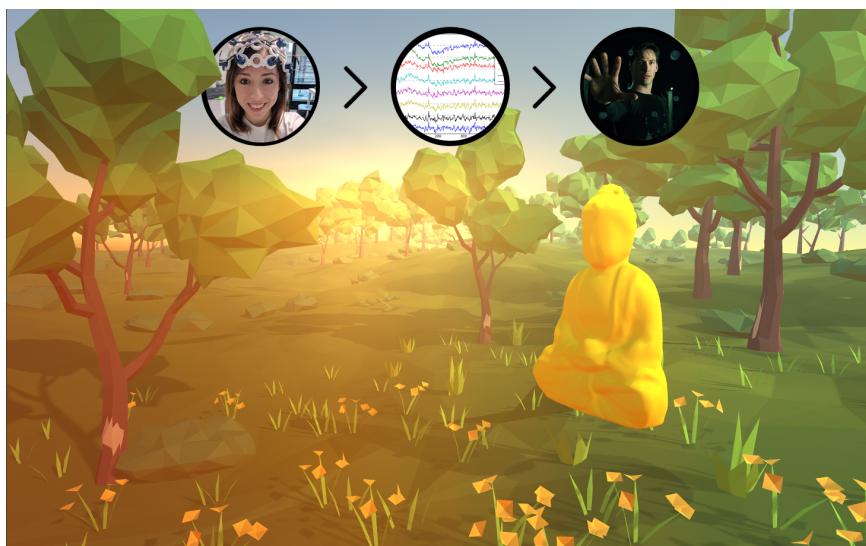


# OVLÁDÁNÍ HRY NEBO APLIKACE POMOCÍ MYŠLENEK

Bc. Jan Jileček\*



## Abstract

Cílem této práce je implementovat dvě myslí ovládané hry. První hra bude sloužit jako alternativní verze klinického neurofeedbacku. Neurofeedback je biofeedback metoda pro léčbu ADHD a dalších kognitivních postižení. Dalším cílem této teze je vytvoření hry ovládané sensorimotorickým kortexem, jinými slovy, představení si pohybu ruky vyprodukuje výstup ve hře, např. herní charakter se pohně doprava. V této práci používám OpenBCI EEG headset a vlastní software pro zachycování a zpracování EEG dat. Jako první krok jsem vyvinul tzv. "Visual Prompter", který předkládá uživateli výzvy, a slouží tak jako víceúčelový sběrač datových sad. Dalším krokem je "Data Extractor", převádějící a analyzující vstupní data (spektrální analýza, připravení datasetu pro neuronovou síť). Hra samotná spoléhá na interpretaci dat z headsetu – k tomu používám detekci mozkových alfa/beta vln pro první hru a pro další hru používám plně propojené konvoluční neuronové sítě (CNN-FC) pro klasifikaci dat. Obojí probíhá v reálném čase a je tak zajištěno ovládání hry. V práci také porovnám více existujících výzkumů, jejich metody a úspěšnost. Dosavadní úspěšnost experimentální sítě je 47%. Potenciální zlepšení na základě výzkumů prezentovaných v této práci je až na 70-80%.

**Keywords:** Neurofeedback, ADHD, OpenBCI, Ultracortex, BCI, mind-controlled game, EEG, ADD, biofeedback, deep convolutional neural networks, brain, prefrontal cortex, motor cortex, meditation, corpus callosum, unity, Istreamer, openvibe, 10-20 system, brain waves

**Supplementary Material:** N/A

\*[xjilec00@stud.fit.vutbr.cz](mailto:xjilec00@stud.fit.vutbr.cz), Faculty of Information Technology, Brno University of Technology

## 1. Úvod

**[Motivace]**Cílem diplomového projektu je hra, která má dvě části. První je vyvinuta pro neurofeedback terapii a druhá implementace je pro demonstraci ovládání hry pomocí motorického kortextu. Neurofeedback hra je psaná v Unity a umožňuje zvadat předmět "silou vůle", nebo by se přeneseně dalo (v kontextu hry) říci "telekineze". Pokud se uživatel soustředí tak, aby měl správný poměr alfa/beta vln v prefrontálním kortextu mozku (poměr alfa a beta vln by měl být v rozmezí 0.7-2.0 a 0-0.7 - alfa vlny se vyskytuje ve frekvenčním pásmu 8-12 Hz a beta vlny 12-38 Hz), pak dojde k aplikaci záporné gravitační síly na herní objekt (socha Buddhy, viz úvodní obrázek). Jakmile soustředěná pozornost ustane, levitující socha spadne a uživatel musí započít znova od začátku.

Druhá hra je zčásti kolaborativní projekt, jehož první fází je aplikace vyvinutá pro akvizici dat – mozkových vln. Na datech mozkových vln je provedena spektrální analýza. Takto obdržená data jsou zpracovávána v reálném čase a ihned klasifikována do 4 tříd (4 směry - up, left, right, down) pro následné ovládání hry - vše v závislosti na detekované motorické činnosti v sensorimotorickém kortextu mozku (představování si pohybu ruky/nohy). Hra má formu bludiště, ve kterém se hráč naviguje pouze silou vlastní mysli. Každý hráč musí před samotnou "ostrou" hrou projít tréninkem, při kterém jsou nasbírána data ve formě jeho mozkových vln, aby se systém adaptoval jeho mozkovým pochodem – k tomu účelu jsou použita data z programu Visual Prompter, který jsem vytvořil pro akvizici EEG dat.

**[Existující výzkumy]** V jednom výzkumu autor použil EEG headset NeuroSky, používající jedinou elektrodu na čele. Jeho cílem bylo ovládat pohyb hada v klasické hře "Snake" na obrazovce. Navrhl metodu pro klasifikaci mrknutí, jelikož ty ovlivňovaly vstupní data nejvíce. Jeho metoda pro detekci mrknutí má úspěšnost 99%. Další směr, kterým se ubral, byl návrh binární úlohy pro detekci "baseline" úrovně mysli a detekci změny tohoto stavu na "mentální počítání". Nejprve se mu tak dařilo s úspěšností 60%, kterou později vylepšil na 90%, ale pouze při otevřených/zavřených očích. Hlavní překážkou v cestě ke kvalitnější klasifikaci byla absence vícero senzorů a nutnost použití pouze jednoho na tvrdě fixovaného na čele. [1] Dalším výzkumníkem je Michal Hlinka a jeho bakalářská práce [2]. Jeho cílem bylo nasbírání praktických dat během jediného trénovacího sezení testovacího subjektu, otestování zda simulace pohybu pomocí videa v trénovací fázi zlepšila úspěšnost při trénování a porovnání původních a vlastních OpenVIBE klasifikátorů. Jeho testovací subjekty podávaly vesměs pozitivní

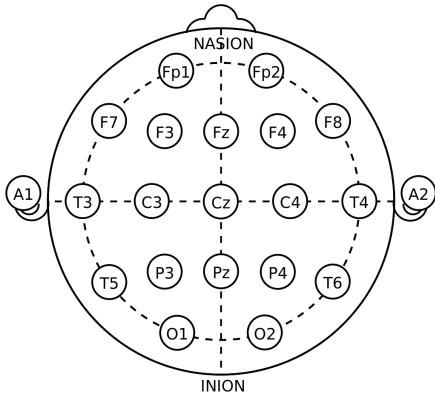
zpětnou vazbu, hraní a celkový průběh experimentů si užívaly. Teoretická úspěšnost klasifikace u něj při hraní byla 64% a reálná úspěšnost při hraní 42%. Někteří ze subjektů se pokusily jeho hru hrát vícekrát a dosáhly lepších výsledků. Stavějíc na výsledcích video simulace během tréninku a ANOVA analýzy, autor došel k závěru, že podpůrná videa při tréninku zlepšují teoretickou úspěšnost na 0.05. Jeho návrhy pro zlepšení trénovacího videa je vylepšení videí takovým způsobem, aby byla více interaktivní, ne tak nudná/nezajímavá a zajistit, aby se testovací subjekt dovedl lépe identifikovat s hercem ve videu. Hlavními poznatkami užitečnými pro tuto práci jsou hlavně následující:

- Autor očekával určité ruchy a šum z headsetu, ale neočekával, že headset bude tak citlivý na pohyby. Díky tomu se rozhodl, že všechny experimenty pro trénovací sadu bude nutné provádět s otevřenýma očima a bez jakýchkoliv pohybů hlavy nebo těla.
- Autor se pokoušel omezit ruchy, a to přidáním meditačních a pozornostních hodnot jako vstup do neuronové sítě, a to pro každý frekvenční rozsah. To se prokázalo jako horší možnost než využívání pouze 5 vstupních rozsahů (alfa - gamma).
- Ve všech kategoriích klasifikace bylo dosaženo dobrých BCI výsledků, kromě klasifikátoru K-NN, K-nearest neighbors, jež není vhodný pro zpracování vícerozměrných dat.

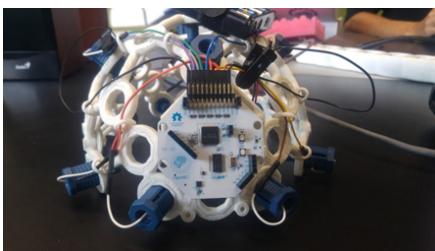
Jeden z nejužitečnějších výzkumu, na kterém budu v této práci stavět nejvíce, je "Multi-Channel Convolutional Neural Networks Architecture Feeding for Effective EEG Mental Tasks Classification" [3]. Chlubí se jednou z nejlepších úspěšností při klasifikaci sensorimotorických aktivit, a to s úspěšností 71% při použití plně propojených konvolučních neuronových sítí (CNN-FC). Ostatní práce používají CSP (Common Spatial Pattern)<sup>1</sup> nebo SVM (Support Vector Machines)<sup>2</sup> pro klasifikaci pohybů končetin do rozdílných tříd. CSP je přímo navržen pro detekci největších rozdílů ve dvou signálech. CNN-FC však má mnohem větší úspěšnost - při opakovém používání a trénování autorem (výhradně jeho EEG vlnami) se byl autor schopen dostat až na úspěšnost klasifikace přes 80%. V práci přiřom využívá hlavně elektrod C3, Cz a C4, detekující EEG signály ze sensorimotorického kortextu (obrázek 1). Používá samozřejmě i elektrody pro prefrontální kortext, ale ty nejsou klíčové pro detekci reálného nebo představovaného pohybu. Na základě

<sup>1</sup>[https://en.wikipedia.org/wiki/Common\\_spatial\\_pattern](https://en.wikipedia.org/wiki/Common_spatial_pattern)

<sup>2</sup>[https://cs.wikipedia.org/wiki/Support\\_vector\\_machines](https://cs.wikipedia.org/wiki/Support_vector_machines)



**Obrázek 1.** Konvenční 10-20 systém pro rozmístění EEG elektrod



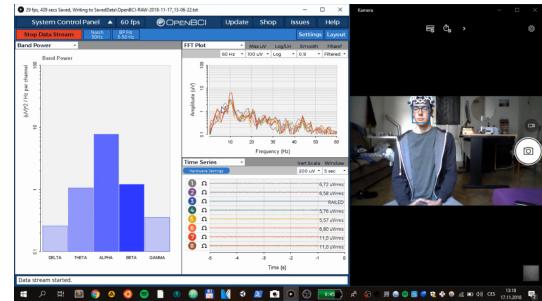
**Obrázek 2.** OpenBCI Ultracortex IV headset

poznatků z tého práce nadále upravují svoji CNN a experimentuji i s umístěním elektrod na centra C3, Cz a C4 a okolí.

## 2. OpenBCI

**[OpenBCI Ultracortex IV]** OpenBCI je open-source BCI (Brain Computer Interface), neboli rozhraní pro komunikaci mezi mozkem a počítačem. Všeobecně se jedná o víceoborové téma, spadající jak do neurologie, psychologie a zpracování signálu, tak do strojového učení. Můžeme říci, že se jedná o systém umělé inteligence, který má více fází, a totož: obdržení signálu, zpracování signálu, získání charakteristik ze signálu, klasifikaci dat a výstup (ovládání PC, robota, real-time biofeedback...). V této diplomové práci je užito OpenBCI Ultracortexu Mark IV. Jedná se o open-source EEG headset použitelný v kombinaci s OpenBCI systémem (obrázek 2). Skeleton headsetu je tisknutelný na 3D tiskárně. Je schopen zaznamenávat mozkovou aktivitu kvalitativně na úrovni hardwaru používaného při vědeckém výzkumu. Hlavní součástí 8-kanálového OpenBCI headsetu je Cyton board (deská). Deska používá RFduino moduly pro bezdrátovou komunikaci pomocí Bluetooth. RFduino jsou založena na Nordic nRF51822 SoC Radio IC. Deska může také komunikovat s Android nebo iOS zařízením přes BLE

OpenBCI Ultracortex spolupracuje se Softwarem OpenBCI GUI. Ten slouží jako mnohoúčelový nástroj pro vizualizaci a filtrování dat, ať už přijatých v reálném



**Obrázek 3.** EEG při meditaci

čase nebo načtených ze souboru. Pro spolupráci OS a GUI je nutné použít přiložený software OpenBCI Hub, který má roli prostředníka mezi zmíněnými zařízeními. GUI může být spuštěno jako samostatná aplikace nebo pomocí Processing (na Javě založený programovací jazyk a nástroj) OpenBCI GUI se skládá z widgetů, které interpretují vstupní EEG data, zobrazují různé statistiky a jinak modulují obdržená data. Na obrázku 3 je zobrazen tzv. "FFT Plot" a "Time Series" a "Band Power". Band Power zobrazuje zastoupení jednotlivých frekvenčních pásem v mozkových vlnách (v tomto případě moje mozkové vlny při meditaci).

### 2.1 Neurofeedback

Části mozku, kterými se v této prací zabývám a používám pro ovládání hry jsou prefrontální kortex a motorická kůra. Prefrontální kortex je zodpovědný hlavně za soustředěnou pozornost, a lze ho posílit pomocí neurofeedbacku. Motorickou kůrou pak budu používat pro ovládání hry. Jednotlivé končetiny budou namapované na klávesy. Testovací subjekt si pak může představovat zvedání pravé ruky, a postava ve vytvořené hře se bude pohybovat doprava. Implementace nástroje pro sběr EEG dat. Prefrontální kortex (PFC) je částí mozku sídlící v přední části, za čelem. Je zodpovědná za plánování komplexních kognitivních úloh, projevování vlastní osobnosti, rozhodovací procesy a tlumení společensky nepřijatelného chování, sebekontrolu, potlačování impulsů a schopnost dokončování úloh. Také zajišťuje vůli jednat v souladu se svými vnitřními cíli a přesvědčeními a udržuje tzv. "pracovní paměť", je tak absolutně nezbytný pro manažerské a vůdcovské schopnosti. PFC je hlavním centrem soustředěné pozornosti a jako takový spoléhá nejvíce na neurotransmitter dopamin. U jedinců s ADHD (porucha pozornosti, impulzivita, rozrušitelnost, zapomnětlivost, roztríštěnost) je prefrontální kortex zpravidla oslaben nebo nevyvinut, takže jejich neschopnost se soustředit je více fyziologického rázu, než psychologického. Důležitou úlohou PFC je také tlumení příchozivých signálů od amygdaly a poskytující tak emocionální regulaci. Skrz techniky zlepšování soustředění (meditace) a ter-

apii neurofeedbackem se však dá negativním ADHD symptomům ulevit a zvýšit tak jedinici kvalitu života. Meditace je jedna z technik používaných pro zlepšení soustředění. Existuje mnoho různých druhů meditace, od meditace dechu, po meditaci v chůzi až po meditaci soustředění se na živly nebo barvy. Dá se říci, že meditace je přirozená forma neurofeedbacku, kdy se meditující soustředí pouze na jeden předmět. [4] Proto je doporučováno při terapii neurofeedbackem současně zavést každodenní meditační rutinu. Je prokázáno, že meditace je jedna z nejsilnějších přirozených metod pro posílení PFC. Motorická kůra je část mozkové kůry mající na starosti plánování, ovládání a provádění vědomých pohybů. Obecně se nachází v přední mozkové kůře.

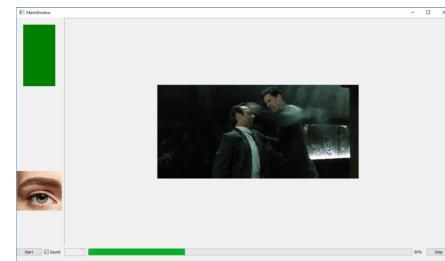
Motorická kůra má 3 hlavní části:

- Primární kortex - je zodpovědný za vytváření neuronových impulsů
- Premotorický kortex - jeho funkce není plně prozkoumána, pravděpodobně je však jeho funkcí příprava na pohyb, synchronizace smyslových vjemů a pohybu a prostorová orientace při uchopování předmětu
- Doplňkový kortex - jeho funkce také není plně známa, má však řadu navrhovaných funkcí, jako plánování pohybu, plánování sekvencí pohybu a koordinaci obou stran těla (např. žonglování)

Ovládání hry pomocí představování si pohybu jednotlivých končetin bylo zvoleno z toho důvodu, že v motorickém kortexu jsou signály těchto činností/představ velice silné, jejich detekce je pak snadnější.

### 3. Visual Prompter

Visual Prompter je nástroj, který jsem vytvořil pro sběr EEG dat od testovacích subjektů. Subjektům je předkládána tzv. "výzva", obsahující textovou instrukci, po níž následuje fáze nahrávání dat z EEG headsetu a videokamery notebooku (pro detekci mrkání). Pro získání prvotního datasetu bylo nutné vytvořit nástroj, který jsem dál použil pro vytvoření několika datových sad (kolegové z týmu nástroj také použili a založili na něm další výzkum). Implementoval jsem proto základní multifunkční aplikaci pro sběr dat, kterou jsem pojmenoval Visual Prompter. Prvotní alpha verze, kterou jsme v týmu používali, se skládá z jednoduchého "prompteru" (předkládá jednotlivé "challenge" (výzvy)), modulu pro záznam z kamery a hlavně modulu pro čtení EEG dat. Program jsem psal v Pythonu 3 a pro GUI použil knihovnu Qt5. Každá prezentovaná výzva se skládá ze tří úrovní (fází). Na levé straně

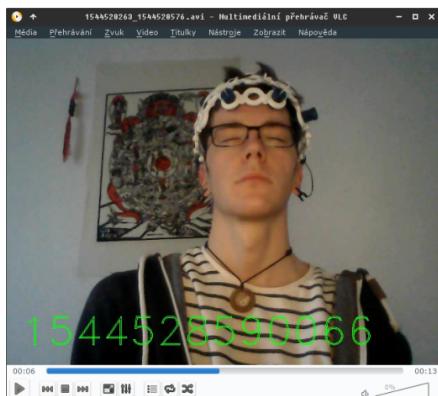


Obrázek 4. Visual Prompter ukazující scénu GIF

GUI (obrázek 4) je zobrazen obrázek oka, reprezentující typ výzvy - pro otevřené nebo zavřené oči (EEG signál je znatelně ovlivněn vizuálními vjemy). Po dokončení úrovně je přehrán zvuk oznamující postup do další úrovně nebo konec výzvy. Zvukový výstup lze ovládat zaškrťávacím políčkem - zvuk je však nutný vždy při průběhu meditačního úkolu, jelikož ten musí proběhnout se zavřenýma očima. Uživatel by bez zvukové signalizace nebyl schopen určit, kdy má s meditací přestat, a docházelo by k nepřesnostem. Jednotlivé výzvy jsou prezentovány náhodně, a v programu jsem implementoval mechanismus, který zajišťuje neopakující se výzvy (resp. nesmí se opakovat za posledních 5 pokusů. Pokud se opakují, hledá se další výzva, která vyhovuje parametrům). První úroveň uživateli prezentuje text s popisem následujícího úkolu, který bude muset uživatel vykonat. Nejvhodnější jsou krátké texty jako "Představuj si zvedání pravé ruky". Dobu trvání fáze lze specifikovat v poli "stages\_duration" v sekundách (první fáze - první index). V této úrovni je testovacímu subjektu přehrán pohyblivý obrázek GIF, který je načten na základě proměnných také ve vstupním json souboru. Uživatel si prohlédne přehrávaný obrázek a může se začít mentálně připravovat na fázi další.

Po připojení USB dongle přijímače EEG dat z headsetu je třeba ještě dostat data do Visual Promptera. K tomu používám knihovnu OpenBCI\_Python, která umožňuje uživateli používat různé moduly pro komunikaci s donglem. Její součástí je i modul LSL, tzv. Lab Streaming Layer. Lab Streaming Layer je unifikovaná kolekce knihoven, které se starají o síťovou komunikaci, časovou synchronizaci, přístup v (témař) reálném čase a také centralizovaný sběr, zpracování a zápis dat.

Další vlákno aplikace je určeno pro nahrávání dat z hlavní webkamery počítače. Vytvořil jsem třídu WebcamRecorder, která pomocí knihovny OpenCV zajišťuje nahrávání videa. Video je při provádění výzev důležité, jelikož uživatel programu může při probíhající výzvě mrkat, nebo jinak pohybovat hlavou, což by mohlo narušit ukládaná data. Nahrávání obličeje uživateli je tedy prováděno hlavně z důvodu případné kontroly



**Obrázek 5.** Visual Prompter ukazující scénu GIF

chyb v datech. Nahrávané video je ukládáno do souboru ve formátu avi, za použití MJPG kodeku a snímkové frekvence 30 snímků za sekundu. Výška a šířka snímku je pak nastavena na nejvyšší možnou, co použitá webkamera umožňuje. Zvuková data nahrávána nejsou. Do každého snímku je navíc "vypálen" časový údaj v milisekundách (obrázek 5), z důvodu snadnější synchronizace EEG dat a videa při manuální kontrole objevivších se chyb, nebo kontroly mrkání testovacího subjektu. K zapisování času je opět použita knihovna OpenCV.

Úkolem Visual Promptera byl sběr dat pro další trénink a získávání signatur signálu charakteristického pro představování si pohybu levé nebo pravé končetiny. Další nezbytnou součástí a nutnou prerekvizitou pro další postup je klasifikace EEG signálu pro ovládání hry. Jeden z kroků je rozložení vstupního signálu na frekvenční pásmo (alfa, beta, theta etc.), ve kterých následně budeme hledat signatury motorického centra mozku, ale nejenom to – tyto frekvenční pásmata použijeme i pro detekci mrkání (mrkání je charakteristické zvýšením delta, theta a alfa frekvence a snížením gamma frekvence), [2] a pro základní neurofeedback hru. Pokud je alfa a beta frekvence ve správném poměru prefrontální kortex je v procesu soustředění, a na základě této znalosti se dá vyprodukovat tímto výstupem ovládaná hra (např. pokud se uživatel soustředí, ve hře se začne zvedat předmět do vzdachu - je pouze na uživateli, jak dlouho ho tam vlastním soustředěním udrží.) Další nástroj pro předzpracování datasetu pro neuronovou síť, který jsem vyvinul, je DataExtractor. Jeho úkolem je provést spektrální analýzu vstupního signálu, respektive vypočítat Power Spectral Density. Využívám k tomu data z výzev (Challenge). Výzvám jsem nastavil fixní čas trvání 10 sekund a okno pro spektrální analýzu na 1 sekundu (250 Hz). Pro každou z 8 elektrod počítám 6 frekvenčních pásem po 10 vzorcích. Do sledovaných

vzorků	Levá	Pravá	Žádná činnost	Úspěšnost
celkově	499	499	499	-
úspěšné	68	344	297	-
procent.	13%	68%	59%	47.36%

**Tabulka 1.** Tabulka PoC výsledků

pásem (Alfa, Beta..) jsem přidal ještě tzv. Mu pásmo<sup>3</sup>, které je na frekvenci od 9 do 11 Hz, na které se vyskytují signály pohybu nejsilněji. Výstupem je json soubor se všemi kanály a pásmeny pro zvolenou výzvu. S takto zpracovanými daty mohu dále pracovat. Příklad spektrogramu, který můj software produkuje, je na obrázku (obrázek 8). Pro analýzu a transformaci používám základní Python funkce pro rychlou fourierovu transformaci signálu (Fast Fourier Transform) a knihovny numpy, matplotlib, seaborn, scipy a pandas. Nasbíraná data jsem rozdělil do trénovací, testovací a ověřovací sady. Pro neuronové sítě používám framework Caffe<sup>4</sup>. Po nasbírání dat od více testovacích subjektů použiji vysoce výkonné výpočetní cloud servery Metacentrum.<sup>5</sup> Klasická plně propojená konvoluční neuronová síť tedy bude mít 8 kanálů se vstupním rozměrem 6\*10. Pro experimenty se sensorimotorickým kortexem používám pouze 3 elektrody, kanály v tom případě používám 3. Pro budoucí experimenty využiji poznatky z práce [3], kde je užito i tzv. sub-bandingu - rozdělení pásma na podpásma pro zvýšení přesnosti klasifikace. Momentálně stavím na rychlé mobilní konvoluční neuronové sítě MobileNet<sup>6</sup>, jelikož pro finální použití bude nutné spouštět neuronovou síť v reálném čase pro real-time klasifikaci (obrázky 6 7) Reálná úspěšnost sítě je okolo 65%, prozatím se dostávám na značně menší hodnoty - potenciální úspěšnost je přes 70% a v případě opakovaného trénování na jednom mozku i přes 80% ([3]). Pro experimentální účely použiji i framework TensorFlow a minifikovanou verzi MobileNet sítě. Experimentální vstupní data budou nezpracované vstupy z elektrod. Momentální úspěšnost neuronové sítě je v tabulce 1.

Dalším krokem po získání frekvenčního spektra je samotná klasifikace.

### 3.1 Ovládání hry

#### 3.1.1 Část I. - Neurofeedback

Pro OpenBCI GUI jsem vyvinul widget s upraveným ovládáním založený na detekci vědomé pozornosti. Při správném poměru alfa/beta vln se začne zasílat systémový signál pro stisk klávesy a lze tak ovládat

<sup>3</sup>[https://en.wikipedia.org/wiki/Mu\\_wave](https://en.wikipedia.org/wiki/Mu_wave)

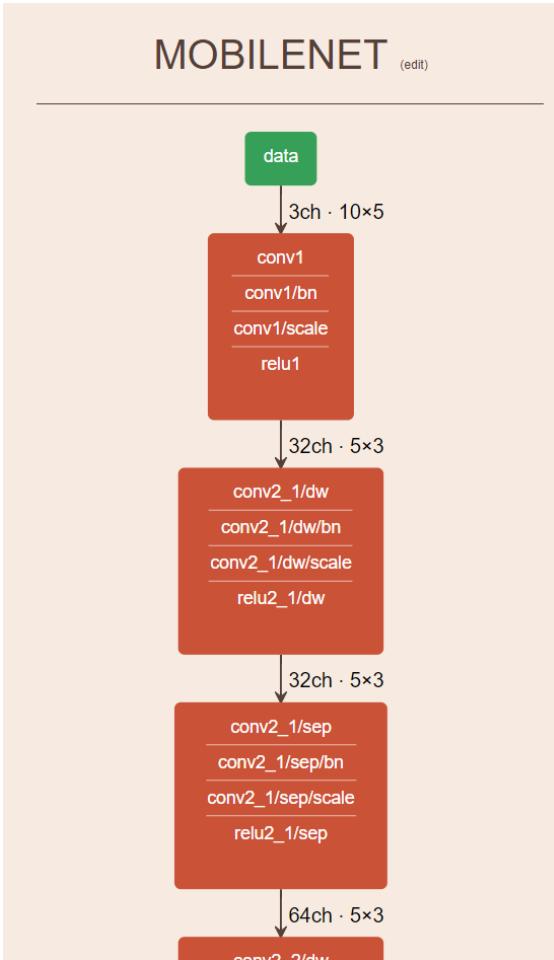
<sup>4</sup><http://caffe.berkeleyvision.org/>

<sup>5</sup><https://metavo.metacentrum.cz/>

<sup>6</sup>[https://github.com/shicai/MobileNet-Caffe/blob/master/mobilenet\\_deploy.prototxt](https://github.com/shicai/MobileNet-Caffe/blob/master/mobilenet_deploy.prototxt)

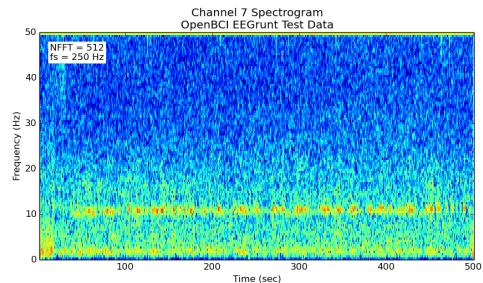
ID	name	type	ch_in	dim_in	ch_out	dim_out	ops	mem
1	data	data	3	10x5	3	10x5		activation 150
2	conv1	submodule(2)	3	10x5	32	5x3	macc 13.44k add 480 div 480	activation 1.44k param 928
5	relu1	ReLU	32	5x3	32	5x3	comp 480	activation 480
6	conv2_1	submodule(2)	32	5x3	32	5x3	macc 138.72k add 480 div 480	activation 1.44k param 9.28k
9	relu2_1/dw	ReLU	32	5x3	32	5x3	comp 480	activation 480
10	conv2_1	submodule(2)	32	5x3	64	5x3	macc 31.68k add 960 div 960	activation 2.88k param 2.18k
13	relu2_1/sep	ReLU	64	5x3	64	5x3	comp 960	activation 960
14	conv2_2	submodule(2)	64	5x3	64	3x2	macc 221.57k add 384 div 384	activation 1.15k param 36.99k
17	relu2_2/dw	ReLU	64	3x2	64	3x2	comp 384	activation 384
18	conv2_2	submodule(2)	64	3x2	128	3x2	macc 49.92k add 768 div 768	activation 2.3k param 8.45k

Obrázek 6. Vstupní část CNN-FC Mobilenet



Obrázek 7. Vstupní část CNN-FC Mobilenet

jakoukoliv hru. Pro demonstraci zde používám hru "Inside" od Playdead. Widget jsem zkompiloval a spustil pomocí frameworku Processing. Pokud se hráč soustředí, postava ve hře dostává signál k chůzi (na obrázku 9 je možno vidět OpenBCI GUI, kde zelený kruh značí aktivní soustředění, a do hry je tak zasílan signál - herní avatar pak jde doprava). Na stejném principu je založeno ovládání neurofeedback hry se zvedáním sochy (při správném poměru alfa/beta



Obrázek 8. Spektrogram visuální části mozku - nejaktivnější je v alfa pásmu - 8-12 Hz



Obrázek 9. Hra ovládaná poměrem alfa/beta vln

vln je zasílán do hry signál pro aplikování negativní gravitační síly na herní objekt). Hru se sochou Buddhy jsem napsal ve framework Unity v jazyce C a použil jsem nízkopolygonální grafiku pro lepší výkon a také estetiku.

### 3.1.2 Část I. - Bludiště

Po natrénování první neuronové sítě ji používám pro ovládání druhé části hry. Hra ve formě bludiště, která je momentálně v alpha verzi, je ovládána pomocí signálů zasílaných na input server (také psané v Unity). Signály jsou zasílány při real-time klasifikaci EEG dat přicházejících přes L-streamer vrstvu. Pokud je pohyb zamýšlen 3x (jsou zachyceny více jak 3 stejná okna samplů), herní avatar se pohne v kýženém směru. Po dosažení bodového limitu je uživatel odměněn audiovizuální zpětnou vazbou.

## 4. Závěr

V této práci jsem vyvinul nástroj pro tváření datových sad, nastudoval problematiku detekce a zpracování EEG signálů, seznámil se s alternativními existujícími výzkumy, implementoval dvě na ovládání EEG signály založené hry a způsoby ovládání a real-time klasifikace. Neurofeedback hra je psaná v Unity, má 3D grafiku a jednoduchý koncept - jde o zvedání předmětu "silou vůle" nebo by se také dalo říci "telekinez". Pokud se uživatel soustředí tak, aby měl správný poměr alfa/beta vln (specificky výskyt alfa vln v rozmezí 0.7-2.0 a beta vln v rozmezí 0-0.7), pak dojde k aplikování záporné gravitační síly na předmět ve hře (socha Buddhy, jako pocta soustředěné pozornosti). Jakmile se

soustředit přestane, levitující socha spadne a uživatel musí začít znovu od začátku. Druhou hrou je zčásti kolaborativní týmový projekt, jehož první částí je nyní vyvinutý Visual Prompter a zobrazovač spektrogramu alfa vln na statických datech. Aplikaci pro zobrazování alfa pásem následně využívám pro real-time detekci dalších frekvenčních pásem a pokračuji klasifikací signálu pomocí neuronových sítí. Výstupem je hra ovládaná do 4 směrů - up, left, right, down - v závislosti na detekované motorické činnosti (představování si pohybu ruky/nohy). Hra má formu bludiště, ve kterém se hráč naviguje pouze silou vlastní myslí. Každý hráč musí před samotnou "ostrou" hrou projít tréninkem, aby se systém adaptoval jeho mozkovým pochodem.

## References

- [1] Alf Inge Wang and Erik Andreas Larsen. Using brain-computer interfaces in an interactive multi-media application. 2012.
- [2] Michal HLINKA. Motor imagery based brain-computer interface used in a simple computer game [online], 2017 [cit. 2019-04-07].
- [3] Sławomir Opałka, Bartłomiej Stasiak, Dominik Szajerman, and Adam Wojciechowski. Multi-Channel Convolutional Neural Networks Architecture Feeding for Effective EEG Mental Tasks Classification. *Sensors (Basel, Switzerland)*, 18(10), oct 2018.
- [4] Psychologie zvládání života. Aplikace metody Abhidhamma - Mirko Frýba — Databáze knih.