

Analýza bio-signálů

Bio-signal Analysis

Zadání diplomové práce

Student: **Bc. Martin Barteček**
Studijní program: N2647 Informační a komunikační technologie
Studijní obor: 2612T025 Informatika a výpočetní technika
Téma: **Analýza bio-signálů**
Bio-signal Analysis

Zásady pro vypracování:

Cílem práce je implementovat aplikaci pro analýzy bio-signálů s využitím GPU. Bude využito zařízení EMOTIV EPOC Headset. Zvolenou technologií je Microsoft .NET a jazyk C++.

1. Seznámení se s problematikou snímání a vizualizace EEG signálů. Přehled existujících technologií s ohledem na další použitelnost zařízení a software v nemedicínských aplikacích.
2. Návrh a implementace aplikace s požadovanou funkcionalitou.
3. Výkonnostní testy a experimenty s reálnými daty, uživateli.
4. Vyhodnocení experimentů a dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] Saeid Sanei, J. A. Chambers: EEG Signal Processing, Wiley-Interscience; 1 edition (September 11, 2007), ISBN-13: 978-0470025819
[2] Jason Standers, Edward Kandrot: CUDA by Example: An Introduction to General-Purpose GPU Programming, ISBN-10: 0131387685, 2010

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Petr Gajdoš, Ph.D.**

Datum zadání: 01.09.2014

Datum odevzdání: 07.05.2015



doc. Dr. Ing. Eduard Sojka
vedoucí katedry



prof. RNDr. Václav Snášel, CSc.
děkan fakulty

Souhlasím se zveřejněním této diplomové práce dle požadavků čl. 26, odst. 9 *Studijního a zkušebního řádu pro studium v magisterských programech VŠB-TU Ostrava*.

V Ostravě 7. května 2015


.....

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

V Ostravě 7. května 2015


.....

Rád bych na tomto místě poděkoval Bc. Jakubu Rodzenákovi za spolupráci na společné části diplomové práce a Ing. Petru Gajdošovi Ph.D za výborné vedení.

Abstrakt

Cílem této práce bylo vytvoření knihovny pro správu headsetu EPOC vyvíjeného společností Emotiv za účelem použití v demo aplikaci pro vizualizaci mozkových informací zachycených headsetem. Knihovna byla vytvořena ke sběru a analýze dat z headsetu a předání příslušných informací do aplikace pro vizualizaci vytvořené kolegou Bc. Jakubem Rodzenákem, se kterým jsem na této práci spolupracoval. Úkolem bylo zkoumat možnosti využití headsetu EPOC nad rámec originálních aplikací vytvořených společností Emotiv. Součástí práce bylo provedení experimentů a testů vyhodnocujících schopnosti headsetu.

Klíčová slova: CUDA, EEG, Emotiv, EPOC, GPU, Kosinová míra, NVIDIA, Rychlá Fourierova transformace

Abstract

The goal of this thesis was to create a library for management of Emotiv EPOC headset for use in demo application for visualization of brain information captured by the headset. The library was created to capture and analyze data from the headset and passing output information to application for visualization made by my colleague Bc. Jakub Rodzenák, who I worked with on this thesis. The main task of this thesis was to examine possibilities of the headset outside of original applications provided by Emotiv company. Last component of this thesis is a set of tests and experiments performed to determine the headset's capabilities.

Keywords: CUDA, EEG, Emotiv, EPOC, Fast Fourier transform, GPU, Cosine measure, NVIDIA

Seznam použitých zkratk a symbolů

BCI	– Brain-computer Interface
CUDA	– Compute Unified Device Architecture
EEG	– Elektroencefalogram
FN	– False Negative
FP	– False Positive
GPU	– Graphics Processing Unit
OpenGL	– Open Graphics Library
SDK	– Software Development Kit
SPC	– Specificity
TN	– True Negative
TP	– True Positive
TPR	– True Positive Rate
ACC	– Accuracy
USB	– Universal Serial Bus

Obsah

1	Úvod	5
2	EEG signál	7
2.1	Záznam	7
2.2	Využití	13
3	BCI	14
3.1	BCI systémy Emotiv	15
3.2	Konkurenční řešení	18
4	Praktická část	20
4.1	Použité technologie	20
4.2	Implementace	21
5	Testování	36
5.1	Deformace EEG signálu	36
5.2	Rozpoznání	39
5.3	Vyhodnocení	45
6	Závěr	47
7	Reference	48
	Přílohy	49
A	Příloha na CD	50

Seznam tabulek

1	Parametry zařízení Emotiv EPOC	17
2	Parametry hlavního počítače	21
3	Parametry dalšího testovacího počítače	21
4	Výsledky klasifikace testovací sady pro zdvih paže pomocí kosinové míry	42
5	Výsledky klasifikace testovací sady pro zdvih paže pomocí neuronové sítě	42
6	Výsledky klasifikace testovací sady pro ohyb paže pomocí kosinové míry	43
7	Výsledky klasifikace testovací sady pro ohyb paže pomocí neuronové sítě	43
8	Výsledky klasifikace testovací sady pro sevření pěsti pomocí kosinové míry	43
9	Výsledky klasifikace testovací sady pro sevření pěsti pomocí neuronové sítě	43
10	Výsledky klasifikace testovací sady pro náklon hlavy pomocí kosinové míry	44
11	Výsledky klasifikace testovací sady pro náklon hlavy pomocí neuronové sítě	44
12	Výsledky klasifikace testovací sady pro rotaci hlavy pomocí kosinové míry	44
13	Výsledky klasifikace testovací sady pro rotaci hlavy pomocí neuronové sítě	44

Seznam obrázků

1	První záznam EEG signálu lidského mozku	8
2	Alpha vlny EEG signálu	8
3	Beta vlny EEG signálu	8
4	Gamma vlny EEG signálu	8
5	Theta vlny EEG signálu	8
6	Delta vlny EEG signálu	9
7	Systém 10/20	11
8	Schéma diferenčního zesilovače	12
9	EEG signál při záchvatu	13
10	Ukázka experimentu s opicemi druhu makak	15
11	Zařízení Emotiv EPOC	16
12	Zařízení Emotiv Insight	16
13	Zařízení NeuroSky®MindWave™	19
14	BCI zařízení firmy Cognionics	19
15	Struktura ulžení dat ve třídě Action	23
16	Architektura knihovny	24
17	První skupina ovládacích prvků	32
18	Kvalita signálu jednotlivých elektrod	33
19	Druhá skupina ovládacích prvků	34
20	Zobrazení uložených vzorků	35
21	Klidový stav na jednom z kanálů	37
22	Zdvih paže	38
23	Ohyb paže v lokti	38
24	Sevření pěsti	39
25	Náklon hlavy na levou stranu	40
26	Návrat hlavy do původní polohy	40
27	Rotace hlavy	41

Seznam výpisů zdrojového kódu

1	Přístupové metody třídy EEG_IO_INTERFACE	26
2	Funkce pro výpočty spektrální analýzy.	28
3	Klasifikace pomocí kosinové míry.	29
4	Klasifikace pomocí neuronové sítě.	31

1 Úvod

V dnešní době se výzkumníci na celé planetě snaží přivést na svět technologie a možnosti, které dříve byly pouze součástí vědeckofantastických románů a filmů. Ačkoliv některé technologie a postupy byly známy již dříve, často je nebylo možné realizovat nebo byla jejich realizace obtížná a nákladná. S příchodem nové a výkonnější techniky se podobné futuristické technologie realizují snadněji a před výzkumníky a vývojáři stojí nyní další problém. Tím problémem je nalézt způsob, jak některé z těch futuristických technologií rozšířit mimo oblast armády či drahých vědeckých zařízení. Novým cílem je rozšířit takové technologie mezi širší veřejnost, aby byly dostupné lidem pro vzdělání, zábavu a také pro další výzkum. Dobrým příkladem je analýza mozkových signálů, kterou lze dnes použít nejen k lékařským účelům v nemocnicích, ale také jako rozhraní mezi člověkem a počítačem. Ačkoliv zatím není možné doopravdy číst lidské myšlenky, je možné pomocí analýzy mozkových vln naučit počítač rozpoznávat některé známé činnosti jako jsou příkazy svalům nebo je možné tréninkem počítač naučit reagovat na některé intenzivní myšlenky.

Tato práce se bude zabývat biosignálem generovaným lidským mozkem v podobě mozkových vln. Bude zde popsána historie získávání tohoto signálu pomocí různých metod. Dále pak jeho složení a jak se toto složení mění v důsledku činnosti mozku nebo vlivem vnějších faktorů. Popis EEG signálu bude také zahrnovat způsoby jeho zpracování a pochopení významu jeho dalšího výzkumu. Budou rovněž popsány možnosti následného využití v medicínských i jiných oblastech. Poté se bude práce zabývat vývojem nejrozličnějších zařízení propojujících mozek s počítači a možnostmi, které takovéto propojení přináší. A to nejen pro vědu, výzkum nebo medicínu, ale také jako prostředek zábavy. V této oblasti budou představeny aktuální systémy schopné snímat a zpracovat EEG signál, zaměřené na jednoduchost a dostupnost při zachování funkčnosti a zajímavých možností využití.

V praktické části této práce se bude využívat zařízení EPOC. Budou zde s tímto zařízením prováděny experimenty, které mají za úkol zjistit jeho možnosti nad rámec schopností, pro které bylo zařízení vyrobeno a je běžně používáno. Budou zde s tímto zařízením testovány možnosti detekce motoriky některých částí lidského těla za účelem případného ovládání například robotických paží. Pro tento účel byla jako součást práce vytvořena knihovna jazyka C++, která využívá data získaná ze zařízení EPOC k následné analýze a detekci požadovaných vzorců v EEG signálu. Tato knihovna byla implementována ve spolupráci s kolegou Bc. Jakubem Rodzenákem, který vytvořil demo aplikaci používající zmíněnou knihovnu. Demo aplikace pak slouží k ovládání zařízení, realizovaného pomocí této knihovny, a vizualizaci výstupů analýzy EEG signálu a detekce požadovaných akcí v tomto signálu. V rámci popisu knihovny se bude práce věnovat datovým strukturám používaných při práci s daty EEG signálu. Rovněž se bude věnovat metodám analýzy tohoto signálu a také rozhodovacím prostředkům pro detekci požadovaných akcí. Knihovna ve své implementaci využívá paralelních výpočtů s použitím grafických karet NVIDIA. K tomuto účelu byla použita technologie CUDA.

Jelikož je výstup práce založen na experimentech určujících možnosti zmíněného za-

řízení, budou v práci tyto experimenty popsány společně s dalšími testy zabývajícími se záznamem signálu pomocí testovaného zařízení a jeho zpracováním v průběhu prováděných experimentů. V rámci těchto testů budou rovněž testovány a popsány vlastnosti použitých klasifikačních metod. Budou vyhodnoceny jejich výsledky v průběhu experimentů. Na základě těchto výsledků bude posouzena vhodnost použití jednotlivých metod v případných dalších aplikacích se zde použitým zařízením nebo zařízením podobným. Výstupem práce pak bude konečný souhrn zjištěných údajů o možnostech testovaného zařízení a zhodnocení jeho schopností pro zamýšlené použití.

2 EEG signál


Tato kapitola se bude zabývat popisem EEG signálu jako zdroje informací nejen pro vědce a lékaře, ale i obyčejné lidi. Kapitola bude popisovat, jak se lidé začali zajímat o signál generovaný mozkem nejen lidí, ale i zvířat a se snažili pochopit jeho význam. Bude zde popsáno co to EEG signál je, z čeho se skládá, co nám může o konkrétním sledovaném subjektu prozradit a jak je možné jej využít. Kapitola obsahuje informace o možnostech pořízení záznamu tohoto signálu, o přístrojích snímajících tento signál a jejich součástech.

Signál EEG je záznam změn elektrického napětí způsobených průchodem elektrického proudu neurony během mozkové aktivity. Je pořizován v lékařství za účelem diagnózy nebo jako vstup do systému BCI. Historie EEG signálu začala už v 19. století, když Richard Caton zveřejnil v roce 1875 poznatky o elektrických jevech při pokusech s králíky a opicemi. V roce 1912 ruský fyziolog Vladimir Vladimirovich Pravdich-Neminsky zveřejnil první záznam EEG signálu zvířat a o dvanáct let později, v roce 1924, zaznamenal první EEG signál lidského mozku německý fyziolog Hans Berger [1] [2], viz obr. 1. Hans Berger také vynalezl elektroencefalograf, tedy přístroj pro pořizování záznamu EEG signálu. Podrobnější informace o historii elektroencefalografie lze nalézt například v díle Barbary E. Schwartz [3].


Výstup elektroencefalografie je soubor grafů mozkových vln. Tyto vlny lze rozdělit podle frekvencí do několika skupin. Jednotlivé vlny se pak objevují při odlišných stavech vědomí a různé mozkové aktivitě. Výskyt určitých vln je také rozdílný v závislosti na věku a je rovněž ovlivněn případnými onemocněními, při kterých se v EEG objevují typy vln, které by v daném okamžiku přítomny být neměly. Při vědomém stavu a aktivitách se na EEG zdravé osoby vyskytují vlny Alpha, Beta a Gamma. Vlny Alpha, viz obr. 2, kam patří frekvence $8 - 15 \text{ Hz}$, jsou přítomny při zavřených očích a v uvolněném stavu. Vlny Alpha byly pozorovány jako první a pojmenoval je výše zmíněný Hans Berger. Při otevření očí se vlny Alpha ztrácejí a objevují se vlny Beta s frekvencí $16 - 31 \text{ Hz}$, viz obr. 3. Vlny Beta jsou přítomny při myšlení, vnímání, koncentraci a při zvýšené pozornosti. Poslední vlny objevující se při vědomí člověka jsou vlny Gamma o frekvenci větší než 32 Hz , viz obr. 4. Tyto vlny se objevují při extrémním soustředění nebo stresu. Všechny vlny objevující se během vědomí se vyznačují nižší amplitudou než vlny nevědomých stavů, které mají amplitudu vyšší, ale jejich frekvence jsou velmi nízké. Mezi vlny nevědomých stavů patří vlny Theta, viz obr. 5, jejichž frekvence je $4 - 7 \text{ Hz}$ a objevují se při emocích, pocitech, snech nebo třeba v transu. Theta vlny se objevují také u dětí, u dospělých při ospalosti nebo při depresi. Posledním typem vln jsou vlny Delta viz obr. 6, mající frekvenci $0,5 - 4 \text{ Hz}$. Tyto vlny se objevují během hlubokého spánku nebo v kómatu. Podrobnější informace o elektroencefalografii lze nalézt například v publikaci [4].

2.1 Záznam


Záznam EEG signálu lze pořizovat invazivně nebo neinvazivně. Invazivní způsob záznamu vyžaduje chirurgický zákrok, který je velice riskantní a může vést k trvalému




Obrázek 1: První záznam lidského EEG signálu, který pořídil německý fyziolog Hans Berger v roce 1924. Horní křivka ukazuje vlastní EEG signál. Spodní část vyobrazuje časovací signál o frekvenci 10Hz [1] [2]




Obrázek 2: Alpha vlny EEG signálu. Jsou to vlny o frekvenci $8 - 15\text{Hz}$, které se vyznačují kromě zmíněné frekvence vyšší amplitudou.[27]




Obrázek 3: Vlny Beta na tomto obrázku jsou vlny s frekvencí $16 - 31\text{Hz}$. Tyto vlny jsou nejběžnější při vědomí zdravého člověka [27]



Obrázek 4: Tvar vln Gamma EEG signálu. Jedná se o vlny s největší frekvencí, a to větší než 32Hz , které se v EEG signálu objevují. Jejich přítomnost u zdravého člověka značí extrémní soustředění nebo stres. [27]



Obrázek 5: Vlny Theta. Jde o vlny s nízkou frekvencí $4 - 7\text{Hz}$. Jsou přítomny ve snech, transu nebo při pocitech a emocích. [27]



Obrázek 6: Vlny Delta. Jedná se o vlny s nejnižší frekvencí v EEG signálu. Jejich frekvence je $0,5 - 4\text{ Hz}$ a jsou přítomny během hlubokého spánku nebo kómatu.[27]

poškození mozku. Během invazivní metody jsou přímo do šedé kůry mozkové vpraveny elektrody. Ačkoliv je tato metoda nebezpečná, poskytuje díky blízkosti elektrod k neuronům nejpřesnější záznamy EEG.

Mnohem bezpečnější metoda záznamu je metoda neinvazivní. Při této metodě se na povrch lebky připevní elektrody bez zásahu do lebky samotné. Dnes se používají různé typy takových zařízení lišících se počtem elektrod, jejich umístěním, kvalitou snímaného signálu a cenou. Jelikož jsou napěťové úrovně mozkové aktivity velice slabé ($1 - 200\text{ }\mu\text{V}$), je k dosažení kvalitního signálu zapotřebí použití kvalitních elektrod z vysoce vodivého materiálu, při kterém nedochází ke zkreslení signálu, a velmi citlivých zesilovačů. Dalším problémem je elektromagnetické rušení přicházející z okolí, jelikož jsou všude zdroje elektromagnetického záření jako například bezdrátové vysílání televize a rádia nebo bezdrátové počítačové sítě. V nemocničních prostředích pak další diagnostická zařízení jako rentgen, magnetická rezonance a podobně. V ideálním případě by měl záznam EEG signálu probíhat v odstíněném prostředí například uvnitř Faradayovy klece. Takováto opatření jsou ale značně nákladná, a proto se ani v nemocnicích běžně nepoužívají. Pro použití v zábavním průmyslu nebo domácím prostředí by navíc bylo takové opatření krajně nepraktické.

2.1.1 Elektrody


Elektrody jsou první v řetězci, který zajišťuje přenos napěťových potenciálů z různých částí mozku do registračního zařízení. Elektrody jsou většinou kovové a druh tohoto kovu značně ovlivňuje kvalitu přenosu napěťového potenciálu ze zdroje do registračního zařízení. Běžně se používá čisté stříbro, nerezová ocel, slitiny cínu, pozlacené stříbro nebo zlato. Existuje celá řada různých typů elektrod, kdy každý typ je vhodný na jiné speciální použití a liší se i jejich umístění na hlavě pacienta. Zde jsou některé typy používaných elektrod převážně z medicínského prostředí.

- **Povrchové elektrody:** Tento typ elektrod se přikládá na očištěnou pokožku hlavy a pod elektrodu se vpravuje vodící médium například elektrodová pasta.
- **Podkožní elektrody:** Vpichují se pod pokožku a jejich využití je omezené na speciální případy, protože zde hrozí nebezpečí infekce nebo krvácení.


- **Tříbodové elektrody:** Jsou tvořeny šroubem reprezentujícím vlastní elektrodu zasazeným do plastové konstrukce ve tvaru písmene *T*. Obdobou tohoto typu jsou elektrody, které jsou tvořeny kovovým kontaktem ve tvaru písmene *S*.
- **Elektrody s fyziologickým roztokem:** U tohoto typu elektrod se kovová část nedotýká přímo pokožky, ale kontakt je zprostředkován skrze tkaninu napuštěnou fyziologickým roztokem. Tento typ elektrod se často používá v nemedicínských aplikacích a existují i varianty, u kterých není nutné používat fyziologický roztok. Takové přístroje jsou ale velice drahé.
- **EEG čepice:** Jde o pružnou čepici, v níž jsou rozmístěny elektrody. Každá elektroda je spojena s registračním přístrojem pomocí vodiče a po nasazení čepice se do elektrod shora vpraví EEG gel.
- **Nasofaryngeální elektrody:** Tyto elektrody se zavádějí nosní dírkou a snímají potenciály baze lební.
- **Tympanální elektrody:** Zavádějí se skrze vnější zvukovod do blízkosti bubínku, kde snímají napěťové pole z horní části vnějšího zvukovodu.
- **Kortikální elektrody:** Jsou používány pouze ve specializovaných neurochirurgických zařízeních. Přikládají se přímo na tvrdou plenu mozkovou a jde tedy o využití při invazivní elektroencefalografii.

Rozmístění elektrod na povrchu lebky bylo sjednoceno v roce 1957 na mezinárodním kongresu EEG, kde byl přijat systém nazývaný *10/20*. Tento systém popisuje pozice elektrod na lebce pro experimenty s EEG signálem. Byl vytvořen za účelem možnosti reprodukovat experimenty a porovnávat je mezi sebou, stejně jako možnost porovnávat testované subjekty samotné. Systém je založen na vztahu pozice elektrody a mozkové kůry. Čísla 10 a 20 označují vzdálenost v procentech od nejbližší elektrody ve směru jedné ze dvou rovin. To znamená, že první elektroda je od výchozího bodu vzdálena 10% délky lebky v dané rovině. Další elektroda ve stejném směru pak 20% od předchozí elektrody a tak dále. Výchozí body na podélné ose jsou umístěny vpředu v oblasti mezi očima a vzadu na nejnižším bodu lebky. Rozložení systému 10/20 ukazuje obr. 7. Každá pozice má své unikátní označení složené s písmena označujícího lalok a čísla označujícího pozici na hemisféře. Písmeno z místa čísla označuje elektrody umístěné na středové ose. Systém 10/20 není vždy dostačující pro vědecké účely, a proto se v takovém případě používá rozšířená verze tohoto systému s názvem 10/10 nebo 10/5. Zde jsou uvedeny významy jednotlivých písmen v označení elektrod.

- | | |
|-------------------------------|------------------------------|
| • C – centrální oblast | • Fp – čelní lalok |
| • P – temenní lalok | • O – týlní lalok |
| • F – čelní lalok | • T – spánková oblast |



Obrázek 7: Rozložení elektrod na povrchu lebky podle mezinárodně dohodnutého systému, který se nazývá 10/20. Toto rozložení se dnes používá pro většinu BCI systémů. [22]




Obrázek 8: Schéma jednoduchého zapojení diferenčního zesilovače, který se používá v zesilovačích EEG signálu před jejich analýzou. [23]

2.1.2 Zesílení

Jak již bylo dříve uvedeno, amplituda signálu na elektrodách se pohybuje v jednotkách až stovkách μV . Je tedy nutné takový signál nejprve zesílit, a poté jej lze analyzovat. Zesílení signálu probíhá ve dvou krocích. Jako první se signál přivede do předzesilovače. V předzesilovači se signál zesílí přibližně tisíckrát. Předzesilovač by měl být umístěn co nejbližee elektrodám. Z výstupu předzesilovače se signál přivede na vstup hlavního zesilovače, který je umístěn v samotném zařízení. V hlavním zesilovači se signál zesílí opět přibližně tisíckrát. K zesilování signálu EEG se používají diferenční zesilovače. Tenhle typ zesilovače je vybaven dvěma vstupy, kdy jeden se používá pouze jako referenční s tím, že zesilovač zesiluje rozdíl napětíového potenciálu mezi oběma těmito vstupy. To znamená, že pokud by napětí na obou vstupech mělo stejnou hodnotu, pak na výstupu zesilovače bude napětí nulové bez ohledu na úroveň potenciálu na jeho vstupech. Příklad elektrotechnického schématu diferenčního zesilovače je vidět na obr. 8, zde s použitím operačního zesilovače.

2.1.3 Filtrace

Filtrace je zde zapotřebí, protože pro analýzu EEG jsou velmi nízké frekvence do 0,5 Hz nežádoucí stejně jako frekvence vyšší než požadované pásmo. Proto se kolem zesilovače



Obrázek 9: Vzorek záznamu EEG signálu, kdy během normálního stavu dojde k epileptickému záchvatu. [24]

zařazují filtry, které tyto nežádoucí frekvence odstraní. Před zesilovač se zařazuje filtr dolní. Ten odstíní frekvence nižší než 0,5 Hz a také stejnosměrnou složku. Za zesilovač se pak zařazuje filtr horní, který omezí maximální frekvenci pro analýzu nejčastěji na 70 Hz. Výše popsany způsob využívá fyzických součástek, ale odstranění nežádoucích frekvencí lze provést také digitálně pomocí frekvenčního spektra. Kromě nižších a vyšších frekvencí než je požadovaný rozsah se filtruje také rušivá frekvence sítě, a to 50 Hz.

2.2 Využití

Využití invazivní metody elektroencefalografie je u lidí omezené pouze na nejnutnější případy v medicíně, kdy je nutné přesně lokalizovat zdroj problému a použití elektrod na povrchu lebky není dostatečné. Příkladem takové situace je operace pacienta s epilepsií.

Běžně se však využívá elektroencefalografie neinvazivní. V medicíně je to například k diagnóze. Abnormální výsledky EEG mohou ukazovat na celou řadu poruch. Mezi ně patří epilepsie nebo jiné záchvaty, poruchy spánku, migrény, poruchy soustředění, poranění hlavy nebo nádorové onemocnění. Příklad záznamu EEG během záchvatu je ukázán na obr. 9. Dále se EEG v medicíně používá k monitorování anestezie, monitorování pacientů v kómatu a podobně. Mezi medicínské využití lze také zařadit zařízení, která pomáhají pacientům s různým postižením. Tyto zařízení využívají systému BCI.

3 BCI


V této kapitole budou popsány systémy propojující mozek s počítačem neboli BCI. Kapitola se bude zabývat historií vývoje těchto zařízení, jejich podobou a využitím. Protože se práce zabývá systémem BCI společnosti Emotiv s názvem EPOC, budou v této kapitole popsány informace o tomto použitém zařízení a rovněž zde budou zmíněna podobná zařízení jak od společnosti Emotiv, tak dalších výrobců zabývajících se touto problematikou.

Systém BCI označuje přímé propojení mezi mozkem s počítačem. Vývoj tohoto systému započal v sedmdesátých letech minulého století na univerzitě v Los Angeles v kalifornii. Tehdy se výzkum zaměřoval hlavně na vývoj umělých zařízení (implantátů) umístěných do mozku pacienta za účelem obnovy schopnosti komunikace, sluchu, zraku a pohybu. Po letech experimentů na zvířatech se první takové zařízení, použité u lidí, objevilo v devadesátých letech minulého století. Tato zařízení však nemusí být zástupci systému BCI, neboť jsou připojena k zařízením, která mají konkrétní účel pro danou aplikaci implantátu, a ne přímo k počítačům. Avšak obě technologie se mohou doplňovat. Implantáty nejsou omezeny pro použití pouze v oblasti mozku, ale lze je použít i na ostatní části nervového systému.

BCI systém zpracovává signály z mozku pomocí počítače a má tak větší škálu možností, jak signál využít. V sedmdesátých letech minulého století bylo při pokusech s opicemi zjištěno, že jsou schopné se naučit generovat požadované vzory v mozkové aktivitě, když jsou za to odměňovány. V osmdesátých letech pak objevil Apostolos Georgopoulos matematickou závislost mezi elektrickými zprávami konkrétních neuronů a směrem pohybu paže testovaných opic [5]. Později experimenty ukázaly, že jsou opice schopné s využitím BCI ovládat kurzor na obrazovce nebo dokonce robotickou paži viz obr. 10. Další experimenty prováděné na kočkách dokázaly dekodovat jejich vizuální signály. Od poloviny devadesátých let se pak vývoj BCI systémů značně zrychlil.

Výzkum BCI systémů u lidí se snaží využívat hlavně neinvazivní metody a zaměřuje se na ovládání různých zařízení jako jsou protézy nebo komunikační zařízení. Avšak vyvíjejí se také BCI systémy využívající implantáty a fungující na opačném principu. Takový systém se snaží člověku nahradit chybějící smysly jako zrak a sluch. V roce 1978 bylo implantováno 68 elektrod pacientovi, který v mládí oslepl. Ten byl následně schopen vnímat světlo. O tento úspěch se zasloužil výzkumník William Dobelle, který dále vyvíjel své zařízení a v roce 2002 implantoval novou verzi svého zařízení 16 pacientům kteří tímto získali základní obrazové vjemy z okolí.

Tím jak se zvětšuje naše pochopení mozkové činnosti a jak se zdokonalují používané technologie se použití BCI rozšiřuje i do oblastí, kde není nutností. Spíše se zajímá o možnosti usnadnění některých činností nebo zábavu. V dnešní době již existují zařízení snímající mozkovou aktivitu, u kterých není nutné používat příliš velké množství elektrod nebo používat různé gely. Proto se BCI systémy rozšiřují do zábavního průmyslu, kde například herní konzole a počítače využívají získaných emocí nebo přímo používají BCI k ovládání počítačových her samotných. Vyvíjejí se stále jednodušší zařízení s co nejmenším počtem elektrod a důležitým faktorem je dnes už také design.



Obrázek 10: Fotografie pořízená při jednom z experimentů s opicemi druhu makak při použití invazivní metody snímání EEG signálu. Opice zde mozkovou aktivitou ovládá robotickou paži, pomocí které se dokáže krmit. [26]

3.1 BCI systémy Emotiv

Prvním systémem společnosti Emotiv je zařízení *EPOC*. Je zaměřený především na domácí použití a tedy na jednoduchost, ergonomii a dostupnost. Systém *EPOC* využívá náhlavní soupravy neboli headsetu se 14 elektrodami pro snímání mozkové aktivity a dvěma referenčními elektrodami. Jde o elektrody využívající fyziologický roztok. Headset taktéž obsahuje gravitační čidla snímající pohyb hlavy. Celý systém je připojen k počítači pomocí bezdrátového přenosu v pásmu 2,4 GHz. Proto je headset vybaven vestavěnou baterií s výdrží až 12 hodin na jedno nabití. Účelem tohoto zařízení je zachycovat emoce, výrazy obličeje a některé kognitivní akce. Zařízení je vyobrazeno na obr. 11.

Druhým systémem vyvíjeným touto společností je zařízení *Insight*. Na rozdíl od předešlého systému *EPOC*, je toto zařízení výrazně jednodušší. Je tvořeno opět náhlavní soupravou, avšak tentokrát jen s pěti elektrodami snímajícími mozkovou aktivitu a dvěma referenčními elektrodami. Jde opět o bezdrátové zařízení tentokrát zaměřené na ještě jednodušší manipulaci a používání. Toho je dosaženo použitím speciálních polymerových elektrod, které nevyžadují aplikaci žádného gelu nebo fyziologického roztoku. Zařízení *Insight* je určeno k monitorování úrovně soustředění, pozornosti, stresu nebo uvolnění. Dále je vybaveno třemi dalšími senzory, které umožňují efektivně snímat pohyby a polohu hlavy. Jde o gyroskop, akcelerometr a magnetometr. zařízení *Insight* lze vidět na obr. 12.

V níže uvedených podkapitolách jsou popsány detailnější informace o zařízení *EPOC*, protože právě toto zařízení bylo použito pro experimenty, které jsou součástí této práce. Tabulka 1 obsahuje soupis parametrů zařízení *EPOC*. Podrobné informace o obou zařízeních a dodávaném software lze nalézt na internetových stránkách společnosti Emotiv.[17]



Obrázek 11: Zařízení Emotiv EPOC. Jde o EEG systém s 14 elektrodami, který je zároveň také jednoduchý. Zařízení EPOC bylo použito v této práci při implementaci knihovny a byly na něm prováděny veškeré testy a experimenty. [18]



Obrázek 12: Systém Emotiv Insight. Je výrazně jednodušší než systém EPOC. Má 5 elektrod a je určen k monitorování úrovně soustředění, nálad apod. [19]

Parametry	
Počet kanálů	14 + 2 (referenční CMS/DRL, lokalizační P3/P4)
Názvy kanálů (10/20)	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4
Vzorkovací metoda	Sekvenční vzorkování, analogově digitální převodník
Vzorkovací frekvence	128 vzorků za vteřinu, 2048 Hz vnitřně
Rozlišení	14 bitů, 1 LSB = 0,51 uV
Šířka pásma	0,2–45 Hz, digitální notch filtr na 50 Hz a 60 Hz
Filtry	zabudovaný digitální 5-ti řadý sinc filtr (dolní propust)
Dynamický rozsah	8400 uV (pp)
Spojovací mód	AC spojený
Spojení	proprietární bezdrátové, pásmo 2,4 GHz
Napájení	LiPoly
Výdrž na baterii	12 hodin
Měření impedance	kontrola kvality spojení v reálném čase pomocí patentovaného systému

Tabulka 1: Technické parametry BCI zařízení EPOC vycházející z internetových stránek společnosti Emotiv.

3.1.1 Provoz

Všechny elektrody tohoto zařízení jsou odnímatelné a jsou skladovány odděleně ve speciálním pouzdře, které je součástí balení. Před použitím je potřeba elektrody navlhčit fyziologickým roztokem a upevnit do ramen headsetu. Tento roztok je taktéž dodáván spolu se zařízením. Pro příjem bezdrátového signálu ze zařízení slouží USB přijímač připojený k počítači. Nabíjení se provádí z počítače pomocí rozhraní USB. Během nabíjení však není možné zařízení používat. Pro informaci o tom, zda jsou všechny elektrody na správných místech posílá zařízení do počítače kromě samotných dat z elektrod také informace o kvalitě příjmu na každé z nich. Systém detekce této kvality má společnost Emotiv patentován. Dále zařízení posílá do počítače informace o aktuální síle bezdrátového propojení a úroveň nabití baterie.

3.1.2 Software

Pro správu headsetu existuje software *Emotive Control Panel*, Tento software zobrazuje stav zařízení, vizualizaci rozmístění kontaktů na hlavě a aktuální kvalitu jejich signálu. Dále zařízení umožňuje vizualizaci základních výrazů obličeje. Obsahuje také správu kognitivních akcí, kde je možné natrénovat myšlenky pro zvednutí objektu, jeho posunutí nebo otočení. Natrénované akce lze uložit pomocí profilů, takže s headsetem může pracovat pohodlně několik uživatelů. Dalším zajímavým software je Xavier EmoKey. Tento software umožňuje uživateli přiřadit detekované kognitivní akci nějakou klávesovou zkratku. Tímto způsobem se dá experimentovat s ovládáním i těch aplikací, které

nejsou přímo spojeny s headsetem. Pro vývojáře software využívajícího headset Emotiv EPOC, a jeho detekci kognitivních akcí, je také k dispozici simulační nástroj zvaný Xavier EmoComposer. Tento nástroj dokáže posílat simulované detekování akce do aplikace využívající Emotiv SDK. Kromě samotných detekcí umožňuje tento nástroj také simulovat ostatní chování headsetu jako jsou správa uživatelů a trénování. Součástí software vybavy je také demonstrační hra *Spirit Mountain*, která ukazuje všechny schopnosti headsetu.

3.1.3 Vlastní zkušenost

Při práci se systémem EPOC bylo zjištěno, že jde opravdu o velmi jednoduchý ale funkční systém EEG, který je relativně dostupný a navíc je také designově velmi zdařilý. Jeho výhodou je bezdrátové řešení komunikace a možnost vyměnit jednotlivé elektrody. Dalšími výhodami jsou výdrž baterie a dostupnost celé řady software jak pro provoz zařízení, tak pro vývoj aplikací, které mají tento systém používat.

Nevýhodou systému je nutnost aplikovat fyziologický roztok na elektrody před každým použitím a také nutnost uchovávat jednotlivé elektrody odděleně od zařízení z důvodu možného mechanického poškození jejich křehkého uchycení k ramenům headsetu při manipulaci. Další nevýhodou je absence možnosti provozovat zařízení drátově, když dojde k vybití baterie, protože jej není možné zároveň používat i nabíjet. Výdrž baterie je však dostatečná, a pokud je zařízení před použitím včas nabito, není absence drátového provozu zásadní.

3.2 Konkurenční řešení

Kromě BCI řešení společnosti Emotiv, existují na trhu další podobná řešení. Jde například o zařízení *MindWaveTM* společnosti NeuroSky®. které je určeno k monitorování úrovně pozornosti, například koncentrace při studiu apod. Vzhledem ke svému zaměření není toto zařízení vybaveno takovým počtem elektrod jako výše popsany systém EPOC společnosti Emotiv. Jde rovněž o bezdrátové řešení a k systému je také dodáván balíček software. Toto zařízení se také prodává ve verzi *Mobile*, což znamená, že jej lze připojit k chytrým telefonům pro ještě větší možnosti využití. Pro porovnání s výše popsanými systémy Emotiv je zařízení *MindWaveTM* vyobrazeno na obr. 13. Další informace o tomto zařízení je možné najít na internetových stránkách výrobce[20]. Kromě těchto zařízení s malým počtem elektrod existují i komplexnější řešení s mnohem větším počtem elektrod. Příkladem může být zařízení společnosti *Cognionics*. Toto zařízení disponuje až 64 elektrodami, které navíc existují ve dvou variantách, pro přímý kontakt s pokožkou lebky nebo pro nasazení headsetu přes vlasy. Konstrukce tohoto zařízení je navržena tak, aby bylo možné použít elektrody bez aplikace speciálního gelu. Stejně jako všechna předchozí zařízení je i toto bezdrátové a kromě přímého přenosu dat umožňuje také záznam signálu na paměťovou kartu. Zařízení je vyobrazeno na obr. 14 a podrobnější informace jsou opět k nalezení na internetových stránkách výrobce[21].



Obrázek 13: Příklad konkurenčního řešení od společnosti NeuroSky®. Toto zařízení se jmenuje MindWave™. Zařízení je určeno např. k monitorování úrovně pozornosti například při učení. [20]



Obrázek 14: BCI zařízení společnosti Cognionics. Ze všech zde popsaných zařízení je tohle nejkomplexnější. Obsahuje až 64 elektrod a je schopno provozu i bez nepřetržitého připojení k počítači díky možnosti záznamu EEG signálu na paměťovou kartu. [21]

4 Praktická část

Následující kapitola bude popisovat jádro této práce, tedy implementaci knihovny pro testování výše popsaného systému EPOC. Budou zde rozebrány cíle práce, struktura samotného software a technologie, které byly při implementaci knihovny použity. Dále zde budou uvedeny informace o použitých metodách analýzy signálu a také informace o použitém hardware.

Náplní této práce bylo implementovat knihovnu pracující s výše zmíněným zařízením Emotiv EPOC. Účelem knihovny bylo přijímat data EEG signálu ze zařízení, ta pak zpracovat a analyzovat. Cílem implementace knihovny a celé práce pak bylo použití v aplikaci, která měla za úkol vizualizovat podněty získané na základě analýzy dat přijatých ze zařízení EPOC. Úkolem práce bylo prozkoumat možnosti detekce takových podnětů, pro které nebylo dané zařízení přímo konstruováno. Předmětem zkoumání tedy byly možnosti detekovat například motorické činnosti, jako jsou pohyby končetin. Obecně bylo úkolem zjistit co všechno se dá analýzou surových dat ze zařízení detekovat a na základě zjištěných schopností zařízení pak vyhodnotit možnosti širšího využití. Kromě samotné správy a analýzy dat zajišťuje také knihovna přístup nadřazené aplikace k zařízení.

4.1 Použité technologie

Kompletní implementace knihovny v této práci byla realizována pomocí programovacího jazyka C++. Původně zamýšlena implementace v prostředí .NET byla v průběhu vývoje nahrazena čistým C++ kódem z důvodu kompatibility s aplikací, jíž je knihovna součástí, protože ve zmíněné aplikaci došlo k nahrazení technologie .NET knihovnami Qt, které doplňují hlavní vizualizaci v prostředí OpenGL. Pro analýzu dat přicházejících z headsetu EPOC byla využita Fourierova transformace. Konkrétně bylo možné použít rychlou Fourierovu transformaci, protože se prováděla na diskrétních datech. Jelikož bylo zapotřebí analyzovat data ze všech senzorů současně a pokud možno v reálném čase, byla zvolena metoda výpočtu pomocí grafických akcelérátorů (GPU). Byla využita technologie CUDA [7] [8] [9] [10] [25]. Je to technologie vytvořená a vyvíjená společností NVIDIA. Jde o speciální konstrukce programovacího jazyka, které umožňují provádění některých výpočetních operací pomocí grafických akcelérátorů NVIDIA. Při použití této technologie je možno výpočty provádět paralelně, jelikož na rozdíl od procesoru jsou grafické akcelérátory vybaveny stovkami výpočetních jader. V případě této práce byla právě technologie CUDA použita na výpočty spojené s analýzou dat EEG signálu z headsetu EPOC. Konkrétně byly na grafické kartě počítány veškeré výpočty rychlé Fourierovy transformace. Tyto výpočty pak byly implementovány za využití optimalizované knihovny pro rychlou Fourierovu transformaci, která byla napsána přímo pro technologii CUDA. Jde o knihovnu CUFFT. Tato knihovna nabízí možnosti transformace reálných i komplexních datových typů a to v 1D, 2D i 3D konfiguraci. Lze s její pomocí provádět jak výpočty s jednoduchou přesností (takzvané *single precision*), tak také výpočty s dvojnásobnou přesností (takzvané *double precision*). Knihovna využívá asynchronního spouštění výpočetních kódů na grafické kartě s využitím takzvaných *streamů*. Výpočty

pomocí této knihovny lze provádět *in place*, to znamená, že výsledná data se ukládají na stejné místo v paměti, kde byla uložena data vstupní před spuštěním transformace. Lze je ovšem také provádět běžně a výstupní data ukládat na samostatné místo v paměti. Celkově je knihovna *CUFFT* implementována s ohledem na současné volání z několika běžících vláken programu a takového využití je tedy bezpečné.

Jelikož implementace knihovny vyžadovala spouštění několika samostatných vláken, byla pro tyto účely použita knihovna *pthread*s. Jako klasifikační metody pro rozpoznávání akcí v EEG signálu byla použita kosinová míra a neuronová síť. Neuronová síť byla implementována s využitím knihovny *FANN*[28]. Tato knihovna se vyznačuje velmi rychlým trénovacím procesem s minimálními nároky na paměť počítače. Jelikož se při sestavování neuronové sítě používají náhodně generované hodnoty není zaručeno, že každé sestavení této sítě se stejnými vstupními daty bude vhodné pro klasifikaci. Protože je však trénování relativně rychlé, je možno toto trénování opakovat, dokud neuronová síť nedosáhne požadované chyby.

Pro vývoj knihovny, jež je obsahem této práce, byl použit počítač Lenovo ThinkPad T520, jehož parametry jsou uvedeny v tabulce 2. Implementace knihovny byla provedena v prostředí Microsoft Visual Studio 2013. Knihovna byla implementována v souladu se specifikací technologie NVIDIA CUDA ve verzi 6.5. Testování bylo kromě výše uvedeného počítače prováděno také na počítači, kde vznikala demo aplikace. Parametry tohoto počítače jsou uvedeny v tabulce 3.

Procesor	Intel(R) Core(TM) i5-2520M 2.5GHz
Operační paměť	8 GB DDR3
Grafický procesor	NVIDIA NVS4200M 1GB GDDR3
Operační systém	Microsoft Winfows 7 Professional 64-bit

Tabulka 2: Parametry hlavního počítače

Procesor	Intel(R) Core(TM) i5-4430 3GHz
Operační paměť	8 GB DDR3
Grafický procesor	NVIDIA GeForce GTX760 2GB GDDR5
Operační systém	Microsoft Winfows 7 Professional 64-bit

Tabulka 3: Parametry dalšího testovacího počítače


4.2 Implementace

Knihovna je tvořena dvěma částmi. První z nich zajišťuje spojení se samotným zařízením. Využívá SDK k zařízení a je implementována jako samostatná knihovna. Takto je zajištěno, že hlavní část knihovny není přímo propojena se skutečným zařízením a je tedy možné ji v budoucnu případně využít pro podobné experimenty s zařízením jiným. Tuto samostatnou část tvoří dvě třídy. První třída s názvem *Headset* jako jediná využívá

části SDK k headsetu EPOC a stará se o připojení k zařízení, o čtení dat a dalších informací jako jsou stav baterie, kvalita bezdrátového signálu a kvalita jednotlivých kontaktů. Třída *Headset* obsahuje instanci druhé použité třídy s názvem *EEGBuffer*. Tato instance v sobě uchovává přečtená data ze zařízení. Samotné snímání dat je prováděno v samostatném vlákne voláním metody *capture* ve třídě *Headset*, kdy se každých 100ms zapisou do instance třídy *EEGBuffer* hodnoty EEG signálu nasbírané zařízením od posledního přečtení dat. Třída *EEGBuffer* zapouzdřuje nasbíraná data a prostřednictvím třídy *Headset* k nim umožňuje přístup ze zbylé části knihovny. Přístup k ostatním informacím je zajištěn voláním příslušných metod instance třídy *Headset*. Vytvořením instance třídy *Headset* vzniká kompletní rozhraní mezi zbylou částí knihovny a samotným zařízením. Výše zmíněná část využívá zdrojového kódu implementovaného a poskytnutého Ing. Petrem Gajdošem Ph.D. Z poskytnuté části byla použita pouze část přijímající a ukládající data ze zařízení. Následně byla upravena pro potřeby hlavní části knihovny.

Hlavní knihovna je tvořena několika dalšími třídami a zajišťuje správu dat, jejich analýzu a komunikaci s vnější aplikací, která tuto knihovnu používá. Řídící třídou této knihovny je třída *EEGManager*. Tato třída uchovává informace o připojeném zařízení v instanci výše zmíněné třídy *Headset*. Zprostředkovává tak veškerou komunikaci s vnější aplikací a na základě podnětů z této aplikace pak spravuje spouštění a ukončování samostatných vláken, která se při práci s daty využívají. Konkrétně jde o následující vlákna. Vlákno *CaptureThread* spravující pouze neustálé čtení dat ze zařízení v konstantních intervalech 100ms a vlákno *AnalysisThread*, které zajišťuje kontinuální provádění výpočtů Fourierovy transformace na datech přicházejících ze zařízení. Protože se hlavní paměť s EEG daty neustále plní a zároveň je zapotřebí umožnit k těmto datům přístup vnější aplikaci, je použit systém dvojité vyrovnávací paměti, který zajišťuje, že data předána vnější aplikaci jsou vždy správná. Tak je možné data zobrazovat v reálném čase a aplikace nemá přímý přístup k hlavní paměti s uloženými daty, ale právě k oné vyrovnávací paměti, která je uložena uvnitř třídy *EEGManager*. Vyrovnávací paměť má konstantní velikost a to dvě sekundy EEG signálu. Stejný princip je použit pro zobrazování spektrální analýzy, kterou provádí vlákno *AnalysisThread* na aktuálních EEG datech. Aplikace pak získává jak data EEG signálu, tak data spektrální analýzy pomocí příslušných metod třídy *EEGManager*, která jí umožní přístup k vyrovnávací paměti. Pomocí speciální metody pak aplikace přepíná vyrovnávací paměti před každým čtením. Tím je zajištěno, že nedojde ke konfliktu dat, protože samotná záměna vyrovnávacích pamětí je prováděna ve vlákne pro analýzu, poté co se dokončí veškeré operace s těmito paměťmi v konkrétním průchodu. Dále třída *EEGManager* obsahuje instanci třídy *ActionManager*. Tato třída má za úkol spravovat data akcí, které se pak mají rozpoznávat. To znamená ukládat vybrané úseky EEG signálu do datových struktur, spravovat výpočty spektrální analýzy pro jednotlivé vzorky, zajišťovat ukládání trénovacích vzorků na disk a jejich načítání do paměti, spravovat parametry pro klasifikaci akcí, spravovat rozhodovací algoritmy a provádět samotnou klasifikaci.

Uchování dat v paměti programu zajišťuje třída *Action*. Tato třída obsahuje potřebné atributy a metody a hlavně vektor s daty všech nahraných záznamů pro konkrétní akci, pro kterou byla instance třídy *Action* vytvořena. Každý prvek zmíněného vektoru obsa-




Obrázek 15: Organizace třídy *Action*, která obsahuje vektor všech vzorků. Každý vzorek pak obsahuje datovou strukturu, která uchovává dvě pole. Jedno pro EEG signál a druhé pro data spektrální analýzy.

huje kompletní data pro jeden uložený záznam. Obsahuje tedy informace o počtu kanálů daného vzorku, velikosti tohoto vzorku a samotná data. Data jsou uložena ve dvou samostatných polích. Jedno pole uchovává originální záznam EEG signálu. Druhé pole uchovává data spektrální analýzy po aplikaci filtrace, která je popsána níže. Obě pole jsou jednorozměrná a ukládají data jednotlivých kanálů za sebou, jak ukazuje obrázek 15. Pole pro data EEG signálu uchovává informace typu **double**, protože jsou takto přijímána ze zařízení. Spektrální analýza je pak uchovávána jako pole typu **float**.

Poslední částí knihovny je třída *EEG_IO_INTERFACE*, která tvoří rozhraní mezi vnější aplikací a knihovnou. Aplikace má přístup pouze k metodám tohoto rozhraní, které pak dále volají metody třídy *EEGManager*. Tento způsob oddělení zajišťuje možnost použití knihovny bez nutnosti vložení celé řady hlavičkových souborů, které by bylo jinak potřeba přiložit. Jde o například o hlavičkové soubory ke knihovně *pthread*s, ke knihovně *CUFFT* a knihovnam pro samotné zařízení. Takto je nutné přiložit pouze potřebné *dll* knihovny, které neovlivňují kompilaci aplikace, jež používá zde implementovanou knihovnu. Metody, které nabízí rozhraní pro vnější aplikaci jsou vypsány ve výpisu 1 části třídy *EEG_IO_INTERFACE*. Schéma celé struktury knihovny je pak vidět na obr. 16.

Jak již bylo zmíněno, k spektrální analýze EEG signálu byla použita rychlá Fourierova transformace za použití knihovny *CUFFT* pro technologii CUDA. Tato knihovna byla použita v jednorozměrném režimu pro každý kanál EEG signálu samostatně a celá analýza probíhala v samostatném výpočetním vlákně programu. Pro vstupní i výstupní



Obrázek 16: Architektura celé knihovny implementované v této práci. Jednotlivé části reprezentují třídy v samotném programu s výjimkou SDK. To je zde uvedeno jako komponenta použitá při implementaci.

data transformace byl použit vždy jen jeden blok v paměti grafické karty. Po výpočtu Fourierovy transformace jsou výsledky uloženy do vyrovnávací paměti, kde jsou uchovávána aktuální data. V případě výpočtu spektrální analýzy při ukládání trénovacích vzorků se využívá stejné části kódu jako při analýze aktuálně čteného EEG signálu. V tomto případě jsou však výsledky ukládány do příslušných datových struktur v paměti programu. Univerzální funkce, která se v této implementaci stará o výpočty spektrální analýzy ve všech potřebných případech, po samotném výpočtu také upraví výstupní data, jelikož výstupem Fourierovy transformace jsou komplexní čísla. Tato čísla jsou zde převedena na reálné hodnoty a zároveň jsou z výsledného spektra odstraněny nežádoucí frekvence. Jde o frekvenci stejnosměrné složky a rušivou frekvenci elektrické sítě 50 Hz. Zdrojový kód této funkce je vidět na výpisu 2.

Vlákno provádějící spektrální analýzu tuto operaci vykonává vždy, pokud se ze zařízení přijímají data EEG signálu. Na podnět z aplikace pak toto vlákno po výpočtu spektrální analýzy pošle spektrum signálu na klasifikaci do třídy *ActionManager*. Tato třída v sobě uchovává všechny trénovací vzorky všech uložených akcí a obsahuje rovněž klasifikační metody. Jako klasifikační metoda byla zvolena neuronová síť, a jako druhý možný způsob, klasifikace pomocí kosinové míry. Pro implementaci neuronové sítě pak byla použita knihovna *FANN*. Výpočet kosinové míry a klasifikace vzorku na základě výsledku tohoto výpočtu byly implementovány přímo podle následujícího matematického popisu.

$$\text{podobnost} = \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_{i=1}^n A_i \times B_i}{\sqrt{\sum_{i=1}^n (A_i)^2} \times \sqrt{\sum_{i=1}^n (B_i)^2}} \quad (1)$$

Konečná klasifikace byla stanovena na základě četnosti jednotlivých akcí v nejlepších výsledcích výpočtu kosinové míry. Zjištěná akce je v případě obou klasifikačních metod poskytnuta aplikaci, která na základě této akce provede její vizualizaci. Část funkce pro klasifikaci pomocí kosinové míry je ukázána ve výpisu 3. Samotný výpočet podobnosti vektorů pomocí kosinové míry není součástí této funkce, jelikož se provádí přímo ve třídě *Action* po zavolání funkce *Compare* na příslušnou instanci třídy *Action*. Právě toto volání je součástí klasifikace uvedené ve výpisu 3. V případě klasifikace s použitím předem natrénované neuronové sítě se pouze pošle na vstup této sítě frekvenční spektrum aktuálního EEG signálu a její výstup se přímo použije pro identifikaci rozpoznané akce. Jelikož v případě použití neuronové sítě není nutno frekvenční spektrum aktuálního signálu porovnávat při každé klasifikaci se všemi uloženými trénovacími vzorky, je tato metoda klasifikace rychlejší. Toto se projeví hlavně v případě, kdy je trénovacích vzorků větší množství, protože časová složitost klasifikace s využitím neuronové sítě nezávisí na tomto množství. Hlavní část klasifikační funkce používající neuronovou síť ukazuje výpis 4. Samotná neuronová síť je pro potřeby této práce sestavována jako síť se třemi vrstvami neuronů. Vstupní vrstva této sítě obsahuje počet neuronů určených součinem počtu snímaných kanálů a počtu hodnot spektrální analýzy. To proto, že ke klasifikaci se posílal jeden vektor vstupních dat složený ze spektrálních analýz všech potřebných kanálů

současně. V případech použitých v této práci, kdy bylo použito 14 kanálů EEG signálu a počet frekvencí spektrální analýzy byl 128, měla neuronová síť ve vstupní vrstvě 1792 neuronů. Jelikož výstupem této sítě měla být hodnota identifikující detekovanou akci, měla výstupní vrstva sítě pouze jeden neuron, jehož hodnota byla po průchodu vstupních dat neuronovou sítí použita jako index v poli dostupných akcí. Prostřední skrytá vrstva této sítě měla 3 neurony. Pro testování detekce akcí byla požadovaná chyba sítě po natrénování stanovena na 0,001. Trénování sítě je prováděno při startu aplikace a poté při každém vybrání neuronové sítě jako klasifikační metody. V obou případech klasifikace je klasifikovaný úsek EEG signálu filtrován, aby se docílilo větší přesnosti klasifikace. Filtrace se realizuje odečtením předem vypočítaného průměrného vzorku spektrální analýzy klidového signálu testované osoby od spektra aktuálního EEG signálu. Teprve po této filtraci je provedena klasifikace pomocí jedné z výše uvedených metod. Výběr metody, která má být pro klasifikaci použita provádí aplikace. Pokud je zvolena neuronová síť, je tato síť natrénována z dostupných trénovacích vzorků uložených akcí.

```

class EEG_IO_INTERFACE
{
public:

    //Headset operations
    inline int      Connect(int mode);
    inline int      GetSensorCQ(int sensor_id);
    inline const char* GetSensorNames();
    inline int      GetWirelessSignal();
    inline int      GetBatteryChargeLevel();
    inline int      GetBatteryChargeMax();
    inline int      GetNoChannels();
    inline int      GetNoEEGChannels();
    inline int      SetEEGChannelRange(unsigned int first, unsigned int last);

    //Analysis operations
    inline int      AnalyzeData();
    inline void      StopAnalysis();
    inline void      Recognition(bool start);
    inline int      SetAnalysisMode(int mode);
    inline bool      IsSimulation();

    // Classification operations
    inline void      UseCosineMeasure();
    inline void      UseFANN();

    //Data operations
    inline bool      IsSignalData();
    inline void      StopCapture();
    inline double*   GetSignalData(int sensor_id, double *signal_power); //Returns actual captured
        signal data. Also stores signal power to given pointer
    inline float*    GetSpectrumData(int sensor_id); //Returns actual captured FFT data
    inline float*    GetTimeStamps();
    inline int      Record(bool start);           // Records raw data from headset for future use
    inline int      SwapBuffers();

```

```

inline bool    IsSwapped(void);
inline int     SaveData(const char* name); // Save recorded data to file
inline int     LoadData(const char* name); // Load recorded data from file
inline double* GetLoadedData(int sensor_id); //Returns data loaded from file

// Action operations
inline int     CreateAction(const char* name);
inline int     AddActionRecords(const char* name, unsigned int* from, unsigned int* to, int
count); //Add all records marked as same action to action class of given name
inline int     GetActionNoRecords(const char* name);
inline double* GetActionSignalData(const char* name, unsigned int channel_id, unsigned
int record_id, unsigned int* no_samples); //Returns pointer to signal data of given record id
for one specified sensor and save number of values of the record to last parameter
inline float* GetActionSpectrumData(const char* name, unsigned int channel_id, unsigned
int record_id, unsigned int* no_samples); //Returns pointer to FFT data of given record id
for one specified sensor and save number of values of the record to last parameter
inline bool    IsAction(char* name, float* strength);

private:

void* manager;
int previous_action;
int current_action;
bool is_simulation;

```

Výpis 1: Přístupové metody třídy EEG_IO_INTERFACE

```
int FFT_forward(float* input, float* buffer, cufftComplex* data, cufftHandle plan, const int count
, float* output)
{
    cufftResult err;

    float max = 1.0f;
    float value = 0.0f;
    float real = 0.0f;
    float img = 0.0f;

    cudaMemcpy(data, input, count*sizeof(float), cudaMemcpyHostToDevice);

    err = cufftExecR2C(plan, (cufftReal*)data, data);
    if (err != CUFFT_SUCCESS)
        return 1;

    if (cudaDeviceSynchronize() != cudaSuccess)
    {
        printf ("Cuda_error:_Failed_to_synchronize\n");
        return 2;
    }

    cudaMemcpy(buffer, data, (count/2)*sizeof(cufftComplex), cudaMemcpyDeviceToHost);

    for(int i = 0; i < count/2; i++)
    {
        real = buffer[i*2];
        img = buffer[i*2 + 1];
        value = sqrtf (real*real + img*img);

        if (i >= 5)
            buffer[i] = value;
        else
            buffer[i] = 0.0f;
    }

    buffer[50] = 0.0f;
    memcpy(output, buffer, count/2*sizeof(float));

    return 0;
}
```

Výpis 2: Funkce pro výpočty spektrální analýzy.

```

inline int ActionManager::CompareCosineMeasure(float** spectrum_data, unsigned int
    first_channel)
{
    unsigned int no_s = SPECTRUM_WIDTH;
    unsigned int no_c = this->no_channels;
    unsigned int data_count = no_s * no_c;
    unsigned int result_size = 0;
    unsigned int index = 0;
    float* result_data;
    unsigned int* result_action;

    float* input = new float[no_c*no_s];

    //Loading action data
    for (unsigned int i = 0; i < this->actions.size(); i++){
        if (!this->actions.at(i).IsLoaded()) this->actions.at(i).Load(this->path);
        result_size += this->actions.at(i).GetNoRecords();
        this->actions.at(i).SetResCount(0);
    }
    result_data = new float[result_size];
    result_action = new unsigned int[result_size];

    for (unsigned int j = 0; j < this->no_channels; j++)
        memcpy(&input[j*no_s], &spectrum_data[j + first_channel][0], no_s * sizeof(float));

    // Filtering
    for (unsigned int j = 0; j < data_count; j++){
        input[j] -= this->reference_action_sample[j];
    }

    // Compares data with all actions
    for (unsigned int i = 0; i < this->actions.size(); i++){
        this->actions.at(i).Compare(input, &result_data[index]);
        for (unsigned int j = 0; j < this->actions.at(i).GetNoRecords(); j++){
            result_action[index + j] = (unsigned int)i;
        }
        index += this->actions.at(i).GetNoRecords();
    }

    //Sort of two arrays
    unsigned int c = 0;
    float tmp_f;
    unsigned int tmp_i;
    for (unsigned int i = 0; i < result_size; i++){
        c = 0;
        for (unsigned int j = 0; j < result_size - i - 1; j++){
            if (result_data[j + 1] > result_data[j]){
                tmp_f = result_data[j + 1];
                result_data[j + 1] = result_data[j];
                result_data[j] = tmp_f;

                tmp_i = result_action[j + 1];
                result_action[j + 1] = result_action[j];
            }
        }
    }
}

```

```
        result_action[j] = tmp_i;
        c++;
    }
}
if (c == 0) break;
}

//Best action
for (unsigned int i = 0; i < COSINE_MEASURE_RESULT_LIMIT; i++){
    this->actions.at(result_action[i]).IncResCount();
}

unsigned int max = this->actions.at(0).GetResCount();
index = 0;
for (unsigned int i = 1; i < this->actions.size(); i++){
    if (this->actions.at(i).GetResCount() > max){
        max = this->actions.at(i).GetResCount();
        index = i;
    }
}
```

Výpis 3: Klasifikace pomocí kosinové míry.

```
inline int ActionManager::CompareFANN(float** spectrum_data, unsigned int first_channel)
{
    unsigned int no_s = SPECTRUM_WIDTH;
    unsigned int no_c = this->no_channels;
    unsigned int data_count = no_s * no_c;
    int index = 0;
    fann_type* output;
    float output_value;

    float* input = new float[no_c*no_s];


    for (unsigned int j = 0; j < this->no_channels; j++)
        memcpy(&input[j*no_s], &spectrum_data[j + first_channel][0], no_s * sizeof(float));

#ifdef FILTER
    // Filtering
    for (unsigned int j = 0; j < data_count; j++){
        input[j] -= this->reference_action_sample[j];
    }
#endif

    output = this->fann->run(input);
    output_value = output[0];


    index = (int)output_value;
    float tmp = output_value - index;
    if (tmp > 0.5f)
        index++;
}
```

Výpis 4: Klasifikace pomocí neuronové sítě.



Obrázek 17: První skupina prvků grafického rozhraní. Slouží k ovládání zařízení, sledování aktuálního signálu včetně pořizování záznamů a umožňuje přístup k zobrazení uložených vzorků.

Použití zde implementované knihovny bylo realizováno přes grafické rozhraní, které je součástí demo aplikace vyvíjené Bc. Jakubem Rodzenákem současně s vývojem této knihovny. Toto grafické rozhraní má dvě hlavní části. Levá část je rozdělena na tři skupiny a obsahuje prvky pro ovládání komunikace se zařízením, práci s uloženými daty a vytvořenými trénovacími vzorky akcí, které mají být následně detekovány. Úvodní skupina obsahuje ovládání samotného headsetu, kde jsou tlačítka pro připojení zařízení, výběr zařízení, výběr metody analýzy dat a její zobrazení, spuštění záznamu čtených dat pro pozdější použití a zobrazení dat již vytvořených akcí. Tato úvodní skupina obsahuje také informace o stavu připojení zařízení a aktuálním stavu jeho interní baterie. Možnosti výběru zařízení a metody analýzy přijímaných dat jsou součástí univerzálního přístupu k implementaci knihovny i aplikace, avšak pro konkrétní experimenty v této práci nejsou tyto možnosti využity, jelikož experimenty byly prováděny pouze se zařízením EPOC a k analýze EEG signálu byla použita pouze rychlá Fourierova transformace. V pravé části obrazovky jsou pak zobrazena data přijímaná ze zařízení. Toto zobrazení má dva režimy. První režim slouží k zobrazení pouze EEG signálu, kde jsou zobrazeny poslední dvě sekundy přečtených dat. Ve druhém režimu jsou současně zobrazeny také spektrální analýzy aktuálních částí EEG signálu. Rozložení výše zmíněných prvků je zobrazeno na obr. 17, kde je použito režimu zobrazení jak EEG signálu, tak jeho spektrální analýzy. Zobrazení pravé části lze přepnout na vizualizaci kvality signálu na jednotlivých elektrodách podle systému 10/20, který byl popsán dříve v podkapitole *Záznam.2.1* Toto zobrazení je ukázáno na obr. 18. Je podobné vizualizaci v ovládacím software headsetu




Obrázek 18: Zobrazení aktuální kvality kontaktu jednotlivých elektrod, tak jak je přijímána ze zařízení. Umožňuje tak zajistit správné umístění zařízení na hlavě a správné rozložení elektrod.

EPOC a je zde implementováno z důvodu usnadnění použití headsetu a rovněž z důvodu univerzálnosti aplikace. Po pořízení záznamu části EEG signálu je využita druhá skupina ovládacích prvků v levé části. Tato skupina slouží k vytváření referenčních vzorků konkrétní akce, která má být následně rozpoznávána. Je zde možnost otevřít soubor s dříve uloženým záznamem EEG signálu. Tento záznam se pak zobrazí v pravé části okna, kde je možno vybrat úseky zachycující mozkovou aktivitu odpovídající akce, pro kterou chceme trénovací sadu vytvořit. Označenou sadu je zde možno také uložit. Použití této části grafického rozhraní je zobrazeno na obr. 19. Takto označená data se uloží do struktury programu, kde se na označených vzorcích provede spektrální analýza. Veškerá data takto vytvořené akce se uchovávají jak v paměti programu, tak také na disku v podobě binárních souborů. Při dalším spuštění aplikace se pak vždy veškeré takto uložené vzorky načtou zpět do paměti programu. Záznamy částí EEG signálu stejně jako označené trénovací vzorky se ukládají do binárních souborů umístěných ve speciálních adresářích. U uložených dat akcí se vytvářejí dva soubory, zvlášť soubor pro data signálu a zvlášť soubor pro data frekvenční analýzy. Pro každou akci se vytváří pouze jeden soubor od každého druhu a obsahuje data ze všech trénovacích vzorků všech kanálů. Třetí skupina ovládacích prvků v levé části slouží ke správě štítků, jimiž se v dříve popsaném postupu označují požadované části EEG signálu. V jednom záznamu EEG signálu je možno označit několik akcí různými štítky. Při ukládání akce se pak uloží vždy jen jedna podle právě zvoleného štítku ve druhé sadě ovládacích prvků, která byla popsána dříve. Součástí grafického rozhraní je také možnost zobrazení uložených sad vzorků pro jednotlivé akce viz



Obrázek 19: Druhá skupina ovládacích prvků, která slouží k označování a ukládání trénovacích vzorků pro jednotlivé akce. Pravá část obsahuje záznam EEG signálu, na kterém se zmíněné vzorky vybírají.

obr. 20. Tyto vzorky jsou zobrazovány vždy pro jeden zvolený kanál vybrané akce a je možno zároveň zobrazit i příslušná frekvenční spektra. Výše popsané grafické rozhraní neřídí spouštění klasifikačních metod ani jejich výběr. Tyto operace jsou řízeny přímo aplikací v prostředí OpenGL, kde se také spouští toto grafické prostředí. Přímou z aplikace lze také navíc řídit připojení a odpojení zařízení a sledovat jeho stav.



Obrázek 20: V téhle části programu je možné zobrazit data předem označených a uložených vzorků akcí. Jsou zobrazovány vždy všechny záznamy dané akce pro zvolený kanál.

5 Testování


Tato kapitola se bude zabývat testováním zařízení EPOC pomocí knihovny vytvořené v této práci. Budou zde popsány tvary EEG signálu při vykonávání určitých akcí. Dále jsou prováděny testy detekce těchto akcí pomocí zmíněného zařízení. Popsány budou také výsledky jednotlivých klasifikačních metod.

Testování bylo důležitou částí této práce, protože určovalo konečný výstup práce na základě schopností testovaného zařízení. Všechny testy, které jsou popsány níže, byly spouštěny na výše zmíněném počítači Lenovo, jehož parametry jsou popsány v podkapitole 4.1. Pro potřeby testování byla pro ovládání knihovny použita demo aplikace. Přes její grafické rozhraní a ovládací prvky byly řízeny operace knihovny při provádění níže popsaných experimentů. Testování se provádělo v několika fázích. Bylo zaměřeno na úroveň změn tvaru EEG signálu při provádění testovaných činností, jejich vlivu na frekvenční spektrum. Dále na schopnosti automatické detekce prováděných akcí a přesnost jednotlivých metod. Následující testování se zabývá pouze akcemi, které nespádají do množiny akcí, jež je možné rozpoznávat přímo pomocí SDK a software dodávanému k testovanému zařízení. Nejsou zde tedy zahrnuty detekce obličejových výrazů jako například mrkání očí nebo úsměv, Rovněž zde nejsou testovány detekce emocí ani kognitivního myšlení. Během všech testů byl kladen důraz na maximální kvalitu kontaktů elektrod.

5.1 Deformace EEG signálu

Testy v této sekci byly zaměřeny na tvar EEG signálu při provádění určitých akcí. Účelem bylo zjistit, zda jsou akce, které chceme následně rozpoznávat dostatečně viditelné na EEG signálu. To proto, že vytváření trénovacích vzorků mělo být prováděno ručně po nahrání určitého úseku EEG signálu, ve kterém bylo několikrát opakováno provádění stejné akce. Jelikož účelem celé práce bylo zjistit použitelnost zařízení k detekci převážně motorických akcí nesouvisejících s obličejovou částí, byly pro testy naplánovány různé pohyby horních a dolních končetin a pohyb celé hlavy. Hlavní zaměření se pak týkalo detekce akcí horních končetin. V případě pohybu hlavy šlo o detekci z elektrod snímajících EEG signál nikoliv o analýzu výstupu vestavěných gravitačních čidel. Ačkoliv se deformace signálu většinou projevují na více kanálech, některé kanály bývají výraznější podle konkrétní akce. V následujících popisech jsou uvedeny srovnávací vzorky z jednoho kanálu, tak aby bylo možno porovnat vliv jednotlivých akcí. V aplikaci se ovšem používají pro klasifikaci všechny kanály současně jako celek.


- **Klidový stav:** Záznam EEG signálu pro tento klidový stav byl nahrán samostatně v uvolněné poloze v sedě. Tímto způsobem se eliminoval vliv stažení některých svalů v těle, který by mohl kolidovat s motorickými akcemi, které se měly rozpoznávat. V průběhu testů se ukázalo, že klidového stavu je obtížné docílit. Ukázka nahraných vzorků klidového stavu na jednom z kanálů je vidět na obr. 21
- **Zdvih paže:** Tento test se zabýval projevem pohybů celé paže na EEG signálu. Byl prováděn ve stoje a paže byla zvedána do strany celá, a to v natažené poloze po




Obrázek 21: EEG signál při klidovém stavu na jednom z kanálů

celou dobu zdvihu. Aby byla poznat změna na EEG signálu, bylo třeba mít při zdvihu svaly pořád napnuté, protože při běžném zvednutí se tato akce na EEG signálu neprojevovala. Ukázka nahraných vzorků pohybu paže je vidět na obr. 22. Z ukázek je vidět, že při pohybu paže se ve frekvenčním spektru objevují nízké frekvence v daleko vyšší koncentraci než v klidovém stavu. Také se zvýšil výskyt frekvencí v oblasti 25Hz .


- **Ohyb paže v lokti:** Tato akce představovala ohnutí paže v lokti směrem k tělu, v této poloze setrvat a zjistit jak se tento pohyb projeví na EEG signálu. Změny signálu byly podobné jako u zdvihu celé paže, avšak nárůst nízkých frekvencí nebyl tak výrazný. Projevoval se také velmi mírný nárůst výskytu frekvencí v pásmu mezi 40Hz a 80Hz . Příklady nahraných vzorků je možno vidět na obr. 23.
- **Sevření dlaně:** Předposledním testem z oblasti horních končetin je pokus o rozpoznání sevření dlaně. Pořízení trénovacích vzorků bylo vykonáno v sevřeném stavu. V případě tohoto testu byla deformace EEG signálu velice mírná a vykazovala různé vzory na jednotlivých kanálech. Na některých se objevoval nárůst nízkých frekvencí, kdežto na jiných se tento nárůst neprojevoval, ale místo toho se objevoval nárůst výskytu frekvencí okolo 60Hz . Pro porovnání s ostatními testy je vzorek z příslušného kanálu vyobrazen na obr. 24.
- **Pohyby prstů:** Tyto pohybové akce byly příliš slabé na to, aby je bylo možné pozorovat na EEG signálu pořízeném testovacím zařízením. Nebylo tak možné vytvořit trénovací vzorky pro další fázi testování.
- **Zdvih nohy a dřep:** V případě pohybů nohy nebylo možné při sledování EEG záznamu rozeznat tuto akci ani změnu ve frekvenční analýze, která by tuto akci identifikovala. Proto opět nebylo možné vytvořit testovací vzorky pro otestování roz-



Obrázek 22: EEG signál při pomalém soustředěném zdvihu pravé paže



Obrázek 23: EEG signál při ohybu paže v lokti směrem k tělu a jeho držení v této poloze




Obrázek 24: EEG signál při sevření pěsti a její držení v této poloze

poznání. Stejně jako v případě nohou, nebylo možné rozlišit v EEG signálu pohyby celého těla jako je dřep nebo předklon.


- **Náklon hlavy:** Tento test představoval naklonění hlavy na stranu a setrvání v této poloze. Po chvíli byl proveden návrat hlavy do původní polohy. Frekvenční spektrum zde testované akce je velmi blízké klidovému stavu, jelikož zde není tak výrazný nárůst výskytu nízkých frekvencí jako v případech pohybů paže. Je zde ovšem mírný nárůst výskytu frekvencí v pásmu mezi 20Hz a 80Hz . Na obr. 25 je vidět část EEG signálu při naklánění hlavy a při setrvání v nakloněné poloze. Při pohybu hlavy zpět do původní polohy se na EEG signálu objevuje výrazný pokles amplitudy, který je vidět na obr. 26. Výše uvedené informace popisují náklon hlavy na pravou stranu. V případě náklonu hlavy na stranu levou je deformace EEG signálu podobná, avšak na začátku náklonu se projevuje pokles amplitudy a při návratu do původní polohy se objevuje naopak mírný nárůst amplitudy EEG signálu.
- **Rotace hlavy:** Tento poslední test zahrnoval rotaci hlavy na levou a pravou stranu a setrvání v této poloze po krátkou dobu. Tato akce se na EEG signálu projevovala výraznějším nárůstem frekvencí v pásmu mezi 20Hz a 90Hz jak je vidět na obr. 27. Nízké frekvence zůstaly blízké klidovému stavu nebo se vyskytoval jejich mírný nárůst. Trénovací vzorky byly pořízeny při rotaci hlavy směrem doleva, protože deformace EEG signálu byla při pohybu na tuto stranu výraznější.

5.2 Rozpoznání


V následujících testech se vždy provádí pokusy o rozpoznání požadované akce od klidového stavu. Pro klasifikační funkce jsou tedy k dispozici pouze dvě sady trénovacích



Obrázek 25: EEG signál při náklonu hlavy směrem k rameni na pravou stranu



Obrázek 26: Deformace EEG signálu při návratu hlavy do vzpřímené polohy po předěšlém náklonu na stranu



Obrázek 27: EEG signál při rotaci hlavy směrem doleva

vzorků, mezi kterými se musí rozhodnout, protože podobnost mezi frekvenčními analýzami je příliš vysoká a není možné přesvědčivě rozpoznávat několik akcí zároveň mezi sebou. Příčinou této podobnosti může být skutečnost že motorické akce, o které se tyto testy zajímají, se projevují hlavně v pásmu velmi nízkých frekvencí kolem 5Hz . Navíc už samotné udržení klidového stavu je velmi obtížné. Před samotným testováním detekce jednotlivých akcí na reálné osobě byly pro každou níže uvedenou akci pořízeny kromě trénovacích vzorků také vzorky testovací. Jejich klasifikací byla zjištěna přesnost použitých klasifikačních metod. Klasifikace testovací sady vzorků probíhala pomocí stejných operací jako následná klasifikace aktuálních dat v reálném čase. V následujících testech jsou v tabulkách také uvedeny statistické veličiny pro každý test. Jde o citlivost (TPR), specifčnost (SPC) a celkovou přesnost (ACC). Pro výpočty těchto veličin jsou použity standardní hodnoty TP , TN , FP , FN . Označením *Akce* v tabulkách je pak myšlena vždy ta akce, u které je tabulka uvedena.

- **TP - true positive** - Počet správně detekovaných akcí.
- **TN - true negative** - Počet správně detekovaných klidových stavů.
- **FP - false positive** - Počet falešných detekcí akce.
- **FN - false negative** - Počet nesprávně detekovaných klidových stavů.

Statistické veličiny jsou určeny následujícími vzorci.

$$TPR = \frac{TP}{TP + FN} \quad (2)$$

$$SPC = \frac{TN}{FP + TN} \quad (3)$$

$$ACC = \frac{TP + TN}{TP + FP + TN + FN} \quad (4)$$

- **Zdvih paže:** Testovací sada pro tuto akci obsahovala 33 vzorků pro klidový stav a 50 vzorků pro samotnou akci. Výsledky ukazuje tabulka 4 a 5.

	Detekce	
	Klid	Akce
Klid	6	27
Akce	50	0
Citlivost	0.00	
Specifičnost	0.18	
Přesnost	0.07	

Tabulka 4: Výsledky klasifikace testovací sady pro zdvih paže pomocí kosinové míry

	Detekce	
	Klid	Akce
Klid	33	0
Akce	19	31
Citlivost	0.62	
Specifičnost	1.00	
Přesnost	0.77	

Tabulka 5: Výsledky klasifikace testovací sady pro zdvih paže pomocí neuronové sítě

Zde je vidět, že klasifikace pomocí kosinové míry v tomto testu neuspěla a neuronová síť vykazuje více než polovinu falešných rozpoznání klidového stavu. Následné testy však ukázaly, že lze rozpoznat pomalé zvednutí paže se staženými svaly od klidového stavu, avšak toto rozpoznání bylo velmi náchylné na udržení klidového stavu. Proto se často stávalo, že akce byla falešně rozpoznána dokud se nedocílilo správného klidového stavu, jaký byl předem nahrán. Toto zjištění mírně koliduje s výsledky klasifikace testovací sady, jelikož při detekci v reálném čase sice docházelo falešným detekcím klidového stavu při použití neuronové sítě, avšak mnohem častější byly falešné detekce akce samotné. Po chvíli tréninku bylo možné docílit snížení falešných detekcí na minimum a neuronová síť pak rozpoznala každý prováděný pokus. Jelikož je však návrat do klidového stavu velmi pozvolný, detekce zdvižení paže byla většinou signalizována o něco déle, než došlo k opětovnému uklidnění EEG signálu. Test také ukázal že rozpoznání funguje stejně jak pro pravou paži, tak i pro paži levou.

- **Ohyb paže v lokti:** V tomto případě byla testovací sada složena ze stejných vzorků pro klidový stav jako v předchozím případě a z 56 vzorků pro akci. Tabulky 6 a 7 ukazují, že kosinová míra opět nevykazuje uspokojivé výsledky. Oproti tomu jsou výsledky neuronové sítě značně lepší než v předchozím případě a rozpoznání by tedy mělo být možné. Testy v reálném čase pak ukázaly, že po správném natrénování a uklidnění EEG signálu byla neuronová síť schopna rozpoznat každé vykonání akce. Také signalizovala tuto akci po celou dobu jejího trvání. Kosinová míra dle očekávání nedokázala akci správně detekovat. Tento test také vykazoval stejné výsledky jak při testování ve stoje, tak při testování v sedě.
- **Sevření dlaně:** Tato akce patřila z akcí zde testovaných k nejobtížnějším na rozpoznání. Testovací sada zde obsahovala 73 vzorků pro akci a stejné vzorky pro klidový

	Detekce	
	Klid	Akce
Klid	0	33
Akce	46	10
Citlivost	0.18	
Specifičnost	0.00	
Přesnost	0.11	

Tabulka 6: Výsledky klasifikace testovací sady pro ohyb paže pomocí kosinové míry

	Detekce	
	Klid	Akce
Klid	33	0
Akce	5	51
Citlivost	0.91	
Specifičnost	1.00	
Přesnost	0.94	

Tabulka 7: Výsledky klasifikace testovací sady pro ohyb paže pomocí neuronové sítě

stav jako v předchozích případech. Jak je vidět v tabulce 8 a 9, kosinová míra zde sice vykazovala mírné zlepšení detekce akce, avšak nedokázala opět detekovat klidový stav. U neuronové sítě se na základě klasifikace testovací sady daly očekávat výskyty falešných detekcí.

	Detekce	
	Klid	Akce
Klid	0	33
Akce	40	33
Citlivost	0.45	
Specifičnost	0.00	
Přesnost	0.31	

Tabulka 8: Výsledky klasifikace testovací sady pro sevření pěsti pomocí kosinové míry

	Detekce	
	Klid	Akce
Klid	26	7
Akce	0	73
Citlivost	1.00	
Specifičnost	0.79	
Přesnost	0.93	

Tabulka 9: Výsledky klasifikace testovací sady pro sevření pěsti pomocí neuronové sítě

Následné testování potvrdilo, že kosinová míra opravdu není schopna akci rozpoznat. Bylo také zjištěno, že rozpoznání této akce pomocí neuronové sítě je obtížnější než v předchozích případech, hlavně kvůli výskytům falešných detekcí. Obtížné rozpoznání bylo způsobeno slabší deformací EEG signálu při provádění této akce. Rozpoznání skutečně prováděné akce však bylo vždy detekováno správně po celou dobu trvání akce.

- **Náklon hlavy:** Testovací sada pro tuto akci měla 59 vzorků. Výsledky klasifikace testovací sady v tomto případě opět ukázaly, že kosinová míra nedokáže akci správně rozpoznat. U neuronové sítě výsledky naznačovaly přítomnost falešných detekcí akce, jak ukazuje tabulka 10 a 11. Rozpoznání náklonu hlavy v reálném čase bylo mírně obtížnější než rozpoznávání pohybů paže v prvních dvou případech. Jelikož je signál této akce výrazně podobnější klidovému stavu, bylo rozpoznávání v tomto případě náchylnější na falešnou detekci. Po docílení dostatečně stabilního klidového stavu, však bylo možné náklon hlavy rozpoznat. Jak naznačovaly výsledky

	Detekce	
	Klid	Akce
Klid	1	32
Akce	57	2
Citlivost	0.03	
Specifičnost	0.03	
Přesnost	0.03	

Tabulka 10: Výsledky klasifikace testovací sady pro náklon hlavy pomocí kosinové míry

	Detekce	
	Klid	Akce
Klid	32	1
Akce	7	52
Citlivost	0.88	
Specifičnost	0.97	
Přesnost	0.91	

Tabulka 11: Výsledky klasifikace testovací sady pro náklon hlavy pomocí neuronové sítě

testovací sady, povedlo se zde opět rozpoznání pouze pomocí neuronové sítě, která také potřebovala více pokusů k natrénování do dostatečně přesného stavu. Akce byla detekována jak při náklonu hlavy doprava, tak při náklonu doleva, jelikož trénovací vzorky obsahovaly pouze části EEG signálu během náklonu. Jejich součástí nebyly tedy změny amplitudy při návratu hlavy zpět do původní polohy. Tento test také ukázal, že na rozdíl od případu, kdy byla paže ohnuta v lokti a přitažena k tělu, nebyla detekce náklonu hlavy trvalá po celou dobu, kdy byla hlava nakloněna. Byl tedy detekován náklon a poté došlo pozvolna k uklidnění signálu a akce již nebyla nadále detekována. I zde rozpoznání fungovalo jak ve stoje, tak v sedě.

- **Rotace hlavy:** Poslední sada testovacích vzorků obsahovala 54 vzorků pro tuto akci. V tabulce 12 a 13 je vidět, že ačkoliv jsou výsledky kosinové míry mírně lepší než v předchozích případech, ke správné detekci opět nestačí. Avšak výsledky neuronové sítě jsou v tomto případě vynikající.

	Detekce	
	Klid	Akce
Klid	8	25
Akce	41	13
Citlivost	0.24	
Specifičnost	0.24	
Přesnost	0.24	

Tabulka 12: Výsledky klasifikace testovací sady pro rotaci hlavy pomocí kosinové míry

	Detekce	
	Klid	Akce
Klid	33	0
Akce	0	54
Citlivost	1.00	
Specifičnost	1.00	
Přesnost	1.00	

Tabulka 13: Výsledky klasifikace testovací sady pro rotaci hlavy pomocí neuronové sítě

V případě detekce rotace hlavy v reálném čase se ukázalo, že je možné tuto akci detekovat pomocí neuronové sítě, avšak docházelo ke zvýšenému počtu falešných detekcí, i přes to, že výsledky na testovací sadě byly bezchybné. Tyto falešné detekce byly způsobeny velkou podobností frekvenčního spektra s klidovým stavem, jelikož při vykonávání této akce nedocházelo k nárůstu výskytu nízkých frekvencí

jako tomu bylo u pohybů celé paže. Po uklidnění signálu, které trvalo opět o něco déle, byla neuronová síť schopna rozeznat rotaci hlavy a to v obou směrech, ačkoliv trénovací vzorky byly pořízeny pouze při rotaci na levou stranu. Na rozdíl od předchozích akcí, však šlo rotaci hlavy detekovat pouze ve stoje.

Rozpoznávání těchto akcí bylo často obtížné reprodukovat. Ačkoliv ve výše uvedených testech bylo možné výsledky opakovat i po sundání zařízení a jeho opětovném nasazení, bylo různě obtížné docílit nahraného klidového stavu. V případě náklonu hlavy trvalo například přibližně 15 minut, než se začaly objevovat pozitivní výsledky. Vzorky pro náklon hlavy byly sice nahrány těsně před pokusy o rozpoznání avšak klidový stav byl nahrán přibližně o 5 hodin dříve v odpoledních hodinách a jeho docílení bylo pak ve večerních hodinách výrazně obtížnější. Stejně pokusy pak byly provedeny následující den v odpoledních hodinách s naprosto stejnými daty, a v tuto dobu pak bylo možné snadněji udržet potřebný klidový stav a náklon hlavy byl bez problémů rozeznán pomocí neuronové sítě. Dále bylo při testování zjištěno, že dlouhodobé nošení zařízení na hlavě není z důvodu mechanického tlaku na lebku příliš pohodlné. Pokud bylo zařízení nasazeno na hlavě déle jak hodinu, projevilo se to výskytem slabé bolesti s postupně rostoucí intenzitou. Přítomnost této bolesti může ovlivnit samotný EEG signál a to jak přímo, tak nepřímo, kvůli rozptýlení pozornosti a koncentrace.

Náročnost výpočtů prováděných v této knihovně na hardware počítače nebyla vysoká. Běh těchto výpočtů neměl žádný vliv na průběh testů ani na běh demo aplikace, která musela být během testování spuštěna. Největší časovou zátěží byl trénink neuronové sítě, který se navíc musel v mnoha případech několikrát opakovat. Jednotlivý trénink pak trval přibližně 20s. Někdy se síť natrénovala na požadovanou chybu do 1000 epoch, avšak někdy bylo zapotřebí i více než 5000 epoch. Trénování bylo omezeno na 10000 epoch, takže pokud se za tuto dobu neuronová síť nedokázala natrénovat na požadovanou hodnotu chyby 0,001, byl trénink sítě opakován. Ve všech výše popsanych testech, kde byla neuronová síť použita se podařilo nakonec požadované chyby dosáhnout.

5.3 Vyhodnocení

Z použitých způsobů klasifikace se ukázala jako použitelná pouze klasifikace pomocí neuronové sítě. Ta po natrénování vykazovala velmi dobré výsledky v dříve popsanych testech. Klasifikace pomocí zde implementované kosinové míry nebyla schopna detekovat klidový stav, docházelo proto k falešné detekci testované akce.

Celkově výše popsané testy ukázaly, že je možné detekovat i motorické akce některých částí lidského těla, ale jde vždy o rozpoznání určité jedné akce od klidového stavu. Nelze detekovat výše popsané akce při provádění dalších činností jako například chůze nebo soustředění se na něco úplně odlišného. Detekce je velice citlivá na rušení, které může být způsobeno jako otřesy například při chůzi, tak deformací EEG signálu způsobených jinou mozkovou aktivitou. Rovněž není možné detekovat uvedené akce od sebe navzájem. Takovéto pokusy sice byly provedeny, ale trénování neuronové sítě bylo velice obtížné. Pokud se to přece jen podařilo, byly výsledky neuspokojivé. Příčinou byla

vysoká podobnost frekvenčního spektra jednotlivých akcí. Tyto problémy s detekcí motorických akcí jsou způsobeny hlavně nízkým počtem elektrod na zařízení a také jejich umístěním. To bylo navrženo pro primární účely zařízení, a proto není dostatek elektrod v oblastech hlavy, které se starají o testované pohyby. Ačkoliv je tedy možné motorické akce rozpoznat, není rozlišení takovéto detekce dostatečné, aby se přístroj dal tímto způsobem použít k ovládání například robotické paže nebo jiných podobných zařízení.

6 Závěr

Cílem práce bylo otestování možností BCI systému Emotiv EPOC. Konkrétně šlo o zjištění, zda je možné pomocí tohoto zařízení detekovat motorické akce částí lidského těla. Tudíž takové akce, pro které nebylo toto zařízení primárně konstruováno. Hlavním úkolem bylo prozkoumat, zda by bylo možné zařízení použít k ovládaní například robotické paže pomocí snímání EEG signálu. Za tímto účelem byla implementována knihovna programovacího jazyka C++, která měla za úkol získat surová data EEG signálu ze zařízení a ty následně analyzovat. K získání dat byly použity potřebné funkce SDK dodávaného k zařízení. Analýza získaných dat probíhala pomocí rychlé Fourierovy transformace, jejíž výpočty byly prováděny na grafickém akcelérátoru NVIDIA pomocí technologie CUDA. Výsledkem výpočtů Fourierovy transformace byla sada spektrálních analýz pro jednotlivé kanály EEG signálu. Tyto spektrální analýzy byly veličiny vstupující do klasifikačních funkcí, které měly za úkol pomocí předem vytvořených referenčních vzorků detekovat v EEG signálu prováděné akce.

Testování ukázalo, že ze dvou použitých metod klasifikace byla úspěšná pouze metoda využívající neuronové sítě. Bylo zjištěno, že pomocí dat EEG signálu poskytovaných testovaným zařízením lze detekovat pohyby paže a hlavy. Nelze je však detekovat současně mezi sebou nýbrž jejich přítomnost oproti klidovému stavu. Celkově však docházelo k častým falešným detekcím, pokud nebylo docíleno dostatečně klidného klidového stavu. Na základě provedených testů lze říci, že ačkoliv bylo možné detekovat několik různých pohybů v oblasti paže, nebyla tato detekce dostatečně přesná a citlivá pro použití s původním záměrem práce. Ovládání robotických paží tímto způsobem by nebylo praktické. Samotné výpočetní operace prováděné při použití zde implementované knihovny nejsou výkonově příliš náročné. Současná technika tak není pro použití této knihovny limitující. Knihovna však využívá technologie paralelních výpočtů na grafických procesorech NVIDIA, a je tedy nutné toto knihovnu používat pouze na výpočetní technice vybavené potřebným zařízením.

V případě potřeby využití této knihovny v aplikacích s jinými zařízeními snímajícími EEG signál, je knihovnu možné v budoucnu rozšířit o SDK těchto zařízení. Rovněž je možné v případě potřeby použít jiné metody výpočtu Fourierovy transformace tak, aby nevyžadovaly použití pouze grafických procesorů NVIDIA. V neposlední řadě je také možné v případě potřeby, knihovnu rozšířit o komplexnější metody analýzy EEG signálu, které by doplnily stávající analýzu pomocí rychlé Fourierovy transformace.

Martin Barteček

7 Reference

- [1] Berger, Hans, *Hans Berger on the electroencephalogram of man : the fourteen original reports on the human electroencephalogram*, Elsevier Pub. Co., c1969. ISBN-13: 978-0444407399 ISBN-10: 0444407391
- [2] Haas, L. F., *Hans Berger (1873–1941), Richard Caton (1842–1926), and electroencephalography*, c2003. PMID: 12486257
- [3] Swartz, Barbara E., *The advantages of digital over analog recording techniques*, 1998. PMID 9741771
- [4] Niedermeyer, E.; Silva, F.L., *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*, c2004. ISBN 0-7817-5126-8
- [5] Georgopoulos, A.; Lurito, J.; Petrides, M.; Schwartz, A; Massey, J., *Mental rotation of the neuronal population vector*, c1989. PMID: 2911737
- [6] Saeid Sanei; Chambers, A. J., *EEG Signal Processing*, Wiley-Interscience c2007. ISBN-13: 978-0470025819 ISBN-10: 0470025816
- [7] Nicholas, W., *CUDA Handbook: A Comprehensive Guide To GPU Programming*, c2013. ISBN-13: 978-0321809469 ISBN-10: 0321809467
- [8] Farber, R. *CUDA Application Design and Development*, c2011. ISBN-13: 978-0123884268 ISBN-10: 0123884268
- [9] Sanders, J.; Kandrot, E., *CUDA by Example: An Introduction to General-Purpose GPU Programming*, c2010. ISBN-13: 978-0131387683 ISBN-10: 0131387685
- [10] Wen-Mei Hwu; Kirk, D., *Programming Massively Parallel Processors: A Hands-on Approach (Applications of GPU Computing Series)*, c2010. ISBN-13: 978-0123814722 ISBN-10: 0123814723
- [11] Drongelen, W., *Signal Processing for Neuroscientists: An Introduction to the Analysis of Physiological Signals*, c2006. ISBN-13: 978-0123708670 ISBN-10: 0123708672
- [12] Freeman, W.; Rodrigo Quian Quiroga, *Imaging Brain Function With EEG: Advanced Temporal and Spatial Analysis of Electroencephalographic Signals*, c2012. ISBN-13: 978-1461449836 ISBN-10: 1461449839
- [13] Dickter, Cheryl L.; Kieffaber, Paul D., *EEG Methods for the Psychological Sciences*, c2013. ISBN-13: 978-1446283004 ISBN-10: 1446283003
- [14] Williams, Janett, *EEG Signals and New Independent Component Analysis Techniques*, c2014. ISBN-13: 978-3639711608 ISBN-10: 3639711602
- [15] Shanbao Tong; Thankor, Nitish V., *Quantitative EEG Analysis Methods and Applications [With CDROM] (Engineering in Medicine & Biology)*, c2009. ISBN-13: 978-1596932043 ISBN-10: 159693204X

-
- [16] Libenson, Mark H., *Practical Approach to Electroencephalography*, c2009. ISBN-13: 978-0750674782 ISBN-10: 0750674784
 - [17] *Emotiv*[online]. c2014. <<http://emotiv.com>>.
 - [18] *Emotiv EPOC*[online]. c2014. <<http://emotiv.com/epoc.php>>.
 - [19] *Emotiv Insight*[online]. c2014. <<http://emotiv.com/insight.php>>.
 - [20] *NeuroSky®MindWave™*[online]. c2015. <<http://neurosky.com/biosensors/eeg-sensor/biosensors>>.
 - [21] *Cognionics*[online]. c2014. <<http://www.cognionics.com/index.php/products/hd-eeg-systems/64-channel-system>>.
 - [22] *electrodes of International 10-20 system for EEG*[online]. 2010. <http://commons.wikimedia.org/wiki/File:21_electrodes_of_International_10-20_system_for_EEG.svg>.
 - [23] *Op-Amp Differential Amplifier*[online]. 2009. <http://commons.wikimedia.org/wiki/File:Op-Amp_Differential_Amplifier.svg>.
 - [24] *Managing first-time seizures and epilepsy in children*[online]. 2014. <<http://www.cmej.org.za/index.php/cmej/article/view/2390/2175>>.
 - [25] *NVIDIA CUDA*[online]. c2015. <http://www.nvidia.com/object/cuda_home_new.html>.
 - [26] *Brain-computer interface*[online]. 2015. <http://en.wikipedia.org/wiki/Brain-computer_interface>.
 - [27] *Electroencephalography*[online]. 2015. <<http://en.wikipedia.org/wiki/Electroencephalography>>.
 - [28] *Fast Artificial Neural Network Library*[online]. 2015. <<http://leenissen.dk/fann/wp/>>.

A Příloha na CD

Součástí diplomové práce je CD obsahující elektronickou formu práce, zdrojové soubory v podobě projektu pro Microsoft Visual Studio 2013 a zkompilevané knihovny.

Obsah přiloženého CD:

- /Knihovny
- /Projekt_MS_VS_2013
- /Diplomova_prace_Martin_Barteczek.pdf
- /Readme.txt