K redukci příznakové dimenzionality využili PCA.

Kombinací všech těchto příznaků ze všech dostupných kanálů dosáhli největší klasifikační přesnosti 97,87 %. Testovali, jak jednotlivé skupiny příznaků ovlivní přesnost klasifikace. Vyšlo jim, že statistické příznaky samy o sobě dosáhly přesnosti 90,33 %, koeficienty AR modelu 83,89 %, fraktální dimenze 80,57 % a PSD 67,07 %.

Ve studii se snažili navrhnout přenosné zařízení. Pro tyto účely je vhodné minimalizovat počet elektrod potřebných pro analýzu. Nejlepší výsledky klasifikace poskytovali kanály F8, F3, O2 a AF3. Kombinací informací z těchto 4 kanálů dosáhli přesnosti klasifikace 97,11 %.

4 Srovnání analytických metod

4.1 Frekvenční oblast

Studie, které využívají kvantitativní analýzu EEG, velmi často provádějí analýzu skrz odhad výkonové spektrální hustoty [36]. V případě EEG je běžná praxe, že se záznam rozdělí do charakteristických frekvenčních pásem. Z PSD může být odvozeno velké množství parametrů, které jsou zmíněny v podkapitole 4.1.1.

První přístup k získání PSD je skrz Fourierovu transformaci. Klasický periodogram počítá DFT z celého signálu. Aby byl získán touto metodou spolehlivý odhad, musel by být signál stacionární. Tuto podmínku však EEG nesplňuje, neboť se v průběhu času různě mění v závislosti na různé aktivitě neuronů. Tento klasický periodogram má velké frekvenční rozlišení, avšak jedná se o vychýlený odhad s velkými odchylkami. [13]

Welchova metoda snižuje odchylky, které je možné vidět v klasickém periodogramu, díky průměrování jednotlivých DFT z krátkých úseků vymezených časovým oknem. Na druhou stranu toto průměrování způsobuje pokles frekvenčního rozlišení. Zvýšit frekvenční rozlišení lze pouze prodloužením okna, ve kterém se počítá dílčí PSD. I přes toto omezení je však Welchova metoda jednou z nejčastěji využívaných metod k získání PSD. [13]

Nevýhodou klasických metod je prosakování některých frekvencí ve spektru (ang. spectral leakage) v důsledku váhování. Multiplikace signálu oknem o konečné délce v časové oblasti odpovídá konvoluci ve frekvenční oblasti. Fourierova transformace signálu vynásobeného oknem je pak komplexnější a překračuje původní frekvenční rozsah. [1] Prosakování frekvencí snižuje frekvenční rozlišení a může tak dojít k přehlednutí některých málo výrazných složek [15]. Zabránit tomu lze použitím např. trojúhelníkového okna před obdélníkovým. Potom ale vyvstává najevo další problém, a sice, že krajní vzorky mají menší váhu než vzorky uprostřed. Tento problém řeší překrývání oken, ke kterému dochází např. ve Welchově metodě. [8]

Další přístup pro výpočet odhadu PSD je přes parametrické metody, které v této práci reprezentuje AR model. Parametrické metody je vhodné použít při kratších signálech (stovky vzorků), neboť i u krátkých signálů dosahují vysokého frekvenčního rozlišení [39]. Na rozdíl od metod využívajících FT u autoregresních metod nedochází k prosakování hodnot ve spektru a výsledný odhad má tudíž lepší frekvenční rozlišení. Kritické je stanovení správného řádu modelu pro získání spolehlivého odhadu PSD. Z tohoto důvodu se uvádí, že je vhodné AR model použít v kombinaci s některou klasickou metodou využívající FFT. [16]

4.1.1 Parametry odvozené z PSD

Základní parametr, který lze z odhadu PSD použít pro komparaci EEG je průměrný výkon v daném frekvenčním pásmu. Získáme tak pouze jedno číslo, které charakterizuje dané pásmo. Např. u komparace spánkových záznamů platí, že při hlubokém spánku dominují v záznamu EEG pomalé frekvence v delta pásmu, zatímco při stavu bdělosti je v tomto pásmu velmi malá aktivita. V rámci tohoto příkladu má pak průměrný výkon v delta pásmu vysokou hodnotu během hlubokého spánku a malou hodnotu při bdělosti jedince. Právě tyto rozdíly určují výkon ve frekvenčním pásmu jako parametr, který se hodí k odlišení těchto stavů. [13] Nejen pro hodnocení spánku, ale i pro analýzu mentální zátěže se ukázaly výkonové příznaky jako vhodné.

Více o signálu může napovědět relativní výkon frekvenčního pásma. Vyjadřuje, kolik procent celkového výkonu signálu je obsaženo ve zvoleném pásmu. Běžné je také hodnocení poměrů výkonů ve dvou zvolených pásmech. V tomto případě je důležité, aby odhady PSD byly počítány v obou pásmech se stejným oknem (v případě využití Welchovy metody) [13].

Metodou AR modelu můžeme kromě výkonových příznaků odvozených z PSD získat i jiný druh příznaků. Jako příznaky mohou sloužit samotné koeficienty modelu využité např. v [21].

4.2 Časově-frekvenční oblast a její parametry

Principem Welchovy metody je průměrování modifikovaných periodogramů z krátných segmentů. Pokud by tyto segmenty nebyly průměrovány, ale výstupy z těchto segmentů byly seřazeny za sebe, obdržíme spektrogram, čili grafické zobrazení odhadu výkonových spekter získaných STFT. Tato metoda aplikuje na signál okno o fixní délce, a proto dosahuje omezeného frekvenčního rozlišení. Je to dáno Heisenbergovým principem neurčitosti [1]. Ze spektrogramu je následně možné extrahovat příznaky jako z PSD získané jinými metodami, a sice výkony v jednotlivých EEG pásmech, jejich poměry atd.

Vlnková transformace představuje časově-frekvenční analýzu podobně jako STFT. Diskrétní vlnková transformace je jednodušší na implementaci než spojitá vlnková transformace. Obecně tato transformace umožňuje analýzu pomocí různě dlouhých oken, a tím dosahuje lepšího frekvenčního rozlišení než STFT. Pro nízké frekvence využívá delší okna, pro vysoké frekvence naopak kratší. Na výsledku se odráží zvolení vhodné mateřské vlnky. Diskrétní WT je hojně používána na analýzu epileptických EEG. Dále se WT často využívá k dekompozici signálů do jednotlivých frekvenčních pásem. Výsledkem dekompozice WT jsou vlnkové koeficienty. Příznaky nebo

parametry z nich odvozené jsou nejčastěji statistické. Může se jednat o průměr koeficientů v dílčích dekompozičních úrovních, směrodatnou odchylku nebo maximum. Dále se můžeme setkat s efektivní hodnotou (ang. Root mean square), energií a výkonem koeficientů či vlnkovou entropií. Někdy jako příznaky můžou sloužit samotné vlnkové koeficienty. [17]

4.3 Nelineární analýza a nelineární parametry

Nelineární analýza se zaměřuje na popis nelinearit a nestacionarit v EEG, umožňuje zkoumat dynamiku těchto záznamů. Přináší tak zcela odlišné informace než předchozí zmíněné metody. Hlavní výzvou u nelineárních metod je správné nastavení vstupních parametrů. Výsledky ovlivní přítomnost, byť i malého, šumu, což může vést k nesprávné interpretaci např. u fraktální dimenze. [40]

Mezi nejpoužívanější parametry patří různé druhy entropie např. aproximativní, Shannonova, Renyi nebo Sample entropie. Tyto parametry mohou být získány z kompletního signálu nebo je možné je extrahovat z dílčích frekvenčních pásem nebo z dílčích dekompozičních úrovní v případě WT. [17]

4.4 Úspěšnost vybraných metod

Analytické metody zmíněné v kapitole 2 se ukázaly jako vhodné pro porovnání dat klidových a dat zátěžových. Tuto skutečnost dokazují provedené výzkumy stručně popsané v kapitole 3. Ty s velmi dobrou mírou úspěšnosti dokázaly data klasifikovat. Podstatné výsledky těchto studií jsou pro přehlednost shrnuty v následující tabulce 4.1. Na základě výsledků prostudovaných studií není ale lehké objektivně metody srovnat. Každá studie pracuje s jinými daty a právě kvalita dat je základním předpokladem pro úspěšnou klasifikaci. Dále studie analyzují data z různých elektrod a cíle jednotlivých studií se mírně liší. Některé se snaží rozlišit pouze 2 skupiny dat (klid vs. zátěž), jiné pracují s více úrovněmi stresu nebo porovnávají, jak se na EEG záznamu projeví např. počítání ve stresu a počítání bez časového limitu. Dalším parametrem, který je potřeba brát v úvahu, je množství příznaků, které vstupují do klasifikátorů. Některé studie jich mají opravdu mnoho, zatímco jiné klasifikují jen na základě několika parametrů. Samotný výběr klasifikátoru a jeho nastavení taktéž ovlivní výsledek.

Tab. 4.1: Shrnutí jednotlivých studií.

Studie	Stavy	Metoda	Klasifikátor	Úspěšnost %
1. [33]	2	FFT - PSD	KNN	97-98
	2	FFT - PSD	SVM	94-98
2. [34]	2;3	FFT - PSD	SVM	96; 75
3. [35]	3	WT - koef.	SVM	94; 85; 80
4. [36]	2	Welch; AR	ANN	88,36; 91,17
5. [38]	7	WT+SpEn+ApEn	-	-
6. [21]	2	PSD, AR, FD	SVM	97,87; 97,11

Úspěšnost první studie [33] 97-98% odpovídá klasifikaci pomocí KNN klasifikátoru s využitím různých elektrod. Kromě tohoto klasifikátoru však autoři využili i SVM, s kterým dosáhli úspěšnosti 94-98 % v závislosti na použitých elektrodách. Druhá studie [34] používala ke klasifikaci všechny dostupné elektrody a dosáhli úspěšnosti 96 %. 75 % úspěšnost odpovídá rozlišení celkem 3 stavů. Třetí studie [35] využila ke klasifikaci dostupné frontální elektrody a jednotlivé úspěšnosti odpovídají klasifikaci jednotlivých úrovní stresu. Úspěšnosti u čtvrté studie [36] jsou úspěšnosti jednotlivých metod tj. Welchovy a AR modelu. Studie zabývající se entropií [38] neprovádí klasifikaci signálů. Výstupem studie je zjištění, že pomocí entropií by bylo možné signály rozlišit. Autoři poslední studie [21] dosáhli úspěšnosti 97.87 % využitím všech elektrod a úspěšnosti 97,11 % použitím pouze F8, F3, O2, AF3 s kombinací všech druhů příznaků.

5 Experimentální část

5.1 Data

Cílem bakalářské práce je pomocí vybrané analytické metody s vhodnými parametry rozlišit elektroencefalografické záznamy ze dvou skupin dat. Pro ověření funkčnosti analytické metody byla vybrána databáze záznamů klidových a zátěžových, přičemž zátěž byla indukována počítáním aritmetických příkladů. Databáze je volně přístupná, dostupná na webových stránkách physionet.org [41].

Data pochází z výzkumu Kyjevské univerzity [42]. K nahrávání záznamů autoři využili přístroj Neurocom monopolar 23-channel system (XAI-MEDICA, Ukrajina), který využívá Ag/AgCl elektrody. Podle mezinárodního 10-20 systému byly použity elektrody následující: Fp1, Fp2, F3, F4, Fz, F7, F8, C3, C4, Cz, P3, P4, Pz, O1, O2, T3, T4, T5 a T6. Data byla vzorkována s vzorkovací frekvencí 500 Hz a vyfiltrována filtrem typu horní propust s mezní frekvencí 0,5 Hz, dolní propustí s mezní frekvencí 45 Hz a pásmovou zádrží pro odstranění síťového brumu (50 Hz).

Samotné záznamy v databázi obsahují segmenty EEG bez artefaktů trvající 182 s pro relaxovaný stav a 62 s pro aritmetickou část. Z původních 66 subjektů bylo 30 subjektů vyřazeno pro nedostatečnou kvalitu EEG dat na základě vizuální inspekce zkušeného odborníka. Celkem tedy databáze obsahuje 72 záznamů pro celkem 36 subjektů.

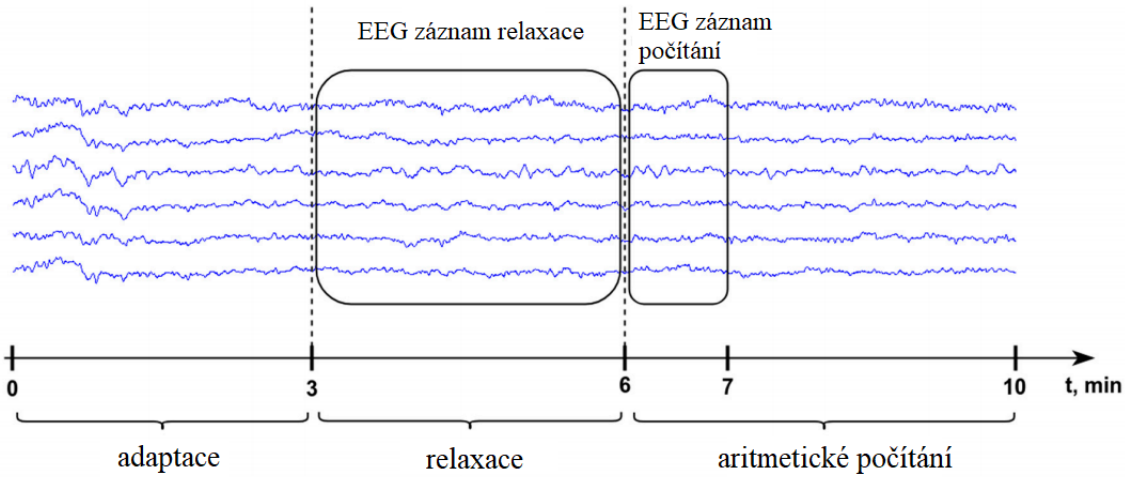

Obr. 5.1: Průběh měření EEG záznamů dle [42].

Měření bylo prováděno za účelem zjištění, zda EEG koreluje s mozkovou aktivitou, která probíhá během kognitivního úkolu - počítání matematických příkladů. Subjekty odečítaly od 4-místného čísla 2-místné např. 4753 - 17. Během měření seděly subjekty v tmavé odhlučněné místnosti. V první části experimentu se měly

snažit, co možná nejvíce relaxovat se zavřenými očima po dobu 6 minut a poté následovala 4 minutová fáze počítání. Během obou fází bylo nutné eliminovat veškeré pohyby rukou atd. Schéma měření je zobrazeno na obrázku 5.1, kde je zvýrazněna část měření, která je v databázi k dispozici.

5.2 Výběr metody a parametrů

Z předchozí kapitoly 4 se jeví, že nejoptimálnější metodou pro rozlišení dat klidových a zátěžových by mohla být analýza krátkodobou Fourierovou transformací (STFT) s výkonovými parametry odvozenými z PSD. Touto metodou extrakce příznaků dosáhli výzkumníci nejlepších výsledků klasifikace. Z toho důvodu je tato analytická metoda využita v následující části.

Duševní stres, který může být navozen právě počítáním příkladů, se projeví především poklesem aktivity v alfa pásmu a nárůstem aktivity v beta pásmu. Studie [34],[35] kladou důraz právě na tyto pásma. Studie [38] ukazuje rozdíly i v delta pásmu. V dalším pokračování práce jsou proto zkoumány výkonové parametry těchto pásem. Jmenovitě se jedná o výkony a relativní výkony v pásmech delta, alfa a beta a poměr výkonů v beta a alfa pásmu.

Aritmetické počítání je složitý komplexní proces. Proto je aktivace pozorovatelná ve více oblastech mozku. Aktivace v prefrontální a frontální oblasti může být spojena se zapojením pracovní paměti, aktivace v zadní parientální oblasti může být spojena s vybavením si matematických faktů a pravidel. [43] Podle aktivace různých mozkových oblastí je vhodné vybrat odpovídající elektrody a jejich záznamy pro analýzu. Frontální a parientální-okcipitální elektrody využívají i zmíněné studie [21], [38]. Výše zmíněné parametry budou zkoumány na záznamech z elektrod Fp1, F8, P4 a O1 tak, aby zajímavé oblasti měly své zastoupení.

5.3 Implementace metody

Pro získání výše zmíněných parametrů záznamů EEG je využita pro tvorbu programu verze MATLAB2020a a knihovna Signal Processing Toolbox od společnosti MathWorks. Realizovány byly celkem dva programy. Jeden slouží pro výpočet parametrů všech subjektů, které uloží do tabulky, s níž se pracuje v rámci statistické analýzy. Druhý program realizuje grafické uživatelské rozhraní. Oba .m soubory jsou vloženy do přiloženého archivu do složky s názvem *zdrojové kódy*. Pro načtení dat z volně dostupné databáze, která jsou ve formátu .edf je využita funkce edfread.m od [44]. V přiloženém archivu je uveden textový soubor obsahující odkaz pro její stažení.

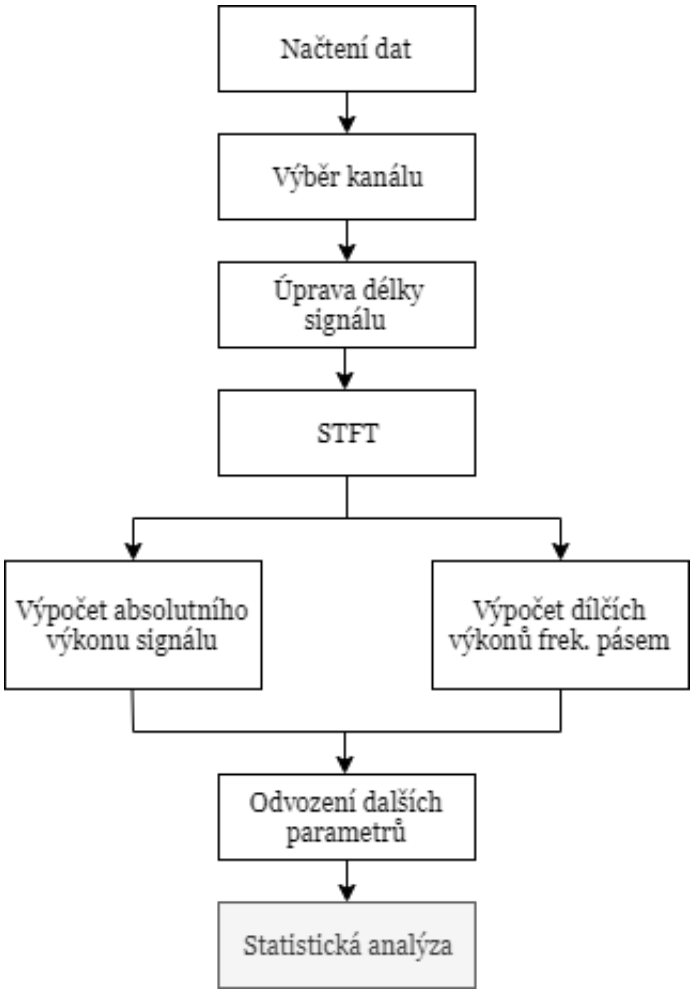

Obr. 5.2: Blokové schéma programu.

Postup jednotlivých kroků v rámci implementace metody je znázorněn na blokovém schématu na obrázku 5.2. Nejprve dochází k načtení záznamů z .edf formátu staženou funkcí edfread.m. Z načtené struktury je vybrán pouze záznam z požadované elektrody (postupně byly analyzovány kanály Fp1, F8, P4 a O1). V případě klidového záznamu dochází k výběru pouze části z dostupného záznamu tak, aby signály zachycující obě podmínky měly stejnou délku, tj. 31 000 vzorků (62 s záznamu). STFT je implementována zabudovanou funkcí *spectrogram*. Do funkce vstupuje analyzovaný časový signál. Nastavovanými parametry jsou typ, překryv a délka časového okna, počet vzorků DFT a vzorkovací frekvence signálu. Okno bylo ponecháno jako defaultně nastavené Hammingovo s překryvem 50 %. Délka okna n byla volena shodná s počtem vzorků DFT jako mocniny 2 (konkrétně 1024, 2048 a 4096 vzorků), což je výhodné kvůli FFT algoritmu. Pokud nejsou definovány výstupní proměnné funkce, dojde k vykreslení spektrogramu. Při definování výstupních proměnných dojde k uložení hodnot ze spektrogramu (jmenovitě jsou uloženy

hodnoty frekvence a času vystupující na příslušných osách a matice PSD).

Hodnoty frekvence a PSD ve výstupních proměnných jsou následně použity pro výpočet absolutního výkonu celého signálu. Výpočet je realizován pomocí funkce *bandpower*, do které vstupuje matice jednotlivých PSD ze všech časových oken a vektor odpovídajících frekvencí. To, že vstupem je výkonová spektrální hustota a nikoliv časová posloupnost, je specifikováno parametrem *'psd'*. Funkce výsledný výkon počítá jako plochu pod křivkou PSD obdélníkovou metodou. V případě, že vstupem je matice hodnot, je výkon vypočten pro každý sloupec, tj. pro každý segment. Výsledný absolutní výkon je tudíž následně zprůměrován z těchto hodnot. Postup je obdobný i pro výpočet výkonů v jednotlivých frekvenčních pásmech EEG. Vstupní parametry funkce *bandpower* jsou pouze doplněny o interval určující hranice analyzovaného pásma tzv. $'freqrange'$. V případě, že zadané hodnoty v intervalu přesně neodpovídají hodnotám ve frekvenčním vektoru, je brána nejbližší hodnota. Z jednotlivých výkonů jsou dopočítány odvozené parametry jako relativní výkony a poměr výkonů v beta a alfa pásmu.

V programu *main.m* jsou výsledné hodnoty získané postupem popsaným v předchozích odstavcích uloženy do přehledné tabulky, která v řádcích zachycuje jednotlivé subjekty a ve sloupcích pak jednotlivé parametry. Pro zefektivnění analýzy je načítání subjektů zajištěno automaticky pomocí cyklu *for*. Grafické uživatelské rozhraní ve druhém souboru *gui.m* umožňuje uživateli zobrazit časové průběhy obou typů signálů pro libovolný subjekt. Díky sliderům je možno zobrazovaný průběh omezit pouze na určitý časový interval. Kromě časových průběhů lze zobrazit spektrogramy buď celého frekvenčního rozsahu, nebo jen zvolených pásem. Je tak docíleno možnosti vizuálního porovnání, jak se PSD změní při přechodu z relaxovaného stavu do stavu zátěže. Při zobrazení spektrogramů dojde k výpočtu výkonových parametrů pro jeden subjekt, které jsou uloženy do tabulky pod jednotlivými grafy.

5.4 Statistická analýza

Statistika je v biologických a medicínských vědách hojně využívána právě např. ke srovnání určitých skupin. Uplatnění statistiky pro tento typ úlohy předpokládá vyslovení hypotézy platné pro měřené veličiny. Ověření platnosti hypotézy se provádí pomocí statistických testů na základě měřených dat. Výsledkem je buď přijetí hypotézy, nebo její zamítnutí a přijetí hypotézy alternativní [45].

Testů hypotéz existuje velké množství. Obecně je lze rozdělit na parametrické a neparametrické, přičemž parametrické testy jsou podstatně náročnější z hlediska předpokladů. Testovaný soubor musí splňovat podmínku normálního rozdělení, aby bylo možné parametrický test použít. Naopak neparametrické testy tento předpoklad nevyžadují. Síla neparametrického testu je menší, avšak použití tohoto testu s sebou

nese menší riziko chybných závěrů, ke kterým může dojít v závislosti na chybných výsledcích parametrického testování dat, která nesplňují požadavky [45].

Rozhodnutí o zamítnutí či nezamítnutí nulové hypotézy lze kromě porovnání testovacího kritéria s kritickou hodnotou provést pomocí tzv. p-hodnoty. Udává pravděpodobnost za platnosti nulové hypotézy, se kterou lze získat stejnou nebo méně pravděpodobnou hodnotu testové statistiky. Čím menší p-hodnota testu je, tím test předpovídá menší pravděpodobnost, že platí nulová hypotéza. Samotné rozhodování o platnosti nulové hypotézy probíhá porovnáním p-hodnoty se zvolenou hladinou významnosti (obvykle 0,05 nebo 0,01). Pokud je p-hodnota menší než zvolená hladina významnosti, nulová hypotéza je zamítnuta a platí hypotéza alternativní. Výsledek je statisticky významný na zvolené hladině významnosti [45].

5.4.1 Popis průběhu analýzy

Pro účely vyhodnocení, zda uvažované parametry jsou vhodné ke komparaci EEG záznamů, byla provedena statistická analýza v softwaru Statistica 12 od společnosti StatSoft. Tabulky vygenerované v programu Matlab byly zkopírovány do programu Microsoft Excel pro další zpracování a import do softwaru Statistica.

K analýze výkonových parametrů v klidu a při zátěži byl využit párový test, neboť jsou porovnávány vzorky závislé přes osobu subjektu. Normální rozdělení jednotlivých parametrů bylo ověřeno Shapiro-Wilkovým testem ve spojení s histogramy. Kompletní výsledky testů normality (p-hodnoty) jsou uvedeny v dílčích souborech v přiloženém archivu. Rozdělení některých parametrů bylo určeno jako normální tak, jako je tomu např. na obrázku 5.3, avšak u všech parametrů tento předpoklad pro použití parametrických testů nebyl splněn (viz obrázek 5.4). V důsledku toho, pro zachování jednoty, musí být testování hypotéz provedeno neparametrickým testem. Jedním z neparametrických testů je Wilcoxonův párový test. Jeho předpokladem je však symetrie dat kolem mediánu. Tento předpoklad nebyl splněn, což dokumentují jednotlivé boxploty na obrázcích 6.1 až 6.28. Nesymetrické rozložení mají parametry např. na obrázcích 6.1, 6.10, 6.16. Z toho důvodu byl pro další analýzu použit znaménkový párový test. Jak znaménkový, tak Wilcoxonovův test ověřuje, zda medián diferencí závislých parametrů je roven nule či nikoliv. Za nulovou hypotézu H_0 lze stanovit tvrzení, které říká, že rozdíl mezi parametry klidovými a zátěžovými není. Alternativní hypotézou H_A je pak tvrzení, že parametry klidové a zátěžové rozdílné jsou, což je klíčová vlastnost pro cíl práce, tj. odlišit signály ze dvou skupin dat.

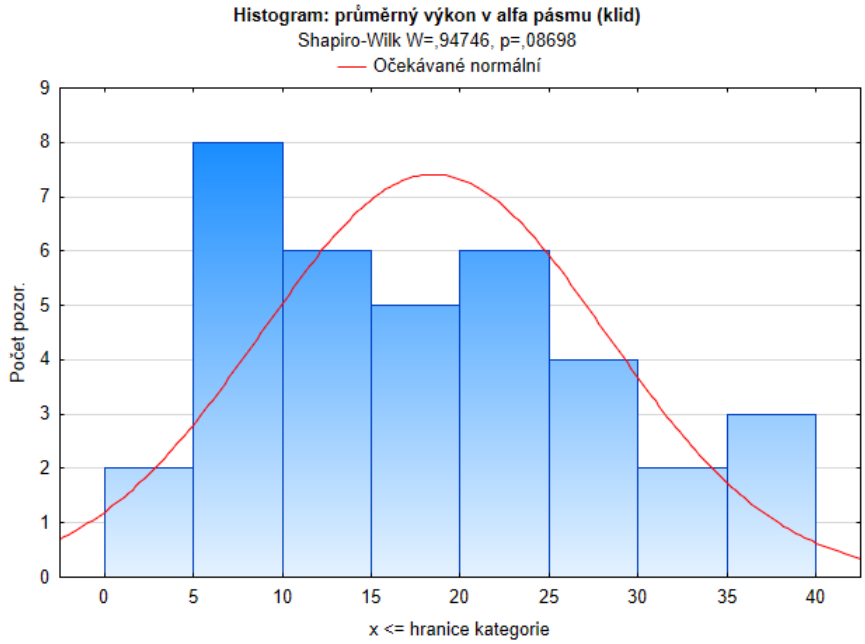

Obr. 5.3: Test normality histogramem s Shapiro-Wilkovým testem pro parametr průměrného výkonu v alfa pásmu v klidu ze záznamů elektrody Fp1.

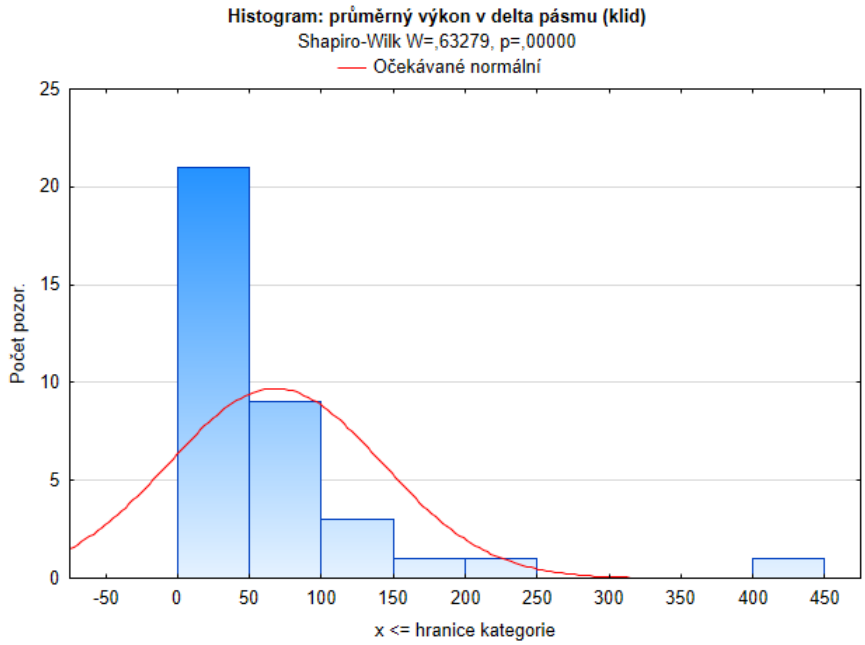

Obr. 5.4: Test normality histogramem s Shapiro-Wilkovým testem pro parametr průměrného výkonu v delta pásmu v klidu ze záznamů elektrody Fp1.

6 Výsledky experimentální části

6.1 Dílčí výsledky pro elektrodu Fp1

Kompletní tabulka hodnot všech parametrů pro všechny subjekty je uvedena v přiloženém archivu pod názvem souboru *fp1_vysledky.xlsx*. V níže uvedené tabulce 6.1 jsou uvedeny mediány jednotlivých příznaků a výsledné p-hodnoty vycházející ze znaménkového párového testu. Mediány průměrných výkonů jsou uvedeny v μV^2. Parametry byly počítány pro tři různé varianty délky časového okna STFT, přičemž n udává délku okna ve vzorcích. Uvedené mediány a boxploty na obrázcích 6.1 až 6.7 vychází z analýzy s časovým oknem STFT $n = 1024$ vzorků (2.048 s).

Rozdíly mezi klidovým a zátěžovým stavem prokázal test statisticky významné na hladině významnosti $\alpha = 0.05$ u parametrů: poměr výkonů v beta a alfa pásmu ($p = 0.01242$; $p = 0.03026$), relativní výkon delta pásma ($p = 0.03026$) a relativní výkon alfa pásma ($p = 0.01242$). Tyto významné rozdíly jsou označeny tučným písmem. Ostatní příznaky nejsou statisticky významně rozdílné. Nejlepší výsledek z trojice pokusů různého nastavení je označen hvězdičkou.

Tab. 6.1: Shrnutí statistické analýzy záznamů z Fp1.

Parametr	Podmínka	Medián	P-hodnota		
			n = 1024	n = 2048	n = 4096
Průměr. výkon delta	klid	43.58	0.24335*	0.24335*	0.24335*
Průměr. výkon delta	zátěž	87.39			
Průměr. výkon alfa	klid	16.99	0.06675*	0.06675*	0.13361
Průměr. výkon alfa	zátěž	12.12			
Průměr. výkon beta	klid	7.04	0.61708	0.40466*	0.40466*
Průměr. výkon beta	zátěž	6.96			
Poměr beta/alfa	klid	0.46	**0.03026**	**0.01242***	**0.01242***
Poměr beta/alfa	zátěž	0.59			
Relativ. výkon delta	klid	0.59	**0.03026***	**0.03026***	0.06675
Relativ. výkon delta	zátěž	0.70			
Relativ. výkon alfa	klid	0.19	**0.01242***	**0.01242***	**0.01242***
Relativ. výkon alfa	zátěž	0.10			
Relativ. výkon beta	klid	0.09	0.24335	0.13361*	0.24335
Relativ. výkon beta	zátěž	0.07			

Na následujících stránkách práce jsou graficky zobrazená rozložení hodnot jednotlivých parametrů. Hodnoty pochází z analýzy záznamů elektrody Fp1 s uplatněním nejkratší délky okna (tj. 1024 vzorků). Na grafech na obrázcích 6.1, 6.2, 6.3, 6.4 a 6.7 je možné vidět odlehlé až extrémní hodnoty. Data nevykazují symetrii kolem mediánu a je patrný poměrně velký rozptyl hodnot, což může negativně ovlivňovat výsledky analýzy. Z grafů na obrázcích 6.1 a 6.5 i z mediánů parametrů výkonu delta pásma je možné usuzovat jistou tendenci růstu těchto hodnot při přechodu z klidového stavu do stavu zátěže, byť statistická významnost rozdílu nebyla potvrzena. Pro alfa pásmo (obrázky 6.2, 6.6) je patrná klesající tendence parametrů, která odpovídá teoretickým předpokladům, stejně jako zvyšující se poměr výkonů v pásmech beta a alfa (obrázek 6.4) odpovídá předpokladům. Výkony beta pásma (obrázky 6.3, 6.7) se vymykají předpokladům, neboť by výkony v tomto pásmu měly se zátěží růst.

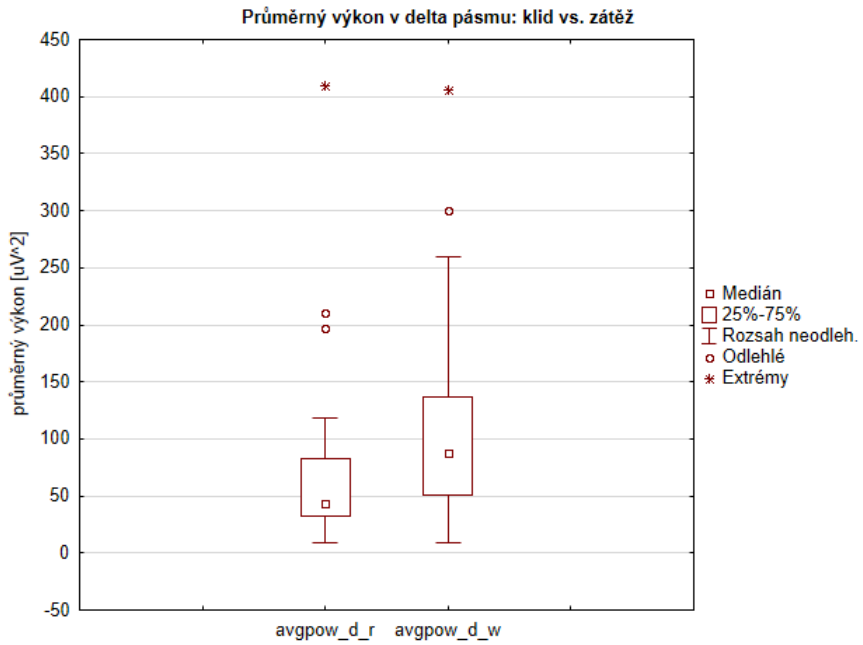

Obr. 6.1: Rozložení hodnot průměrných výkonů v delta pásmu záznamů z elektrody Fp1.

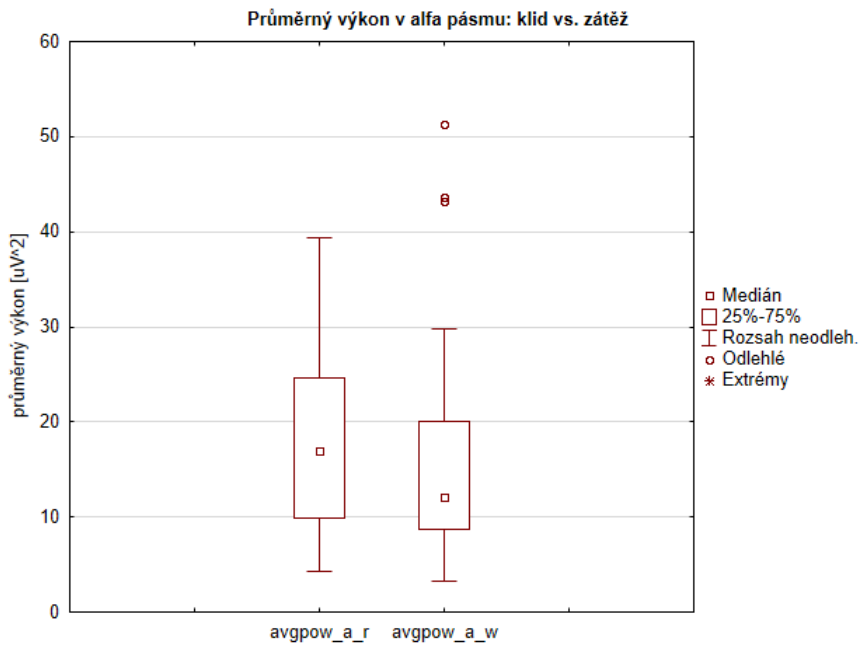

Obr. 6.2: Rozložení hodnot průměrných výkonů v alfa pásmu záznamů z elektrody Fp1.

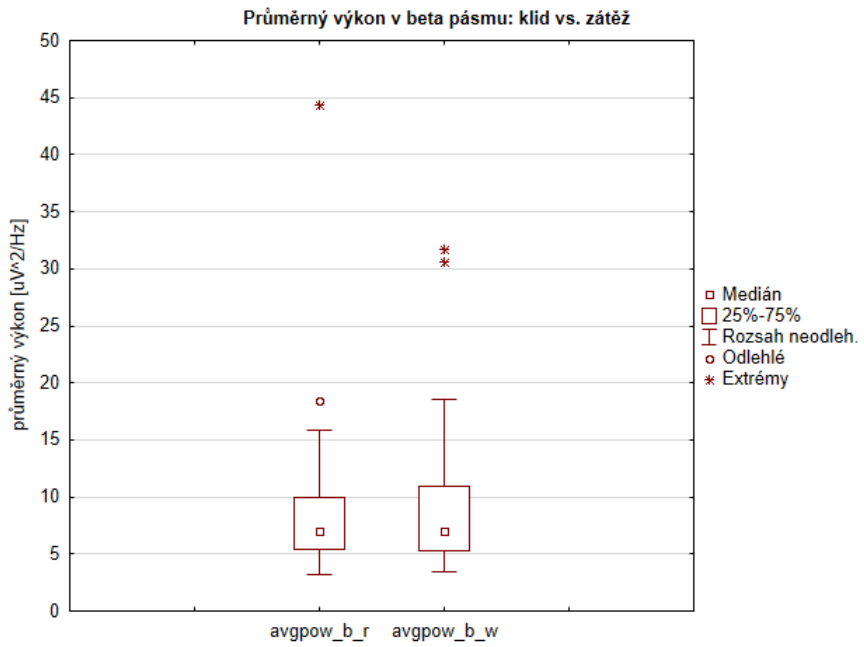

Obr. 6.3: Rozložení hodnot průměrných výkonů v beta pásmu záznamů z elektrody Fp1.

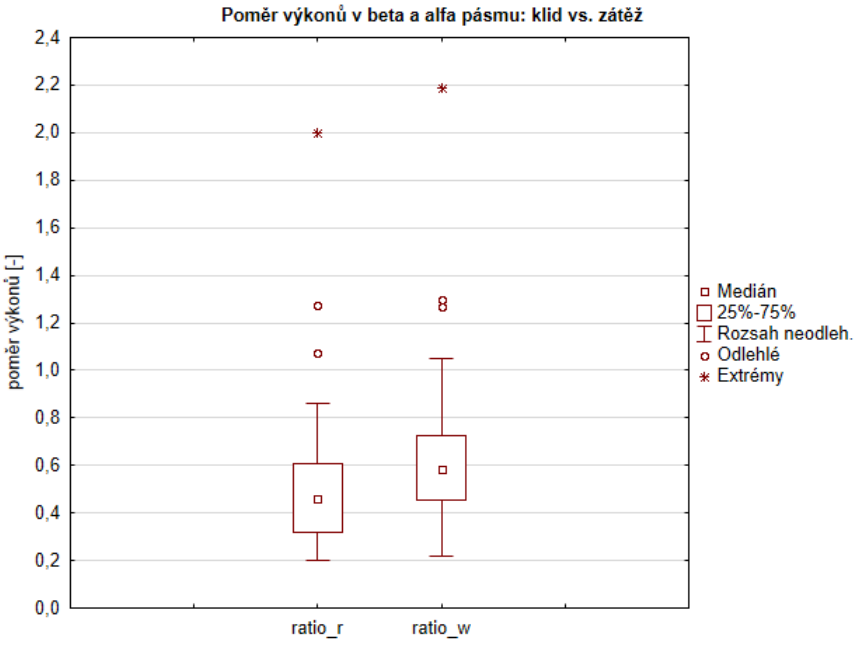

Obr. 6.4: Rozložení hodnot poměrů výkonů v beta a alfa pásmu záznamů z elektrody Fp1.

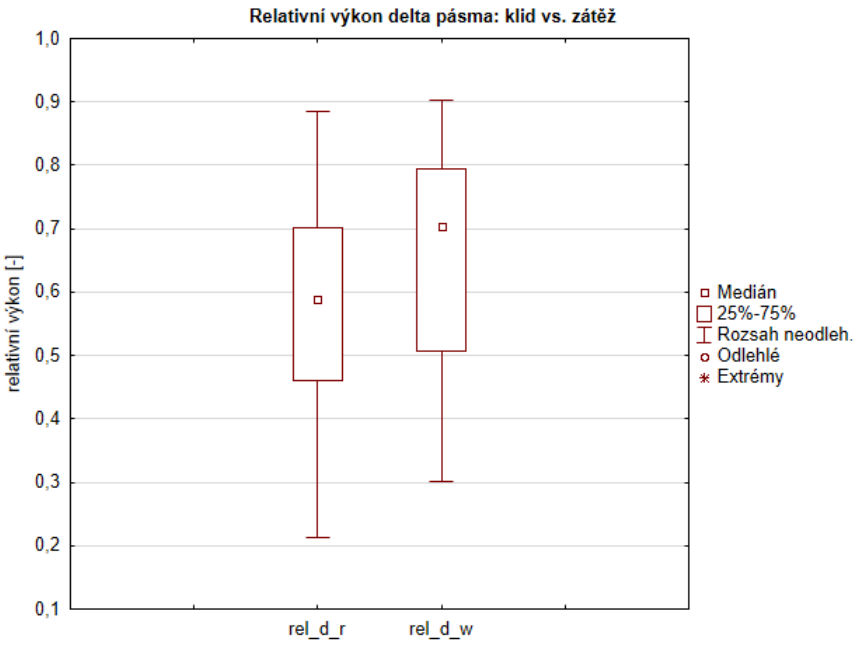

Obr. 6.5: Rozložení hodnot relativních výkonů delta pásma záznamů z elektrody Fp1.

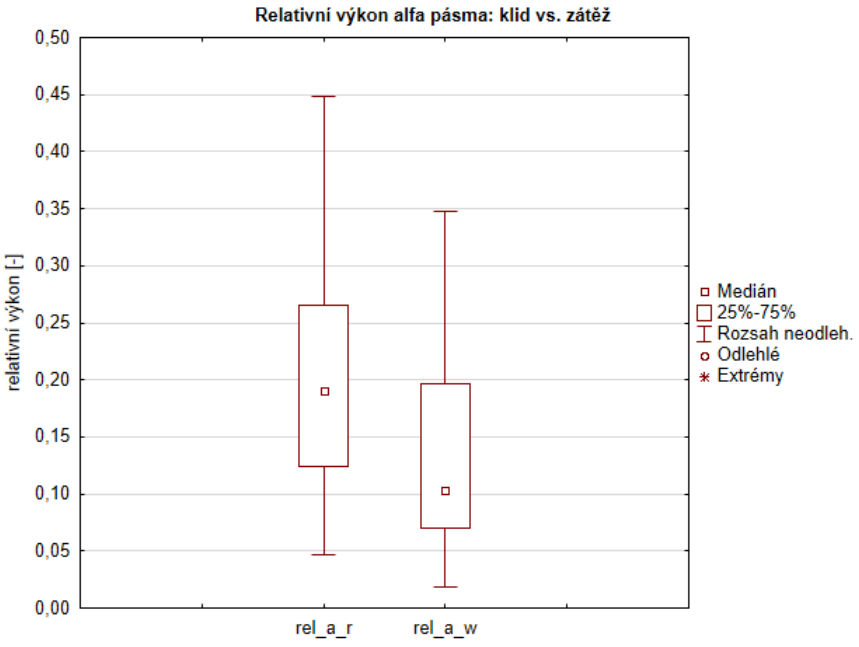

Obr. 6.6: Rozložení hodnot relativních výkonů alfa pásma záznamů z elektrody Fp1.

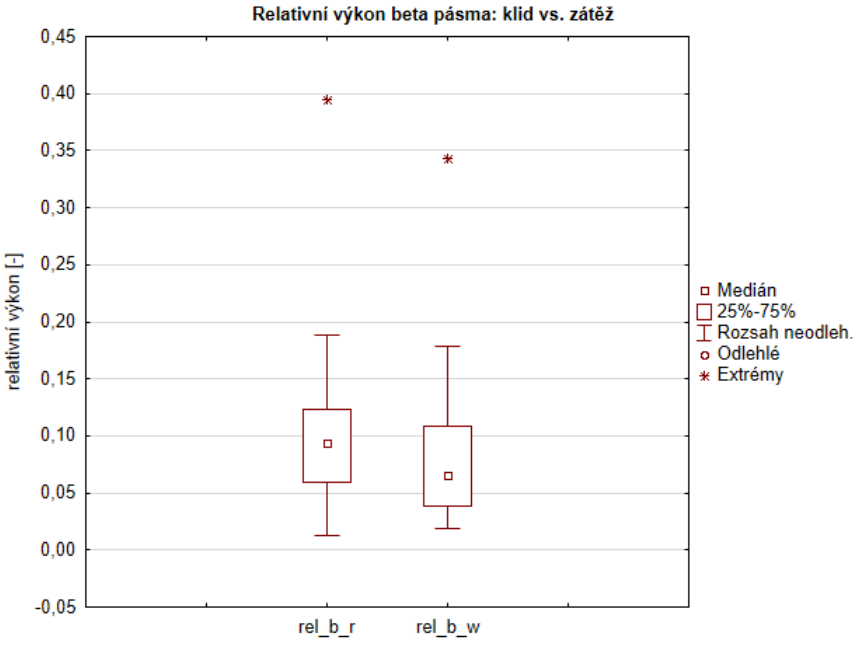

Obr. 6.7: Rozložení hodnot relativních výkonů beta pásma záznamů z elektrody Fp1.

6.2 Dílčí výsledky pro elektrodu F8

Veškeré hodnoty parametrů získané analýzou záznamů z elektrody F8 jsou uvedeny v souboru *f8_vysledky.xlsx* přiloženém k této práci. V následující tabulce 6.2 jsou shrnuty mediány parametrů a výsledky znaménkového párového testu v podobě p-hodnot pro tři varianty analýzy s různým nastavením časového okna STFT. Délka okna n je ve vzorcích. Mediány parametrů pochází z analýzy s oknem délky $n = 1024$ vzorků stejně jako boxploty rozložení hodnot zobrazené na obrázcích 6.8 až 6.14. Mediány průměrných výkonů jsou uvedeny v μV^2.

Statisticky významné rozdíly je možné pozorovat u parametrů: poměr výkonů v beta a alfa pásmu ($p = 0.01242$; $p = 0.03026$), relativní výkon delta pásma ($p = 0.01242$; $p = 0.03026$) a relativní výkon alfa pásma ($p = 0.01242$; $p = 0.00461$; $p = 0.00154$) stejně jako tomu bylo u elektrody Fp1 v předcházející podkapitole 6.1. Navíc zde vychází statisticky významný rozdíl parametru průměrného výkonu v alfa pásmu ($p = 0.03026$) pro nastavení nejkratšího časového okna STFT. Tyto p-hodnoty jsou označeny tučným písmem. Ostatní parametry statisticky významné rozdíly nevykazují. Nejlepší výsledek z trojice pokusů je označen hvězdičkou.

Tab. 6.2: Shrnutí statistické analýzy záznamů z F8.

Parametr	Podmínka	Medián	P-hodnota		
			n = 1024	n = 2048	n = 4096
Průměr. výkon delta	klid	50.76	0.24335*	0.40466	0.40466
Průměr. výkon delta	zátěž	56.30			
Průměr. výkon alfa	klid	15.61	**0.03026***	0.13361	0.06675
Průměr. výkon alfa	zátěž	11.86			
Průměr. výkon beta	klid	6.76	0.61708*	0.86763	0.86763
Průměr. výkon beta	zátěž	7.35			
Poměr beta/alfa	klid	0.48	**0.01242***	**0.01242***	**0.03026**
Poměr beta/alfa	zátěž	0.62			
Relativ. výkon delta	klid	0.60	**0.01242***	**0.01242***	**0.03026**
Relativ. výkon delta	zátěž	0.66			
Relativ. výkon alfa	klid	0.18	**0.01242**	**0.00461**	**0.00154***
Relativ. výkon alfa	zátěž	0.13			
Relativ. výkon beta	klid	0.10	0.86763	0.40466*	0.40466*
Relativ. výkon beta	zátěž	0.08			

Grafy znázorňující rozložení hodnot parametrů záznamů z elektrody F8 na obrázcích 6.8 až 6.14 jsou velmi podobné grafům předcházejícím na obrázcích 6.1 až 6.7, které platí pro elektrodu Fp1. Rozdílná je mírně vyšší hodnota mediánu průměrného výkonu v beta pásmu v zátěžovém záznamu oproti klidovému, avšak boxplot na obrázku 6.10 ukazuje téměř stejný rozsah hodnot tohoto parametru, což se odráží i na výsledné p-hodnotě.

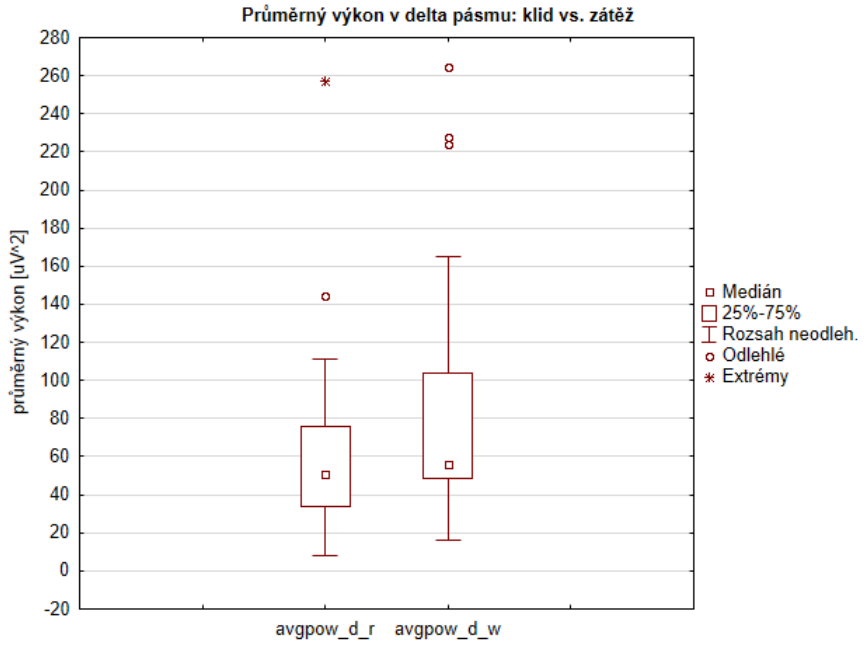

Obr. 6.8: Rozložení hodnot průměrných výkonů v delta pásmu záznamů z elektrody F8.

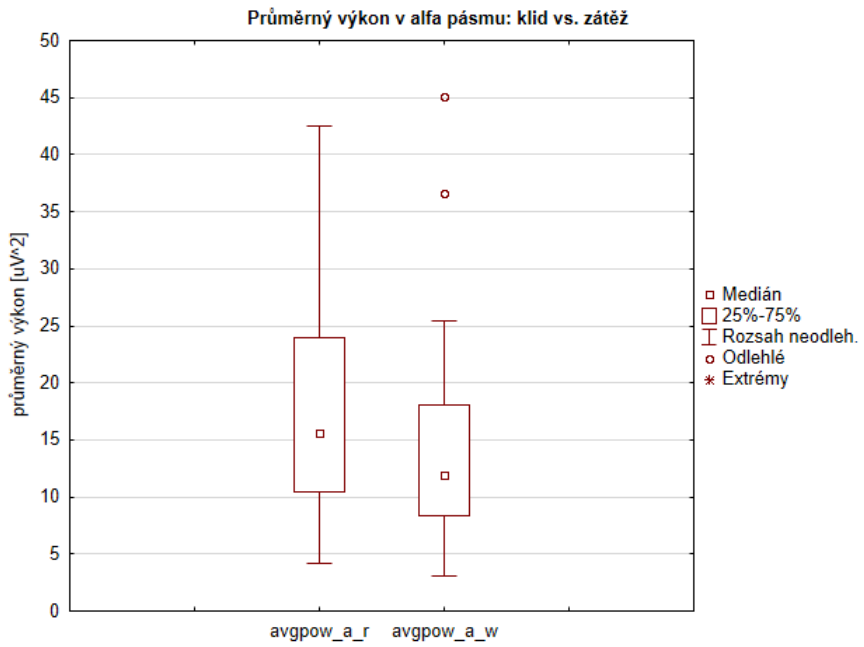

Obr. 6.9: Rozložení hodnot průměrných výkonů v alfa pásmu záznamů z elektrody F8.

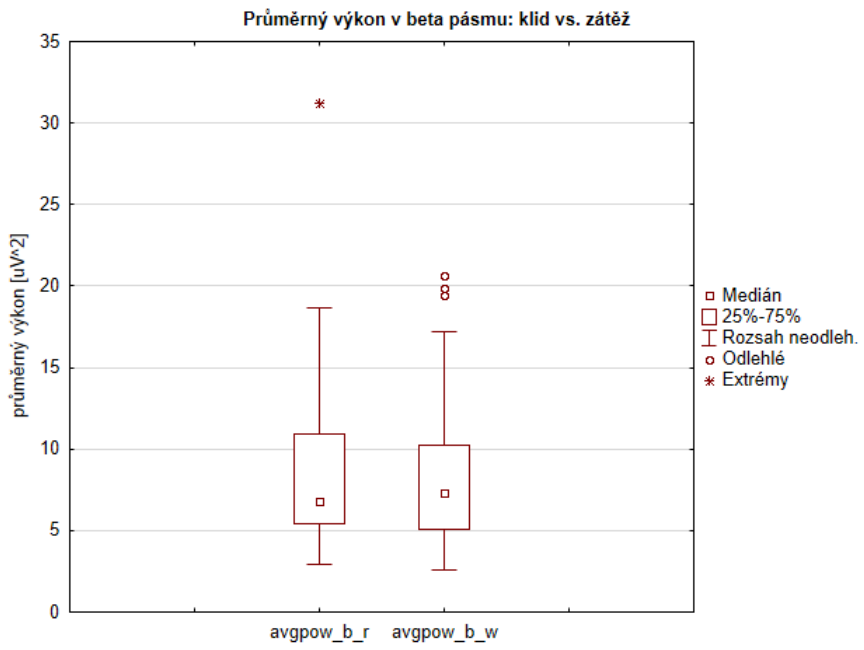

Obr. 6.10: Rozložení hodnot průměrných výkonů v beta pásmu záznamů z elektrody F8.

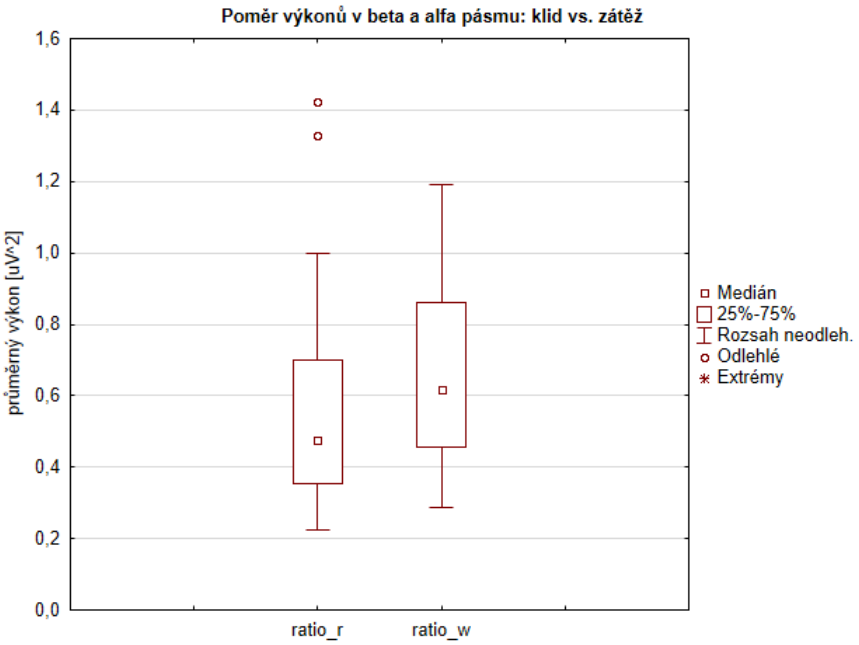

Obr. 6.11: Rozložení hodnot poměrů výkonů v beta a alfa pásmu záznamů z elektrody F8.

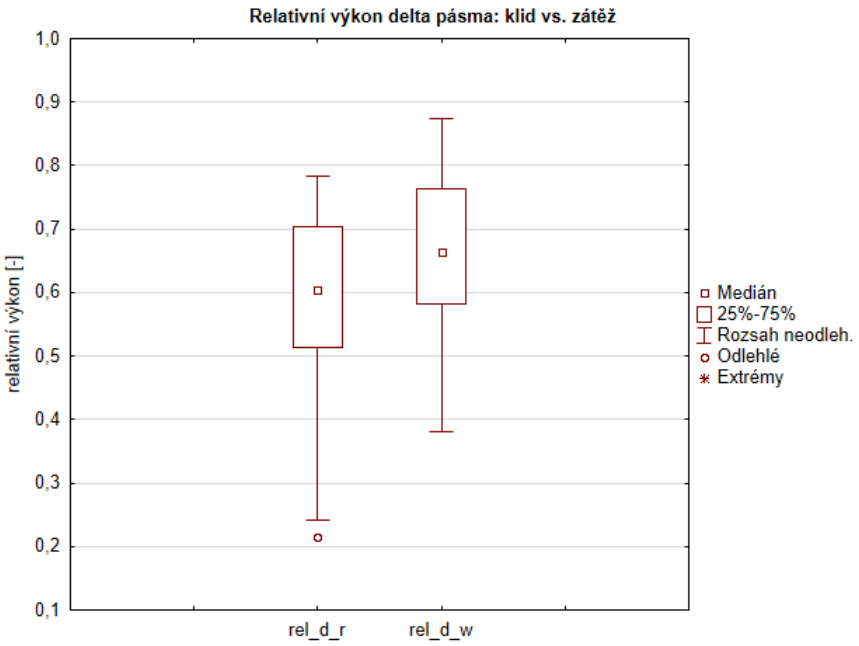

Obr. 6.12: Rozložení hodnot relativních výkonů delta pásma záznamů z elektrody F8.

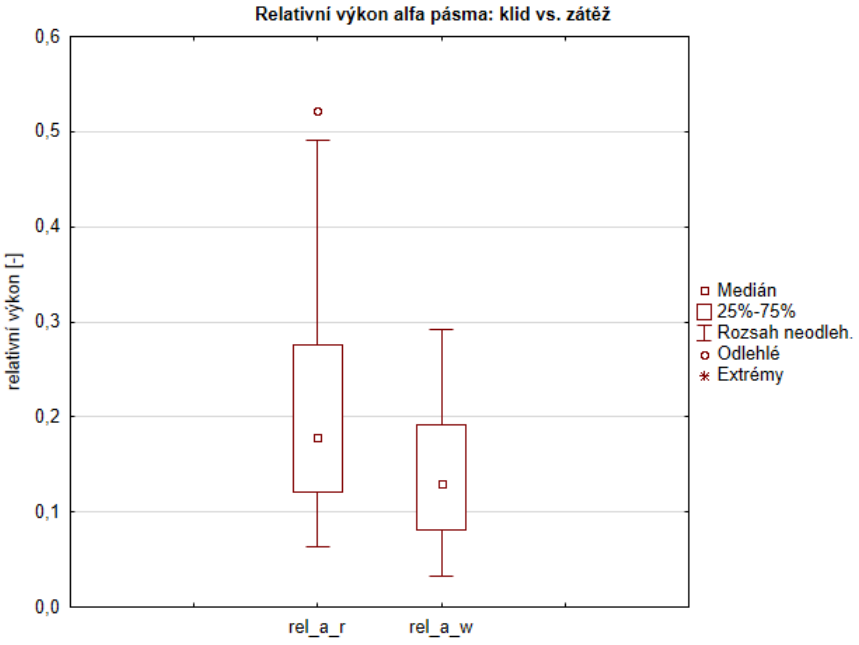

Obr. 6.13: Rozložení hodnot relativních výkonů alfa pásma záznamů z elektrody F8.

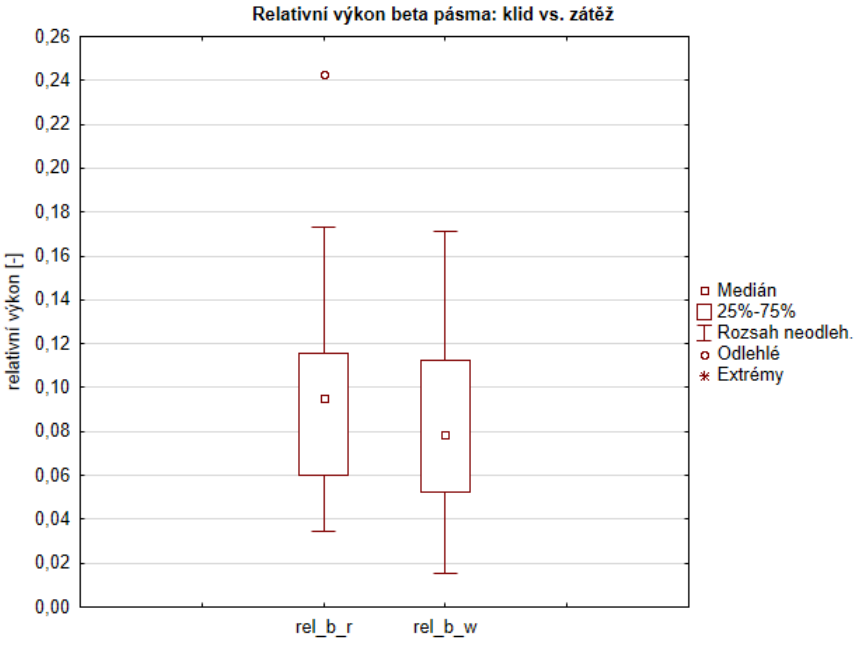

Obr. 6.14: Rozložení hodnot relativních výkonů beta pásma záznamů z elektrody F8.

6.3 Dílčí výsledky pro elektrodu P4

Úplné výsledky všech parametrů pro všechny subjekty jsou přiloženy k práci v souboru s názvem *p4_vysledky.xlsx*. V souhrnné tabulce tabulce 6.3 jsou uvedeny mediány parametrů a výsledné p-hodnoty znaménkového párového testu. Mediány průměrných výkonů jsou uvedeny v μV^2. Statistická analýza byla provedena pro tři varianty nastavení délky časového okna pro výpočet STFT. Délka n je uvedena ve vzorcích. Mediány parametrů pochází z analýzy s oknem délky $n = 1024$ stejně jako boxploty rozložení hodnot zobrazené na obrázcích 6.15 až 6.21.

V rámci analýzy záznamů z elektrody P4 vychází rozdíly mezi všemi parametry ze dvou stavů statisticky významné alespoň pro jednu variantu nastavení časového okna STFT (viz tabulka 6.3). Nejnižších p-hodnot dosahuje test pro parametry průměrného a relativního výkonu alfa pásma a pro poměr výkonů beta a alfa pásma. Statisticky významné rozdíly jsou pro přehlednost označeny tučně, nejlepší výsledek z trojice pokusů hvězdičkou.

Tab. 6.3: Shrnutí statistické analýzy záznamů z P4.

Parametr	Podmínka	Medián	P-hodnota		
			n = 1024	n = 2048	n = 4096
Průměr. výkon delta	klid	52.19	**0.01242***	**0.01242***	0.24335
Průměr. výkon delta	zátěž	46.08			
Průměr. výkon alfa	klid	53.28	**0.00003**	**0.00001***	**0.13361**
Průměr. výkon alfa	zátěž	26.98			
Průměr. výkon beta	klid	13.29	**0.00154***	**0.00461**	0.40466
Průměr. výkon beta	zátěž	9.35			
Poměr beta/alfa	klid	0.22	**0.00047**	**0.00013***	**0.01242**
Poměr beta/alfa	zátěž	0.35			
Relativ. výkon delta	klid	0.41	**0.00461***	**0.00461***	0.06675
Relativ. výkon delta	zátěž	0.48			
Relativ. výkon alfa	klid	0.41	**0.00047***	**0.00047***	**0.01242**
Relativ. výkon alfa	zátěž	0.31			
Relativ. výkon beta	klid	0.08	**0.03026***	0.06675	0.24335
Relativ. výkon beta	zátěž	0.09			

Grafy znázorňující rozložení hodnot parametrů záznamů z elektrody P4 jsou zobrazeny na obrázcích 6.15 až 6.21. Oproti předcházejícím dvěma analýzám elektrod Fp1 a F8 vykazuje delta pásmo u elektrody P4 klesající tendenci průměrného výkonu s přechodem do stavu zátěže (obrázek 6.15). Průměrný výkon v beta pásmu vykazuje opět klesající tendenci, která je v rozporu z předpoklady. Relativní výkon tohoto pásma je ovšem v zátěži vyšší, což má souvislost s poklesem celkového výkonu signálu. Výkon v alfa pásmu a poměr výkonů beta a alfa se chovají podle předpokladů.

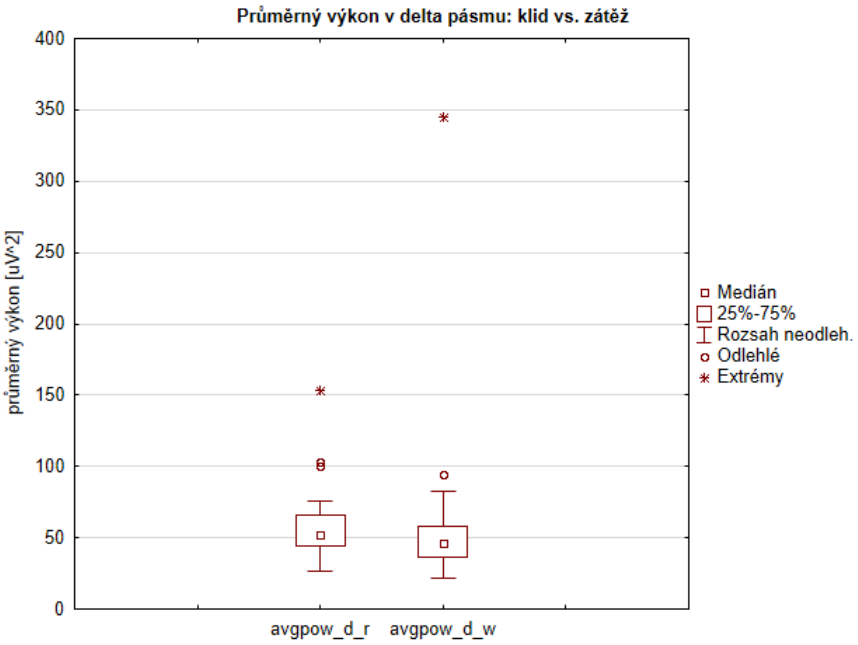

Obr. 6.15: Rozložení hodnot průměrných výkonů v delta pásmu záznamů z elektrody P4.

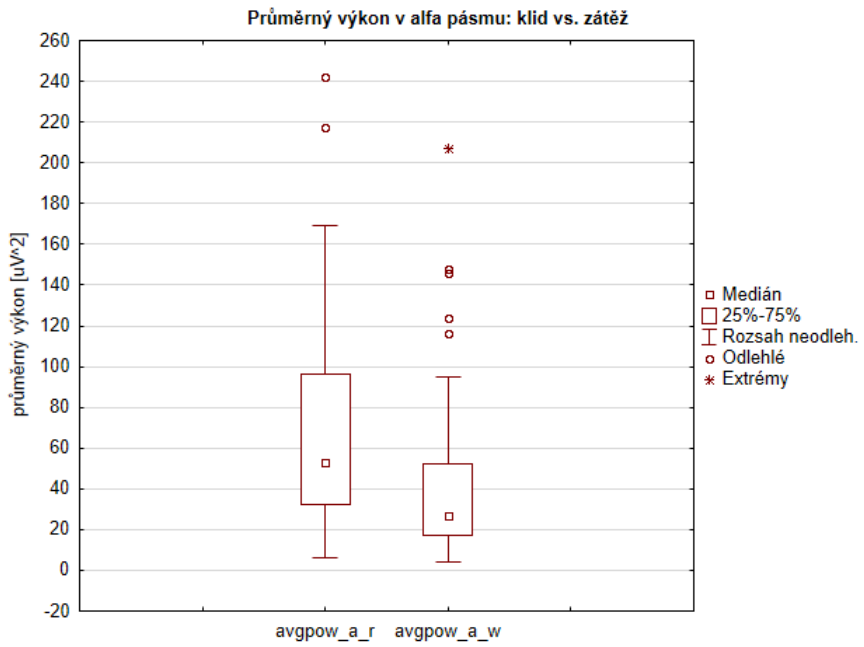

Obr. 6.16: Rozložení hodnot průměrných výkonů v alfa pásmu záznamů z elektrody P4.

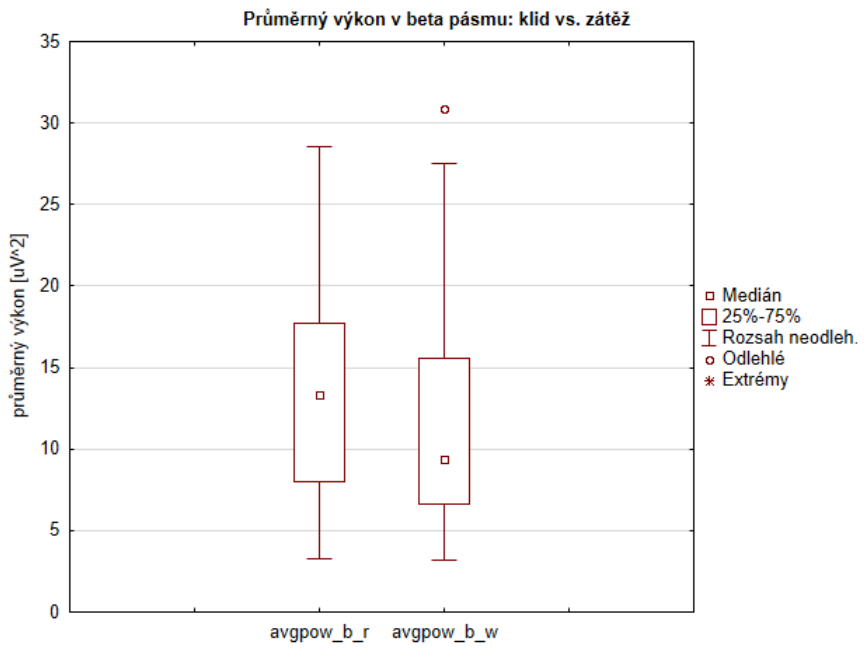

Obr. 6.17: Rozložení hodnot průměrných výkonů v beta pásmu záznamů z elektrody P4.

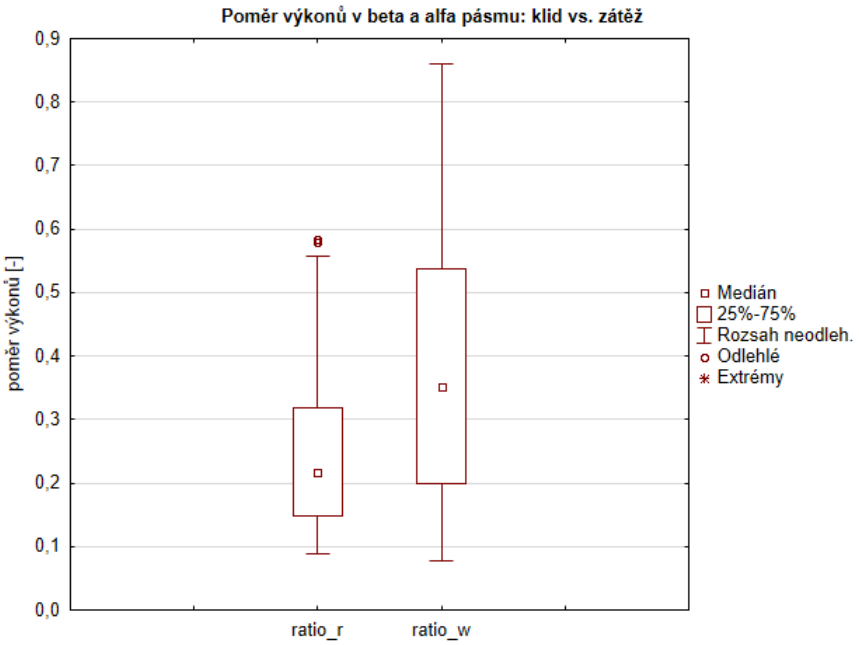

Obr. 6.18: Rozložení hodnot poměrů výkonů v beta a alfa pásmu záznamů z elektrody P4.

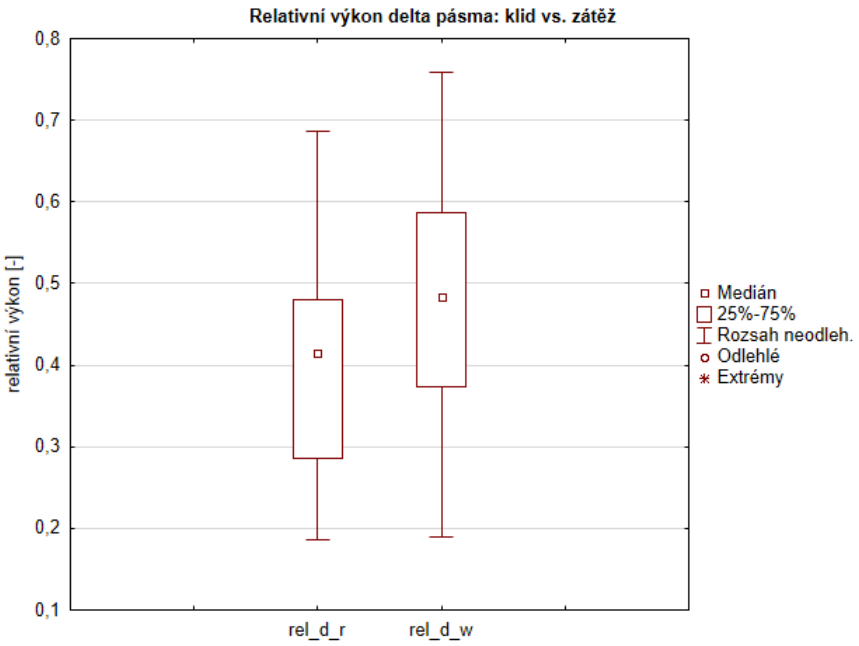

Obr. 6.19: Rozložení hodnot relativních výkonů delta pásma záznamů z elektrody P4.

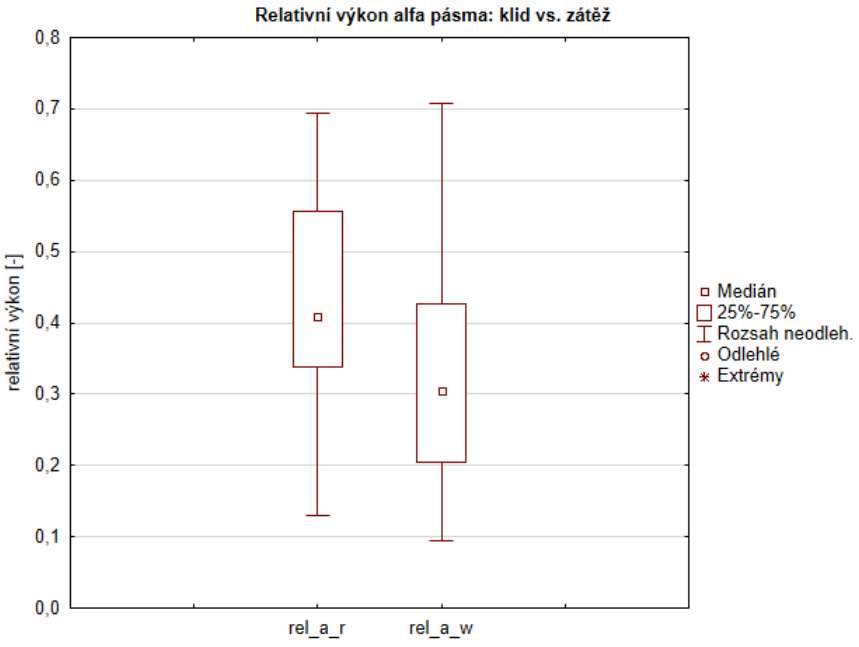

Obr. 6.20: Rozložení hodnot relativních výkonů alfa pásma záznamů z P4.

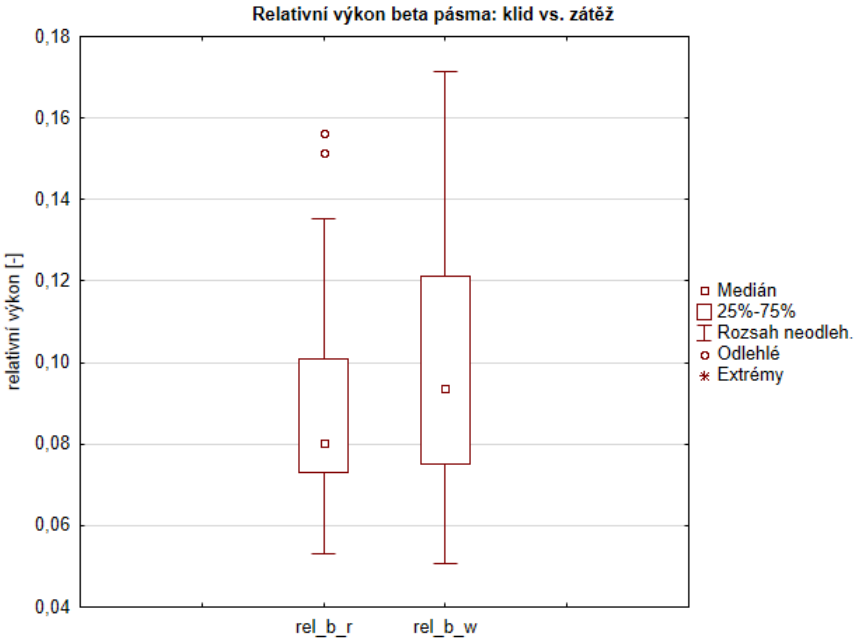

Obr. 6.21: Rozložení hodnot relativních výkonů beta pásma záznamů z P4.

6.4 Dílčí výsledky pro elektrodu O1

Kompletní výsledky parametrů vypočítaných ze záznamů elektrody O1 jsou uvedeny v přiloženém souboru s názvem *o1_vysledky.xlsx*. V tabulce 6.4 jsou přehledně zobrazeny výsledky znaménkového párového testu v podobě p-hodnot a mediány parametrů vypočítané z analýzy STFT s oknem $n = 1024$. Z analýzy se stejným nastavením pochází i boxploty zobrazující rozsah daných parametrů na obrázcích 6.22 až 6.28. Mediány průměrných výkonů v tabulce jsou uvedeny v μV^2.

Analýzou záznamů z elektrody O1 byly zjištěny statisticky významné rozdíly u stejných parametrů jako v případě elektrody F8 (viz podkapitola 6.2) a navíc u parametru průměrného výkonu v beta pásmu s p-hodnotou $p = 0.03026$ pro variantu s nejkratším časovým oknem STFT. Nejnižších p-hodnot opět dosahují testy pro parametry průměrného a relativního výkonu v alfa pásmu a poměr výkonů v beta a alfa pásmu. Statisticky významné rozdíly jsou v tabulce 6.4 vyznačeny tučně, nejlepší výsledek z trojice nastavení analýzy hvězdičkou.

Tab. 6.4: Shrnutí statistické analýzy záznamů z O1.

Parametr	Podmínka	Medián	P-hodnota		
			n = 1024	n = 2048	n = 4096
Průměr. výkon delta	klid	51.39	0.24335	0.06675*	0.13361
Průměr. výkon delta	zátěž	42.38			
Průměr. výkon alfa	klid	66.66	**0.00047**	**0.00013**	**0.00003***
Průměr. výkon alfa	zátěž	32.80			
Průměr. výkon beta	klid	12.26	**0.03026***	0.06675	0.06675
Průměr. výkon beta	zátěž	10.72			
Poměr beta/alfa	klid	0.21	**0.00047**	**0.00001***	**0.00013**
Poměr beta/alfa	zátěž	0.30			
Relativ. výkon delta	klid	0.35	**0.00154***	**0.00154***	**0.00461**
Relativ. výkon delta	zátěž	0.45			
Relativ. výkon alfa	klid	0.46	**0.00047***	**0.00154**	**0.00154**
Relativ. výkon alfa	zátěž	0.35			
Relativ. výkon beta	klid	0.08	0.40466	0.13361*	0.13361*
Relativ. výkon beta	zátěž	0.10			

Grafické zobrazení rozložení hodnot parametrů záznamů z elektrody O1 pomocí boxplotů je uvedeno na níže uvedených obr. 6.22 až 6.28. Stejně jako při analýze elektrody P4 vykazuje delta pásmo i u elektrody O1 klesající tendenci průměrného výkonu s přechodem do stavu zátěže, a to zejména při pohledu na mediány parametrů ve dvou stavech. Průměrný výkon v beta pásmu vykazuje opět klesající tendenci, která je v rozporu z předpoklady. Relativní výkon tohoto pásma nevykazuje významné rozdíly. Výkon v alfa pásmu a poměr výkonů beta a alfa se chovají podle předpokladů a rozdíly těchto parametrů jsou statisticky významné.

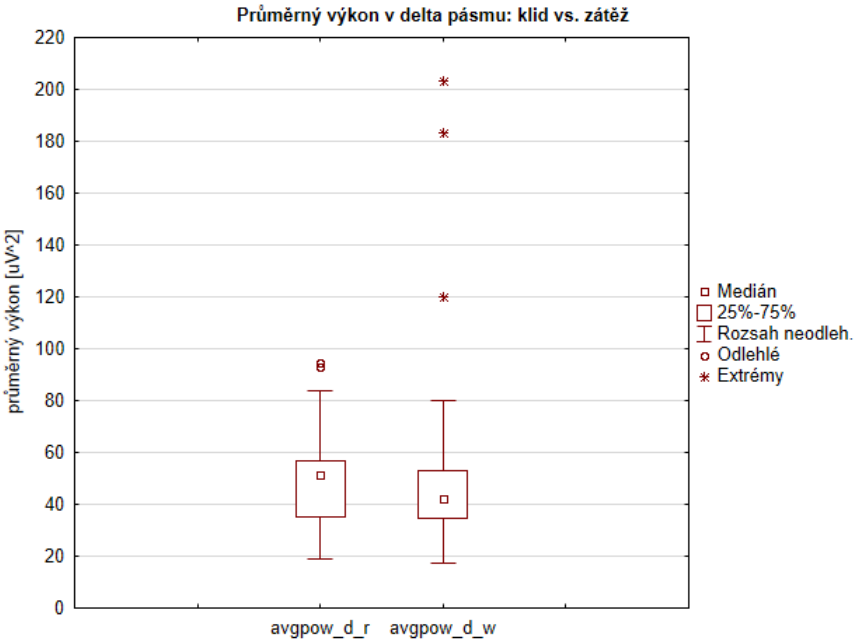

Obr. 6.22: Rozložení hodnot průměrných výkonů v delta pásmu záznamů z elektrody O1.

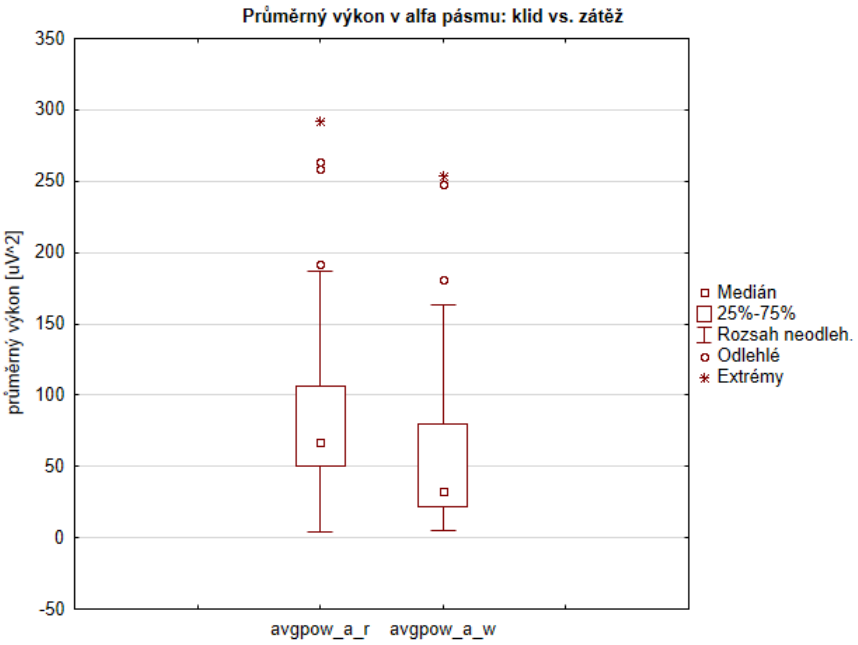

Obr. 6.23: Rozložení hodnot průměrných výkonů v alfa pásmu záznamů z elektrody O1.

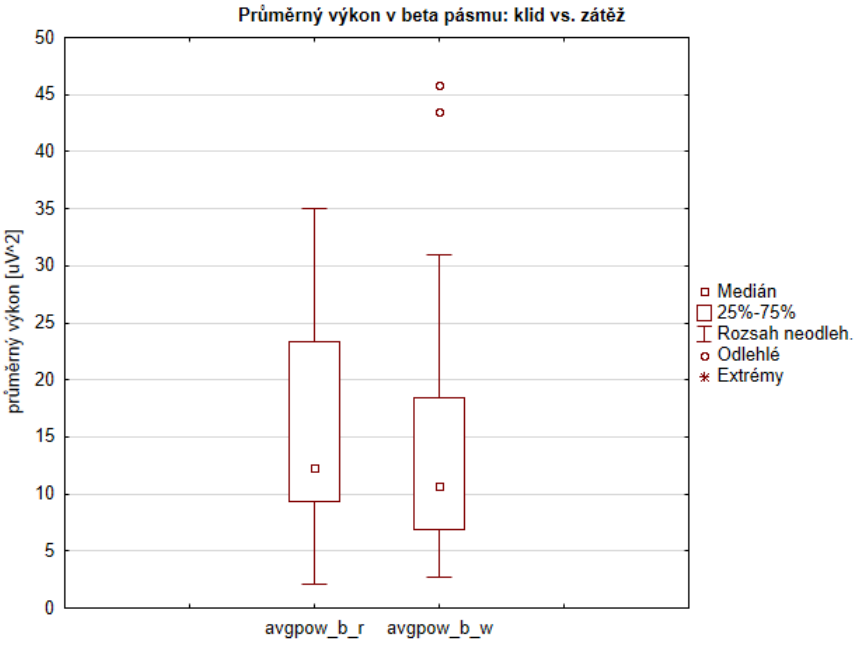

Obr. 6.24: Rozložení hodnot průměrných výkonů v beta pásmu záznamů z elektrody O1.

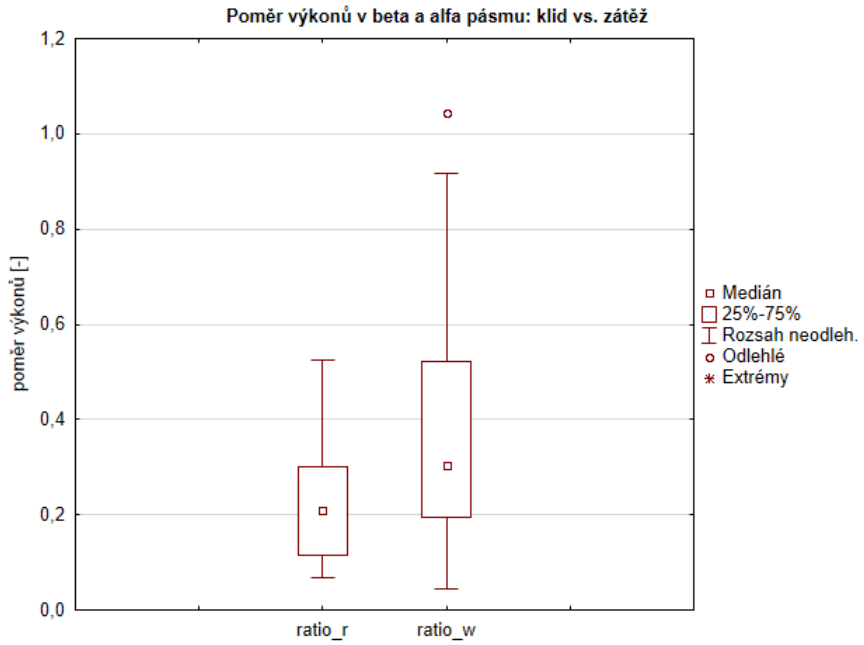

Obr. 6.25: Rozložení hodnot poměrů výkonů v beta a alfa pásmu záznamů z elektrody O1.

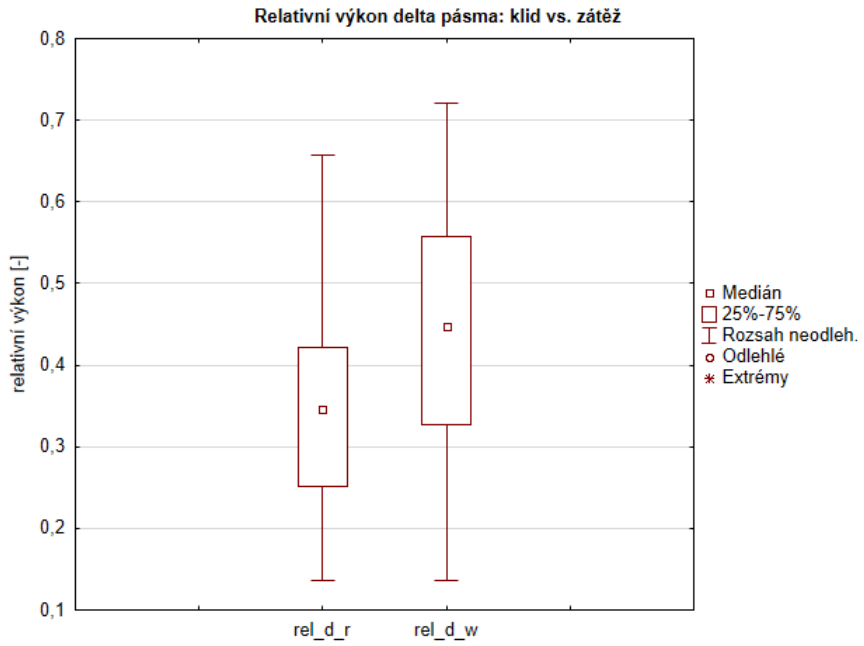

Obr. 6.26: Rozložení hodnot relativních výkonů delta pásma záznamů z elektrody O1.

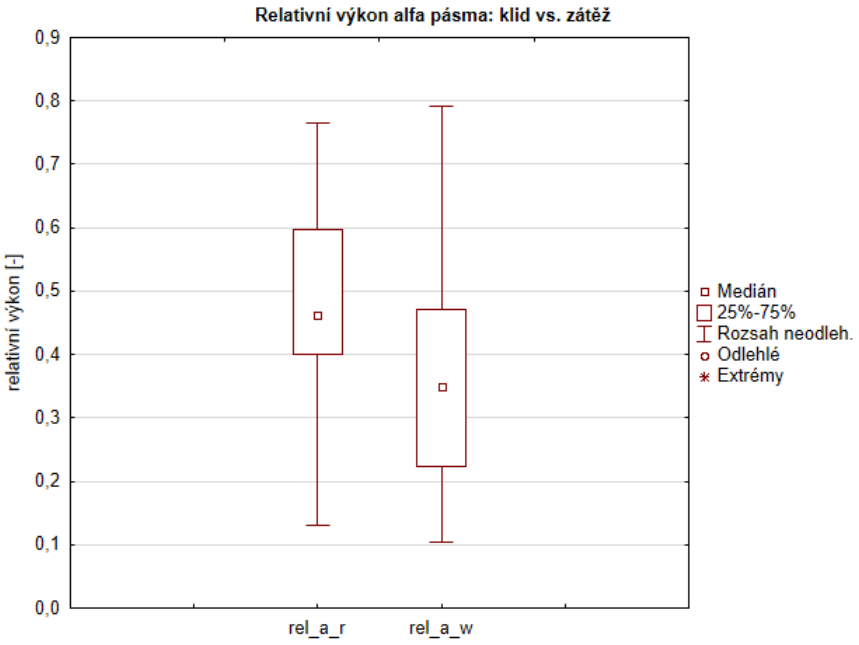

Obr. 6.27: Rozložení hodnot relativních výkonů alfa pásma záznamů z O1.

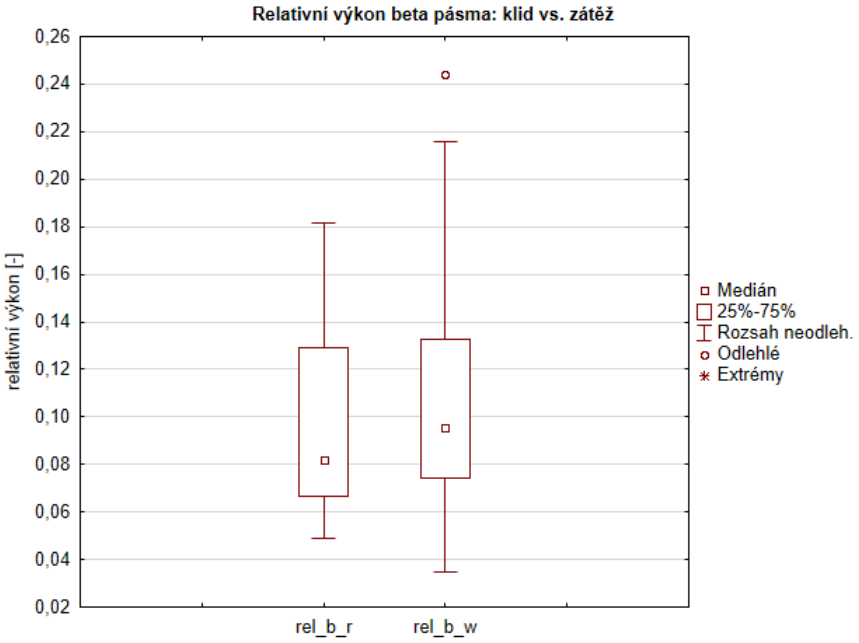

Obr. 6.28: Rozložení hodnot relativních výkonů beta pásma záznamů z O1.

6.5 Modifikace původní analýzy

6.5.1 Analýza energeticky výrazné oblasti spektrogramu

V rámci vizuální kontroly spektrogramů byla ve frekvenčním alfa pásmu, které je pro analýzu mentální zátěže důležité, objevena zajímavá oblast mezi 10–12 Hz, která se mezi klidovým a zátěžovým záznamem viditelně liší u většiny subjektů. Cílem této analýzy bylo nalézt parametr, který by měl lepší schopnost signály odlišit, zvláště u záznamů, které statisticky významné rozdíly spíše nevykazovaly (např. záznamy z elektrody Fp1 viz podkapitola 6.1). Toto subpásmo bylo analyzováno ze záznamů pocházejících z již zmíněné elektrody Fp1 a dále z P4, která v rámci základní analýzy podávala nejlepší výsledky. Ukázku spektrogramů je možno vidět na obrázku 6.29 (při výpočtu bylo využito okno délky $n = 1024$ vzorků). Jako parametr slouží průměrný výkon pásma. Statistická analýza znaménkovým párovým testem prokázala statisticky významné rozdíly mezi klidovými a zátěžovými parametry na hladině významnosti $\alpha = 0.05$ s p-hodnotou $p = 0.030260$ pro záznamy z Fp1 a s p-hodnotou $p = 0.000126$ pro záznamy z P4. P-hodnota zúženého pásma je nižší, než p-hodnota celého alfa pásma u záznamů z Fp1. U elektrody P4 se p-hodnota zvýšila, avšak nikoli výrazně.

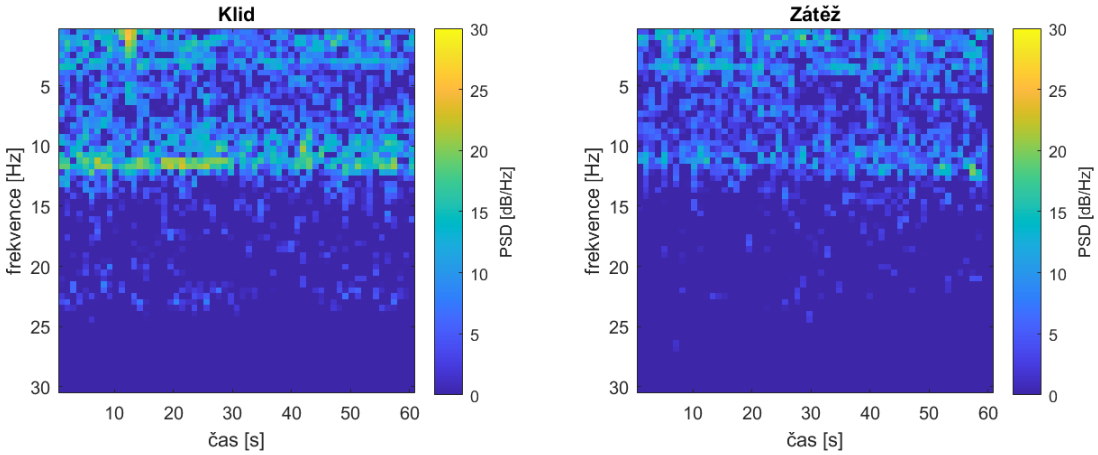

Obr. 6.29: Ukázka spektrogramů klidového (vlevo) a zátěžového (vpravo) záznamu z elektrody P4 od subjektu 33.

6.5.2 Analýza signálů s aditivním šumem

Cílem analýzy zašuměných signálů bylo ověřit robustnost implementované metody vůči šumu. Generátor šumu byl realizován funkcí *wgn* z knihovny Communications od společnosti MathWorks, která generuje vzorky bílého gaussovského šumu. Filtrací

pásmovými propustmi takto vzniklého signálu byly ponechány jen složky o frekvencích v intervalu 1–3 Hz a 20–60 Hz. První interval frekvencí má simulovat frekvence EOG záznamu a druhý interval frekvence EMG záznamu. Tento postup byl realizován na základě článku [46]. Vygenerovaný šum byl přičten ke vzorkům zátěžového signálu vždy po cca 10 sekundách s trváním 0.5 sekundy, což dokumentuje obrázek 6.30.

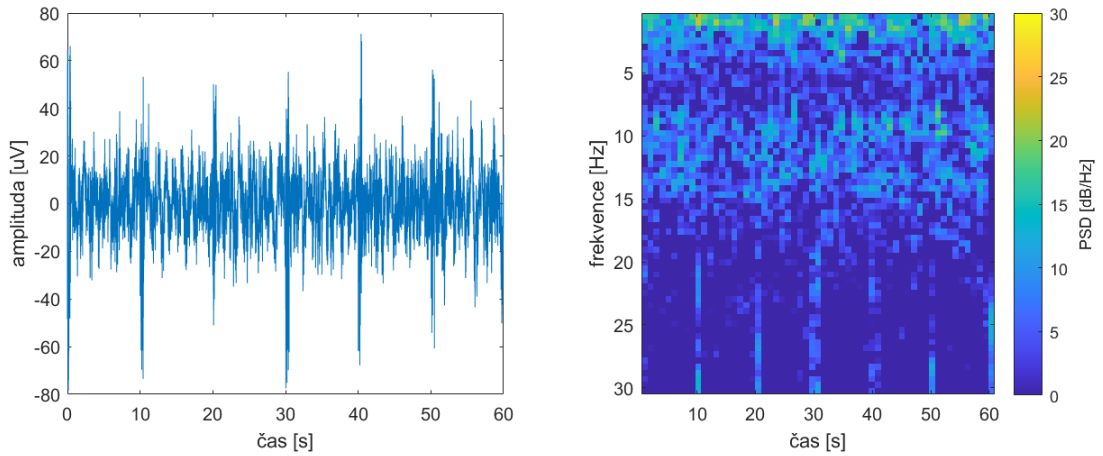

Obr. 6.30: Ukázka časového průběhu záznamu (vlevo) a spektrogramu (vpravo) záznamu z elektrody P4 od subjektu 2 s aditivním šumem.

Idea za tímto postupem je taková, že při relaxovaném stavu, kdy je subjekt uvolněný, nehýbe se, má zavřené oči a nemrká, je vliv EOG a EMG artefaktů minimální. V rámci zátěžového stavu může subjekt však očima pohybovat např. při čtení příkladů. EMG artefakty za této podmínky mohou vzniknout např. svraštěním čela při přemýšlení nebo pohybem prstu při klikání na tlačítko odpovědi na příklad.

Šum byl přidán do zátěžových záznamů z elektrody P4. Analýza probíhala s nastavením časového okna STFT $n = 1024$ vzorků. Výsledky statistické analýzy jsou uvedeny v tabulce 6.5. Mediány průměrných výkonů jsou uvedeny v μV^2. Kompletní výsledky jsou uvedeny v tabulce v souboru *p4+šum_vysledky.xlsx*. Je možné pozorovat změnu mediánů hodnot parametrů u zátěžových záznamů zejména pro pásma delta a beta, která byla ovlivněna přítomností EOG a EMG simulovaných artefaktů. Přidáním těchto artefaktů jen do zátěžového signálu se ještě více zvýraznily rozdíly mezi parametry, což se odráží i na nízkých p-hodnotách znaménkového párového testu. Rozdíly všech parametrů až na výjimku relativního výkonu delta pásma prokazují statisticky významné rozdíly. Pro zvýraznění jsou označeny tučným písmem. V tomto konkrétním případě artefakty přispěly k lepším výsledkům analýzy. Vždy ale závisí na pásmu zájmu a na druhu šumu. Pokud by byl do signálu přidán šum s dominantními frekvencemi např. v alfa pásmu, pak by teoreticky statistický test

Tab. 6.5: Statistická analýza záznamů z elektrody P4 s aditivním šumem.

Parametr	Podmínka	Medián	P-hodnota n = 1024
Průměr. výkon delta	klid	52.19	**0.03026**
Průměr. výkon delta	zátěž	46.44	
Průměr. výkon alfa	klid	53.28	**0.00003**
Průměr. výkon alfa	zátěž	27.01	
Průměr. výkon beta	klid	13.29	**0.00003**
Průměr. výkon beta	zátěž	15.79	
Poměr beta/alfa	klid	0.22	**0.00000**
Poměr beta/alfa	zátěž	0.58	
Relativ. výkon delta	klid	0.41	0.61708
Relativ. výkon delta	zátěž	0.40	
Relativ. výkon alfa	klid	0.41	**0.00001**
Relativ. výkon alfa	zátěž	0.24	
Relativ. výkon beta	klid	0.08	**0.00001**
Relativ. výkon beta	zátěž	0.12	

nedokázal parametry rozlišit, v krajním případě by bylo možné sledovat opačný trend tj. vzrůst výkonu alfa pásma při zátěži.

7 Diskuze výsledků

Statistická analýza byla provedena celkem pro tři nastavení experimentu. Změna nastavení spočívala v různých délkách časového okna, které se posouvá po signálu v rámci STFT. Jako nejlepší se projevila délka okna $n = 1024$ vzorků (2.048 s), se kterou bylo prokázáno nejvíce statisticky významných výsledků. Zároveň toto nejkratší okno nejlépe splňuje předpoklad stacionarity úseků záznamu. Dále byly zkoumány parametry získané analýzou s použitým oknem $n = 2048$ a $n = 4096$ vzorků (4.096 s a 8.192 s). Obdobně dosahuje i studie [34] nejlepších výsledků s použitím kratšího okna. Zvýšení frekvenčního rozlišení způsobené použitím delšího okna nepřineslo zlepšení výsledků.

Z hlediska zkoumaných parametrů se jako nejoptimálnější projevily parametry poměr výkonů beta a alfa pásma a relativního výkonu alfa, popřípadě i delta, pásma. Tyto parametry dosahují nejmenších p-hodnot, což značí nejmenší podporu nulové hypotézy (nejméně podporují tvrzení, že se parametry neliší). Velmi nízké p-hodnoty vyhodnotil znaménkový test i u průměrného výkonu alfa pásma na záznamech elektrod P4 a O1 z parientální a okcipitální oblasti mozku. Výkon alfa pásma se projevuje podle teoretických předpokladů, tzn. v zátěžových záznamech je možné pozorovat jeho pokles oproti klidovému stavu. Z těchto předpokladů vychází i studie [34]. Především z tohoto důvodu se chová podle předpokladů i poměr výkonů beta a alfa pásma i přesto, že výkon v beta pásmu nevykazuje statisticky významné rozdíly ve většině případů. Zvýšit výkon beta pásma v rámci zátěžových záznamů by bylo teoreticky možné aplikací časového limitu pro výpočet jednotlivých příkladů, tak jako to realizují např. v [35]. Časový limit by mohl subjekt více motivovat a přimět ho se více soustředit na výpočty. Studie [38] na základě experimentů uvádí schopnost pozorovat největší změny v rámci delta pásma. S tímto závěrem jsou však prezentované výsledky průměrného výkonu v delta pásmu v rozporu, protože jedině analýzou záznamů z elektrody P4 byly určeny rozdíly jako statisticky významné. U průměrného výkonu delta pásma je pozorována rostoucí tendence se zátěží v záznamech z elektrod Fp1 a F8, což je v souladu s předpoklady na základě [7], kde autoři uvádí, že při zátěži aktivita v delta pásmu roste. Relativní výkon tohoto pásma statisticky významné rozdíly prokazuje.

Nejvíce statisticky významných rozdílů mezi parametry bylo získáno analýzou záznamů z elektrody P4, která se nachází v pravé části parientální oblasti mozku. Jedná se o oblast, kterou literatura [43] označuje jako významnou pro hodnocení mentální zátěže spolu s frontální oblastí. Nejlepších výsledků klasifikace, nikoliv diferenciace, dosáhly studie analýzou záznamů z prefrontálních a frontálních elektrod Fp1 [33], Fp2 [35] a F8 [21].

Analýza energeticky významného pásma frekvencí ze spektrogramu poskytla

další důležitý parametr, který pro tento konkrétní dataset vykazuje statisticky významné rozdíly.

Tím, že metoda výsledné parametry průměruje z dílčích výkonů v jednotlivých segmentech, měla by být poměrně robustní vůči šumu, který se pouze náhodně objeví. Simulace EOG a EMG artefaktů ovlivnila hodnoty parametrů pozitivně, neboť rozdíly vyšly statisticky významně rozdílné s nízkými p-hodnotami na hladině významnosti $\alpha = 0.05$, a to zejména díky metodice simulování. Poukazuje to tak na komplikovanou interpretaci těchto výsledků. Nárůst průměrného výkonu v beta pásmu není způsoben zvýšenou mozkovou beta aktivitou, ale přítomným šumem způsobeným simulovaným EMG.

Porovnání dosažených výsledků s výsledky studií jiných autorů z teoretické rešerše je poměrně komplikované, protože publikované studie uvádí většinou až úspěšnost provedené klasifikace záznamů do skupin pomocí nástrojů umělé inteligence. Studie [35] nicméně uvádí rozdíly parametrů alfa pásma mezi kontrolní (počítání bez časového limitu) a stresovou (počítání s časovým limitem) podmínkou pro tři úrovně stresu s p-hodnotami $p = 0.03$, $p = 0.042$ a $p = 0.05$. To však stále neodpovídá stavům klidu a zátěže, se kterými se pracuje v rámci této práce.

Závěr

V teoretické části této bakalářské práce byly stručně shrnuty základy EEG a vlastnosti jednotlivých frekvenčních pásem, do kterých lze spektrum EEG záznamu rozdělit. Byly popsány vybrané analytické metody, pomocí nichž lze provést komparaci (diferenciaci) záznamů ze dvou skupin dat.

V rámci praktické části práce byl proveden výběr optimální metody, která byla získána porovnáním popisovaných metod. V porovnání byly zohledněny vlastnosti metod i jejich výsledky ve vybraných studiích. Zvolena byla metoda STFT s výkonovými parametry, která byla implementována v softwaru MATLAB za pomoci dostupných funkcí. Pro uživatelský komfort bylo vytvořeno grafické uživatelské rozhraní, které umožňuje vizuální srovnání. Cílem praktické části bylo ověřit schopnost vybrané metody odlišit signály ze dvou skupin. Pro toto ověření byly vybrány signály z veřejně dostupné internetové databáze zachycující signály EEG v relaxovaném, klidovém stavu a ve stavu mentální zátěže při počítání aritmetických příkladů.

Parametry byly vyhodnoceny statistickou analýzou. Konkrétně bylo využito neparametrického znaménkového párového testu. Nejlepších výsledků dosáhly parametry poměr výkonů v beta a alfa pásmu, relativní i průměrný výkon alfa pásma a relativní výkon delta pásma. Přesto, že je beta aktivita klíčová pro hodnocení mentální zátěže, výkony beta pásma většinou nevykazovaly statisticky významné rozdíly. Nejvíce statisticky významných rozdílů mezi parametry bylo stanoveno analýzou elektrody P4 a využitím časového okna STFT $n = 1024$ vzorků, které odpovídá 2 s. Dále byla provedena analýza energeticky výrazného pásma ve spektrogramech, která přinesla další významný parametr pro tento konkrétní dataset a byly simulovány EOG a EMG artefakty, které zde demonstrují obtížnost interpretace výsledků analýzy.

V návaznosti na tuto práci by bylo možné provést klasifikaci záznamů do dvou skupin na základě výše zmíněných parametrů, které vykazují dobrou schopnost záznamy klidové a zátěžové rozlišit.

Literatura

[1] TONG, Shanbao a Nitish Vyomesh THAKOR. *Quantitative EEG analysis methods and clinical applications*. Boston: Artech House, c2009. Artech House engineering in medicine & biology series. ISBN 978-1-59693-204-3

[2] SIULY, Siuly, Yan LI a Yanchun ZHANG. *EEG Signal Analysis and Classification* [online]. Cham: Springer International Publishing, 2016 [cit. 2020-11-19]. Health Information Science. ISBN 978-3-319-47652-0. Dostupné z: doi:10.1007/978-3-319-47653-7

[3] VOJTĚCH, Zdeněk. *EEG v epileptologii dospělých*. Praha: Grada, 2005. ISBN 80-247-0690-3

[4] Electrode locations of International 10-20 system for EEG (electroencephalography) recording. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001- [cit. 2020-11-19]. Dostupné z: <`https://en.wikipedia.org/wiki/10%E2%80%9320_system_(EEG)#/media/File:21_electrodes_of_International_10-20_system_for_EEG.svg/`>

[5] TEPLAN, M. FUNDAMENTALS OF EEG MEASUREMENT. *MEASUREMENT SCIENCE REVIEW* [online]. 2002, **2**(2) [cit. 2020-11-16]. Dostupné z: <`http://www.edumed.org.br/cursos/neurociencia/MethodsEEGMeasurement.pdf/`>

[6] JACKSON, Alice F. a Donald J. BOLGER. The neurophysiological bases of EEG and EEG measurement: A review for the rest of us. *Psychophysiology* [online]. 2014, **51**(11), 1061-1071 [cit. 2020-11-21]. ISSN 00485772. Dostupné z: doi:10.1111/psyp.12283

[7] CAMPISI, Patrizio a Daria LA ROCCA. Brain waves for automatic biometric-based user recognition. *IEEE Transactions on Information Forensics and Security* [online]. 2014, **9**(5), 782-800 [cit. 2020-11-16]. ISSN 1556-6013. Dostupné z: doi:10.1109/TIFS.2014.2308640

[8] CAMPBELL, Ian G. EEG Recording and Analysis for Sleep Research. *Current Protocols in Neuroscience* [online]. 2009, **49**(1), 10.2.1-10.2.19 [cit. 2020-10-28]. ISSN 19348584. Dostupné z: doi:10.1002/0471142301.ns1002s49

[9] JAN, Jiří. *Číslicové zpracování a analýza signálů: stručné skriptum*. Brno: Vysoké učení technické v Brně, 2010. ISBN 978-80-214-4018-0

[10] UNDE, Sukhada A. a Revati SHRIRAM. Coherence Analysis of EEG Signal Using Power Spectral Density. In: *2014 Fourth International Conference on Communication Systems and Network Technologies* [online]. IEEE, 2014, 2014, s. 871-874 [cit. 2020-10-28]. ISBN 978-1-4799-3070-8. Dostupné z: doi:10.1109/CSNT.2014.181

[11] JAN, Jiří. *Číslicová filtrace, analýza a restaurace signálů*. 2. upr. a rozš. vyd. Brno: VUTIUM, 2002. ISBN 80-214-1558-4

[12] BORADE, Rupali a Damayanti GHARPURE. FPGA Implementation of Nonparametric Power Spectrum Estimation Methods. In: *2018 International Conference on Computational Techniques, Electronics and Mechanical Systems (CTEMS)* [online]. IEEE, 2018, 2018, s. 30-35 [cit. 2020-10-28]. ISBN 978-1-5386-7709-4. Dostupné z: doi:10.1109/CTEMS.2018.8769222

[13] VALLAT, Raphael. *Compute the average bandpower of an EEG signal* [online]. 2018 [cit. 2020-12-07]. Dostupné z: <`https://raphaelvallat.com/bandpower.html`>

[14] THAKOR, Nitish V. a Shanbao TONG. Advances in Quantitative Electroencephalogram Analysis Methods. *Annual Review of Biomedical Engineering* [online]. 2004, **6**(1), 453-495 [cit. 2020-10-28]. ISSN 1523-9829. Dostupné z: doi:10.1146/annurev.bioeng.5.040202.121601

[15] FAUST, O., R.U. ACHARYA, A.R. ALLEN a C.M. LIN. Analysis of EEG signals during epileptic and alcoholic states using AR modeling techniques. *IRBM* [online]. 2008, **29**(1), 44-52 [cit. 2020-10-28]. ISSN 19590318. Dostupné z: doi:10.1016/j.rbmret.2007.11.003

[16] AL-FAHOUM, Amjed S. a Ausilah A. AL-FRAIHAT. Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains. *ISRN Neuroscience* [online]. 2014, **2014**, 1-7 [cit. 2020-10-28]. ISSN 2314-4661. Dostupné z: doi:10.1155/2014/730218

[17] KHOSLA, Ashima, Padmavati KHANDNOR a Trilok CHAND. A comparative analysis of signal processing and classification methods for different applications based on EEG signals. *Biocybernetics and Biomedical Engineering* [online]. 2020, **40**(2), 649-690 [cit. 2020-11-21]. ISSN 02085216. Dostupné z: doi:10.1016/j.bbe.2020.02.002

[18] SUBHA, D. Puthankattil, Paul K. JOSEPH, Rajendra ACHARYA U a Choo Min LIM. EEG Signal Analysis: A Survey. *Journal of Medical Systems* [online]. 2010, **34**(2), 195-212 [cit. 2020-10-28]. ISSN 0148-5598. Dostupné z: doi:10.1007/s10916-008-9231-z

[19] GUO, Meishan a Zhong WU. Noise Reduction for High-Accuracy Automatic Calibration of Resolver Signals via DWT-SVD Based Filter. *Electronics* [online]. 2019, **8**(5) [cit. 2020-12-31]. ISSN 2079-9292. Dostupné z: doi:10.3390/electronics8050516

[20] ILYAS, Mohd Zaizu, Puteh SAAD a Muhammad Imran AHMAD. A survey of analysis and classification of EEG signals for brain-computer interfaces. In: *2015 2nd International Conference on Biomedical Engineering (ICoBE)* [online]. IEEE, 2015, 2015, s. 1-6 [cit. 2020-11-21]. ISBN 978-1-4799-1749-5. Dostupné z: doi:10.1109/ICoBE.2015.7235129

[21] WANG, Qiang a Olga SOURINA. Real-Time Mental Arithmetic Task Recognition From EEG Signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* [online]. 2013, **21**(2), 225-232 [cit. 2020-12-10]. ISSN 1534-4320. Dostupné z: doi:10.1109/TNSRE.2012.2236576

[22] ZARJAM, P., J. EPPS, N. H. LOVELL a FANG CHEN. Characterization of memory load in an arithmetic task using non-linear analysis of EEG signals. *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* [online]. IEEE, 2012, 2012, , 3519-3522 [cit. 2021-5-23]. ISBN 978-1-4577-1787-1. Dostupné z: doi:10.1109/EMBC.2012.6346725

[23] DELGADO-BONAL, Alfonso a Alexander MARSHAK. Approximate Entropy and Sample Entropy: A Comprehensive Tutorial. *Entropy* [online]. 2019, **21**(6) [cit. 2020-10-29]. ISSN 1099-4300. Dostupné z: doi:10.3390/e21060541

[24] PINCUS, S. M. a A. L. GOLDBERGER. Physiological time-series analysis: what does regularity quantify? *American Journal of Physiology-Heart and Circulatory Physiology* [online]. 1994, **266**(4), H1643-H1656 [cit. 2020-10-29]. ISSN 0363-6135. Dostupné z: doi:10.1152/ajpheart.1994.266.4.H1643

[25] MESIN, Luca. Estimation of Complexity of Sampled Biomedical Continuous Time Signals Using Approximate Entropy. *Frontiers in Physiology* [online]. 2018, **9** [cit. 2020-11-16]. ISSN 1664-042X. Dostupné z: doi:10.3389/fphys.2018.00710

[26] ANIER, A., T. LIPPING, R. FERENETS, P. PUUMALA, E. SONKAJÄRVI, I. RÄTSEP a V. JÄNTTI. Relationship between approximate entropy and visual

inspection of irregularity in the EEG signal, a comparison with spectral entropy. *British Journal of Anaesthesia* [online]. 2012, **109**(6), 928-934 [cit. 2020-12-29]. ISSN 00070912. Dostupné z: doi:10.1093/bja/aes312

[27] ZHANG, Aihua, Bin YANG a Ling HUANG. Feature Extraction of EEG Signals Using Power Spectral Entropy. In: *2008 International Conference on BioMedical Engineering and Informatics* [online]. IEEE, 2008, 2008, s. 435-439 [cit. 2020-12-29]. ISBN 978-0-7695-3118-2. Dostupné z: doi:10.1109/BMEI.2008.254

[28] TIAN, Yin, Huiling ZHANG, Wei XU, Haiyong ZHANG, Li YANG, Shuxing ZHENG a Yupan SHI. Spectral Entropy Can Predict Changes of Working Memory Performance Reduced by Short-Time Training in the Delayed-Match-to-Sample Task. *Frontiers in Human Neuroscience* [online]. 2017, **11** [cit. 2020-12-29]. ISSN 1662-5161. Dostupné z: doi:10.3389/fnhum.2017.00437

[29] ZARJAM, P., J. EPPS a FANG CHEN. Spectral EEG features for evaluating cognitive load. In: *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* [online]. IEEE, 2011, 2011, s. 3841-3844 [cit. 2020-12-29]. ISBN 978-1-4577-1589-1. Dostupné z: doi:10.1109/IEMBS.2011.6090954

[30] AL-NUAIMI, Ali H., Emmanuel JAMMEH, Lingfen SUN a Emmanuel IFEACHOR. Higuchi fractal dimension of the electroencephalogram as a biomarker for early detection of Alzheimer's disease. In: *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* [online]. IEEE, 2017, 2017, s. 2320-2324 [cit. 2020-12-29]. ISBN 978-1-5090-2809-2. Dostupné z: doi:10.1109/EMBC.2017.8037320

[31] KESIĆ, Srdjan a Sladjana Z. SPASIĆ. Application of Higuchi's fractal dimension from basic to clinical neurophysiology: A review. *Computer Methods and Programs in Biomedicine* [online]. 2016, **133**, 55-70 [cit. 2020-12-29]. ISSN 01692607. Dostupné z: doi:10.1016/j.cmpb.2016.05.014

[32] VIJITH, V. S., Jisu Elsa JACOB, Thomas IYPE, K GOPAKUMAR a Doris George YOHANNAN. Epileptic seizure detection using non linear analysis of EEG. In: *2016 International Conference on Inventive Computation Technologies (ICICT)* [online]. IEEE, 2016, 2016, s. 1-6 [cit. 2020-11-19]. ISBN 978-1-5090-1285-5. Dostupné z: doi:10.1109/INVENTIVE.2016.7830193

[33] PRIYA, Taruv Harshita, P. MAHALAKSHMI, VPS NAIDU a M. SRINIVAS. Stress detection from EEG using power ratio. In: *2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE)*

[online]. IEEE, 2020, 2020, s. 1-6 [cit. 2020-11-25]. ISBN 978-1-7281-4142-8. Dostupné z: doi:10.1109/ic-ETITE47903.2020.401

[34] JUN, Guo a K. G. SMITHA. EEG based stress level identification. In: *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* [online]. IEEE, 2016, 2016, s. 003270-003274 [cit. 2020-11-25]. ISBN 978-1-5090-1897-0. Dostupné z: doi:10.1109/SMC.2016.7844738

[35] AL-SHARGIE, F. M., T. B. TANG, N. BADRUDDIN a M. KIGUCHI. Mental Stress Quantification Using EEG Signals. IBRAHIM, Fatimah, Juliana USMAN, Mas Sahidayana MOHKTAR a Mohd Yazed AHMAD, ed. *International Conference for Innovation in Biomedical Engineering and Life Sciences* [online]. Singapore: Springer Singapore, 2016, 2016-12-18, s. 15-19 [cit. 2020-11-25]. IFMBE Proceedings. ISBN 978-981-10-0265-6. Dostupné z: doi:10.1007/978-981-10-0266-3_4

[36] SAIDATUL, A., M.P. PAULRAJ, Sazali YAACOB a M.A. YUSNITA. Analysis of EEG signals during relaxation and mental stress condition using AR modeling techniques. In: *2011 IEEE International Conference on Control System, Computing and Engineering* [online]. IEEE, 2011, 2011, s. 477-481 [cit. 2020-11-26]. ISBN 978-1-4577-1642-3. Dostupné z: doi:10.1109/ICCSCE.2011.6190573

[37] PRÁŠEK, Petr. *Úvod do číslicového zpracování signálů - UCZ* [online]. Praha, 2001 [cit. 2021-01-02]. Dostupné z: <`http://noel.feld.cvut.cz/vyu/ucz/cv3/`>

[38] ZARJAM, Pega, Julien EPPS a Nigel H. LOVELL. Characterizing mental load in an arithmetic task using entropy-based features. In: *2012 11th International Conference on Information Science, Signal Processing and their Applications (ISSPA)* [online]. IEEE, 2012, 2012, s. 199-204 [cit. 2020-11-27]. ISBN 978-1-4673-0382-8. Dostupné z: doi:10.1109/ISSPA.2012.6310545

[39] TŮMA, Jiří. *FREQUENCY SPECTRUM ESTIMATION BY AUTOREGRESSIVE MODELING* [online]. VŠB - Technická univerzita Ostrava, 2015 [cit. 2020-12-07]. Dostupné z: <`http://homel.vsb.cz/~tum52/publications/Tuma-322-PT.pdf`>

[40] MÜLLER, Wolfram, Alexander JUNG a Helmut AHAMMER. Advantages and problems of nonlinear methods applied to analyze physiological time signals: human balance control as an example. *Scientific Reports* [online]. 2017, **7**(1) [cit. 2020-12-07]. ISSN 2045-2322. Dostupné z: doi:10.1038/s41598-017-02665-5

[41] Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R. & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. Circulation [Online]. 101 (23), pp. e215–e220, [cit. 2021-01-04]. Dostupné z: <https://physionet.org/content/eegmat/1.0.0/>

[42] ZYMA, Igor, Sergii TUKAEV, Ivan SELEZNOV, Ken KIYONO, Anton POPOV, Mariia CHERNYKH a Oleksii SHPENKOV. Electroencephalograms during Mental Arithmetic Task Performance. *Data* [online]. 2019, **4**(1) [cit. 2021-01-04]. ISSN 2306-5729. Dostupné z: doi:10.3390/data4010014

[43] RUECKERT, Linda, Nicholas LANGE, Arnaud PARTIOT, Ildebrando APPOLLONIO, Irene LITVAN, Denis LE BIHAN a Jordan GRAFMAN. Visualizing Cortical Activation during Mental Calculation with Functional MRI. *NeuroImage* [online]. 1996, **3**(2), 97-103 [cit. 2020-12-11]. ISSN 10538119. Dostupné z: doi:10.1006/nimg.1996.0011

[44] Brett Shoelson (2021). edfRead, MATLAB Central File Exchange. Retrieved January 3, 2021 [cit. 2020-11-15]. Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/31900-edfread>

[45] PAVLÍK, Tomáš a Ladislav DUŠEK. *Biostatistika* [online]. Brno: Akademické nakladatelství CERM, s.r.o Brno, 2012 [cit. 2021-5-10]. ISBN 978-80-7204-782-6. Dostupné z: https://portal.med.muni.cz/clanek-590-biostatistika.html

[46] ZENG, Ke, Dan CHEN, Gaoxiang OUYANG, Lizhe WANG, Xianzeng LIU a Xiaoli LI. An EEMD-ICA Approach to Enhancing Artifact Rejection for Noisy Multivariate Neural Data. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* [online]. 2016, **24**(6), 630-638 [cit. 2021-5-24]. ISSN 1534-4320. Dostupné z: doi:10.1109/TNSRE.2015.2496334

Seznam symbolů, veličin a zkratek

ADHD Attention Deficit Hyperactivity Disorder

AIC Akaike information criterion

ApEn Aproximativní entropie

AR Autoregresní model

ARMA Autoregresní model s klouzavým průměrem

BCI Brain-computer Interface

DFT Diskrétní Fourierova transformace

ECoG Elektrokortikografie

EEG Elektroencefalografie

EMG Elektromyografie

EOG Elektrookulografie

EPSP Excitační post-synaptický potenciál

FIR Filtr s konečnou impulzní charakteristikou

FFT Fast Fourier Transform

FT Fourierova transformace

HFD Higuchiho fraktální dimenze

ICA Independent Component Analysis

IPSP Inhibiční post-synaptický potenciál

KNN K-nearest neighbors

PCA Principal Component Analysis

PSD Výkonová spektrální hustota (ang. Power Spectral Density)

SD Směrodatná odchylka

SNR Poměr signálu k šumu

SpEn Spektrální entropie

STFT	Short-time Fourier Transform
SVM	Support Vector Machines
WT	Wavelet Transform

A Obsah přiloženého archivu

V přiloženém komprimovaném archivu je textový soubor popisující obsah příloh. Dále je v archivu uložen textový soubor s odkazem, přes který je možné stáhnout použité EEG záznamy a zároveň odkaz pro stažení funkce edfread.m, která je využita pro načítání souborů. Pro jednotlivé elektrody jsou uvedeny kompletní výsledky v .xlsx souborech. Tabulky hodnot parametrů jsou získány spuštěním souboru main.m. Spuštěním programu gui.m se spustí grafické uživatelské rozhraní.

```
/ ..................................... kořenový adresář přiloženého zip souboru
├── Odkazy.txt ..................................... odkazy ke stažení
├── readme.txt ..................................... popis obsahu příloh
├── Tabulky ........................................ kompletní tabulky výsledků
│   ├── f8_vysledky.xlsx
│   ├── fp1_vysledky.xlsx
│   ├── o1_vysledky.xlsx
│   ├── p4_vysledky.xlsx
│   └── p4+šum_vysledky.xlsx
└── Zdrojové kódy
    ├── main.m
    ├── gui.m
    └── gui.fig
```