



**Univerzita Tomáše Bati ve Zlíně**  
**Fakulta aplikované informatiky**

Disertační práce

**Návrh algoritmu pro biometrickou identifikaci  
osob pomocí analýzy EEG signálu**

**Design of biometric person identification algorithm using EEG  
signal analysis**

Autor: Ing. Jaromír Švejda  
Studijní program: Inženýrská informatika  
Studijní obor: Inženýrská informatika  
Školitel: doc. Ing. Roman Šenkeřík, Ph.D.

Zlín, srpen 2017

© Jaromír Švejda

Vydala **Univerzita Tomáše Bati ve Zlíně** v edici **Doctoral Thesis**

**Summary.**

Publikace byla vydána v roce 2017

*Klíčová slova: Brain Computer Interface, Elektroencefalografie, Biometrie, Neuronové sítě.*

*Key words: Brain Computer Interface, Electroencephalography, Biometry, Neural networks.*

Plná verze disertační práce je dostupná v Knihovně UTB ve Zlíně.

ISBN 978-80-.....

## PODĚKOVÁNÍ

Tato práce by nemohla vzniknout bez významné podpory několika osob, z nichž každá z nich velmi významně přispěla ke konečné podobě textu práce.

Rád bych proto v první řadě poděkoval mému školiteli, doc. Ing. Romanu Šenkeříkovi, Ph.D., za vždy objektivní a konstruktivní kritiku, která celou práci držela ve správném směru.

Další dík patří řediteli Ústavu informatiky a umělé inteligence prof. Mgr. Romanu Jaškovi, Ph.D., za jeho cenné rady a zkušenosti, a také za průběžný příděl optimismu v okamžicích, kdy to bylo nejvíce potřeba. Velmi si toho vážím a jsem si jist, že bez jeho podpory by tato práce zcela určitě nemohla vzniknout.

Velmi důležitá je i jazyková úprava textu. Této práci se ujala Mgr. Lenka Mecerodová, již patří obrovské poděkování za odhalení a opravu gramatických nesrovnalostí v textu práce.

Největší dík však patří mé rodině, jež mě podporovala i za tu cenu, že čas, který bych mohl strávit s nimi, jsem strávil prací na disertační práci. Vážím si jejich obětavosti a psychické podpory.

## **ABSTRAKT**

Identifikace založené na jedinečnosti biologických charakteristik jsou předmětem řady výzkumů. V současnosti je čím dál častěji diskutována otázka využití elektrické aktivity mozku v biometrických systémech. Tato práce se soustředí zejména na elektroencefalografické (EEG) záznamy, které jsou získány neinvazivní metodou. Dále obsahuje popis originálního nekonvenčního přístupu k identifikaci pomocí EEG, přičemž tento přístup je dále otestován na vybraných reálně naměřených datech.

Úvod shrnuje dosavadní přístupy použité k řešení identifikace subjektů podle EEG. Dále je diskutován současný stav řešené problematiky, který odhaluje komplikace spojené s výše zmiňovanou úlohou. Následuje popis cílů disertační práce. Hlavním cílem je poskytnout návrh algoritmu, jež lze využít pro realizaci biometrické identifikace. Teoretický rámec je zaměřen na popis EEG technologie, BCI systémů, biometrii a neuronové sítě. Ve stručnosti jsou pak uvedeny metody zpracování výsledků, na které navazuje podrobný popis vlastního algoritmu, k němuž jsou pak uvedeny výsledky testování. Jednotlivé testy jsou zaměřeny na odhalení limitů jak samotného algoritmu, tak EEG záznamů. Poté je uveden vědecký a praktický přínos práce. V závěru jsou shrnuty klíčové poznatky z testování a diskutovány jednotlivé cíle práce.

## **ABSTRACT**

Identifications based on unique biological characteristics are subject of number of researches. Currently, the usage of electrical activity of the brain in biometrical systems is more and more often discussed. This thesis is focused on electroencephalographic (EEG) records, which are obtained by non-invasive method. Further, it contains a description of original unconventional approach to EEG identification, which is then tested on chosen real measured data.

Introduction summarizes existing approaches to solve subject identification based on EEG. Further, current state of art reveals issues with mentioned task. The following chapter describe goals of dissertation thesis. The main goal is to design an algorithm, which could be used in biometrical identification task. The theoretical chapter focuses on description of EEG technology, BCI systems, biometry and neural networks. Further chapter briefly describes selected processing methods which is followed by detailed description of the algorithm. The results of algorithm testing are the topic of another chapter. Individual tests are aimed at limits revelation of both algorithm and EEG record. Then the chapter of contribution to both science and practice is included. Finally, conclusion summarizes key findings from algorithm testing and individual goals of dissertation thesis are discussed.

# OBSAH

PODĚKOVÁNÍ .....	III
ABSTRAKT .....	IV
ABSTRACT.....	IV
OBSAH .....	V
1. ÚVOD.....	1
2. SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY .....	3
3. CÍLE DIZERTAČNÍ PRÁCE .....	6
4. TEORETICKÝ RÁMEC .....	7
4.1 EEG technologie .....	7
4.2 Brain Computer interface.....	10
4.3 Historie a současný stav biometrie .....	11
4.3.1 Snímání biometrických dat .....	12
4.3.2 Reprezentace dat .....	13
4.3.3 Využití biometrie .....	13
4.4 Neuronové sítě .....	14
4.4.1 Historie .....	14
4.4.2 Teoretický popis.....	16
4.4.3 Aplikace neuronových sítí .....	25
5. ZVOLENÉ METODY ZPRACOVÁNÍ .....	30
6. POPIS ALGORITMU PRO IDENTIFIKACI OSOB POMOCÍ EEG SIGNÁLU .....	31
6.1 Měření EEG záznamů .....	32
6.2 Normalizace dat .....	32
6.3 Předzpracování dat.....	34
6.4 Klasifikace.....	37
6.4.1 Hopfieldova síť .....	37

6.4.2 Spider–Hopfieldova síť.....	41
6.5 Softwarová realizace.....	44
7. EXPERIMENTÁLNÍ ČÁST .....	46
7.1 Korelační analýza EEG signálu.....	46
7.2 Identifikace subjektů pomocí EEG signálu.....	52
7.2.1 Testování s REC EEG záznamy .....	52
7.2.2 Testování s CAP EEG záznamy .....	57
8. PŘÍNOS PRÁCE PRO VĚDU A PRAXI .....	61
8.1 Přínos pro vědu .....	61
8.2 Přínos pro praxi.....	61
9. ZÁVĚR .....	63
SEZNAM POUŽITÉ LITERATURY.....	66
SEZNAM OBRÁZKŮ .....	75
SEZNAM TABULEK .....	76
SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK .....	77
PUBLIKAČNÍ AKTIVITY AUTORA.....	79
ODBORNÝ ŽIVOTOPIS AUTORA.....	81

# 1. ÚVOD

Elektrická aktivita mozku patří mezi unikátní biologické charakteristiky osob. Nejčastěji se tato aktivita snímá pomocí technologie EEG (elektroencefalografie), která se řadí mezi neinvazivní metody a je tak v této oblasti v současnosti nejdostupnějším nástrojem. Vzhledem k povaze získaného EEG signálu je pro jeho analýzu nutný vysoký výpočetní výkon. Jeho praktické využití v reálných biometrických aplikacích je tak omezeno dobou nutnou k jeho zpracování. Kromě vysokých výpočetních nároků může být dalším důvodem i zatím ne příliš uživatelsky přívětivé řešení pořizování záznamu. Přestože se jedná o neinvazivní metodu, stále se tato technologie potýká s problémem nízké kvality získaného signálu v případě nesprávné instalace snímače.

Nejvíce diskutovaným uplatněním EEG signálu je v současné době využití v BCI (Brain Computer Interface) systémech, které slouží k propojení snímačů mozkové aktivity s externím zařízením. Počítač v těchto systémech plní obvykle roli prostředníka – zabezpečuje zpracování naměřené mozkové aktivity a překládá ji do příkazů externího modelu. Během zpracování signálu dochází k rozpoznávání unikátních charakteristik EEG signálu, které by dále mohly být využity pro biometrické účely.

Tato práce se zabývá možnostmi využití EEG signálu pro biometrické účely; zejména k identifikaci osob pomocí analýzy EEG signálu. Poukazuje i na technické limity, jež je nutné brát v úvahu při praktickém nasazení EEG v biometrických systémech.

Jedním z prvních výzkumů v této oblasti se zabýval Poulos (1999a, 1999b, 2002), který se svými kolegy zjišťoval možnosti využití parametrů AR modelu a LVQ (Linear Vector Quantizer) neuronových sítí. Později k těmto metodám přidali spektrální analýzu, výpočetní geometrii, nelineární zpracování nebo bilineární modely. Na základě výsledků klasifikace mezi dvěma (Poulos, 1999a) a čtyřmi (Poulos, 1999b; Poulos, 2002) třídami se vědcům podařilo ukázat slibný potenciál použité metody. Výsledky jejich analýzy se zakládaly na frekvenčním pásmu alpha EEG záznamu a podařilo se jim dosáhnout přesnosti až 91 % pro čtyři třídy. Mohammadi (2006) společně s AR modelem použil soutěživých neuronových sítí (Competitive Neural Networks), s nimiž dosáhl úspěšnosti 80–100 % v případě rozpoznávání mezi 10 subjekty. Ve stejném roce byla použita opět LVQ neuronová síť společně s FFT (Fast Fourier Transformation) se spektrálním rozlišením 1/180 Hz a 22s časovým oknem (Šťastný, 2006). Testování probíhalo s osmi subjekty a úspěšnost

identifikace byla závislá na konkrétních subjektech. U jednoho totiž bylo dosaženo až 100% úspěšnosti, další čtyři byly rozpoznáni ve více jak 95 % případů a poslední tři pak 50 % a méně případů, přičemž nejslabší výsledek byl pouhých 10 %. V roce 2012 pak byla použita metoda SVM (Support Vector Machine) a další metody, které jsou běžné pro zpracování zvukových signálů (Nguyen, 2012). S tímto přístupem vědci dosáhli přesnosti 99 % pro tři subjekty, 46,24 % pro jednu množinu s devíti subjekty a 80,8 % pro druhou množinu s devíti subjekty. Jeden z nejnovějších výzkumu dále zkoumá využití výkonové spektrální hustoty frekvenčního pásma gamma (30 – 50 Hz) EEG záznamu a srovnává ji s ostatními pásmy (alpha, beta, delta, theta). Studie uvádí zpracování 19 EEG kanálů naměřených při zavřených a otevřených očích. EER (equal error rate) byla 0,0196. Přístup opět ukazuje slibný potenciál s důrazem na nutnost dalšího výzkumu.

Z uvedených studií vyplývá, že záleží také na zkoumané množině EEG záznamů, což je i důvodem proč je jednou dosaženo téměř 100% úspěšnosti a podruhé úspěšnost spadne pod 50 %.

V této disertační práci je prezentována nekonvenční metoda, jež může sloužit jako alternativa k výše uvedeným přístupům. Algoritmus, který je součástí této metody, byl otestován na dvou databázích EEG záznamů.



## 2. SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

Genetické rysy v lidském Elektroencefalogramu (EEG), které by dokázaly jednoznačně identifikovat jedince, jsou středem zájmu vědecké komunity již od roku 1924, tj. od raných začátků pořizování EEG záznamů Hansem Bergerem. Nalezení správné genotyp – fenotyp mapy by pomohlo vytvořit hlavní a levný nástroj pro porozumění a včasnou diagnózu mnoha nemocí, zejména pak těch, které zasahují mozek. Jako hlavní by byl vnímán zejména proto, že by se jednalo o nástroj vytvořený na základě kvantitativního měření EEG vlastností, které jako takové mají blíže ke genovým funkcím než tradiční interpretace kognitivního testování (Pozo-Banos, 2014).

Biometrické systémy, využívající EEG jako neinvazivního a relativně úsporného „okna“ do lidského mozku, se v současné době dostávají do popředí zájmu vědecké komunity. Většina současného vědeckého úsilí je však zaměřena na vývoj diagnostických a monitorovacích nástrojů nemocí, jako jsou spánková apnoe, schizofrenie nebo epilepsie; dále na vytváření tzv. Brain Machine Interface (BMIs), které asistují postiženým lidem (Pozo-Banos, 2014).

Potenciál EEG signálu pro použití jako jednoho z biometrických znaků osob, byl prokázán již v roce 2001 (Paranjape). Tuto skutečnost dokazují i další pozdější publikace, které popisují zejména algoritmy určené pro biometrickou autentizaci. Každý z dosud vyvinutých algoritmů přistupuje k dané problematice z jiného hlediska.

Palaniappan (2008) popisuje dvoufázovou metodu biometrické autentizace, která využívá EEG signály těchto aktivit:

- nečinnost
- řešení matematické úlohy
- představa rotujícího tělesa
- psaní dopisu
- vizuální počítání

U každé aktivity jsou vypočteny tyto vlastnosti:

- autoregresivní koeficienty
- spektrální výkon kanálu
- rozdíl spektrálního výkonu interhemisférických kanálů
- nelineární složitost

Celá autentizace pak probíhá ve dvou fázích, při nichž jsou odstraněny dvě klíčové autentizační chyby:

- FAE (False Accept Error) – chyba nesprávného přijetí

- FRE (False Reject Error) – chyba nesprávného odmítnutí

Pro každou chybu jsou s využitím hodnot výše zmíněných vlastností dopočítány prahové hodnoty, které určují hranici mezi přijetím a odmítnutím předloženého vzorku dat. Pro otestování algoritmu byly použity signály z šesti elektrod rozmístěných na hlavě dle mezinárodního 10–20 systému.

První fáze na základě prahové hodnoty pro přijetí rozhodne, zda má být předložený subjekt přijat či nikoliv. Ve druhé fázi je s využitím prahové hodnoty pro odmítnutí otestováno, zda nedošlo k nesprávnému přijetí nebo nesprávnému odmítnutí subjektu.

Palaniappan v jiné své publikaci z roku 2007 uvádí také využití neuronové sítě (Elmanova neuronová síť) pro fázi klasifikace. S popisovanou klasifikační strategií, která byla aplikována na 1 600 surových EEG signálech, naměřených z 35 elektrod, bylo dosaženo maximálního rozpoznávací přesnosti 98,6 %.

Další publikace, jež představují algoritmy určené pro EEG biometrii, dokazují, o jak aktuální problematiku se jedná (Khalifa, 2012; Revett, 2012; Singh, 2012).

I přes velké množství doposud popsanych algoritmů, je problematika identifikace osob na základě jejich EEG obtížnější, než se zpočátku předpokládalo. Je to dáno tím, že samotná identifikace spoléhá na informace získané z komplexních heterogenních EEG rysů, které jsou výsledkem vypracovaných modelů dědičnosti, díky nimž se celý problém stává velmi citlivým na jeho proměnné (čas, frekvence, místo, záznam vzoru a algoritmus) (Pozo-Banos, 2014).

Doposud provedené studie, které se týkají EEG, mozkových vln, biometrie, identifikace osob a verifikace, lze rozdělit dle přístupu k dané problematice do těchto skupin:

- REC a REO (Resting with Eyes Closed/Open) – studie, které spoléhají na EEG data zaznamenávající subjekty ve stavu odpočinku se zavřenýma (REC) nebo otevřenýma (REO) očima (Paranjape, 2001; Campisi, 2011; La Rocca, 2012; Barzegaran et al, 2016).
- ERP (Event Related Potential) – naměřené záznamy vždy odpovídají reakci subjektu na různé druhy vnějších podnětů. Doposud však byly realizovány pouze studie s vizuálně evokovanými podněty (VEP). (Palaniappan, 2002; Palaniappan, 2004; Palaniappan, 2005; Singhal, 2007; Sokka et al, 2014).
- Multi-tasking – do této kategorie patří studie, které používají záznamy EEG z myšlenkově náročných úkolů, například výpočet matematických

úloh, psaní dopisů nebo představení pohybu. Studie obvykle zkoumají rozdíly v průběhu signálů získaných z odlišných aktivit (Schalk, 2004; Palaniappan, 2005; Bao, 2009; Yang, 2012).

- Nepřímá identifikace – výzkumy zaměřené na identifikaci uživatele pomocí hesla ukrytého v myšlence (Palaniappan, 2014; Yeom, 2013a; Yeom, 2013b).

Další problematikou je technologie sensorů, snímajících mozkovou aktivitu, která prodělala obrovský krok kupředu. I tak je stále nutné, aby se uživatel těchto sensorů dotýkal. Samotný instalační proces EEG přístrojů se navíc potýká s dlouhou dobou přípravy, která si mnohdy vyžaduje kvalifikovaného odborníka. Kromě toho většina těchto zařízení stále spoléhá na vodivý gel, který je určený ke snížení impedance mezi lebkou a elektrodou a tím tedy i k dosažení kvalitního signálu. Nicméně i tak lze považovat EEG biometrii za velmi slibnou zabezpečovací technologii budoucnosti (Pozo-Banos, 2014).

### 3. CÍLE DIZERTAČNÍ PRÁCE

Hlavním cílem dizertační práce je navrhnout robustní a časově efektivní algoritmus pro biometrickou identifikaci osob pomocí EEG signálu.

K měření signálu bylo v rámci dizertační práce využito náhlavní zařízení od společnosti Emotiv, jehož rozmístění elektrod je znázorněno na Obr. 2. Prvním dílčím cílem bylo tedy ověřit potenciál EEG signálu, naměřeného ze znázorněných oblastí mozku, pro identifikaci založenou na biometrických datech.

Identifikaci samotnou lze realizovat zejména pomocí metod založených na umělé inteligenci. Pro jejich nasazení je však nutné použití vhodných charakteristik EEG signálu, jejichž pomocí lze jednotlivé subjekty od sebe odlišit, tj. musí pro každý subjekt dosahovat jedinečných vlastností. Druhým dílčím cílem dizertační práce bylo nalezení vhodných unikátních charakteristik EEG signálu, které bude možné k výše uvedeným účelům využít.

Časová náročnost a robustnost identifikačního algoritmu je závislá na mnoha faktorech; například délka vzorku signálu EEG, počet subjektů v trénovací množině, počet elektrod použitých ke snímání mozkové aktivity apod. Třetím dílčím cílem této práce pak bylo nalézt faktory, jež mají nejvýraznější vliv právě na časovou efektivitu a robustnost, a využít je k nalezení optimálního nastavení algoritmu.

Dizertační práce měla za úkol ověřit následující předpoklady, které jsou podrobněji rozebrány ve výsledcích experimentů a v závěru práce:

- EEG signály mají potenciál pro využití v biometrických systémech.
- Charakteristiky EEG signálu jsou jedinečné pro každý subjekt.
- Identifikační algoritmus využívající EEG signály splňuje podmínky pro jeho nasazení v real-time aplikacích.

## 4. TEORETICKÝ RÁMEC

Biometrická identifikace osob pomocí EEG signálu se v teoretické rovině dotýká více vědeckých oborů. V první řadě je to biologie, z níž je důležitá zejména biologická stavba mozku. K současnému popisu mozku značně přispěly především výzkumy v oblasti medicíny, která využívá k pozorování mozku celou řadu technologií, mezi nimiž je pro tuto práci důležitá zejména elektroencefalografie (EEG). Kromě medicíny se v poslední době začíná rozrůstat využití EEG i pro technické účely zejména v systémech BCI (Brain - Computer Interface).

Vzhledem k tomu, že EEG záznam může být považován za biologickou charakteristiku živého organismu, lze uvažovat o jeho použití také v biometrických systémech. Zpracování EEG záznamu však není triviální úlohou, proto je k tomuto účelu vhodné použít technologii neuronových sítí.

Tato kapitola shrnuje teoretické poznatky týkající se EEG technologie, BCI systémů, biometrie a neuronových sítí.

### 4.1 EEG technologie

Základní funkční jednotkou mozku je neuron. Lidský mozek obsahuje přibližně  $10^{10}$  až  $10^{11}$  nervových buněk. Při své činnosti vytváří tyto buňky elektrické a magnetické pole (Paranjape, 2001; Forstmann, 2015). Tato pole jsou způsobena součtem elektrických signálů pocházejících z proudění iontů neurony. Toto proudění se objevuje především v mozkové kůře. Každá elektrická aktivita mozku pak odpovídá nějakému vnějšímu podnětu (mrknutí oka, pohyb rukou apod.).

Vzniklé elektrické pole lze poměrně jednoduše naměřit pomocí elektrod umístěných na lebce subjektu. Takto naměřený signál se nazývá electroencephalogram a reprezentuje sumu elektrické aktivity v jednotlivých oblastech mozku. EEG je tedy záznam časové změny elektrického potenciálu způsobeného mozkovou aktivitou. Nedostatkem této metody je právě sumace neuronových signálů. Každá aktivní synapse (spojení mezi dvěma neurony) při vzruchu vyšle do prostředí elektromagnetický puls. Hlavním zdrojem EEG je potom elektrická aktivita synaptodendritických membrán v povrchových vrstvách kortexu. Počty těchto pulsů jsou ve vysokých řádech a také jejich lokalizace v rámci celé hlavy není možné zachytit jen několika snímači na pokožce hlavy. Přesto se tato technologie úspěšně používá zejména v medicíně pro diagnostiku různých nemocí mozku (epilepsie, nespavost apod.) (Lakshmi, 2014).

Elektrody jsou na lebce rozmístěny obvykle na standardizovaných pozicích, které jsou dány mezinárodním 10–20 systémem (Homan, 1987) nebo jeho modifikací (MCN – Modified Combinatorial Nomenclature) (Oostenveld, 2001), která je určena pro měření podrobnějšího EEG signálu z většího počtu elektrod. Číslice v názvu systému odkazují na fakt, že skutečná vzdálenost mezi sousedními elektrodami je rovna 10 nebo 20 % z celkové šířky, popřípadě délky lidské lebky. Oba systémy tak přináší metodiku pojmenování pozic jednotlivých elektrod.

Název pozice je složen ze dvou částí; první část odkazuje pomocí písmen na konkrétní mozkový lalok: F – čelní, T – spánkový, C – centrální, P – parietální a O – týlní. Vzhledem k tomu, že v mozku neexistuje žádný centrální lalok, je nutné dodat, že písmeno C je použito pouze pro identifikační účely. V písmenném označení je dále používáno i písmeno A, které odkazuje na elektrody umístěné na pomyslné středové linii; konkrétně jde o oblast v okolí ušního boltce. Dále jsou definovány i pozice s označením Pg (oblast v okolí nosohltanu) a Fp (oblast v okolí čelní oblasti mozku). Druhá část pak pomocí čísla odkazuje na pozici v levé/pravé hemisféře; sudá čísla (2, 4, 6, 8) označují pozice v pravé hemisféře, zatímco lichá čísla (1, 3, 5, 7) jsou určena pro levou hemisféru.


MCN systém popisuje nové pozice, které jsou lokalizovány vždy v půli cesty mezi pozicemi, které byly popsány v původním 10–20 systému. Tyto nové pozice jsou od sebe opět vzdálené o 10 % z celkové vzdálenosti mezi krajními body lebky subjektu. Nové pozice si vyžádaly řadu změn ve značení jednotlivých lokací. Zatímco k číselné části bylo nutné pouze přidat číslo 9 pro pozice v levé hemisféře, písmenná část si vyžádala výraznější změny. Pozice jsou označovány pomocí dvou písmen, která udávají, mezi jakými dvěma původními pozicemi se nová lokace nachází. Například FC je oblast mezi původní čelní (F) a centrální (C) oblastí. Jedinou výjimkou je AF, které označuje oblast mezi Fp a F. Pro účely MCN systému musely být navíc přejmenovány čtyři body z původního 10–20 systému (T3, T4, T5 a T6) na T7, T8, P7 a P8. Pro více informací viz (DIY, 2012).

Z každé elektrody je naměřena elektrická aktivita mozku, jejíž napěťová úroveň se pohybuje v řádech jednotek až stovek  $\mu\text{V}$ . Získaný signál je však nestacionární a jeho statistické vlastnosti jsou závislé jak na konkrétním subjektu, tak i na konkrétní pozici elektrody.


V rámci dizertační práce je k měření EEG signálu využíváno zařízení od společnosti Emotiv (Obr. 1). Rozložení elektrod tohoto zařízení je zobrazeno a popsáno dle výše popsaných metodik na Obr. 2.



Obr. 1.: Emotiv EPOC Neuroheadset (Emotiv, 2017)



Obr. 2.: Rozložení elektrod zařízení Emotiv EPOC Neuroheadset

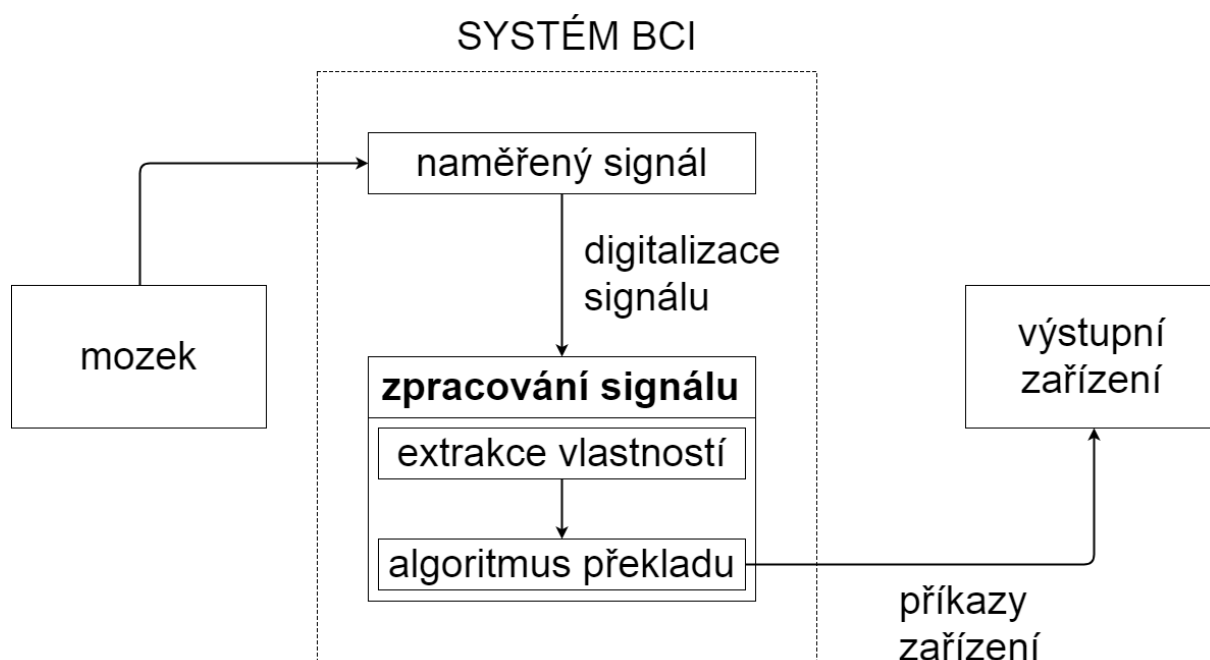


Obr. 3.: Ukázka EEG signálu

Na Obr. 3. je zobrazena ukázka EEG signálu, získaného pomocí zařízení Emotiv EPOC neuroheadset. Každý ze 14 naměřených kanálů je barevně odlišen a má pro zobrazení nastavenou amplitudu 200  $\mu\text{V}$ . Zařízení získává vzorky s frekvencí 128 Hz, takže v uvedeném obrázku je zachyceno přibližně 10 sekund EEG signálu.

## 4.2 Brain Computer interface

Brain – Computer Interface (BCI) je rozhraní, které slouží k propojení mozku s počítačem. Pro svou činnost vyžaduje signály reprezentující činnost mozku a algoritmus, jenž tyto signály dokáže zpracovat tak, aby je bylo možné používat pro další specifické činnosti, jako je například ovládání robotických zařízení pomocí mozkové aktivity nebo interakce se softwarovou aplikací (Schalk, 2004). Obecný princip BCI technologie znázorňuje Obr. 4.



Obr. 4.: Obecný princip systému BCI

Snímání mozkové aktivity lze provádět třemi možnými přístupy: invazivní, částečně invazivní a neinvazivní. Invazivní přístup vyžaduje neurochirurgický zákrok, kterým se provádí implantace senzorů přímo do šedé kůry mozkové. Pomocí této metody lze získat signál z mozku ve velmi dobré kvalitě. Nevýhodou však zůstává náchylnost k rozšiřování zjizvené tkáně v mozku, což může mít za následek zeslabení nebo dokonce ztrátu měřeného signálu (Collinger et al, 2013).

Částečně invazivní systémy jsou charakteristické tím, že jsou rozděleny na dvě části. Jedna je implantována uvnitř lebky a druhá se nachází zcela mimo



mozek. Typickým zástupcem je technologie ECoG (Electrocorticography), jež používá ke své činnosti elektrody umístěné přímo na odhaleném povrchu mozku. K jejich umístění je vyžadován chirurgický zákrok zvaný kraniotomie. Signál je silnější než u neinvazivních metod a je zároveň méně citlivý na tvorbu zjizvené tkáně (Hiremath et al, 2015).

Předchozí dva přístupy sice poskytují velmi přesné signály, nicméně umístění elektrod vyžaduje chirurgické zásahy ať už do lebky, nebo přímo do samotného mozku. Tento problém odstraňují neinvazivní metody, mezi něž patří např. EEG (Electroencephalography) nebo fMRI (functional magnetic resonance imaging). Na druhou stranu je nutné se spokojit s méně přesnými signály, které jsou zpravidla zatíženy nežádoucími šumy způsobenými v případě EEG technologie tím, že signál musí projít přes kostní tkáň, čímž značně ztratí na své kvalitě (Ang et al, 2015; Ruiz, 2013).

Pro běžné technické aplikace se nejčastěji používají neinvazivní metody snímání mozkové aktivity, zejména zařízení, jež jsou založená na EEG technologii. Proto kdykoliv bude dále zmínka o snímání mozkové aktivity, bude tím myšlena právě technologie EEG.

Návrh algoritmu, určeného pro zpracování signálu, komplikuje fakt, že EEG signál není stacionární, tj. že jeho charakteristické vlastnosti se mění v závislosti na čase. Navíc jsou tyto vlastnosti také závislé na snímaném subjektu. Je tedy nutné používat takový algoritmus, který bude schopen signál zpracovat i navzdory výše uvedeným komplikacím.

### **4.3 Historie a současný stav biometrie**

Pojem biometrika pochází ze dvou řeckých slov: bios (život) a metron (měření). Tedy v celém významu biometrika označuje měření živého organismu. V přesném významu jde pouze o měření a rozpoznávání charakteristik člověka. Metoda biometrie vede k identifikaci člověka na základě jeho unikátních tělesných vlastností. Biometrie je metoda rozpoznávání osob založená na fyziologických charakteristikách. Mezi tyto vlastnosti patří naměřené otisky prstů, geometrie ruky, písmo, duhovky, sítnice, žíly a další. V současnosti se biometrické technologie stávají základem bezpečné identifikace. Systémy identifikace osob a biometrické systémy jsou rozsáhlá a diskutovaná témata v oboru bezpečnosti (Rak, 2008).

Každá životní forma v nám známém vesmíru je tvořena složitou strukturou. To, že by se dvě nebo více organických struktur shodovaly, je naprosto nepravděpodobné. Celý proces identifikace je založený na rozpoznávání fyzických charakteristik osoby. Proto má obrovský význam použití metod

biometrie všude tam, kde záleží na unikátní identifikaci. Jde především o aplikace spojené s bezpečnou autorizací do chráněného systému nebo k určení správné totožnosti. Nejčastěji se tedy biometrie používá pro přístup do budovy (respektive do sítě k citlivým informacím), pro kontrolu totožnosti osob či ochranu dat.

Ověřování neboli verifikace označuje proces potvrzení správnosti (pravosti). Nejprve dojde k sejmutí (skenování) potřebných fyziologických charakteristik a vytvoření referenčního profilu (vzoru). Při identifikaci se nasnímaný vzorek porovná se šablonou. Výsledek celého procesu je vlastně shoda (povolen přístup) nebo neshoda (odmítnutí). O nic jiného se biometrie dále nestará.

Pro účely porovnání se vzorem se v první řadě musí vyhledat šablona (template) v databázi podle identifikátoru přiřazeného uživateli a provést porovnání s aktuálním měřením. Výsledek výstupu je jednoznačný a měl by být okamžitý, což přímo souvisí s přímým datovým propojením s databází a snímačem, popřípadě s dalšími počítači.

Počáteční inicializací šablon v databázi je nasnímání vzorů například pod administrátorským přístupem nebo při tvorbě nového uživatelského účtu. Mělo by se několikrát provést opakovaným snímáním, aby v budoucím ověřování nedocházelo k problémům.

#### **4.3.1 Snímání biometrických dat**

Na hardwarové úrovni se nasnímá analogický reálný vstup (obrazový, tepelný, hlasový, chemický atp.), který musí být převeden do digitální podoby binárních dat. Tato fáze biometrické identifikace je nejvíce citlivá na chyby. Jednak může dojít k nepřesnosti na straně konkrétního snímacího zařízení, protože dochází k diskretizaci naměřených dat nebo k ovlivnění okolním šumem (zaprášeny, poškrábaný senzor), jednak mohou vzniknout problémy autorizující se osoby, a to neúmyslným poškozením skenovaného organického tělesného vzorku. U otisku prstu je tato problematika vyřešena tak, že se provádí nejen snímání obrazu samotného otisku, ale využívá se navíc sekundární senzor (obvykle teplotní), který dokáže zjistit, jestli je objekt živý nebo ne.

Nejvíce rozšířené biometrické vlastnosti používané pro identifikační účely jsou uvedeny níže spolu se stručným popisem toho, co se měří (Rak, 2008):

- Otisk prstu (struktura papilárních linií a jejich detailů) (Murillo-Escobar et al, 2015).
- Dynamika podpisu (rozdíly v tlaku a rychlosti psaní) (Cpałka, 2016).
- Geometrie tváře (vzdálenosti specifických částí – oči, nos, ústa...) (Napieralski, 2014).

- Duhovka (obrazový vzorec duhovky) (Itkis et al, 2015).
- Sítnice (struktura žil na očním pozadí) (Tajuddin, 2015).
- Geometrie ruky (rozměry dlaně a prstů) (Park, 2013).
- Struktura žil na zápěstí (struktura žil) (Zuo, 2016).
- Tvar ucha (rozměry viditelné části ucha) (Abaza et al, 2013).
- Hlas (tón a zabarvení hlasu) (Nehru, 2016).
- DNA (řetězec deoxyribonukleové kyseliny) (Hashiyada, 2011).

### **4.3.2 Reprezentace dat**

Do databáze se neukládají celá nasnímaná data (např. u obrazu celá matice posloupnosti pixelů), protože by to bylo zbytečně paměťově náročné a také je nežádoucí ukládat do databáze stejné redundantní či podobné části binární posloupnosti. Jsou vybrány pouze ty části celého vzorku, které se podstatně liší od ostatních.

Při ukládání do vzdáleného počítače není proces omezen velikostí paměti, ale existuje určité nebezpečí průniku do systému zvnějšku, čili je nutné tuto komunikaci i samotnou databázi dále zabezpečit. Toto však není úlohou biometrie, ale obecného problému zvolení správného zabezpečení šifrované komunikace a fyzických dat v místě úložiště.

### **4.3.3 Využití biometrie**

Síla biometriky není v utajení informací používaných pro autentizaci, ale v jedinečnosti těchto informací. Nejnovější biometrické technologie umožňují identifikaci člověka automaticky, rychle a spolehlivě. Navíc ověření identity založené na biometrii nabízejí výrazně vyšší úroveň bezpečnosti než tradiční metody, protože využívají charakteristik, které jsou pro každou osobu unikátní, stálé v průběhu času a není možné je padělat nebo odcizit.

K biometrické autentizaci patří široké spektrum aplikací: přístup k pracovní stanici či osobnímu notebooku, přístup do sítě, aplikace přihlášení, ochrany dat, vzdálený přístup ke zdrojům, zabezpečení transakcí a zabezpečení serverů. Důvěra v tyto elektronické transakce má zásadní význam pro zdravý růst globální ekonomiky. Využívá se samostatně nebo integrovaně s dalšími technologiemi, jako jsou čipové karty, šifrovací klíče a digitální podpisy a klasická hesla. Využití biometrie pro osobní ověřování se stává výhodné a značně přesnější než současné metody (jako je například využití hesla nebo PINu). Důvodem je, že biometrické prvky spojí událost s konkrétní osobou. Mohou poskytnout jedinečné záznamy.

Další alternativní metodou identifikace, která s biometrií úzce souvisí, je využití snímače EEG záznamu, na němž je v současnosti prováděn výzkum z hlediska jeho využitelnosti pro široké spektrum aplikací, jako je například ovládání RC modelů, kurzoru myši nebo vývoj aplikací založených na audiovizuálním interagujícím prostředí.

## 4.4 Neuronové sítě

V této kapitole je popsána teorie neuronových sítí, s ohledem na jejich konkrétní využití v oblasti analýzy EEG signálu. Popis začíná stručnou historií a následným popisem základních principů, na kterých jsou neuronové sítě založeny. Poté je uvedeno základní rozdělení neuronových sítí společně s výčtem aplikací, na něž je možné jednotlivé typy nasadit.

### 4.4.1 Historie

V odborné literatuře je za počátek vzniku oboru neuronových sítí považován rok 1943. Tehdy Warrena McCulloch a Waltera Pitts vydali článek, který měl zásadní vliv na ostatní badatele. Jeho obsahem bylo představení velmi jednoduchého matematického modelu neuronu, opírající se o základní stejnojmennou buňku nervové soustavy. Spojením těchto neuronů vytvořili jednoduché neuronové sítě, jež byly schopné počítat libovolnou aritmetickou či logickou funkci. O další možnosti praktického využití však neuvažovali (Beale, 1990).

Dalším milníkem byl rok 1949, kdy vyšla kniha Donalda Hebba s názvem *The Organization of Behaviour*. Hebb se snažil vysvětlit některé experimentální výsledky psychologie. Pro synapse neuronů navrhl učící pravidlo, jež bylo inspirováno myšlenkou, že podmíněné reflexy, pozorovatelné u všech živočichů, jsou vlastnostmi jednotlivých neuronů. Jeho práce ovlivnila ostatní vědce, zabývající se podobnými otázkami (Beale, 1990).

Ve 40–50 letech k žádným dalším zásadním pokrokům nedošlo. Z tohoto období stojí za zmínku například první neuropočítač Snark z roku 1951, který se, i přes svou technickou úspěšnost, nedočkal žádného zajímavého praktického využití. Prvním úspěšným neuropočítačem se tak stal až *Mark I Perceptron*, který byl sestaven během let 1957–1958 Frankem Rosenblattem, Charlesem Wightmanem a dalšími. Základní úloha, pro niž byl tento neuropočítač navržen, bylo rozpoznávání obrazců. Frank Rosenblatt přinesl oboru neuronových sítí také první model dopředné neuronové sítě zvané *Perceptron*. Tomuto modelu navrhl také učící algoritmus, o kterém matematicky dokázal, že pro daná tréninková data nalezne po konečném počtu kroků

odpovídající váhový vektor parametrů (pokud existuje), nezávisle na jeho počátečním nastavení. Některými odborníky je Frank Rosenblatt považován za zakladatele oboru neuronových sítí (Beale, 1990).

Krátce po objevu Perceptronu přišel Bernard Widrow se svými studenty s dalším typem neuronového výpočetního prvku, který byl nazván *ADALINE* (ADaptive LInear NEuron). Model byl vybaven novým učícím pravidlem, jež se až dodnes nezměnilo. Funkčnost *ADALINE* byla demonstrována na mnoha jednoduchých typových příkladech (Beale, 1990).

Na přelomu 50. a 60. let docházelo k úspěšnému rozvoji neurovýpočtů v oblasti návrhu modelů neuronových sítí a jejich implementace. Přes nesporné úspěchy se však obor neuronových sítí v tomto období potýkal se dvěma zásadními problémy. Tím prvním bylo zanedbání analytického výzkumu neuronových modelů. Vědci se v této době zabývali spíše experimentálními činnostmi. Druhým problémem bylo nadšení některých výzkumných pracovníků, které vedlo k velké publicitě neopodstatněných prohlášení typu „za několik málo let bude vyvinut umělý mozek“, což bylo v té době pochopitelně stejně nerealizovatelné jako dnes. Tato prohlášení bohužel měla za následek diskreditaci neuronových sítí v očích odborníků, kteří se tak začali zabývat příbuznými obory umělé inteligence. Výzkum neuronových sítí se tedy v této době na čas pozastavil. K tomu přispěla zejména kampaň Marvinina Minského a Seymoura Paperta z roku 1969. Tito autoři rukopisu *Perceptrons* v něm uvedli, že jeden perceptron není schopen vyřešit jednoduchou logickou funkci, tzv. vylučovací disjunkci (XOR). Dnes víme, že je tento problém řešitelný pomocí vícevrstvého perceptronu, nicméně v té době nebyl znám učící algoritmus pro tento druh sítě, takže autoři tehdy došli k mylnému závěru, že takový algoritmus vzhledem ke komplikovanosti funkce nemůže existovat. Jejich tvrzení pak bylo všeobecně přijato jako platné a matematicky dokázané a výzkum neuronových sítí tím významně utrpěl, neboť byly finančně podpořeny jiné výzkumy. Neuronové sítě se na čas staly neperspektivním oborem (Beale, 1990).

Mezi lety 1967–1982 nebyly výzkumy v oboru neuronových sítí příliš podporovány. Přesto se ojedinele a izolovaně prováděly, a to zejména mimo území USA, kde měla kniha *Perceptrons* veliký vliv. Vědci však byli nuceni vydávat své články pod takovými názvy, ze kterých nebylo patrné, že se jedná právě o neuronové sítě. Mezi ty nejtalentovanější vědce se v tomto období řadí například Stephen Grossberg, Harry Klopf, Teuvo Kohonen nebo David Willshaw. Tito a mnozí další vědci se zasloužili o renesanci oboru neuronových sítí (Beale, 1990).

Počátkem 80. let se vědci osmělili a začali podávat vlastní grantové projekty zaměřené na neuropočítače a jejich aplikace. Jako první svou finanční podporu poskytla v roce 1983 grantová agentura DARPA (Defense Advanced Research Project Agency). Další organizace podporující základní a aplikovaný výzkum agenturu DARPA následovaly (Beale, 1990).

Další zásluhu na renesanci oboru měl světově uznávaný fyzik John Hopfield, který se v této době zabýval neurovýpočty. Své výsledky publikoval v roce 1982 a 1984. Ukázal souvislost některých modelů neuronových sítí s fyzikálními modely magnetických materiálů. Svými zvanými přednáškami získal pro neuronové sítě stovky kvalifikovaných vědců, matematiků a technologů (Beale, 1990).


V roce 1986 byl popsán učící algoritmus zpětného šíření chyb (backpropagation) pro vícevrstvou neuronovou síť, čímž byl vyřešen problém, který stál za pozastavením výzkumu neuronových sítí na konci 60. let. Algoritmus backpropagation je dosud jedním z nejpoužívanějších algoritmů a právě jeho publikováním dosáhl zájem o neuronové sítě svého vrcholu (Beale, 1990).

V následujícím roce se v San Diegu konala první větší konference specializovaná na neuronové sítě (IEEE International conference on Neural networks), na které byla založena mezinárodní společnost pro výzkum neuronových sítí INNS (International Neural Network Society). INNS o rok později začala vydávat svůj časopis *Neural networks*. Následně se začaly vydávat další časopisy specializované právě na neuronové sítě. Také na univerzitách byly založeny ústavy zabývající se tímto oborem a začaly otevírat nové výukové programy zaměřené na neurovýpočty. Tento trend pokračuje dodnes (Beale, 1990).

#### **4.4.2 Teoretický popis**

Základní prvek každé neuronové sítě je neuron. Z matematického hlediska je neuron obecně chápán jako nelineární, parametrická a ohraničená funkce. Stejně tak lineární parametrická funkce bývá označována jako lineární neuron.

Každý neuron má vstupní proměnné, parametry (váhy), přenosovou funkci a výstupní hodnotu. Princip funkce neuronu je zobrazen na Obr. 5. Na vstup se přivede požadovaný počet vstupních hodnot ( $x_1 - x_n$ ). Každý vstup má nastavenou svoji váhu ( $w_1 - w_n$ ), se kterou vstupuje do přenosové funkce  $f$  (někdy zvané také jako aktivační funkce). Výsledek výpočtu přenosové funkce se zadanými parametry je pak výstupem neuronu ( $y$ ) (Dreyfus, 2005; Pham et al, 2014).



Obr. 5: Schéma umělého neuronu


Přenosová funkce může být parametrizována jakýmkoliv vhodným způsobem. Používají se obvykle následující dva přístupy:

- Parametry jsou přiřazeny ke vstupům neuronu. Výstupem je pak nelineární kombinace vstupů ( $x_i$ ), které jsou vážené pomocí parametrů neuronu ( $w_i$ ) obvykle nazývané termínem „váhy“ případně „synaptické váhy“ (s ohledem na biologickou inspiraci neuronových sítí). V terminologii se u tohoto přístupu používá ještě termín „potenciál“, pod kterým se skrývá lineární kombinace vstupů. Nejčastěji se pak používá následující matematický předpis potenciálu  $v$ , jako vážená suma vstupů sečtená s konstantní hodnotou, která se nazývá „bias“. Bias je do vztahu včleněn přidáním komponenty  $x_0=1$  k vektoru  $x$  (Dreyfus, 2005).

$$v = w_0 + \sum_{i=1}^{n-1} w_i x_i \quad (4.4.2.1)$$

V uvedeném vztahu je  $w_0$  váha biasu,  $w_i$  jsou váhy jednotlivých vstupů,  $x_i$  jsou hodnoty přivedené na jednotlivé vstupy neuronu a  $n$  je počet vstupů neuronu. Takto definovaný potenciál vstupuje do přenosové funkce  $f$ . Nejčastěji je využívána funkce ve tvaru sigmoidy (funkce ve tvaru písmene S), které bývá dosaženo pomocí funkce  $\tanh$  nebo její inverzí (Dreyfus, 2005). Příklad průběhu takové funkce je uveden na Obr. 6. Celkový výstup  $y$  z neuronu tedy může být zapsán pomocí následujícího vztahu:

$$y = \tanh(w_0 + \sum_{i=1}^{n-1} w_i x_i) \quad (4.4.2.2)$$




Obr. 6: Příklad průběhu sigmoidy

- Parametry jsou přiřazeny k samotné nelinearitě neuronu, tj. určují tvar nelineární funkce, která je u neuronu použita jako jeho přenosová funkce. V tomto přístupu se používají RBF (Radial basis function) funkce nebo vlnové funkce (wavelet). První vychází z teorie aproximace, druhý z teorie zpracování signálů (Dreyfus, 2005). Příkladem tohoto přístupu může být následující definice výstupu pomocí Gaussovy RBF (Obr. 7):

$$y = \exp\left(-\frac{\sum_{i=1}^n (x_i - w_i)^2}{2w_{n+1}^2}\right) \quad (4.4.2.3)$$

Zde jsou parametry  $w_i$  pozicemi středu Gaussovy funkce a  $w_{n+1}$  určuje směrodatnou odchylku.



Obr. 7: Příklad průběhu Gaussovi funkce


Největší rozdíl mezi oběma přístupy je z hlediska praktického využití v tom, že RBF a vlnové funkce popisují pouze lokální nelinearitu, která se asymptoticky vytrácí ve všech směrech vstupního prostoru. Na druhé straně,



funkce ve tvaru sigmoidy dokáže popsat nelinearitu v celém rozsahu potenciálu určeného vztahem  $v=0$  (Dreyfus, 2005).

Z výše uvedeného je patrné, že neuron je vždy nelineární, parametrická funkce svých vstupních proměnných. Složením těchto nelineárních funkcí ze dvou nebo více neuronů vzniká neuronová síť. Spojení dvou neuronů se nazývá *synapse*. Neuronové sítě je možné rozdělit do dvou základních kategorií: dopředné a rekurentní (Dreyfus, 2005).

**Dopředná neuronová síť** je nelineární funkcí svých vstupů; tato funkce je složena z přenosových funkcí jednotlivých neuronů. Graficky je znázorněna jako množina vzájemně propojených neuronů, přes které proudí informace pouze v jednom směru, tj. od vstupů k výstupům. Síťový graf dopředné neuronové sítě je acyklický, takže v něm není obsažena žádná cesta, kterou by bylo možné se vrátit na začátek. Neurony, jež provádí finální výpočet, se nazývají výstupními neurony, ostatní jsou označovány jako skryté neurony. Výpočty, prováděné jednotlivými neurony, jsou zpravidla realizovány softwarovými programy. V reálných aplikacích se pak nejčastěji používá vícevrstvá síť (Obr. 8), která obsahuje více jak jednu vrstvu neuronů (Dreyfus, 2005; Tahmasebi, 2011).




Obr. 8: Obecná struktura vícevrstvé neuronové sítě

V ukázkovém schématu jsou dvě vrstvy – jedna se skrytými a druhá s výstupními neurony. Vstupy nejsou neurony v pravém slova smyslu, protože se starají pouze o přenos vstupních hodnot ke vstupům jednotlivých skrytých neuronů. Výstupy skrytých neuronů pak pokračují na vstupy výstupních

neuronů. V každém neuronu se realizuje nelineární funkce. Čas, potřebný k výpočtu jednotlivých přenosových funkcí, je obvykle velice krátký. Dopředné neuronové sítě jsou také často považovány za statické, neboť pokud je na vstup přiveden statický vstup, tak bude statický i výstup sítě. Jestliže přenosové funkce jsou ve tvaru sigmoidy, pak se celá síť obvykle označuje jako vícevrstvý perceptron nebo také MPLs (multilayer perceptrons) (Dreyfus, 2005; Zhang, 2014).

V praxi nejvíce používaná dopředná síť je složená z jedné skryté vrstvy obsahující neurony s přenosovou funkcí ve tvaru sigmoidy a výstupní vrstvou, ve které je pouze jeden lineární neuron (Dreyfus, 2005; Matias, 2014). Schéma této sítě je zobrazeno na Obr. 9.



Obr. 9: Schéma vícevrstvého perceptronu

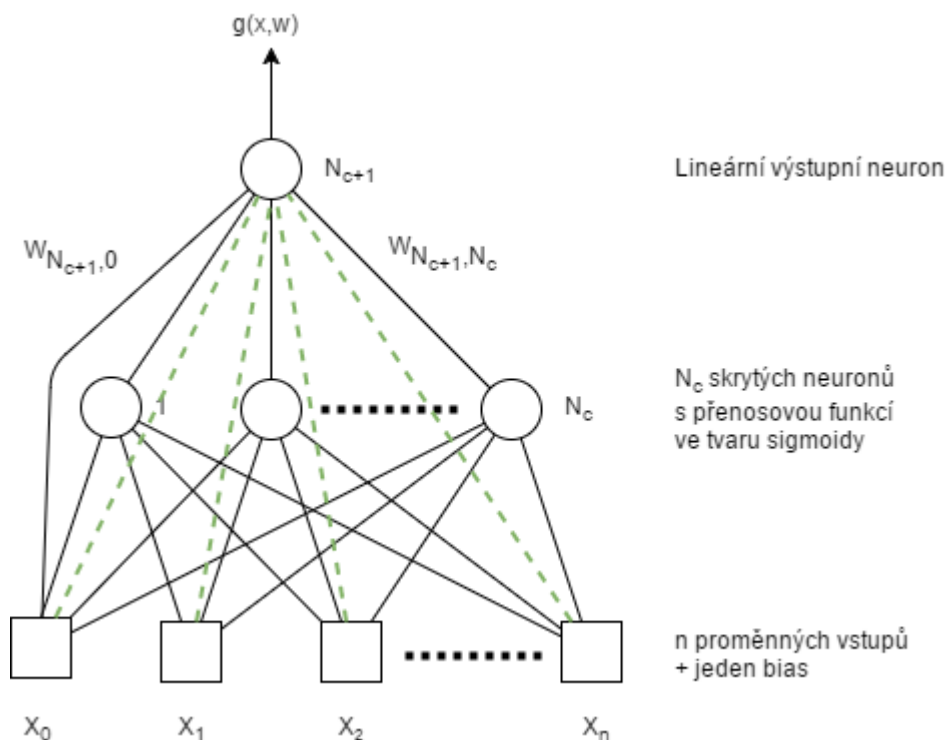
Výstup takto sestavené neuronové sítě lze matematicky zapsat pomocí tohoto vztahu:

$$g(x, w) = \sum_{i=1}^{N_c} [w_{N_{c+1},i} \tanh(\sum_{j=1}^n w_{ij} x_j + w_{i0})] + w_{N_{c+1},0} \quad (4.4.2.4)$$

Jako přenosová funkce je u neuronů ve skryté vrstvě použita sigmoida vyjádřená pomocí funkce  $\tanh$ . U každého skrytého neuronu navíc vystupuje i váha biasu ( $w_{i0}$ ). Výstupní neuron je lineární, protože se svými vstupy (výstupy skrytých neuronů) provádí pouze lineární operace. Nejprve je násobí jednotlivými vstupními vahami ( $w_{N_{c+1},i}$ ) a potom získané vážené vstupy sečte společně s váhou pro bias. V konečném důsledku je výstupem vícevrstvého

perceptronu opět nelineární funkce vstupů a jeho parametrů (Dreyfus, 2005; Zhang, 2014).

Pokud má funkce, která je počítaná pomocí dopředné neuronové sítě, obsahovat významné lineární komponenty, pak může být vhodné přidat přímá propojení mezi vstupy a výstupním neuronem (Dreyfus, 2005). Schéma takto upraveného vícevrstvého perceptronu je zobrazeno na Obr. 10.



Obr. 10: Schéma vícevrstvého perceptronu s přidánými přímými propojeními mezi vstupy a výstupním neuronem (čárkovaná čára)

Matematický zápis pak bude vypadat takto:


$$g(x, w) = \sum_{i=1}^{N_c} [w_{N_{c+1},i} \tanh(\sum_{j=1}^n w_{ij} x_j)] + \sum_{j=0}^n w_{N_{c+1},j} x_j \quad (4.4.2.5)$$

Ve vzorci je u skrytých neuronů uvažována nulová váha biasu.

**Rekurentní neuronová síť** představuje nejobecnější architekturu neuronových sítí, v jejichž síťových grafech se objevují cykly, tj. existuje alespoň jedna cesta, kterou je možné se vrátit na počáteční uzel (neuron). Vzhledem k tomu, že výstup neuronu nemůže být zároveň funkcí sebe sama, vyžaduje tato architektura, aby byl do výpočtu zahrnut i čas. Výstup neuronu totiž nemůže být funkcí sám pro sebe jen ve stejném časovém okamžiku, ale může být funkcí svých minulých hodnot (Dreyfus, 2005).

Pro popis rekurentních neuronových sítí se používá podobný aparát, jaký je obvyklý u popisu diskrétních systémů: diferenční (rekurentní) rovnice. Ke každé synapsi je přiřazeno časové zpoždění (může být rovno nule), které je

celočíslným násobkem základní časové jednotky (vzorkovací perioda)  $T$ . Diskrétní rekurentní neuronové sítě poskytují množinu nelineárních diferenčních rovnic, tvořené spojením funkcí jejích neuronů a časovými zpožděními jednotlivých synapsí. Z důvodu zachování kauzality musí každý cyklus v grafu obsahovat alespoň jedno spojení s nenulovým časovým zpožděním (Dreyfus, 2005). Příklad jednoduché rekurentní neuronové sítě je uveden na Obr. 11.



Obr. 11: Rekurentní neuronová síť se dvěma vstupy

Čísla ve čtvercích jsou zpoždění přiřazená k příslušným synapsím. Síť obsahuje cyklus, který začíná a končí u neuronu s číslem 3. Cesta cyklu prochází přes neuron 4. Protože má síť u synapse mezi 4. a 3. neuronem uvedeno zpoždění o délce jedné časové jednotky, lze tuto síť označit za kauzální. Přenosová funkce neuronu 3 uvažuje ve svém výpočtu hodnotu výstupu neuronu 4 z předchozího časového okamžiku (Dreyfus, 2005).

K matematickému popisu rekurentních neuronových sítí se používají diferenční rovnice. V případě lineárních systémů se obecně používá tato soustava rovnic:

$$\begin{aligned} x(k) &= Ax(k-1) + Bu(k-1) \\ g(k) &= Cx(k-1) + Du(k-1) \end{aligned} \quad (4.4.2.5)$$

V soustavě rovnic vystupuje  $x(k)$  jako stavový vektor v čase  $kT$ ,  $u(k)$  jako vstupní vektor v čase  $kT$ ,  $g(k)$  jako výstupní vektor v čase  $kT$  a  $A$ ,  $B$ ,  $C$ ,  $D$  jako matice. Stavové proměnné jsou minimální množinou proměnných, jejichž hodnoty mohou být v čase  $(k+1)T$  vypočítány za předpokladu, že jejich

počáteční hodnoty jsou známy a zároveň hodnoty vstupních proměnných jsou známy pro všechny předchozí kroky ( $0 - kT$ ). Počet stavových proměnných určuje řád systému (Dreyfus, 2005).


Obdobně je definována kanonická forma nelineárních systémů:

$$\begin{aligned} x(k) &= \Phi[x(k-1), u(k-1)] \\ g(k) &= \Psi[x(k-1), u(k-1)] \end{aligned} \quad (4.4.2.6)$$

Zde  $\phi$  a  $\psi$  jsou nelineární vektorové funkce (např. neuronová síť). Opět zde  $x$  vystupuje jako stavový vektor. Podobně jako u lineárního systému jsou stavové proměnné členy minimální množiny proměnných, jejichž pomocí lze model kompletně popsat v čase  $k+1$  za předpokladu, že jsou známy počáteční hodnoty stavových proměnných a hodnoty vstupu v čase  $0$  až  $kT$  (Dreyfus, 2005).

Každá rekurentní síť je převoditelná do kanonické formy, která je tvořena dopřednými neuronovými sítěmi tak, že některé výstupy jsou napojeny na vstupy přes jednotky časového zpoždění. Tyto jednotky jsou označovány symbolem  $q^{-1}$  (Dreyfus, 2005).

Jako příklad poslouží převedení ukázkové rekurentní sítě z Obr. 11 do kanonické formy uvedené na Obr. 12.



Obr. 12: Kanonická forma rekurentní neuronové sítě

Z uvedeného je tedy patrné, že základní součástí každé neuronové sítě je dopředná neuronová síť.

Důležitou součástí neuronové sítě je algoritmus, který se používá pro nastavení parametrů (vah) jednotlivých neuronů. Tomuto procesu se říká

„učení“ a má za úkol ohodnotit parametry neuronové sítě tak, aby byla co nejlépe schopna plnit účel, pro který byla určena. Na základě učící strategie lze neuronové sítě rozdělit na sítě s učitelem a bez učitele (Dreyfus, 2005).

U dopředných neuronových sítí bylo zmíněno, že provádí výpočet specifické nelineární funkce. Prakticky mohou nastat dvě situace:

- Nelineární funkce je známa analyticky. Neuronová síť pak plní úlohu aproximace funkce.
- Nelineární funkce není známa analyticky, ale je znám konečný počet numerických hodnot této funkce. Ve většině aplikací nejsou tyto hodnoty získány přesně, protože jejich měření jsou prováděna na fyzickém, chemickém, finančním, ekonomickém, biologickém či jinak podobně složitém procesu. Úkolem neuronové sítě je provést aproximaci regresní funkce za pomoci dostupných dat, tj. vytvořit statický model sledovaného procesu.

Nejčastěji se u dopředných neuronových sítí s učitelem vyskytuje druhá zmíněná situace. O učení s učitelem se jedná v případě, kdy funkce, kterou má síť implementovat, je známa v některých nebo ideálně ve všech jejích bodech; „učitel“ předkládá „příklady“ vstupních hodnot a k nim odpovídající hodnoty výstupu. To, co „učitel“ předkládá neuronové síti, se pak stává úlohou, kterou má tato síť řešit, tj. aby po předložení naučeného vstupu byla schopna vrátit požadované hodnoty na výstupu.

Učení dopředných neuronových sítí může být zahájeno v okamžiku nastavení komplexity modelu, která je vyjádřena počtem neuronů ve skryté vrstvě. Cílem samotného procesu učení je pak odhadnout parametry neuronové sítě tak, aby u trénovací množiny bylo dosaženo minimální střední kvadratické odchylky. Proto je učení považováno za numerický optimalizační problém.

Bude-li se pro jednoduchost uvažovat model s jedním výstupem  $g(x,w)$ , pak pro  $N$  vzorů v trénovací množině je metodou nejmenších čtverců definován tento vztah pro účelovou funkci:

$$J(w) = \frac{1}{2} \sum_{k=1}^N [y_p(x^k) - g(x^k, w)]^2 \quad (4.4.2.7)$$

Dvojice  $k$ ,  $y_p(x^k)$  odpovídají reálné naměřené hodnotě, která má být modelována, bude-li na vstup přiveden vektor  $x^k$ . Parametry neuronové sítě jsou vyjádřeny vektorem vah  $w$  a funkcí  $g(x^k, w)$ , která vyjadřuje výstup získaný pro váhy  $w$  a předložený vstupní vektor  $x^k$ . Proto je účelová funkce  $J(w)$  funkcí všech nastavitelných parametrů  $w$ . Algoritmus učení pak hledá takové parametry  $w$ , pro které je  $J(w)$  *minimální*.

Pro modely, které jsou lineární vzhledem ke svým parametrům (např. RBF s fixními středy a šířkou, polynomiální funkce apod.) je účelová funkce kvadratická – na takové modely lze aplikovat metodu nejmenších čtverců.

Pro nelineární modely (dopředné neuronové sítě, RBF s nastavitelnými středy a šířkou apod.) je optimalizační problém nelineární s více proměnnými, což činí metodu nejmenších čtverců pro tyto modely nepoužitelnou. Používají se iterativní metody, které provádí posloupnost ohodnocení parametrů, dokud není dosaženo minima nebo dokud nejsou splněna kritéria spokojenosti.

Dopředná neuronová síť může být také použita na úlohu analýzy dat nebo vizualizaci. V takových případech je k dispozici množina dat popsána vektorem s velkým množstvím komponent. Pak může být žádoucí tato data „shlukovat“ na základě podobnostních kritérií, která jsou předem známa. Metody pro vytváření takových „shluků“ jsou velice dobře známé ze statistiky. Dopředné neuronové sítě mohou být nasazeny na úlohu velmi podobnou úloze shlukování: v mnohorozměrné reprezentaci dat nalézt takovou reprezentaci, která bude dosahovat co nejnižšího rozměru (zpravidla dvourozměrné) a zároveň zachová možnost rozpoznání podobností nebo blízkosti jednotlivých prvků obsažených v předložených datech. Pro tuto úlohu není použit žádný učitel, takže učicí fáze sítě by měla vést k odhalení podobností mezi jednotlivými prvky v databázi a následně je přeložit do podoby shluků v nové reprezentaci dat nebo do podoby „mapy“. Nejpopulárnějšími dopřednými neuronovými sítěmi bez učitele jsou „samoorganizující se mapy“ a „Kohonenovy mapy“.

#### 4.4.3 Aplikace neuronových sítí

Neuronové sítě nachází uplatnění v celé řadě úloh technické i netechnické povahy (Du, 2014; Pham et al, 2014; Kohn et al, 2014; Chandra, 2016; Greenspan, 2016; Lakshmanan, 2016; Chung et al, 2017, Zhang, 2017). Tyto úlohy jsou obvykle popsány množinou naměřených hodnot  $\{x_k, k=1\dots N\}$ , množinou provedených měření  $\{y_p(x_k), k=1\dots N\}$  a kvantitativními vlastnostmi  $z_p$ , které obvykle odpovídají konkrétním veličinám fyzikálním, chemickým, ekonomickým, apod. Předpokladem je existence vztahu mezi  $x_k$  a  $z_p$ , přičemž je dále snaha tento vztah matematicky popsat. Získaný matematický předpis pak musí být platný v oblasti hodnot, pro něž byla měření prováděna, a to za podmínky, že je k dispozici konečný počet měření a že samotné měření podléhá šumu. Navíc nemusí být samozřejmé, že pomocí měření budou získány hodnoty proměnných, které skutečně ovlivňují kvantitativní parametry  $z_p$ . Jinými slovy, je snaha sestavit model zkoumaného procesu pouze na základě dostupných

měření – takový model se pak označuje termínem black box (Ugalde, 2013; Papernot, et al, 2016). V terminologii neuronových sítí se jednotlivá pozorování, na kterých bude model založen, nazývají „vzory“ (Dreyfus, 2005).

Opakem black box modelu je knowledge base model, který je navržen na základě matematických rovnic odvozených z principů fyzikálních, chemických, ekonomických apod. Knowledge base model může mít omezený počet nastavitelných parametrů, které mají obecně fyzikální význam. Neuronové sítě mohou být sestaveny z bloků tzv. grey box modelů nebo semi-fyzikálních modelů. Tím se objevují vlastnosti jak knowledge base (expertní znalost), tak i black box modelů (data). Neuronová síť je tedy sestavena jak na základě matematického popisu, tak i na základě naměřených dat ze zkoumaného procesu (Dreyfus, 2005; Socher et al, 2013, Du, 2014).

Dopředné neuronové sítě s učitelem nachází uplatnění nejčastěji v případech, kdy parametry modelu mají být nastaveny na základě vzorů tak, aby výsledný model co nejpřesněji simuloval vztah mezi vstupem a výstupem zkoumaného systému. Výhoda neuronových sítí, oproti konvenčním nelineárním modelovacím metodám, je v jejich schopnosti poskytovat modely s požadovanou přesností na základě menšího počtu vzorů, nebo také jinými slovy poskytnutí mnohem přesnějšího modelu ze stejného počtu vzorů. Obecně poskytují neuronové sítě nejlepší využití dostupných dat pro modely s více jak dvěma vstupy (Dreyfus, 2005; Bahdanau, 2014; Mnih, 2014).

Dalším typem úlohy, u níž se s výhodou využívá neuronových sítí s učitelem, je klasifikace. Cílem je zde přiřadit jednotlivé předložené položky ke třídám (kategoriím) obsažených v množině předem definovaných tříd. Algoritmus, který provádí samotnou klasifikaci, se nazývá klasifikátor (Dreyfus, 2005).

Klasifikátory se pak používají v aplikacích založených na rozpoznávání vzorů, jimiž mohou být např. ručně psané číslice nebo znaky (Pradeep, 2014), obrazy (Wang, 2015), zvukové záznamy (Wu, 2016), časové sekvence (Chand, 2014) aj. Uplatnění nachází také v mnoha dalších oblastech, jako je např. ekonomie (Liu, 2016), finance (Chand, 2014), sociologie (Dong, 2015), jazykové zpracování (Collobert et al, 2011), aj. Vzorem může být obecně jakýkoliv objekt, který je popsán pomocí množiny svých numerických deskriptorů: obraz může být popsán množinou intenzit jednotlivých pixelů, časovou sekvencí lze popsat pomocí číselné řady vztahené ke zvolenému časovému úseku, text je pak popsán například frekvencí výskytu významných slov apod. Obvyklé otázky, na které se klasifikátor snaží nalézt odpověď, mohou být např.: Kterému znaku odpovídá předložený neznámý symbol? Je předložený signál normální nebo anomální? Představuje uvedená společnost



bezpečnou investici? Je text relevantní vzhledem k dalšímu obsahu? (Dreyfus, 2005)

Klasifikátor nemusí vždy dát kompletní odpověď. Naopak může poskytnout pouze její část. V praxi se klasifikátory často používají pouze jako „pomocníci“ při rozhodování. Kromě jednoznačného přiřazení objektu k příslušným třídám mohou neuronové sítě také poskytnout informaci o pravděpodobnosti příslušnosti předloženého objektu k jednotlivým třídám. Tato vlastnost se s výhodou využívá při komplexním rozpoznávání vzorů, kdy je implementováno několik různých klasifikátorů, které poskytují odhady pravděpodobností příslušnosti objektu k jednotlivým třídám. Konečné rozhodnutí potom provádí nadřazený systém, který přiřazuje objekty k jednotlivým třídám na základě jednotlivých odhadů poskytnutých použitými klasifikátory (Dreyfus, 2005; Rivas-Perea, 2010; Sridhar, 2013).

V důsledku vývoje výkonného zpracování dat a zálohovacích systémů je k dispozici obrovské množství dat, ať už ve formě číselné (intenzivní zpracování dat, výsledky experimentů) nebo znakové (fragments textu). Extrahování informací z takového množství dat je velmi obtížné. V této oblasti výrazně pomáhá počítačová grafika prostřednictvím uživatelsky přívětivé reprezentace dat. Nicméně, lidský operátor není schopen vizualizovat vícedimenzionální data v jakékoliv efektivní formě. Často se provádí projekce vícedimenzionálních dat do prostoru s nižší dimenzí (zpravidla se dvěma). Dopředné neuronové sítě bez učitele (např. Kohonenova mapa) patří mezi výkonné metody pro realizaci takové vizualizace dat (Dreyfus, 2005; Hausfeld, 2014; Priam, 2016; Thrun, 2016).

V kapitole 4.4.2 bylo znázorněno, že rekurentní neuronové sítě mohou být převedeny do kanonické formy, která je tvořena dopřednou neuronovou sítí a externími rekurentními propojeními. Proto mají rekurentní sítě s učitelem velmi podobné vlastnosti jako dopředné neuronové sítě s učitelem. Druhé zmíněné sítě se běžně používají pro tzv. statické modelování na základě vzorů. Rekurentní sítě jsou pak používány pro účely dynamického modelování na základě vzorů, tj. k nalezení diferenčních rovnic z naměřených záznamů vstupu a výstupu, které popisují zkoumaný proces (Dreyfus, 2005; Graves, 2013; Bengio et al, 2015).

Návrh dynamického modelu může pak mít několik využití (Dreyfus, 2005):

- Simulátor pro predikování vývoje procesu popsaného modelem, jehož rovnice nejsou přesné (Sussillo, 2013).

- Simulátor pro proces, jehož knowledge base model je známý a přesný, ale nelze jej přesně vyřešit v reálném čase, protože obsahuje mnoho obyčejných nebo parciálních diferenciálních rovnic, jejichž řešení nemůže být určeno numericky v reálném čase v požadované přesnosti. V takovém případě lze generovat trénovací množinu ze zdrojového kódu, který řeší rovnici, a poté navrhnout rekurentní neuronovou síť, jež poskytne přesné řešení v mnohem kratším výpočetním čase. Navíc může být výhodné využít diferenciálních rovnic knowledge base modelu jako návod pro návrh architektury neuronového modelu – tento přístup je pak označován jako grey box nebo také semi-fyzikální model (Dragoi, 2014).
- Jednokrokový prediktor integrovaný do řídicího systému (Chandra, 2015).

Posledním typem neuronové sítě, u kterého bude diskutována možnost praktické aplikace, jsou rekurentní neuronové sítě bez učitele. Aktivační funkce těchto sítí bývá skoková funkce a jejich dynamika se vyznačuje principem utváření pevných bodů. Je-li síť uvedena do inicializačního stavu a dále ponechána vlivům své vlastní dynamiky, pak po konečném počtu přechodných stavů dosahuje tzv. stabilního stavu, v němž setrvává, dokud nebude znovu inicializována. Stabilní stav je závislý na inicializačním stavu. Konečný stav, tj. vektor, jehož částmi jsou (binární) stavy neuronů sítě, může být reprezentován jako binární kód části informace. V matematickém popisu sítě se nachází energetická (Lyapunova) funkce, jejíž vlastností je, že v průběhu evoluce vnitřní dynamiky sítě její hodnota postupně klesá, tj. stabilní stav je určen minimální hodnotou energetické funkce (Dreyfus, 2005; He, 2014; Chen et al, 2014).

Pokud existuje rekurentní neuronová síť, jejíž energetická funkce je identická s účelovou funkcí optimalizačního problému, potom jsou pevné body vnitřní dynamiky rekurentní neuronové sítě řešením kombinatorického optimalizačního problému. Je-li možné takovou síť sestavit, pak dokáže nalézt řešení problému vývojem z nastaveného inicializačního stavu (Dreyfus, 2005).

Řešení kombinatorického optimalizačního problému pomocí rekurentní neuronové sítě vyžaduje (Dreyfus, 2005):

- Nalezení rekurentní neuronové sítě, jejíž energetická funkce je identická s účelovou funkcí optimalizačního problému.
- Nalezení parametrů takové sítě.

- Řízení dynamiky sítě tak, aby bylo zajištěno, že se bude vyvíjet směrem k dosažení tzv. dobrého minima účelové funkce, například s využitím výhod stochastických metod (simulované žíhání apod.).

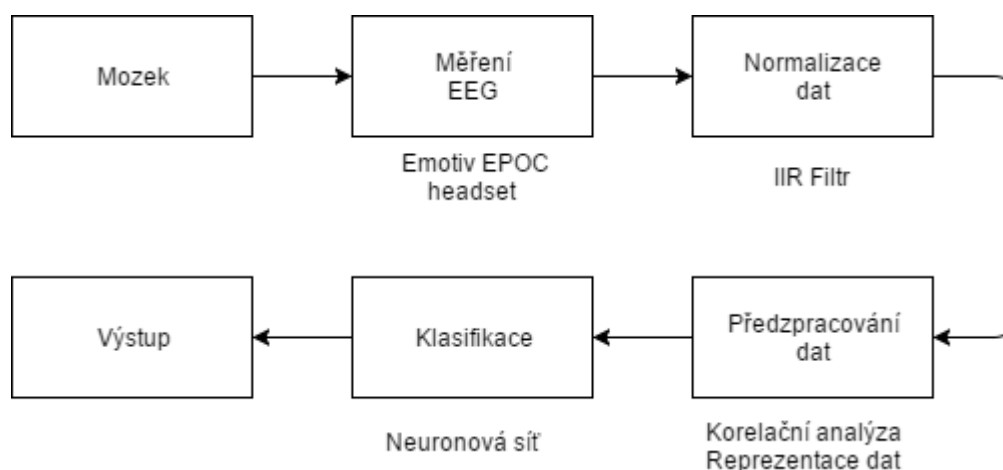
## 5. ZVOLENÉ METODY ZPRACOVÁNÍ

Dosažení uvedeného cíle bylo realizováno za pomoci následujících metod zpracování:

- Měření EEG technologie – veškeré výsledky identifikace jsou založeny na záznamech pořízených pomocí EEG přístrojů. Byl použity REC EEG a CAP EEG záznamy. Volba právě těchto druhů záznamů má své opodstatnění, neboť právě jejich pořizovací podmínky minimalizují výskyt nežádoucích signálů. První je měřen v klidovém stavu při zavřených očích, druhý pak v průběhu spánku.
- Normalizace EEG záznamu – je-li to vyžadováno, pak se provádí normalizace naměřeného záznamu. Pouze v případech, kdy jsou na vstupu již normalizovaná data, není tento proces nutný. Normalizování se provádí pomocí jednoduchého IIR filtru s klouzavým průměrem, čímž je ze signálu odstraněna plovoucí stejnosměrná složka.
- Korelační analýza – EEG záznam je pořízen pomocí většího počtu elektrod (14 v případě REC EEG a 13 v případě CAP EEG). Každá elektroda je umístěna nad jinou oblastí mozku. Korelační analýza pak byla provedena za účelem nalezení vzájemných závislostí mezi signály poskytnutých z jednotlivých elektrod. Výsledky byly použity i pro návrh identifikačního algoritmu. Pro realizaci byl zvolen program Wolfram Mathematica 8.
- Předzpracování dat – normalizované záznamy bylo nutné převést do podoby vhodné pro neuronovou síť. K tomuto účelu byl navržen vlastní algoritmus, který převádí EEG záznam za pomoci korelační analýzy do bipolární podoby.
- Neuronové sítě – v procesu identifikace je využita Hopfieldova neuronová síť. Vzhledem k tomu, že se úloha ukázala jako příliš složitá pro jednu Hopfieldovu síť, byla využita architektura vzájemně propojených neuronových sítí.
- Testování algoritmu – v průběhu testování byly zkoumány závislosti jednotlivých parametrů EEG záznamu na úspěšnost identifikace prováděné pomocí navrženého algoritmu. K testování byl použit pomocný nástroj vyvinutý v programovacím jazyce Python 3. Pro každý provedený výpočet byl zaznamenán výsledek, který vyjadřoval, zda byla identifikace určena správně či nikoliv. Míra úspěšnosti byla potom dána poměrem mezi správnými a všemi výsledky identifikace.

## 6. POPIS ALGORITMU PRO IDENTIFIKACI OSOB POMOCÍ EEG SIGNÁLU

V této kapitole jsou popsány jednotlivé metody, které v rámci dizertační práce byly použity ke zpracování EEG záznamů. Je zde zařazen popis algoritmu pro biometrickou autentizaci osob, který je hlavním cílem práce. Pořadí jednotlivých kapitol je založeno na postupu zpracování EEG záznamu uvedeného na Obr. 13, jehož cílem je na základě předloženého naměřeného záznamu určit osobu, které záznam přísluší.



Obr. 13: Blokové schéma algoritmu zpracování EEG záznamu

Vstupním bodem algoritmu je mozek, na němž je prováděno měření pomocí neinvazivní EEG technologie. Získaná data je pak potřeba normalizovat pomocí IIR filtru a předzpracovat do takové podoby, se kterou je schopna pracovat neuronová síť. Protože byla použita Hopfieldova síť (HS), bylo nutné data převést do binární, resp. bipolární formy. K tomuto účelu byl navržen vlastní algoritmus založený na korelační analýze EEG záznamu. Pro úspěšnou inicializaci HS je nutné připravit množinu vzorů (tréninkové vzory), mezi kterými bude síť vybírat ten, který nejvíce odpovídá vstupnímu vzoru. HS byla zvolena z toho důvodu, že primární úlohou, pro kterou je určena, je právě rozpoznávání vzorů s využitím principu autoasociativní paměti. Vzhledem k tomu, že síť samotná je pro větší počet tréninkových vzorů prakticky nepoužitelná, byla v rámci dizertační práce navržena metodika použití Hopfieldovy sítě, která tento hlavní nedostatek odstraňuje. Tato metodika byla pojmenována jako „Spider–Hopfieldova síť“. Výstupem algoritmu je pak z tréninkové množiny jeden konkrétní vzor, který podle výše zmíněného algoritmu nejpravděpodobněji odpovídá vzoru, předloženému na vstupu.

## 6.1 Měření EEG záznamů

Měření EEG záznamů v současnosti umožňuje celá řada přístrojů, jako např.: BrainGate, Emotiv EPOC headset, NeuroSky, actiCap apod. Na trhu se objevují stále nové a nové typy EEG přístrojů, které jsou zaměřeny pro využití spíše v technické než medicínské oblasti. V této disertační práci byl použit Emotiv EPOC headset (Obr. 1 a Obr. 2) pro získání vlastní testovací databáze EEG záznamů, jež byla dále použita při pilotním testování navrženého identifikačního algoritmu.

Pro účely identifikace osob je vhodné, aby naměřený signál obsahoval co nejméně artefaktů, což jsou úseky signálu, které vznikají jako reakce na nežádoucí stimuly. Zmíněné artefakty mohou být biologického (činnost srdce, smyslové reakce, svalová aktivita apod.) nebo technického původu (síťové rušení, síťový brum, šum přístroje, elektrostatické potenciály apod.). Pokud by artefakty nebyly ze signálu odstraněny, může při identifikaci signálu docházet k nežádoucímu ovlivnění výsledků.

Emotiv EPOC headset poskytuje signál, který je v nejvyšší možné míře zbaven technických artefaktů. V případě nutnosti potlačení vybraných biologických artefaktů je nutné buď použít dodatečných speciálních algoritmů, nebo při samotném získávání dat vhodným způsobem zamezit jejich generování.

Při získávání záznamů testovací EEG databáze byla snaha navodit všem dobrovolníkům stejné podmínky. Každý dobrovolník byl instruován k tomu, aby měl po dobu měření zavřené oči a snažil se navodit tzv. klidový stav, při kterém nemyslí na nic konkrétního a neprovádí žádný výrazný pohyb svalů. Tímto způsobem byla minimalizována svalová aktivita a zrakový vjem dobrovolníka. V rámci eliminace sluchového vjemu bylo v místnosti, kde měření probíhalo, vytvořeno „tiché“ prostředí, což znamená, že po dobu provádění měření bylo zajištěno, aby se v okolí dobrovolníka neregneroval nežádoucí zvukový vjem.

## 6.2 Normalizace dat

Proces normalizace signálu se může lišit v závislosti na konkrétním měřícím zařízení. Následující popis se vztahuje pouze na Emotiv EPOC headset.

Data jsou získávána přímo z výstupu neznaménkového 14bitového AD převodníku, kterým je samotný headset vybaven. Ve skutečnosti to má za následek, že plovoucí stejnosměrná úroveň signálu se pohybuje přibližně kolem hodnoty 4200  $\mu\text{V}$ . Záporná hodnota napětí je pak přenášena pomocí kladné hodnoty nižší, než je úroveň průměru, a kladné hodnoty napětí pak

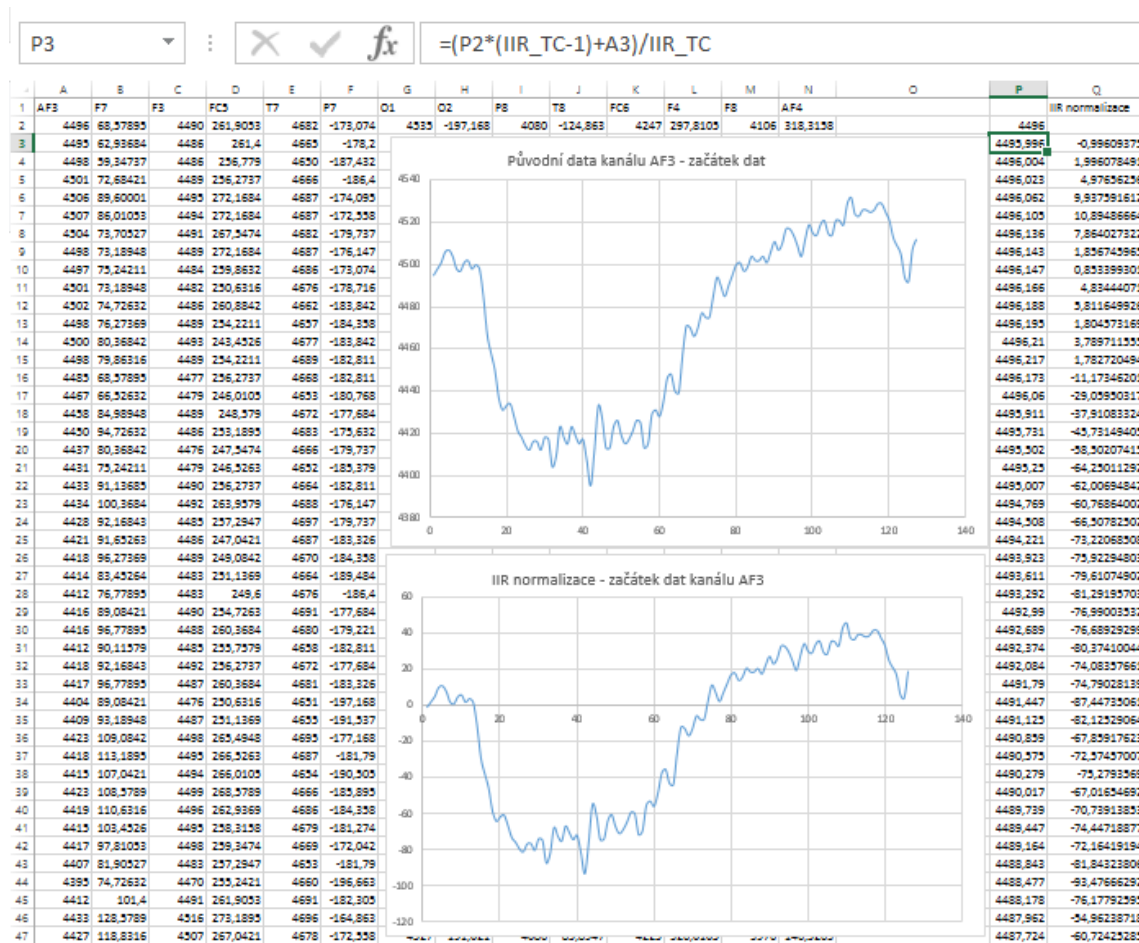
hodnotami vyššími, než je zmíněný průměr. Odstranění stejnosměrného offsetu je nutné provést před vykonáním jakékoliv analýzy signálu. Nejjednodušší a zároveň nejméně přesnou metodou je prosté odečtení hodnoty offsetu. Ideální je však aplikace vhodného filtru, protože jak bylo výše zmíněno, je stejnosměrná složka signálu plovoucí. Výrobce headsetu doporučuje využít IIR filtr, který je schopen sledovat úroveň nosného signálu a tuto následně odečíst od aktuální hodnoty. Pseudokód algoritmu IIR filtru je následující:

```
1. // Počáteční nastavení algoritmu
2. IIR_TC = 256;
3. EEG_data = input_data( : , 3:16 );
4. [rows columns] = size(EEG_data);
5. //rows - počet hodnot, columns = 14
6. AC_EEG_data = zeros(rows, columns);
7. back = EEG_data( 1, : );
8. // Normalizace dat
9. for r = 2 : rows
10.  back = (back* ( IIR_TC- 1 ) +
           EEG_data( r, :)) / IIR_TC;
11.  AC_EEG_data = EEG_data( r, :)- back;
```

*Zdrojový kód 1: Pseudokód algoritmu pro normalizaci dat*

*IIR\_TC* je časová konstanta IIR filtru, která musí být nastavena na dvojnásobek vzorkovací frekvence záznamu. Vzhledem k tomu, že jsou v záznamu ukládána i jiná data než hodnoty EEG, je nutné si ze záznamu vybrat jen EEG data. Ta jsou uložena do dvourozměrného pole s názvem *EEG\_data*. Poté je rezervováno místo na výstupu ve stejném rozsahu, jaký mají aktuálně zpracovávaná data. Před spuštěním samotného algoritmu jsou pak ze všech čtrnácti kanálů uloženy první hodnoty do pole *back*. Následuje algoritmus samotné normalizace, který prochází postupně jeden řádek záznamu po druhém a průběžně vypočítává klouzavý průměr, který následně odečítá od aktuálně zpracovávané hodnoty. Ukázka normalizace provedená pro ilustraci v programu Microsoft Excel pro jeden vybraný kanál je uvedena na Obr. 14. Normalizaci je

nutné pochopitelně provést pro všechny naměřené kanály, což se ve finální aplikaci provádí dle výše uvedeného pseudokódu.



Obr. 14: Ukázka normalizace pro úsek kanálu AF3 o délce 1 s

### 6.3 Předzpracování dat


Cílem tohoto kroku zpracování dat z EEG záznamu je připravit reprezentaci jednotlivých vzorů tak, aby s nimi bylo možné pracovat v Hopfieldově síti. Výstupem je pak vektor s bipolárními hodnotami.

Algoritmus předzpracování očekává na vstupu EEG data, která by již měla být normalizována. Je to z toho důvodu, že po provedení této fáze se již není možné vrátit zpět k původním hodnotám EEG záznamu, neboť výsledná forma reprezentace dat je založena na výsledcích korelační analýzy jednotlivých kanálů nikoliv na hodnotách samotných. Normalizace v pozdějších fázích tedy není možná.

V případě zařízení Emotiv EPOC headset je v EEG záznamu celkem 14 kanálů, nicméně průběh algoritmu předzpracování dat je zcela nezávislý



na konkrétním počtu kanálů. Při vyšším počtu kanálu se pouze prodlouží délka vzorku o předem definovaný počet bitů.



Obr. 15: Algoritmus pro převod EEG záznamu na vzor s bipolárními stavy

Součástí výzkumu, realizovaného v rámci disertační práce, byla i korelační analýza EEG záznamu. Tato analýza odhalila závislost vzájemných korelací mezi jednotlivými kanály na subjektu. Každý subjekt vykazoval jiné hodnoty vzájemných korelací a zároveň i jinou dynamiku změn pozic u dvojic kanálů, mezi nimiž byla nalezena nejvyšší korelace. Podrobnosti o této analýze jsou později uvedeny v kapitole 7.1. Zmíněné vlastnosti byly využity při vytváření bipolární reprezentace jednotlivých vzorů.

Před samotným popisem algoritmu je třeba zmínit, že kromě výsledků korelační analýzy by bylo možné využít i jiných statistických charakteristik, u nichž by se ukázalo, že jsou pro každý subjekt jedinečné a zároveň se mezi jednotlivými subjekty liší. V případě EEG záznamu je však hledání takových charakteristik komplikováno tím, že EEG signál patří mezi nestacionární

signály, takže využití hodnot základních statistických charakteristik (např. střední hodnota, směrodatná odchylka, rozptyl apod.) negarantuje žádné smysluplné výsledky.

Pro algoritmus předzpracování dat je klíčová volba charakteristiky EEG záznamu, kterou bude celý proces převodu řízen. Průběh celého algoritmu je ilustrován na Obr. 15. Jako první se provede výpočet zvolené charakteristiky pro každý kanál zvlášť. Na základě předchozího výzkumu byla v tomto kroku zvolena nejvyšší hodnota pearsonova korelačního koeficientu vypočteného podle vzorce:

$$R_{xy} = \frac{c_{xy}}{\sqrt{c_{xx} * c_{yy}}} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (6.3.1)$$

Hodnota  $R_{xy} = 1$  značí zcela přímou závislost signálu, naopak  $R_{xy} = -1$  poukazuje na zcela nepřímou závislost. Je-li  $R_{xy} = 0$ , pak jsou signály na sobě zcela nezávislé (Vaz, 2013).

Pro každý kanál byla vypočtena hodnota  $R_{xy}$  ve vztahu ke všem ostatním kanálům v EEG záznamu. Následně byla pro každý kanál vyhledána nejvyšší hodnota  $R_{xy}$ , která byla danému kanálu nastavena jako hodnota parametru  $p_n$ .

Dalším krokem je seřazení kanálů sestupně podle velikosti hodnoty parametru. Vznikne tak seznam kanálů seřazený podle míry závislosti na ostatních kanálech. Pro účel identifikace jsou zajímavé ty kanály, které leží v horní polovině seznamu, neboť vykazují nejsilnější přímou závislost s některým z ostatních kanálů. To je důvod, proč jsou tyto kanály v dalších krocích upřednostňovány před těmi, které leží v dolní polovině seznamu; zde se nachází signály s nejslabší závislostí na ostatních kanálech.

Na základě pozice kanálu v seznamu je každému z nich přiřazen bipolární kód dle těchto pravidel:

- Kanál s nejvyšší hodnotou charakteristiky má přiřazeno kódové slovo, které je složeno jen z jedniček.
- Ostatní kanály, které se nacházejí v horní polovině seznamu, mají přiřazeno kódové slovo podle toho, zda jsou svojí hodnotou charakteristiky blíže k prvnímu kanálu, nebo ke kanálu, který má nejvyšší hodnotu v rámci dolní poloviny seznamu. V prvním případě se v kódovém slově nachází méně záporných jedniček než v druhém případě, kdy je polovina kódového slova tvořená z kladných a druhá polovina ze záporných jedniček.
- Všechny kanály, které se nachází v dolní polovině seznamu, dostávají přiřazené kódové slovo, které je složeno ze záporných jedniček.

Tato fáze převodního algoritmu je jediná, která může ovlivnit výslednou podobu vzoru. Kódová slova, uvedená na Obr. 15, představují jednu z možných variant nastavení algoritmu pro 8bitová kódová slova. S tímto nastavením bylo provedeno pilotní testování algoritmu, jehož výsledky jsou uvedeny v kapitole 7.2. Nicméně je možné zvolit libovolnou délku kódových slov. Čím delší kódová slova, tím více se budou jednotlivé vzory od sebe lišit. Volbou délky kódového slova lze do určité míry ovlivnit úspěšnost následné identifikace. Tu však také ovlivňuje celá řada dalších faktorů, které jsou diskutovány později ve výsledcích pilotního testování algoritmu.

V okamžiku, kdy jsou jednotlivým kanálům přiřazena kódová slova, lze přistoupit k další fázi. Tou je zpětné seřazení kanálů do původního pořadí, v jakém do algoritmu vstupovaly. Díky tomuto kroku se v algoritmu projeví nejen hodnota zvolené charakteristiky kanálu, ale také poloha kanálu, pro který byla tato hodnota získána.

Výsledný vzor je tvořen bipolárním vektorem, který je postupně složen z jednotlivých kódových slov v pořadí, do něhož byly kanály seřazeny v předchozím kroku. Tato číselná podoba vzoru pak vstupuje do další fáze identifikačního algoritmu. Grafická reprezentace je určena spíše pro lidské oko než pro algoritmus samotný. Hodnota 1 se zobrazuje jako černý čtverec a hodnota -1 jako bílý čtverec.


## **6.4 Klasifikace**

Tato kapitola se skládá ze dvou částí. Nejprve je uveden teoretický popis Hopfieldovy sítě, v němž jsou uvedeny její základní vlastnosti. Poté následuje popis modifikace HS, která byla v rámci disertační práce navržena z důvodu zvýšení robustnosti při praktické aplikaci HS.

### **6.4.1 Hopfieldova síť**

Hopfieldova síť (HS) byla v době svého vzniku (1982) značným odklonem od populárního perceptronu. John Hopfield při návrhu této sítě zdůraznil dynamické charakteristiky biologických sítí s rekurentním propojením: rekurentní neuronové sítě, jakožto dynamické systémy, exhibují atraktory, které jsou stabilními stavy dynamiky (Pham et al, 2014; Dreyfus, 2005).

Architektura HS je znázorněna na Obr. 16. Každý neuron je propojen se všemi ostatními neurony.



Obr. 16: Architektura Hopfieldovy sítě

Obvykle bývá uváděno schéma, ve kterém se nevyskytují výstupy z neuronové sítě, protože HS ve skutečnosti žádné výstupy nemá. Základní princip funkce byl částečně uveden u rekurentních neuronových sítí bez učitele v kapitole 4.4.2, tj. po inicializaci neuronů se postupně dostává ke stabilnímu stavu své vnitřní dynamiky. V okamžiku, kdy k této stabilizaci dojde, lze výstup sítě pozorovat pomocí aktuálního stavu všech neuronů, které jsou ve schématu označeny jako  $y_1 - y_n$ .

HS nemá žádné externí vstupy. Její chování závisí pouze na její vlastní dynamice. Globální stabilitu sítě (tj. záruka, že síť konverguje ke stabilnímu stavu bez ohledu na inicializační stav) zaručuje pravidlo symetrie propojení neuronů, které stanovuje, že váha spojení mezi neuronem  $i$  a neuronem  $j$  je stejná v obou směrech. Během stabilního stavu dynamiky jsou zakódovány jednotlivé kódy z obsahu paměti. Následující dynamický proces, který začíná nastavením inicializačního stavu a pokračuje autonomním vývojem směrem k rovnovážnému stavu, lze chápat jako vybavovací proces asociativní paměti. Jinými slovy, inicializační stav může být interpretován jako binární kód poškozené informace (tak, jak je zaznamenána snímačem) a koncový stav pak představuje binární kód správné (nepoškozené) informace (Dreyfus, 2005).

První popis HS z roku 1982 používal binární hodnoty (1, 0) pro excitaci neuronů. Pozdější popis z roku 1984 pracuje s bipolárními hodnotami (1, -1). Aktivační funkcí neuronů je skoková funkce (Dreyfus, 2005).

Funkce HS je specifikována tréninkovou množinou  $P$  vzorů, z nichž každý je popsán vektorem  $n$  bipolárních (binárních) stavů vstupních, resp. výstupních

neuronů (viz vzorec 6.4.1.1), které v případě autoasociativní paměti splývají (Fausett, 1994).

$$s(p) = (s_1(p) \dots s_n(p)) \text{ pro } p = 1, \dots, P \quad (6.4.1.1)$$

Další popis je platný pro bipolární vzory. V případě binárních vzorů se používají vhodně modifikované verze uvedených vztahů.

Tréninkové vzory jsou použity pro nastavení váhové matice podle Hebbova zákona definovaného vztahem:

$$\begin{aligned} w_{ij} &= \sum_p s_i(p)s_j(p) \text{ pro } i \neq j \\ w_{ij} &= 0 \text{ pro } i = j \end{aligned} \quad (6.4.1.2)$$

Algoritmus použití HS lze pak rozdělit do následujících kroků:

1. Inicializace vah pomocí Hebbova zákona.
2. Dokud síť nezrelaxuje do stabilního stavu, pak probíhá relaxace do stabilního stavu podle kroků 2.1–2.3.
  - 2.1. Pro každý vstupní vektor  $x$  se opakují kroky 2.2 a 2.3.
  - 2.2. Inicializace sítě vnějším vstupním vektorem  $x$ . Provádí se nastavením stavů jednotlivých neuronů sítě na jednotlivé stavy dané vnějším vstupním vektorem. Tento krok lze vyjádřit vztahem:

$$y_i = x_i \text{ pro } i = 1, \dots, n \quad (6.4.1.3)$$

- 2.3. Pro každý neuron  $y_i$  opakovat kroky 2.3.1–2.3.3, přičemž nezáleží na pořadí, v jakém budou výpočty pro jednotlivé neurony prováděny.

- 2.3.1. Výpočet vnitřního potenciálu neuronu  $\xi$ :

$$\xi_i = x_i + \sum_j y_j w_{ji} \quad (6.4.1.4)$$

- 2.3.2. Stanovení výstupu neuronu pomocí aktivační funkce definované těmito pravidly ( $\theta$  je prahová hodnota a obvykle je nastavena na 0):

$$\begin{aligned} y_i &= 1 \text{ pokud } \xi_i > \theta \\ y_i &= y_i \text{ pokud } \xi_i = \theta \\ y_i &= -1 \text{ pokud } \xi_i < \theta \end{aligned} \quad (6.4.1.5)$$

- 2.3.3. Transport hodnoty  $y_i$  ostatním neuronům. Tento krok se provede aktualizací  $y_i$  a při výpočtu vnitřního potenciálu dalšího neuronu jsou již použity nové hodnoty pro neurony, u kterých byly kroky 2.3.1 a 2.3.2 již provedeny.

3. Test konvergence. V tomto kroku se zjišťuje, zda síť již dosáhla některého ze vzorů, obsaženého v tréninkové množině  $s(p)$  (Fausett, 1994).

Aktualizace neuronů mohou probíhat v náhodném pořadí, musí však být prováděny stejnou průměrnou rychlostí.

V analogii s fyzikálními ději definoval John Hopfield pro svou síť tzv. energetickou funkci  $E$ , která každému stavu sítě přiřazuje jeho potenciální energii. Jedná se o funkci, která je zdola ohraničená a pro daný stav je nerostoucí. Stavem systému se rozumí množina aktivací všech neuronů. V okamžiku nalezení vhodné energetické funkce je síť schopna konvergovat ke stabilní množině aktivací neuronů v daném časovém okamžiku.

Energetická funkce pro diskrétní HS je dána vztahem:

$$E = -0,5 \sum_{i \neq j} \sum_j y_i y_j w_{ij} - \sum_i x_i y_i + \sum_i \theta_i y_i \quad (6.4.1.6)$$

Z definice energetické funkce vyplývá, že stavy sítě s nízkou energií mají největší stabilitu. Změnu energie  $\Delta E$  lze při změně aktivace sítě o  $\Delta y_i$  vyjádřit vztahem:

$$\Delta E = -[\sum_j y_j w_{ij} + x_i - \theta_i] \Delta y_i \quad (6.4.1.7)$$

Vztah 6.4.1.7 je závislý na skutečnosti, že v daném okamžiku může svou aktivaci aktualizovat vždy pouze jeden neuron. Dále při jakékoliv změně  $\Delta y_i$ , ať už kladné nebo záporné, je vždy  $\Delta E < 0$ , z čehož vyplývá, že energie nemůže růst. Protože je energetická funkce ohraničena, musí síť dosáhnout stabilního stavu, při kterém se energie v následujících iteracích již nemění.

Z uvedeného popisu HS je zřejmé, že adaptace podle Hebbova zákona se provádí jednorázově. Doba trvání této fáze je závislá pouze na počtu tréninkových vzorů. Naproti tomu aktivní režim představuje iterativní proces, při kterém se postupně minimalizuje energie sítě prostřednictvím diskrétní varianty gradientní metody s nejistou konvergencí. Cílem adaptace HS podle Hebbova zákona je pak nalezení takové konfigurace, aby funkce sítě v aktivním režimu realizovala autoasociativní paměť, tj. bude-li vstup sítě blízký nějakému tréninkovému vzoru, pak by výstup sítě měl odpovídat právě tomuto vzoru. Z hlediska energie by každý tréninkový vzor měl být lokálním minimem energetické funkce, tj. stabilním stavem sítě. V jeho blízkém okolí, v tzv. oblasti abstrakce, se pak nachází všechny vstupy blízké příslušnému tréninkovému vzoru. Tyto vstupy pak představují inicializační stavy sítě, ze kterých se pomocí minimalizace energetické funkce dostane síť do příslušného minima a tím i do stabilního stavu, který pak odpovídá konkrétnímu tréninkovému vzoru. Z geometrického hlediska se energetická plocha rozpadá na oblasti atrakce lokálních minim. HS pak při své činnosti přiřazuje ke každému vstupu o oblasti atrakce některého lokálního minima právě toto minimum (Fausett, 1994).

Hlavním problémem HS jsou tzv. fantomové vzory, jež se v energetické ploše objevují ve formě lokálních minim, kterým ovšem neodpovídá žádný tréninkový vzor. Výstup sítě pak pro vstup, který leží v oblasti atrakce fantomového vzoru, neodpovídá žádnému tréninkovému vzoru a nedává tedy žádný smysl. Existují ovšem modifikace HS, které se tento nedostatek snaží odstranit např. pomocí adaptivní dynamiky, při níž se takto vzniklé vzory mohou dodatečně odučit (Fausett, 1994).

John Hopfield rovněž formuloval přibližný vztah pro určení kapacity HS. Tento vztah existuje ve dvou základních variantách: pro binární a bipolární vzory.

$$\begin{aligned} P &\approx 0,15n \leftarrow \text{pro binární vzory} \\ P &\approx \frac{n}{2 \log_2 n} \leftarrow \text{pro bipolární vzory} \end{aligned} \quad (6.4.1.8)$$

kde  $n$  je počet neuronů v síti a  $P$  je počet vzorů, které HS dokáže rozeznat.

V praxi se ukazuje, že tyto teoretické odhady jsou poněkud nadhodnocené. Opět existují modifikace Hopfieldova modelu autoasociativní paměti, které se snaží tento nedostatek odstranit.

V současnosti se HS používá zřídka. Důvodem je právě zmíněný problém fantomových vzorů, který se objevuje mnohem dříve, než by se na základě výše uvedených vzorců pro výpočet kapacity sítě očekávalo. HS tak díky tomu vykazuje nepřijatelné výsledky, a proto je chápána spíše jako teoretický model; Nicméně pokud je na konkrétní úlohu nasazena vhodným způsobem, může přinášet prakticky použitelné výsledky a tím posunout HS z teoretické roviny do oblasti praktických aplikací. Jeden z vhodných způsobů použití HS popisuje následující kapitola.

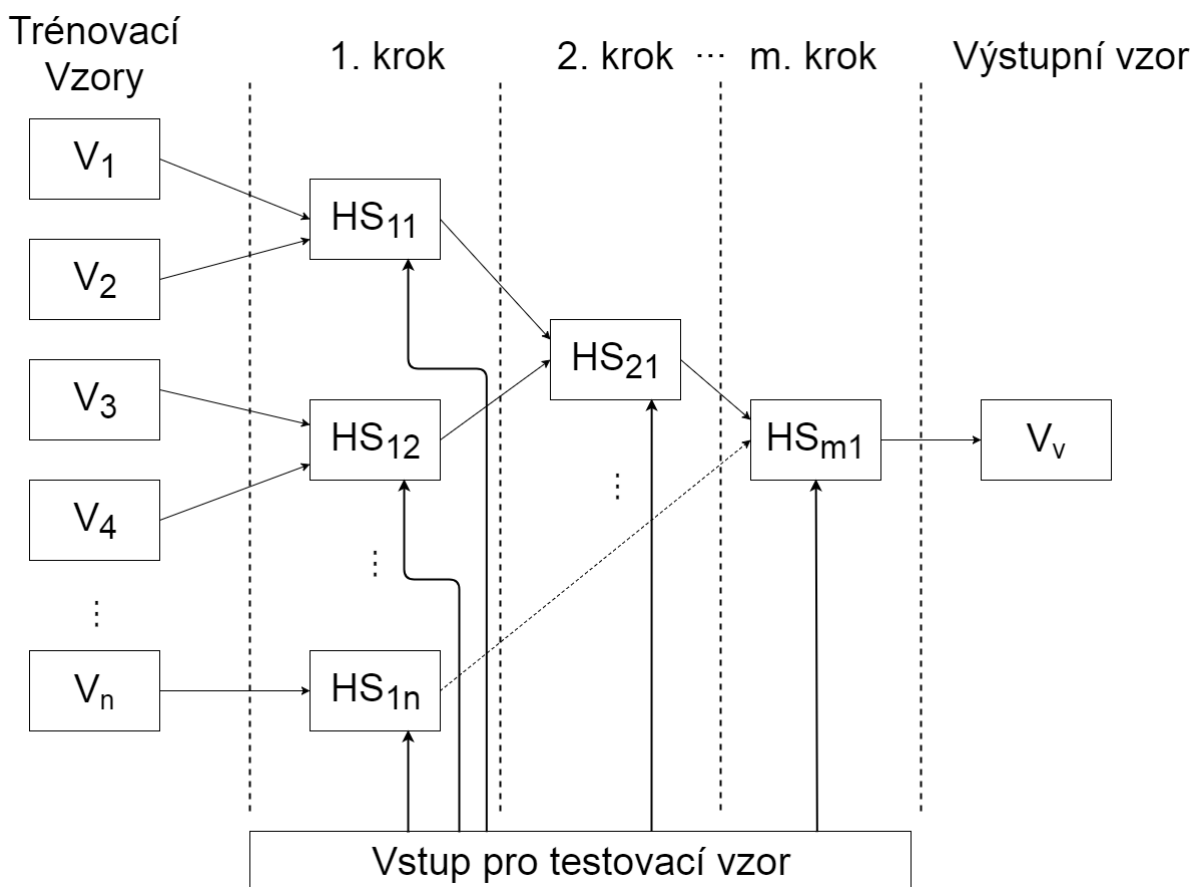
#### 6.4.2 Spider–Hopfieldova síť

V průběhu testování bylo zjištěno, že si Hopfieldova síť začíná vytvářet fantomové vzory mnohem dříve, než jak vyplývá ze vzorců 6.4.1.8. Testy byly nejprve prováděny na úloze rozpoznávání znaků definovaných vektorem o délce 256 stavů, který byl vykreslen do mřížky 16 x 16 bodů. Navzdory kapacitě HS, která byla podle vzorce stanovena na 16 vzorů, se ukázalo, že již při třech vzorech se začaly objevovat fantomové vzory. Pokud ovšem byla síť nastavena na rozpoznání mezi pouhými dvěma vzory, pak se fantomové vzory neobjevovaly. Těchto poznatků využívá navržená metodika použití Hopfieldovy sítě, která byla v rámci disertační práce navržena.

Metodika dostala název Spider–Hopfieldova síť, neboť je inspirována vyřazovacím systémem, který se často využívá ve sportovních utkáních. Rozpis utkání je u tohoto systému znázorněn pomocí grafu, který se nazývá pavouk.

Obecné schéma Spider–Hopfieldovy sítě je uveden na Obr. 17. Tento přístup využívá HS v její nejlepší možné konfiguraci pro úlohu rozpoznávání vzorů.

Prakticky má smysl uvažovat minimálně dva vzory, mezi kterými se bude HS rozhodovat. Jak již bylo řečeno, HS funguje pro dva vzory bez obtíží, spojených s fantomovými vzory. Z praktických testů vyplynulo, že v případě dvou vzorů HS vždy správně konvergovala do jednoho ze svých trénovacích vzorů.



Obr. 17: Obecné schéma Spider–Hopfieldovy sítě

Rozhodovací proces pak probíhá v několika na sebe navazujících kolech, do kterých se postupně dostává méně a méně trénovacích vzorů, až zůstane jediný výstupní vzor, který je výsledkem klasifikačního procesu.


Spider–Hopfieldova síť využívá několik Hopfieldových neuronových sítí (HS) vzájemně propojených do pavoučího grafu. Každá HS dostane před spuštěním k dispozici nejvýše dva vzory, které použije pro inicializaci svých vah podle Hebbova zákona. Poté si převezme testovací vzor, podle něhož inicializuje stavy svých neuronů. Následuje fáze relaxace, během které HS zrelaxuje




do jednoho ze dvou trénovacích vzorů. Jelikož se v případě dvou vzorů neprojeví fantomové vzory, je výsledný stav sítě vždy jedním z trénovacích vzorů. Tato vlastnost je zabezpečena volbou délky vzorů. Pokud by totiž byly vzory příliš krátké, pak by se mohly fantomové vzory objevit i v případě dvou trénovacích vzorů. Výsledný stav HS si pak přebírá jako jeden ze svých trénovacích vzorů následující HS v dalším kroku rozhodovacího procesu. Každý průběh jedné HS lze tedy považovat za rozhodovací proces, ze kterého zůstane vždy jeden vítězný vzor.

Všechny HS jsou v rámci jednotlivých kroků spouštěny synchronizovaně. Pokud zůstane některý z trénovacích vzorů lichý, pak HS zrelaxuje právě do tohoto vzoru, který se může „konfrontovat“ s některým z ostatních trénovacích vzorů např. až u poslední HS. Tato situace je rovněž znázorněna na Obr. 17.

Průběh klasifikačního procesu ilustruje výsledek testování Spider–Hopfieldovy sítě opět na úloze rozpoznávání písmen viz Obr. 18 a Obr. 19.



Obr. 18: Testovací vstup do Spider–Hopfieldovy sítě v rámci testu na úloze rozpoznávání znaků



Obr. 19: Průběh klasifikačního procesu Spider–Hopfieldovy sítě na úloze rozpoznávání znaků. Jsou zobrazeny pouze výsledky jednotlivých kroků nikoliv inicializační stav. Trénovací množina na začátku obsahovala všechny znaky anglické abecedy


## 6.5 Softwarová realizace

Pro účely testování výše popsaného algoritmu byla vyvinuta aplikace v programovacím jazyce Python 3. Ke zkrácení výpočetního času bylo využito paralelního zpracování dat prostřednictvím výpočetní knihovny *numpy*. Samotný výpočet může být zpomalen kvůli procesu načítání dat z CSV souboru; proto je použita technika cache paměti, díky které dochází k eliminaci času potřebného pro načítání vstupních dat v případech, kdy je požadováno provést více testů na jedné množině vstupních dat. Grafický výstup aplikace realizovaný pomocí nativní grafické knihovny *tkinter* jazyka Python sloužil zejména pro grafické znázornění dílčích výsledků identifikace.


Primárně je aplikace určena pouze k provádění testů a sledování jejich dílčích výstupů. Vývoj aplikace byl soustředěn zejména na optimalizování algoritmu, nikoliv na grafickou část. Ukázkový výstup z aplikace je ilustrován na porovnání výsledků mezi Hopfieldovou sítí a Spider–Hopfieldovou sítí (Obr. 20 a Obr. 21).

Výstup z aplikace se skládá ze tří řádků. V prvním řádku jsou zobrazeny trénovací vzory, které byly použity pro inicializaci vah. Sítí s takto nastavenými vahami jsou postupně předkládány testovací vzory (2. řádek výstupu), podle nichž dochází k inicializaci sítě. Ta potom postupně zrelaxuje do stabilního stavu, který je pak považován za výstup z neuronové sítě (3. řádek výstupu). Pro každý z uvedených testovacích vzorů je tedy proveden vždy jeden kompletní výpočet dle výše popsaného algoritmu.

V obou případech bylo v trénovací množině použito stejných 10 vzorů. Výsledky se výrazně liší. U klasické HS nedošlo k úspěšné identifikaci ani v jednom případě, zatímco v případě Spider–Hopfieldovy sítě bylo dosaženo úspěchu v sedmi případech z deseti.



Obr. 20: Ukázka výstupu při použití Hopfieldovy sítě trénované na 10 vzorů



*Obr. 21: Ukázka výstupu při použití Spider–Hopfieldovy sítě trénované na 10 vzorů*

Úspěšnou identifikaci lze z výstupu poznat podle toho, zda se shoduje grafická reprezentace trénovacího vzoru s výstupem z neuronové sítě, tj. u jednotlivých sloupců se porovnají grafické výstupy uvedené na prvním a třetím řádku. Za výstup z neuronové sítě je považován stabilní stav finální HS.

Výsledky podrobnějšího testování navrženého algoritmu jsou uvedeny v následující kapitole.

## 7. EXPERIMENTÁLNÍ ČÁST

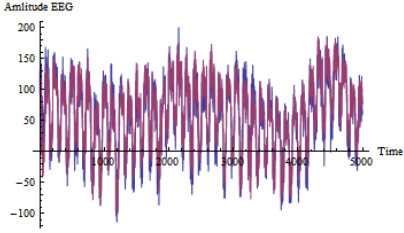
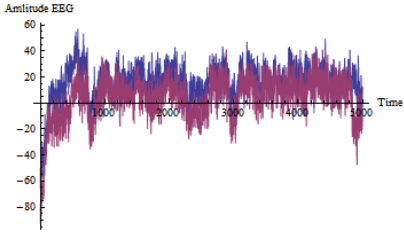
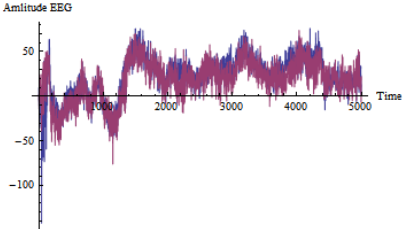
V této kapitole jsou prezentovány výsledky experimentů, které lze rozdělit na dvě hlavní skupiny. První skupina se zabývá analýzou samotného REC EEG záznamu, která měla odhalit, zda lze v získaném signálu nalézt takovou charakteristiku, která bude vykazovat vlastnosti vhodné pro účely identifikace osob. Mezi tyto vlastnosti patří zejména požadavek, aby byla tato charakteristika pro každý subjekt jedinečná, ale zároveň, aby zůstávala pro jeden konkrétní subjekt neměnná. V případě EEG signálu se ukázalo, že proces identifikace charakteristik, které zmíněné požadavky splňují, je komplikován vlastnostmi samotného signálu EEG, který je obecně nestacionární. Signál tedy nelze zpracovávat celý najednou, lze jej ale rozdělit na menší stacionární úseky. Analýza EEG signálu byla nakonec zaměřena na odhalení vztahů mezi jednotlivými kanály EEG záznamu pomocí Pearsonova korelačního koeficientu. Výsledky z této analýzy poté nasměrovaly výzkum do fáze návrhu algoritmu vhodného pro identifikaci osob pomocí EEG záznamu, kde bylo využito výsledků korelační analýzy pro jednotlivé subjekty ve fázi vytváření reprezentace dat pro neuronovou síť.

Druhá skupina experimentů se pak zabývá testováním navrženého algoritmu. Nejprve byly provedeny počáteční testy na menší databázi EEG záznamů, aby se odhalily základní vlastnosti a parametry navrženého algoritmu. Poté byla použita jiná rozsáhlejší databáze, s jejíž pomocí byla testována zejména závislost počtu trénovacích vzorů na vlastnosti algoritmu.

### 7.1 Korelační analýza EEG signálu

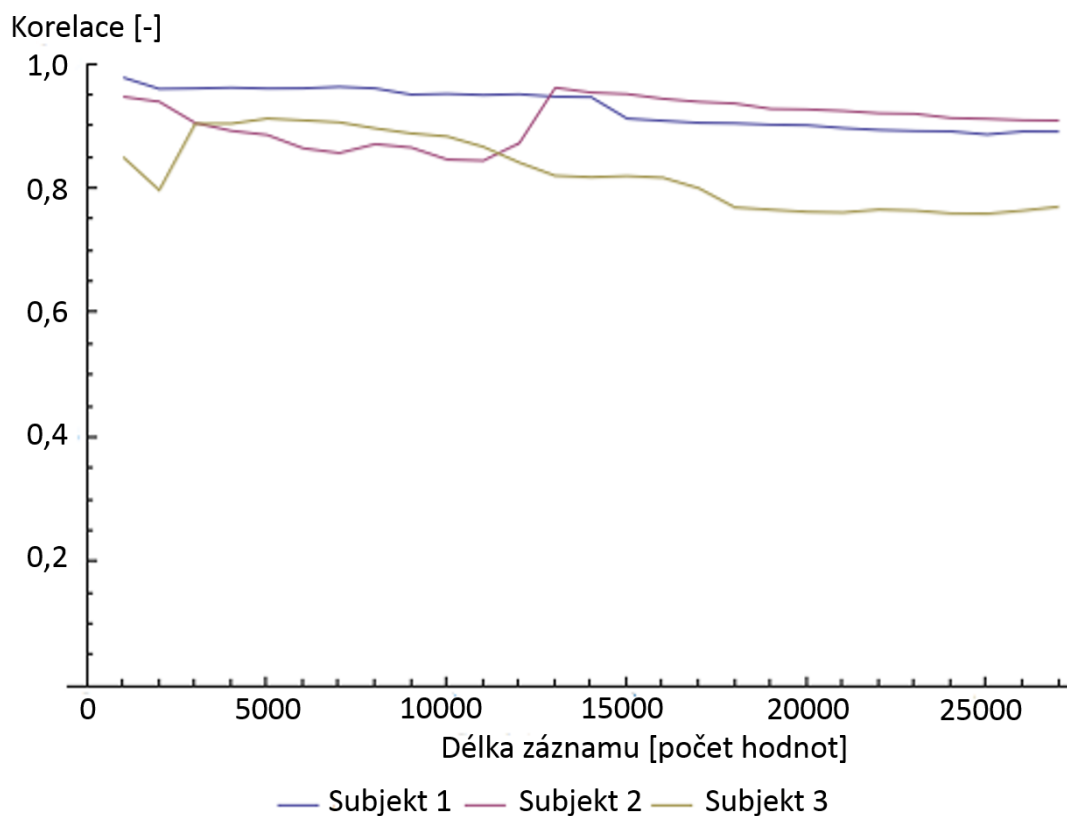
Nejprve byla provedena analýza EEG signálu, s cílem ověřit využitelnost EEG signálu v biometrických systémech. Získaná data byla podrobena korelační analýze, při níž byly zkoumány podobnosti mezi jednotlivými REC EEG signály pro jednotlivé dobrovolníky, kteří se experimentu zúčastnili. Dosažené výsledky pro vybrané tři dobrovolníky (subjekt 1 až subjekt 3) jsou uvedeny v tabulce Tabulka 1. V tabulce jsou uvedeny dvojice signálů, u nichž bylo dosaženo pro daný subjekt nejvyšší korelace společně s hodnotou této korelace. Poslední sloupec pak ukazuje průběh těchto signálů. Všechny hodnoty v tabulce byly získány pro signály o délce 5 000 vzorků (39 sekund). I když byly pro všechny subjekty zajištěny stejné laboratorní podmínky, konečné výsledky se mezi jednotlivými dobrovolníky výrazně liší.

Tabulka 1. Výsledky analýzy pro tři vybrané dobrovolníky

Osoba	Názvy kanálů	Korelace	Grafické porovnání kanálů
Subjekt 1	(AF3, F3)	95,7985	
Subjekt 2	(O2, P8)	81,7761	
Subjekt 3	(P7,O1)	87,9316	

V rámci korelační analýzy byl zkoumán i vliv délky analyzovaného signálu na hodnotu nejvyšší dosažené korelace mezi dvěma signály. Výpočet korelace byl nejprve proveden pro signál o délce 1 000 vzorků, což odpovídá přibližně 8 sekundám záznamu EEG. Každý další výpočet byl pak proveden pro signály o 1 000 vzorků delší. Vztah mezi délkou signálu a hodnotou korelace je znázorněn na Obr. 22.

Další korelační analýza si kladla za cíl zjistit, jakým způsobem se mění hodnota vzájemné korelace mezi EEG signály v závislosti na čase. U všech dobrovolníků byly pro účely analýzy použity REC EEG záznamy o délce 25 000 vzorků (195,3 s). Podobně jako v předchozí analýze byly vypočteny hodnoty korelací mezi jednotlivými naměřenými signály. Tentokrát však vždy pro část signálu s délkou 10 000 vzorků (78,125 s) při časovém posunu 1 000 vzorků (7,8125 s). Ukázka výsledků této analýzy je uvedena v tabulce Tabulka 2 a na Obr. 23.



Obr. 22.: Závislost hodnoty nejvyšší korelace na délce signálu


Tabulka 2. Výsledky analýzy pro subjekt 1

ID	První hodnota	Poslední hodnota	Nejvyšší korelace	Názvy kanálů
1	1	10000	0,952552	AF3 F3
2	1001	11000	0,948659	AF3 F3
3	2001	12000	0,950475	AF3 F3
4	3001	13000	0,94621	AF3 F3
5	4001	14000	0,946543	AF3 F3
6	5001	15000	0,914729	P7 O1
7	6001	16000	0,909592	P7 O1
8	7001	17000	0,901304	P7 O1
9	8001	18000	0,900297	P7 O1
10	9001	19000	0,892232	AF3 T7
11	10001	20000	0,923422	AF3 F4
12	11001	21000	0,916445	AF3 F4
13	12001	22000	0,869922	AF3 F4
14	13001	23000	0,84772	T7 P7
15	14001	24000	0,839024	T7 P7
16	15001	25000	0,901458	T7 F8

Tabulka 2 je výsledkem analýzy pro jednoho dobrovolníka a uvádí části signálu, pro které byly provedeny výše zmíněné výpočty. Jednotlivé části jsou vymezeny pozicí první a poslední hodnoty. Pak byla vyhledána hodnota nejvyšší

korelace a pozice elektrod, mezi nimiž tato korelace byla získána. Pro lepší orientaci je tabulka doplněna ilustrací pozic jednotlivých elektrod na hlavě subjektu (Obr. 23). Zvýrazněné pozice jsou ty, mezi nimiž byla získána hodnota nejvyšší korelace.

Výsledky se mezi jednotlivými dobrovolníky značně lišily, i když všichni dobrovolníci prováděli stejnou činnost. Zatímco u prvního subjektu byla nejvyšší korelace v průběhu 16 dílčích úseků signálu nalezena u šesti různých dvojic elektrod, u druhého subjektu byla pokaždé mezi stejnými elektrodami (O2, P8). Nakonec u třetího subjektu bylo dosaženo opět jiného chování. Zde byla nejvyšší korelace nalezena u těchto tří dvojic elektrod: (P7, O1), (F3, P7) a (FC6, F8).



*Obr. 23: Pozice elektrod s nejvyšší korelací pro subjekt 1*

Konkrétní výsledky pro subjekt 2 a subjekt 3 jsou uvedeny ve stejné podobě jako v případě subjektu 1 – nejprve jsou uvedeny tabulky s výsledky výpočtů pro jednotlivé úseky záznamů (Tabulka 3 a Tabulka 4), za kterými opět následují ilustrace pozic jednotlivých elektrod se zvýrazněnými pozicemi těch, mezi nimiž byla v průběhu analýzy dílčích úseků záznamu získána nejvyšší hodnota korelace (Obr. 24 a Obr. 25). Výsledky dále ukazují, že je z hlediska detekce odlišností mezi jednotlivými subjekty důležitá i poloha oblastí, mezi nimiž se objevila nejsilnější přímá závislost.


Tabulka 3. Výsledky analýzy pro subjekt 2

ID	První hodnota	Poslední hodnota	Nejvyšší korelace	Názvy kanálů
1	1	10000	0,846923	O2 P8
2	1001	11000	0,817771	O2 P8
3	2001	12000	0,859306	O2 P8
4	3001	13000	0,969112	O2 P8
5	4001	14000	0,961076	O2 P8
6	5001	15000	0,959598	O2 P8
7	6001	16000	0,95466	O2 P8
8	7001	17000	0,95149	O2 P8
9	8001	18000	0,947908	O2 P8
10	9001	19000	0,939777	O2 P8
11	10001	20000	0,942595	O2 P8
12	11001	21000	0,939619	O2 P8
13	12001	22000	0,933342	O2 P8
14	13001	23000	0,686855	O2 P8
15	14001	24000	0,69902	O2 P8
16	15001	25000	0,652335	O2 P8

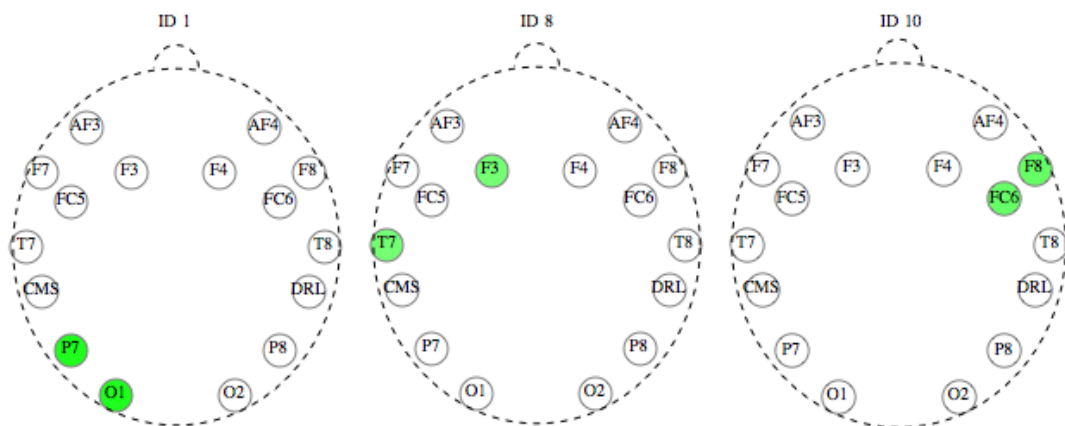
Tabulka 4. Výsledky analýzy pro subjekt 3

ID	První hodnota	Poslední hodnota	Nejvyšší korelace	Názvy kanálů
1	1	10000	0,88404	P7 O1
2	1001	11000	0,840489	P7 O1
3	2001	12000	0,8111294	P7 O1
4	3001	13000	0,736946	P7 O1
5	4001	14000	0,697164	P7 O1
6	5001	15000	0,632396	P7 O1
7	6001	16000	0,54687	P7 O1
8	7001	17000	0,601577	F3 T7
9	8001	18000	0,578018	F3 T7
10	9001	19000	0,601577	FC6 F8
11	10001	20000	0,578018	FC6 F8
12	11001	21000	0,589425	FC6 F8
13	12001	22000	0,599788	P7 O1
14	13001	23000	0,673097	FC6 F8
15	14001	24000	0,685173	FC6 F8
16	15001	25000	0,696007	FC6 F8





Obr. 24: Pozice elektrod s nejvyšší korelací pro subjekt 2



Obr. 25: Pozice elektrod s nejvyšší korelací pro subjekt 3

Další výzkum byl zaměřen na detekci mrkání očí. Tento stav lze rozpoznat s využitím databáze tzv. univerzálních signatur, které vznikly na základě pozorování podobností mezi signály mozkové aktivity různých jedinců; například mrknutí oka se projevuje u většiny lidí podobným průběhem, a proto bylo možné vytvořit univerzální signaturu pro tuto i řadu dalších činností (pohyb obočí, úst, očí, stav klidného vědomí, stav vzrušení apod.). Databáze těchto univerzálních signatur je k dispozici v rámci software, který byl součástí zakoupeného EEG přístroje. Cílem testování bylo prověřit, nakolik je obtížné realizovat aktivitu mrknutí očí tak, aby tato byla rozpoznána softwarem, který používá právě již zmíněné univerzální signatury. Byla-li využita signatura čistě pro aktivitu mrknutí očí, průměrná úspěšnost detekce byla 65,45 %. Zvýšení úspěšnosti pak bylo dosaženo tím, že dále byla využita signatura stavu otevřených očí. V tomto případě se úspěšnost pohybovala kolem 98 %. Vyšší úspěšnost může být v tomto případě způsobena tím, že na rozdíl od aktivity mrknutí oka je stav otevřených očí lépe rozpoznatelný.

Výsledky uvedených analýz odhalují možnosti praktického uplatnění EEG signálu pro účely identifikace osob. Další část výzkumu se zaměřila na vývoj takového algoritmu, který by zjištěné skutečnosti dokázal využít pro identifikaci osob pomocí EEG záznamů.

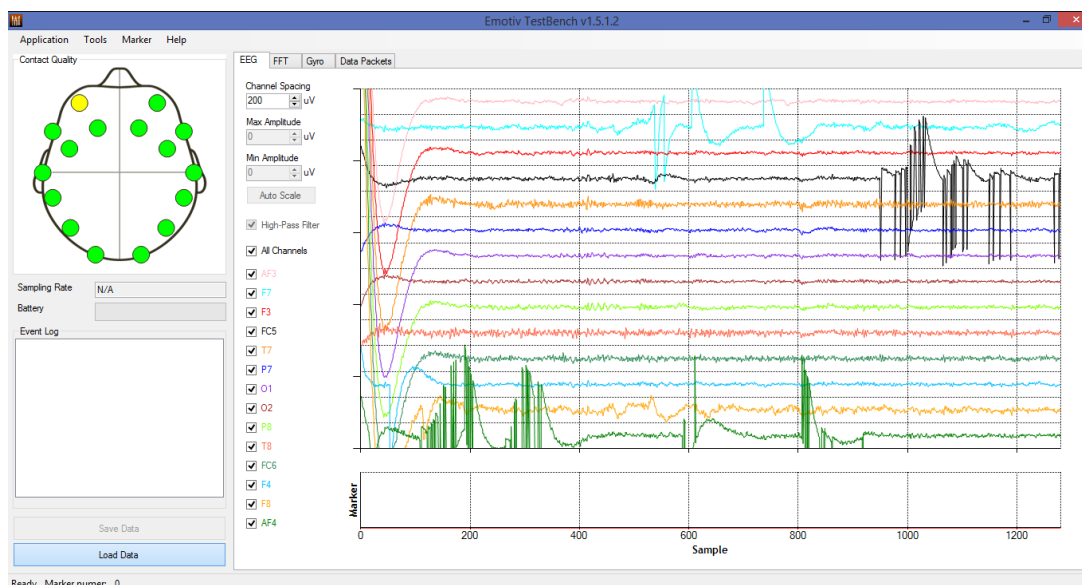
## **7.2 Identifikace subjektů pomocí EEG signálu**

Navržený algoritmus identifikace osob pomocí EEG signálu byl otestován na reálných záznamech EEG, jež byly v průběhu výzkumu naměřeny pomocí Emotiv EPOC headset přístroje, na základě podmínek, které jsou blíže specifikovány v kapitole 6.1. Další testování algoritmu se zaměřilo na zkoumání jeho vlastností s jinou, rozsáhlejší databází záznamů EEG, které byly pořízeny v průběhu spánku. Konkrétní popis této databáze je společně s výsledky experimentů uveden v kapitole 7.2.2.

### **7.2.1 Testování s REC EEG záznamy**

Součástí výzkumu bylo také pořízení vlastní databáze EEG záznamů. Tato databáze poté sloužila v pilotním testování k ověření úspěšnosti navrženého identifikačního algoritmu, popsaného v kapitole 6. Výsledky navíc ukazují i vliv dalších faktorů (např. počet trénovacích vzorů, délka trénovacích vzorů a časový odstup mezi trénovacími vzory a testovacím vzorem) na úspěšnost samotné identifikace.

Před samotnou realizací jednotlivých testů bylo nutné výsledky technicky upravit do podoby vhodné pro další zpracování. Společně s měřicím přístrojem Emotiv EPOC headset byla pro ukládání záznamu použita přidružená aplikace Emotiv TestBench, která je součástí softwarového vybavení, dodávaného výrobcem přístroje. Ukázkový vzhled a výstup této aplikace je uveden na Obr. 26. V průběhu měření je v aplikaci vidět aktuální průběh elektrické aktivity mozku ve všech 14 kanálech v podobě 14 grafů se vzájemně posunutou x-ovou osou tak, aby bylo možné všechny kanály sledovat přehledně ve stejných časových okamžicích. Po skončení měření je možné záznam uložit do souboru ve formátu EDF (European Data Format), který je v současné době běžně používaným standardem pro ukládání biologických dat. Headset však měří kromě EEG i další data, která nejsou pro zpracování EEG nezbytně potřebná (např. data z gyroskopu, kvalita signálu z jednotlivých elektrod, čítač záznamů apod.). Proto bylo přikročeno k úpravě, jejímž cílem bylo vybrat z uloženého záznamu pouze EEG data a uložit je do formátu CSV. Tato konverze byla provedena pouze z důvodu snadnější manipulace s daty v aplikaci vyvinuté pro účely testování, viz kapitola 6.5.



Obr. 26: Ukázka výstupu v aplikaci Emotiv TestBench

Každý EEG záznam pak již obsahoval pouze hodnoty naměřené ze 14 elektrod se vzorkovací frekvencí 128 Hz. Pro každou sekundu záznam tedy obsahuje 128 hodnot. Pro účely testování byl pak z celkového EEG záznamu vybrán úsek o zvolené délce, aby sloužil k vytvoření bipolární podoby vzoru dle algoritmu popsaného v kapitole 6.3. Délka vybraného úseku záznamu je vždy dána počtem jeho hodnot. U jednotlivých testů byla tato délka zvolena tak, aby bylo možné využít celou délku pořízeného záznamu. Pokud je zvolený úsek záznamu použit pro vytvoření trénovacího vzoru, pak se jedná o trénovací záznam. Analogicky, úsek záznamu, který byl východiskem pro vytvoření testovacího vzoru, je terminologicky označen jako testovací záznam. Úspěšnost identifikace je pak dána poměrem mezi úspěšně provedenými identifikacemi a celkovým počtem identifikací.

Test, jehož výsledky ukazuje Tabulka 5, byl proveden na základě následujícího postupu. Každý pořízený záznam jednotlivých subjektů dosahoval jiné délky. Aby bylo možné test provést pro všech 10 subjektů, bylo nutné brát ohled na délku nejkratšího záznamu. Kvůli tomu byla délka záznamu, který sloužil k vytvoření vzorů (trénovacích i testovacích) pro neuronovou síť, nastavena na 16 768 hodnot. Všechny trénovací vzory byly zpracovány z prvních 16 768 hodnot záznamu do bipolární podoby o velikosti 112 bitů (8 bitů na každý kanál). Záznam, který byl použit pro získání testovacího vzoru, měl stejnou délku jako v případě trénovacích vzorů. Vzniklo tak „okno“ o délce 16 768 hodnot, se kterým se v průběhu testu postupně posunovalo. Posun, uvedený v tabulce, je počítán od začátku celého EEG záznamu, posun 17 000

tedy značí, že testovací záznam začíná na 17 000. hodnotě uložené v celkovém EEG záznamu daného subjektu.

Výsledek testu odhaluje vliv posunu testovacího záznamu na úspěšnost identifikace. Čím více se testovací záznam překrýval s trénovacími záznamy, tím vyšší úspěšnosti bylo dosaženo. Svou roli zde sehrála i blízká podobnost některých trénovacích vzorů, díky čemuž docházelo k mylné identifikaci; např. subjekt 5 byl často zaměňován se subjektem 6. V tabulce je uvedena průběžná úspěšnost identifikace jak pro jednotlivé posuny testovacího záznamu, tak i pro jednotlivé subjekty. Průměrná úspěšnost během tohoto testu byla 88,24 %.

Tabulka 5. Vliv posunu testovacího záznamu na úspěšnost identifikace mezi deseti subjekty (délka vzorů nastavena na 16 768 hodnot)

Posun první hodnoty testovacího vzoru	Úspěšnost identifikace pro subjekty 1 - 10 (A/N)										Úspěšnost identifikace [%]
	1	2	3	4	5	6	7	8	9	10	
17000	A	A	A	A	N	A	A	A	N	N	70
16000	A	A	A	A	N	A	N	A	N	A	70
15000	A	A	A	A	N	A	A	A	A	A	90
14000	A	A	A	A	N	A	A	A	A	A	90
13000	A	A	A	A	N	A	N	A	A	A	80
12000	A	A	A	A	A	A	N	A	A	A	90
11000	A	A	A	A	A	A	A	A	A	A	100
10000	A	A	A	A	A	A	N	A	A	A	90
9000	A	A	A	A	A	A	N	A	A	A	90
8000	A	A	A	A	A	N	A	A	A	A	90
7000	A	A	A	A	A	N	A	A	A	A	90
6000	A	A	A	A	A	N	A	A	A	A	90
5000	A	A	A	A	A	N	A	A	A	A	90
4000	A	A	A	A	N	N	A	A	A	A	80
3000	A	A	A	A	N	A	A	A	A	A	90
2000	A	A	A	A	A	A	A	A	A	A	100
1000	A	A	A	A	A	A	A	A	A	A	100
Úspěšnost identifikace pro jednotlivé subjekty [%]	100,00	100,00	100,00	100,00	58,82	70,59	70,59	100,00	88,24	94,12	

Další test zjišťoval vliv délky trénovacího i testovacího záznamu na úspěšnost identifikace. Výsledky ukazuje Tabulka 6. Tento test tentokrát probíhal tak, že bylo použito prvních  $n$  hodnot EEG záznamu jako trénovací záznam a následujících  $n$  hodnot pak jako testovací záznam. Hodnota  $n$  se v tabulce nachází ve sloupci „Délka záznamů“. Opět je uvedena úspěšnost identifikace pro jednotlivé kroky testu a pro jednotlivé subjekty.

Průměrná úspěšnost identifikace byla v tomto případě 53,53 %. Tato nízká hodnota poukazuje na fakt, že je nutné pro úspěšnou identifikaci použít dostatečně dlouhý EEG záznam. Se zkracující se délkou záznamu totiž

docházelo k výraznému poklesu úspěšnosti identifikace, která klesla až na 30 % v případě délek záznamů 5 000, 3 000 a 2 000 hodnot.

Tabulka 6. Vliv délky vzorů na úspěšnost identifikace mezi deseti subjekty

Délka záznamů	Úspěšnost identifikace pro subjekty 1 - 10 (A/N)										Úspěšnost identifikace [%]
	1	2	3	4	5	6	7	8	9	10	
16768	A	A	A	A	N	A	A	A	N	N	70
16000	A	A	N	A	N	A	N	A	N	A	60
15000	A	A	N	A	N	A	N	A	N	N	50
14000	A	A	N	A	N	A	A	N	N	A	60
13000	A	A	N	A	A	N	A	A	N	A	70
12000	A	A	N	A	A	N	A	A	A	A	80
11000	A	A	N	A	N	N	A	A	N	A	60
10000	A	A	N	A	N	N	A	N	A	A	60
9000	A	A	N	A	N	N	A	N	A	A	60
8000	A	A	A	A	N	N	N	N	N	A	50
7000	A	A	A	A	N	N	N	N	N	A	50
6000	N	N	A	A	N	A	A	N	N	A	50
5000	N	N	N	A	N	N	A	N	N	A	30
4000	N	N	A	A	N	N	A	A	N	A	50
3000	N	N	N	N	A	N	N	A	N	A	30
2000	N	N	N	A	N	N	A	N	N	A	30
1000	A	N	A	A	A	A	N	N	N	N	50
Úspěšnost identifikace pro jednotlivé subjekty [%]	70,59	64,71	35,29	94,12	23,53	35,29	64,71	47,06	17,65	82,35	

Tabulka 7 a Tabulka 8 obsahují výsledky testů, které se zabývaly problematikou vlivu odstupu testovacího záznamu od trénovacích záznamů. Nejprve bylo pro test použito 10 subjektů (Tabulka 7), kdy se ukázalo, že průměrná úspěšnost identifikace byla 60,91 %. Takto nízká hodnota může být ovlivněna vzdáleností mezi trénovacími a testovacím vzorem, nicméně následující testy (Tabulka 8) prokázaly, že na úspěšnost identifikace má výrazný vliv také vzájemná podobnost trénovacích vzorů jednotlivých subjektů. Počet subjektů pro jednotlivé testy byl snížen na polovinu. Nejprve byly vytvořeny dvě skupiny (subjekt 1 – subjekt 5, subjekt 6 – subjekt 10). V případě první skupiny se úspěšnost zvýšila na 83,64 %, druhá skupina pak nezaznamenala výraznějšího zlepšení, neboť úspěšnost se zvýšila pouze o necelé 1 %. Při podrobnější analýze výsledků byl z hlediska grafické podoby vzorů odhalen vliv podobnosti jednotlivých trénovacích vzorů subjektů na celkovou identifikaci.

Trénovací vzory ve druhé skupině si byly vzájemně velmi podobné, což zapříčinilo častý výskyt mylných identifikací. Tuto skutečnost potvrzuje i třetí skupina, jejíž subjekty byly vybrány právě na základě vzájemně podobnosti, resp. odlišnosti jednotlivých trénovacích vzorů tak, aby si byly co nejméně vzájemně podobné. V tomto případě se přesnost zvýšila na 94,55 % (z 55 pokusů byly pouze 3 neúspěšné identifikace).

Tabulka 7. Vliv odstupů testovacího záznamu od trénovacích záznamů na úspěšnost identifikace mezi deseti subjekty. Délka vzorů nastavena na 12 000 hodnot

Číslo subjektu	Úspěšnost identifikace (A/N)										Úspěšnost identifikace [%]
	1	2	3	4	5	6	7	8	9	10	
Odstup testovacího vzoru											
0	A	A	N	A	A	N	A	A	A	A	80
1000	A	A	N	A	N	N	A	A	N	A	60
2000	A	A	N	N	N	N	A	A	N	A	50
3000	A	A	N	N	N	N	A	A	N	A	50
4000	A	A	N	A	N	A	A	N	N	A	60
5000	A	A	A	A	N	A	A	N	N	N	60
6000	A	A	A	N	N	A	A	N	N	A	60
7000	A	A	A	A	N	A	A	N	N	A	70
8000	A	A	A	A	N	A	A	A	N	N	70
9000	A	A	A	N	N	A	A	N	N	N	50
10000	A	A	A	A	N	A	A	N	N	N	60
<b>Průměrná úspěšnost identifikace [%]</b>	60,91										

Tabulka 8. Vliv odstupů testovacího záznamu od trénovacích záznamů na úspěšnost identifikace pro tři skupiny vzorů s pěti subjekty. Délka vzorů nastavena na 12 000 hodnot

Číslo skupiny	Úspěšnost (A/N)														
	1					2					3				
	1	2	3	4	5	6	7	8	9	10	1	4	7	8	10
Offset testovacího vzoru															
0	A	A	N	A	A	N	A	A	A	A	A	A	A	A	A
1000	A	A	N	A	A	N	A	A	N	A	A	A	A	A	A
2000	A	A	N	A	A	N	A	A	N	A	A	A	A	A	A
3000	A	A	A	A	N	A	A	N	N	A	A	A	A	A	A
4000	A	A	A	A	N	A	A	N	N	A	A	A	A	A	A
5000	A	A	A	A	N	A	A	N	N	N	A	A	A	A	N
6000	A	A	A	A	N	A	A	N	N	A	A	A	A	A	A
7000	A	A	A	A	N	A	A	N	N	A	A	A	A	A	A
8000	A	A	A	A	N	A	A	A	N	A	A	A	A	A	A
9000	A	A	A	A	A	A	A	A	N	N	A	A	A	A	N
10000	A	A	A	A	A	A	A	A	N	N	A	A	A	A	N
<b>Průměrná úspěšnost identifikace [%]</b>	83,64					61,82					94,55				

Úspěšnost navrženého algoritmu je závislá na délce trénovacích a testovacích záznamů, dále na počtu subjektů, míře podobnosti trénovacích vzorů a v neposlední řadě také na časovém odstupu mezi trénovacími a testovacími

vzory. V posledním zmíněném není závislost zcela zřejmá, neboť se hodnota úspěšnosti držela okolo 60 % a nevykazovala klesající trend jako v případě sledování závislosti úspěšnosti na délce záznamu.

Klíčem k co nejúspěšnější identifikaci je vybrat vhodný počet subjektů, pro něž se postupně vytvoří trénovací vzory pro HS ze záznamu o dostatečné délce (např. 12 000 hodnot). U trénovacích vzorů je pak důležité, aby byly do nejvíce rozdílné, jinak dochází k mylné identifikaci kvůli tomu, že v energetické ploše HS jsou v případě podobných vzorů jejich atrakce tak blízko sebe, že dochází ke konvergenci k jinému lokálnímu minimu, než by správně mělo být. Pokud nastane situace, kdy bude nutné některý vzor z důvodu podobnosti s jiným vzorem vyměnit, pak lze vzít jinou část záznamu o stejné délce (je-li k dispozici), případně provést nové měření.

### **7.2.2 Testování s CAP EEG záznamy**

CAP (Cyclic Alternating Pattern) neboli cyklický střídavý vzor, je periodická EEG aktivita vyskytující se v NREM spánku. Je charakteristická tím, že cerebrální aktivace (fáze A) je následována periodami deaktivace (fáze B), které oddělují mezi sebou dvě fáze v intervalu menším než 1 minuta. Perioda fáze A společně s periodou fáze B definují tzv. CAP cyklus. Ke zformování CAP sekvence je pak potřeba alespoň dvou CAP cyklů. Přestože jde o fyziologický jev, je CAP také ukazatelem spánkové nestability, která může být spojována s několika patologickými stavy spánku. Lze tedy podle něj diagnostikovat některé spánkové nemoci (Terzano, 2002).

Pro účely testování algoritmu identifikace byla vybrána databáze EEG záznamů, které obsahovaly záznamy CAP v průběhu spánku subjektu. Tato databáze je volně dostupná přes webový portál PhysioNetu, viz (Goldberger, 2000). Oficiálně je tato databáze kolekcí 108 polysomnografických záznamů osob registrovaných v Centru spánkových nemocí v italském Ospedale Maggiore v Parmě. Vlny obsahují u každé osoby nejméně 3 kanály EEG, 2 kanály EOG (Elektrookulografie), EMG vybraných svalů, respirační signály a EKG. Dále některé záznamy obsahují také EEG bipolární trasy, založené na 10–20 systému (Fp1-F3, F3-C3, C3-P3, P3-O1 a/nebo Fp2-F4, F4-C4, C4-P4, P4-O2). Součástí databáze jsou i záznamy 16 zdravých pacientů, u kterých nebyla zjištěna žádná neurologická porucha. Ostatní záznamy souvisí s pacienty, u nichž byla diagnostikována některá z těchto nemocí: bruxismus, nespavost, narkolepsie, nocturnal frontal lobe epilepsie, periodické pohyby nohou, poruchy REM spánku nebo porucha dýchání ve spánku. Jednotlivé záznamy databáze lze získat v podobě EDF souboru, nicméně na webovém portálu PhysioNetu se

nachází převáděcí online nástroj, jehož pomocí lze získat záznamy v podobě CSV souboru. Všechny záznamy v databázi byly pořízeny se vzorkovací frekvencí 512 Hz. Vzhledem k tomu, že záznamy již byly k dispozici normalizované, neprováděl se v případě testování této databáze normalizační krok.

Aby byly testy prováděny s co nejrelevantnějšími daty, byly vybrány pouze ty záznamy, které obsahovaly co největší počet EEG kanálů. Reálně se ukázalo, že nejvyšším počtem EEG kanálů mezi všemi 108 záznamy bylo 13 kanálů, které ale byly součástí pouze 30 záznamů.

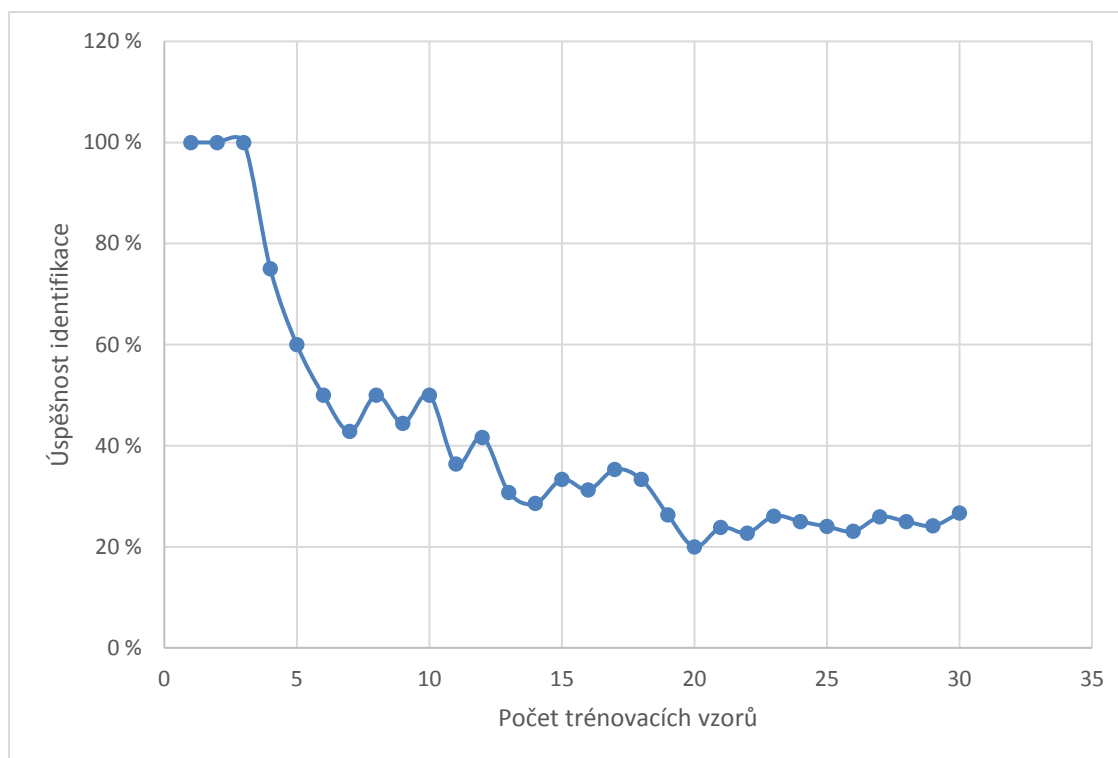
Nejprve byl algoritmus identifikace otestován se všemi 30 záznamy (Tabulka 9). V dalších krocích byl vždy odebrán poslední záznam, dokud nezůstal jeden. Z výsledků vyplývá, že algoritmus pro 11 a více trénovacích vzorů vykazoval velmi špatné výsledky. Teprve od počtu 10 vzorů a méně se úspěšnost začala zvedat směrem k lepším hodnotám, až nakonec u tří vzorů dosáhla úspěšnosti 100 %, kde zůstala i v případě dvou a jednoho vzoru. K výsledku pro jeden vzor je však potřeba dodat, že zde by algoritmus zrelaxoval do správného stabilního stavu vždy, protože žádný jiný stav, který by aktuálně jedinému stavu konkuroval, není v daném okamžiku v síti obsažen. Proto má smysl za realistický považovat až výsledek s minimálně dvěma trénovacími vzory. Další poznámka k výsledkům se opět týká vzájemné grafické podobnosti vzorů. Jsou-li jako trénovací vzory vybrány takové, které se vzájemně nepodobají, pak je úspěšnost identifikace vyšší. V průběhu testování bylo zpozorováno, že identifikace byla úspěšná vždy u stejných vzorů, což je způsobené tím, že právě tyto vzory byly v rámci množiny trénovacích vzorů jedinečnými, díky čemuž nedocházelo k záměně s jinými vzory.



Tabulka 9. Závislost počtu trénovacích vzorů na úspěšnosti identifikace

Počet trénovacích vzorů	Úspěšnost identifikace [%]	Počet trénovacích vzorů	Úspěšnost identifikace [%]	Počet trénovacích vzorů	Úspěšnost identifikace [%]
1	100	11	36	21	24
2	100	12	42	22	23
3	100	13	31	23	26
4	75	14	29	24	25
5	60	15	33	25	24
6	50	16	31	26	23
7	43	17	35	27	26
8	50	18	33	28	25
9	44	19	26	29	24
10	50	20	20	30	27

K výsledkům, které uvádí Tabulka 9, se vztahuje i graficky znázorněný průběh změny úspěšnosti identifikace na počtu trénovacích vzorů (Obr. 27). Nejúspěšnější identifikace byla pro dva a tři vzory, nejméně pak pro 20 vzorů. Svou roli v jednotlivých testech měla již zmíněná vzájemná podobnost vzorů. Z uvedených výsledků vyplývá, že algoritmus nelze doporučit pro úlohu klasifikace většího počtu vzorů. Naopak pro menší počet lze při vhodném výběru trénovacích vzorů dosáhnout i 100% úspěšnosti.



Obr. 27: Průběh úspěšnosti identifikace v závislosti na počtu trénovacích vzorů

Tabulka 10. Vliv rozdílnosti délek trénovacích a testovacích záznamů na úspěšnost identifikace

Délka trénovacího záznamu	Délka testovacího záznamu	Úspěšnost identifikace [%]	Délka trénovacího záznamu	Délka testovacího záznamu	Úspěšnost identifikace [%]
29000	1000	0	14000	16000	75
28000	2000	25	13000	17000	75
27000	3000	25	12000	18000	75
26000	4000	50	11000	19000	75
25000	5000	50	10000	20000	75
24000	6000	75	9000	21000	75
23000	7000	50	8000	22000	75
22000	8000	50	7000	23000	50
21000	9000	50	6000	24000	0
20000	10000	50	5000	25000	25
19000	11000	50	4000	26000	25
18000	12000	50	3000	27000	50
17000	13000	50	2000	28000	25
16000	14000	70	1000	29000	25
15000	15000	75			

V průběhu výzkumu byla uvažována i otázka, zda je možné použít jinou délku pro trénovací a testovací záznamy. Bylo by totiž výhodné, kdyby se ukázalo, že pro fázi relaxace do stabilního stavu by bylo možné využít mnohem kratších záznamů než ve fázi inicializace vah. K samotnému procesu identifikace by pak bylo potřeba mnohem kratšího času. Test, který se touto problematikou zabýval, však tuto domněnku nepotvrdil. Pro účely testu byly záměrně vybrány stejné čtyři vzory, u kterých v předchozím testu bylo dosaženo úspěšnosti 75 %. Výsledky tohoto testu obsahuje Tabulka 10. Z této tabulky vyplývá, že dodržení stejné délky pro trénovací i testovací záznamy je v souladu s dosažením nejvyšší možné přesnosti. Naopak příliš krátký záznam, ať už na straně testovacího nebo na straně trénovacího záznamu, způsobí rapidní pokles v úspěšnosti identifikace.

## 8. PŘÍNOS PRÁCE PRO VĚDU A PRAXI

Tato kapitola diskutuje vědecký a praktický význam disertace. Vědecký přínos je zaměřen na popsané algoritmy zpracování EEG záznamu. Praktické uplatnění je pak směřováno k možnostem využití výsledků práce v reálných aplikacích.

### 8.1 Přínos pro vědu

Disertace zkoumala možnost identifikace pomocí EEG záznamu a popisuje nekonvenční algoritmus, který může být další alternativou ke stávajícím metodám. Výsledek práce je otevřený dalšímu zkoumání v této oblasti a může sloužit jako základ pro další výzkumnou činnost, která se bude např. snažit stávající řešení dále modifikovat za účelem dosažení lepších parametrů (úspěšnost, rychlost, univerzálnost, efektivita apod.).

Hopfieldova síť je obvykle považována spíše za teoretický model a není tak příliš často používána v praktických úlohách. Uvedený výzkum ukazuje metodiku aplikace HS, díky kterému lze dosáhnout i při použití standardního modelu HS vyšší úspěšnosti, než jak je tomu v případě klasického přístupu použití jedné neuronové sítě. Metodika využívá architekturu vzájemného propojení více neuronových sítí, což je oblast, která může být dále zkoumána s ohledem na různé typy spojovacích architektur.

Další oblastí vhodnou pro budoucí výzkum může být grafická reprezentace EEG signálu. V práci byl navržen algoritmus, který vycházel z vlastností EEG záznamu. Nicméně může být aplikován i pro jiné druhy signálu. Právě možností nasazení na jiné typy signálu se mohou zabývat další výzkumy. Kromě toho lze vytvořit modifikované verze algoritmu. I když je v popisu uvedeno využití korelační analýzy, nemusí tato být jedinou vhodnou charakteristikou.

### 8.2 Přínos pro praxi

Ačkoli je práce popsána spíše v teoretické rovině, lze nalézt i praktické aplikace, v nichž by mohly být výsledky práce využity. V první řadě byla součástí výzkumu i analýza využitelnosti EEG signálu pro biometrickou identifikaci osob. Z prezentovaných výsledků vyplývá, že EEG signál je, navzdory své komplikovanosti, použitelný k rozpoznávání osob, ovšem za určitých podmínek. Těmi jsou vhodný počet trénovacích vzorů, dostatečná délka záznamu jak na straně trénovací, tak na straně testovací množiny, a dostatečná vzájemná odlišnost vzorů, která je rovněž závislá na celkové velikosti grafického vzoru. Výsledky lze tedy použít v biometrických systémech, ale

s tím, že je ke správné činnosti potřeba delších záznamů, což snižuje efektivitu EEG identifikace zejména kvůli času, který je pro úspěšnou identifikaci potřebný.

K dalším praktickým uplatněním lze zařadit využití pro nastavení nástrojů usnadnění, které používají uživatelé s handicapem při práci s počítačem. Každý takový uživatel má obvykle jiné požadavky na pomocné prostředky. Pokud je počítač užíván více takovými uživateli, pak by bylo užitečné, kdyby na základě identifikace dokázal operační systém sám nastavit jednotlivá nastavení systému, na něž je daný uživatel zvyklý (citlivost myši, velikost písmen, zvuky kláves apod.). Namísto zdoluhavého nastavování samotným uživatelem by všechno automaticky nakonfiguroval operační systém, protože by měl k jednotlivým naučeným uživatelům přiřazenou příslušnou množinu nastavení vlastností systému.

Kromě identifikace z celého EEG záznamu se nabízí aplikace pro rozpoznání biologických projevů na základě EEG. V této oblasti se v současnosti používají neuronové sítě, shluková analýza, rozpoznávání vzorů a další moderní metody zpracování signálů.

Přínos pro praxi lze shrnout obecně tak, že výsledky práce lze využít v aplikacích, ve kterých je požadováno zpracování EEG záznamu za účelem jeho přiřazení k jedné z předem definovaných tříd, jimiž mohou být samotné subjekty, biologické stimuly nebo jiné relevantní abstraktní předpisy klasifikovaných objektů.

## 9. ZÁVĚR

V oblasti biometrie je snaha nalézt biologické charakteristiky, jež by byly prakticky použitelné pro jednoznačnou a hlavně robustní identifikaci osob. Úspěšně se tak používá zabezpečení pomocí otisku prstů, geometrie dlaně, oční sítnice, oční duhovky nebo dynamiky chůze. EEG záznam, který zaznamenává elektrickou aktivitu mozku, je rovněž jedinečnou charakteristikou biologických systémů. Jeho největší nevýhodou je jeho složitost a nestacionárnost; nicméně lze jej rozdělit na menší stacionární úseky. Kromě toho je nutné jej měřit na více místech současně, nelze se spolehnout pouze na jednu elektrodu. Celkový EEG záznam se tedy zpravidla skládá z více signálů. Moderní přístroje EEG používají ke své činnosti elektrody umístěné na pozicích, které jsou značené na základě mezinárodního systému značení (tzv. 10–20 systém).

Disertace se zabývá možností využití EEG záznamu pro účely identifikace a zároveň popisuje nekonvenční přístup k řešení této problematiky. Ten je založený na míře vzájemné závislosti mezi naměřenými EEG signály vyjádřené pearsonovým korelačním koeficientem. V samotném algoritmu jsou pak upřednostňovány signály, mezi kterými existuje nejsilnější korelace, zatímco signály, mezi nimiž je míra korelace slabá, jsou penalizovány. V algoritmu předzpracování je míra korelace zohledněna tím, že nejsilněji korelující kanály obsahují ve své grafické reprezentaci více černých pixelů. Slabě korelující signály jsou naopak bílé. Toto barevné odlišení je však zvoleno kvůli uživatelské preferenci, samotný algoritmus místo černé barvy používá číslo 1 a místo bílé barvy číslo -1. Celková grafická reprezentace celého záznamu je pak složena z reprezentací jednotlivých kanálů.

Jakmile je vytvořena konečná grafická podoba EEG záznamu, postupuje se k dalšímu kroku zpracování, a tím je inicializace neuronové sítě pomocí bipolárních trénovacích vzorů (1, -1). Úloha identifikace se pak stává úlohou rozpoznávání grafických objektů, kde jednotlivými objekty jsou grafické reprezentace jednotlivých EEG záznamů. K řešení této úlohy je určena Hopfieldova síť, což byl i důvod pro její zvolení. V odborné literatuře se však uvádí, že HS patří mezi teoretické modely a nebývá často v praxi využita. Nicméně práce dokazuje, že HS má potenciál pro použití i na úlohu identifikace pomocí EEG, jen je nutné nespoléhat se pouze na schopnosti jedné samostatné HS, ale naopak jich do řešení problému zapojit více. Hlavním důvodem, proč není HS tak používaná, jsou fantomové vzory, které si síť začne vytvářet v případě většího počtu vzorů. Schopnosti HS jsou závislé na velikosti vzorů – čím větší vzory, tím více vzorů je HS schopna od sebe rozlišit a případně začne

od většího počtu vzorů vytvářet fantomové vzory. Existují i teoretické vzorce, které by měly být nápomocny při určení vlastnosti konkrétního nastavení HS, v praxi se však ukázalo, že odhady, jež tyto vzorce poskytují, jsou silně nadhodnocené, a tudíž ne příliš využitelné. Pro dva vzory HS dává nejúspěšnější výsledky; jeden vzor nemá (v případě klasifikace mezi více vzory) význam uvažovat, neboť v té chvíli v podstatě nedochází k procesu klasifikace, spíše lze mluvit o procesu konvergence k jedinému minimu na energetické ploše. Proto byl zvolen postup, kdy každá HS po inicializaci neuronů testovacím vzorem rozhoduje mezi dvěma naučenými vzory tím, že zrelaxuje do stavu, který je danému vzoru blíže. Tento stav je potom ze sítě odečten a použit jako jeden z trénovacích vzorů další HS. Tento proces pokračuje až do okamžiku, kdy zůstane poslední síť, která rozhodne o finálním výsledku procesu identifikace. Tento algoritmus byl v práci pojmenován jako „Spider–Hopfieldova síť“ kvůli podobnosti s vyřazovacím systémem hodnocení sportovních soutěží, kterému se také říká pavouk.

Navržený algoritmus byl otestován na reálných EEG záznamech pocházejících ze dvou rozdílných databází. První byla pořízena během řešení disertační práce, druhá pak byla vypůjčena z již proběhnutého výzkumu v Centru spánkových nemocí v italském Ospedale Maggiore v Parmě. Z dosažených výsledků plyne, že úspěšnost výsledků závisí na délce EEG záznamu; ukázalo se, že je vhodné použít záznam o délce alespoň 12 000 hodnot (93,75 s). Tento výsledek je však platný jen pro zkoumanou skupinu subjektů a závisí rovněž na počtu subjektů.

Dále se prokázalo, že čím nižší je počet trénovacích vzorů, tím přesnější je identifikace. Nejvyšší průměrná úspěšnost byla 94,55 % pro 5 vzorů. Měření bylo prováděno tak, že trénovací i testovací záznamy byly dlouhé 12 000 hodnot s tím, že trénovací záznamy zůstávaly v pevné oblasti (trénovací vzory byly tedy vždy generovány na základě stejné oblasti záznamu) a testovací záznam se od oblasti trénovacích záznamů postupně vzdaloval; nejprve začínal zároveň s koncem trénovací oblasti a pak se po kroku 1 000 hodnot postupně posunoval až ke vzdálenosti 10 000 hodnot o konce trénovací oblasti. K mylné identifikaci došlo v tomto případě celkem 3krát z celkem 55 pokusů, a to vždy u stejného subjektu. Tento výsledek potvrzuje důležitost vzájemné podobnosti vzorů mezi sebou.

Každý nový vzor, který je do trénovací množiny přidán, ovlivní tvar energetické funkce HS. Z uživatelského pohledu je velmi obtížné odhadnout, jaký vliv bude mít nový vzor na energetickou funkci, a tedy i na úspěšnost identifikace. Kontrola podobnosti vzorů je předmětem budoucího výzkumu,

neboť by se její vhodnou aplikací mohlo dosáhnout udržování stabilní robustnosti algoritmu při zvyšujícím se počtu vzorů.

Jak již bylo zmíněno, je pro úspěšnou identifikaci nutné použít delší záznam. I když byla snaha v nástroji pro testování dosáhnout co nejkratších výpočetních časů pro jednotlivé části algoritmu (0,05 s pro jeden výpočet s 10 vzory), stále ještě je nutné uvažovat délku pořizovacího času samotného EEG záznamu, který se při uvažovaných 10 vzorech ukázal být 93,75 s při 80% úspěšnosti. Kromě toho je významná i doba trvání instalace a inicializace měřicího přístroje, která se pohybuje v řádech minut. Pro zvýšení úspěšnosti je nutné uvažovat menší počet vzorů. Celková úspěšnost je také ovlivnitelná opět vzájemnou odlišností vzorů – čím budou vzory rozdílnější, tím úspěšnější bude identifikace. Z hlediska použití v real-time systémech byla zkoumána také situace, kdy by testovací vzor měl jinou (zpravidla kratší) délku než vzory trénovací. Zde se však ukázalo, že je nutné držet délky obou typů záznamů na stejné délce, jinak identifikace neprobíhá úspěšně. Z uvedených faktů je tedy zřejmé, že využitelnost EEG identifikace v real-time systémech je zatím obtížně představitelná. Může za to patrně komplexita a nestacionarita EEG záznamu. Tato problematika se nabízí jako námět k dalšímu výzkumu.

## SEZNAM POUŽITÉ LITERATURY

ABAZA, Ayman, et al. A survey on ear biometrics. *ACM computing surveys (CSUR)*. 2013, vol. 45, iss. 2, no. 22.

ANG, Kai Keng, et al. A randomized controlled trial of EEG-based motor imagery brain-computer interface robotic rehabilitation for stroke. *Clinical EEG and neuroscience*. 2015, vol. 46, iss. 4, s. 310-320.

BAHDANAU, Dzmitry, Kyunghyun CHO a Yoshua BENGIO. Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473v7*. 2016.

BAO, Xuecai, Jinli WANG a Jianfeng HU. Method of Individual Identification Based on Electroencephalogram Analysis. *International Conference on New Trends in Information and Service Science*. 2009, s. 390-393.

BARZEGARAN, Elham, et al. Perception-related EEG is more sensitive to Alzheimer's disease effects than resting EEG. *Neurobiology of aging*. 2016, vol. 43, s. 129-139.

BEALE, Russel a Tom JACKSON. *Neural computing: an introduction*. Bristol: Hilger, 1990. ISBN 9-780852-742624.

BENGIO, Samy, et al. Scheduled sampling for sequence prediction with recurrent neural networks. *Advances in Neural Information Processing Systems*. 2015. s. 1171-1179.

CAMPISI, P., G. SCARANO, F. BABILONI, F. DEVICO FALLANI, S. COLONNESE, E. MAIORANA a L. FORASTIERE. Brain waves based user recognition using the “eyes closed resting conditions” protocol. *2011 IEEE International Workshop on Information Forensics and Security*. IEEE, 2011, s. 1-6. ISBN 978-1-4577-1017-9.

CHAND, Shelvin, Rohitash CHANDRA. Cooperative coevolution of feed forward neural networks for financial time series problem. *Neural Networks (IJCNN)*. 2014, International Joint Conference on. IEEE, s. 202-209.

CHANDRA, Rohitash. Competition and collaboration in cooperative coevolution of Elman recurrent neural networks for time-series prediction. *IEEE transactions on neural networks and learning systems*. 2015, vol. 26, iss. 12, s. 3123-3136.



CHANDRA, Rohitash a Shelvin CHAND. Evaluation of co-evolutionary neural network architectures for time series prediction with mobile application in finance. *Applied Soft Computing*. December 2016, vol. 49, s. 462-473.

CHEN, Xiyuan, et al. Application of a genetic algorithm Elman network in temperature drift modeling for a fiber-optic gyroscope. *Applied optics*. 2014, vol. 53, iss. 26, s. 6043-6050.

CHUNG, I-Hsin, et al. Parallel deep neural network training for big data on blue gene/q. *IEEE Transactions on Parallel and Distributed Systems*. 2017, vol. 28, iss. 6, s. 1703-1714.

COLLINGER, Jennifer L., et al. High-performance neuroprosthetic control by an individual with tetraplegia. *The Lancet*. 2013, vol. 381, iss. 9866, s. 557-564.

COLLOBERT, Ronan, et al. Natural language processing (almost) from scratch. *Journal of Machine Learning Research*. August 2011, s. 2493-2537.

CPAŁKA, Krzysztof, Marcin ZALASIŃSKI, Leszek RUTKOWSKI. A new algorithm for identity verification based on the analysis of a handwritten dynamic signature. *Applied soft computing*. 2016, vol. 43, s. 47-56.

DIY tDCS. *Where Do The Electrodes Go?* [online]. 2012 [cit. 2017-06-13]. Dostupné z: <http://www.diytdcs.com/tag/1020-positioning/>

DONG, Zhen, et al. Vehicle type classification using a semisupervised convolutional neural network. *IEEE Transactions on Intelligent Transportation Systems*. 2015, vol. 16, iss. 4, s. 2247-2256.

DRAGOI, Elena Niculina, et al. Grey and black-box modelling based on neural networks and artificial immune systems applied to solid dissolution by rotating disc method. *Chemical Engineering and Processing: Process Intensification*. August 2014, vol. 82, s. 173-184.

DU, Wei, Sunney Yung Sun LEUNG a Chun Kit KWONG. Time series forecasting by neural networks: A knee point-based multiobjective evolutionary algorithm approach. *Expert systems with applications*. 2014, vol. 41, iss. 18, s. 8049-8061.

DREYFUS, G. *Neural networks: methodology and applications*. New York: Springer, 2005. ISBN 978-3-540-22980-3.

EMOTIV [online]. ©2017 [cit. 2017-06-13]. Dostupné z: <http://www.emotiv.com/>

FAUSETT, L. V. *Fundamentals of Neural Networks: architectures, algorithms, and applications*. Englewood Cliffs, New Jersey: Prentice-Hall, 1994.

FORSTMANN, Birte U., Max C. KEUKEN a Anneke ALKEMADE. An introduction to human brain anatomy. *An Introduction to Model-Based Cognitive Neuroscience*. Springer New York, 2015. s. 71-89.

GOLDBERGER, A. L., L. A. N. AMARAL, L. GLASS, J. M. HAUSDORFF, P. Ch. IVANOV, R. G. MARK, J. E. MIETUS, G. B. MOODY, C-K PENG a H. E. STANLEY. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation*. June 2000, vol. 101, no. 23, s. 215-220.

GRAVES, Alex, Abdel-rahman MOHAMED a Geoffrey HINTON. Speech recognition with deep recurrent neural networks. *Acoustics, speech and signal processing (ICASSP)*. 2013 IEEE international conference on. IEEE, 2013, s. 6645-6649.

GREENSPAN, Hayit, Bram VAN GINNEKEN a Ronald M. SUMMERS. Guest editorial deep learning in medical imaging: Overview and future promise of an exciting new technique. *IEEE Transactions on Medical Imaging*. 2016, vol. 35, iss. 5, s. 1153-1159.

HASHIYADA, Masaki. DNA biometrics. *Biometrics*. InTech, 2011.

HAUSFELD, Lars, Giancarlo VALENTE a Elia FORMISANO. Multiclass fMRI data decoding and visualization using supervised self-organizing maps. *NeuroImage*. August 2014, vol. 96, s. 54-66.

HE, Xing, et al. A recurrent neural network for solving bilevel linear programming problem. *IEEE transactions on neural networks and learning systems*. 2014, vol. 25, iss. 4, s. 824-830.

HIREMATH, Shivayogi V., et al. Brain computer interface learning for systems based on electrocorticography and intracortical microelectrode arrays. *Frontiers in integrative neuroscience*. 2015, vol. 9.

HOMAN, R. W., J. HERMAN a P. PURDY. Cerebral location of international 10–20 system electrode placement. *Electroencephalography and Clinical Neurophysiology*. 1987, vol. 66, iss. 4, s. 376-382.

ITKIS, Gene, et al. Iris Biometric Security Challenges and Possible Solutions: For your eyes only? Using the iris as a key. *IEEE Signal Processing Magazine*. 2015, vol. 32, iss. 5, s. 42-53.

KHALIFA, W., et al. A survey of EEG based user authentication schemes. *Informatics and Systems (INFOS), 8th International Conference on*. IEEE, 2012, s. 55-60.

KOHN, Nils, et al. Neural network of cognitive emotion regulation—an ALE meta-analysis and MACM analysis. *Neuroimage*. 2014, vol. 87, s. 345-355.

LA ROCCA, D., P. CAMPISI a G. SCARANO. EEG biometrics for individual recognition in resting state with closed eyes. *Biometrics Special Interest Group (BIOSIG)*. 2012, BIOSIG-Proceedings of the International Conference of the. IEEE, s. 1-12.

LAKSHMANAN, Gowri a Mary POSONIA. A Novel Analysis on Application of Neural Support on Nuclear Reactor Control Process Monitoring. *Indian Journal of Science and Technology*. 2016, vol. 9, iss. 10.

LAKSHMI, M. Rajya, Dr TV PRASAD a Dr V. Chandra PRAKASH. Survey on EEG signal processing methods. *International Journal of Advanced Research in Computer Science and Software Engineering*. 2014, vol. 4, iss. 1. s. 84-91.

LIU, Shuangrong, et al. Prediction of share price trend using FCM neural network classifier. *Informative and Cybernetics for Computational Social Systems (ICCSS)*. 3rd International Conference on. IEEE, 2016, s. 81-86.

MATIAS, Tiago, et al. Learning of a single-hidden layer feedforward neural network using an optimized extreme learning machine. *Neurocomputing*. 2014, vol. 129, s. 428-436.

MNIH, Andriy; GREGOR, Karol. Neural variational inference and learning in belief networks. *arXiv preprint arXiv:1402.0030v2*. 2014.

MOHAMMADI, G., P. SHOUSHARI, B. MOLAEI ARDEKANI a M. B. SHAMSOLLAHI. Person identification by using AR model for EEG signals. *Proceeding of World Academy of Science, Engineering and Technology*. 2006, vol. 11, s. 281-285.

MURILLO-ESCOBAR, M. A., et al. A robust embedded biometric authentication system based on fingerprint and chaotic encryption. *Expert Systems with Applications*. 2015, vol. 42, iss. 21, s. 8198-8211.

NAPIERALSKI, Jan Andrzej, Michal Mirosław PASTUSZKA a Wojciech SANKOWSKI. 3D face geometry analysis for biometric identification. *Mixed Design of Integrated Circuits & Systems (MIXDES)*. 2014 Proceedings of the 21st International Conference. IEEE, 2014. s. 519-522.

NEHRU, Osheen a Kamal KUMAR. Review Paper of Voice Biometrics. *International Journal of Engineering Science*, 2016, vol. 6, no. 5, s. 5257-5260.

NGUYEN, P., D. TRAN, X. HUANG a D. SHARMA (2012, January). A proposed feature extraction method for eeg-based person identification. *Proceedings on the International Conference on Artificial Intelligence (ICAI)*. The Steering Committee of The World Congress in Computer Science, Computer Engineering and Applied Computing (WorldComp), 2012, s. 1.

OOSTENVELD, R. a P. PRAAMSTRA. The five percent electrode system for high-resolution EEG and ERP measurements. *Clinical Neurophysiology*. 2001, vol. 112, iss. 4, s. 713-719.

PALANIAPPAN, R., P. RAVEENDRAN, Jia-Ping LIN, Yong-Sheng CHEN a Li-Fen CHEN. Individual identification technique using visual evoked potential signals. *Electronics Letters*. 2002, vol. 38, iss. 25, s. 684-691.

PALANIAPPAN, R. Method of identifying individuals using VEP signals and neural network. *IEE Proceedings - Science, Measurement and Technology*. 2004, vol. 151, iss. 1, s. 16-20.

PALANIAPPAN, R. Identifying Individuality Using Mental Task Based Brain Computer Interface. *Intelligent Sensing and Information Processing, 2005. ICISIP 2005. Third International Conference on*. IEEE, 2005. s. 238-242.

PALANIAPPAN, R. Two-stage biometric authentication method using thought activity brain waves. *International Journal of Neural Systems*. 2008, vol. 18, iss. 1, s. 59-66.

PALANIAPPAN, R. a K. REVETT. PIN generation using EEG: a stability study. *International Journal of Biometrics*. 2014, vol. 6, iss. 2, s. 95-105.

PAPERNOT, Nicolas, et al. Practical black-box attacks against deep learning systems using adversarial examples. *arXiv preprint arXiv:1602.02697v4*, 2017.

PARANJAPE, R. B., et al. The electroencephalogram as a biometric. *Electrical and Computer Engineering, 2001. Canadian Conference*. IEEE, 2001, s. 1363-1366.

PARK, GiTae a Soowon KIM. Hand biometric recognition based on fused hand geometry and vascular patterns. *Sensors*. 2013, vol. 13, iss. 3, s. 2895-2910.

PHAM, Viet-Thanh, et al. Hidden hyperchaotic attractor in a novel simple memristive neural network. *Optoelectronics and Advanced Materials, Rapid Communications*. 2014, vol. 8, no. 11–12, s. 1157-1163.

POULOS, M., M. RANGOUSI, V. CHRISSIKOPOULOS a A. EVANGELOU. Person identification based on parametric processing of the EEG. *Electronics, Circuits and Systems. Proceedings of ICECS'99. The 6th IEEE International Conference on*. 1999a, vol. 1, s. 283-286. IEEE. ISBN 0-7803-5682-9

POULOS, M., M. RANGOUSI, V. CHRISSIKOPOULOS a A. EVANGELOU. Parametric person identification from the EEG using computational geometry. *Electronics, Circuits and Systems. Proceedings of ICECS'99. The 6th IEEE International Conference on*. IEEE, 1999b, vol. 2, s. 1005-1008.

POULOS, M., M. RANGOUSI, N. ALEXANDRIS a A. EVANGELOU. Person identification from the EEG using nonlinear signal classification. *Methods of information in Medicine*. 2002, vol. 1, no. 1, s. 64-75.

POZO-BANOS, M. D., J. B., ALONSO, J. R., TICAY-RIVAS a C. M., TRAVIESO. Electroencephalogram subject identification: A review. *Expert Systems with Applications*. 2014, vol. 41, iss. 15, s. 6537-6554.

PRADEEP, J., E. SRINIVASAN a S. HIMAVATHI. An investigation on the performance of hybrid features for feed forward neural network based English handwritten character recognition system. *WSEAS Transactions on Signal Processing*. 2014, vol. 10, no. 1, s. 21-29.

PRIAM, Rodolphe a Mohamed NADIF. Data visualization via latent variables and mixture models: a brief survey. *Pattern Analysis and Applications*. 2016, vol. 19, iss. 3, s. 807-819.

RAK, Roman. *Biometrie a identita člověka ve forezních a komerčních aplikacích*. 1. vyd. Praha: Grada, 2008, 631 s., 32 s. barev. obr. příl. ISBN 978-80-247-2365-5.

REVETT, K. Cognitive biometrics: a novel approach to person authentication. *International Journal of Cognitive Biometrics*. 2012, vol. 1, no. 1, s. 1-9.

RIVAS-PEREA, P., J. G. ROSILES, a M. I. M CHACON. Traditional and neural probabilistic multispectral image processing for the dust aerosol detection problem. *Image*

*Analysis & Interpretation (SSIAI), IEEE Southwest Symposium on.* IEEE, 2010. s. 169-172.

RUIZ, Sergio; BIRBAUMER, Niels; SITARAM, Ranganatha. Abnormal neural connectivity in schizophrenia and fMRI-brain-computer interface as a potential therapeutic approach. *Frontiers in psychiatry*. 2013, vol. 4.

SCHALK, G., D. J. MCFARLAND, T. HINTERBERGER, N. BIRBAUMER, J. R. WOLPAW, Jürgen MELLINGER a Gerwin SCHALK. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE Transactions on Biomedical Engineering*. 2004, vol. 51, iss. 6, s. 259-279.

SINGH, Y. N., S. K. SINGH a A. K. RAY. Bioelectrical signals as emerging biometrics: Issues and challenges. *ISRN Signal Processing*, 2012, vol. 2012.

SINGHAL, G. K. a P. RAMKUMAR. Person Identification Using Evoked Potentials and Peak Matching. *2007 Biometrics Symposium*. 2007.

SOCHER, Richard, et al. Reasoning with neural tensor networks for knowledge base completion. *Advances in neural information processing systems 26*. 2013, s. 926-934.

SOKKA, Laura, et al. Alterations in attention capture to auditory emotional stimuli in job burnout: an event-related potential study. *International Journal of Psychophysiology*. 2014, vol. 94, iss. 3, s. 427-436.

SRIDHAR, D.; KRISHNA, IV Murali. Face image classification using combined classifier. *Signal Processing Image Processing & Pattern Recognition (ICSIPR)*, 2013 International Conference on. IEEE, 2013. s. 97-102.

SUSSILLO, David a Omri BARAK. Opening the black box: low-dimensional dynamics in high-dimensional recurrent neural networks. *Neural computation*. 2013, vol. 25, iss. 3, s. 626-649.

ŠŤASTNÝ, Jakub, Pavel VRCHOTA a Pavel SOVKA. EEG-based biometric person identification. *Analysis of Biomedical Signals and Images, 18-th Biennial International EURASIP Conference BIOSIGNAL*. 2006, s. 76-78.

TAHMASEBI, Pejman a Ardeshir HEZARKHANI. Application of a modular feedforward neural network for grade estimation. *Natural resources research*, 2011, vol. 20, iss. 1, s. 25-32.

TAJUDDIN, Mohammed a C. NANDINI. Secured crypto biometric system using retina. *International Advanced Research Journal in Science, Engineering and Technology*. 2015, vol. 2, iss. 1, s. 28-32.

TERZANO, M. G., L. PARRINO, A. SHERIERI, R. CHERVIN, S. CHOKROVERTY, C. GUILLEMINAULT, M. HIRSHKOWITZ, M. MAHOWALD, H. MOLDOFSKY, A. ROSA, R. THOMAS a A. WALTERS. Atlas, rules, and recording techniques for the scoring of cyclic alternating pattern (CAP) in human sleep. *Sleep Medicine*. March 2002, vol. 2, no. 6, s. 537-553.

THRUN, Michael C., et al. Visualization and 3D printing of multivariate data of biomarkers. *Proceedings of International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision*. 2016, s. 7-16.

UGALDE, Hector M. Romero, et al. Neural network design and model reduction approach for black box nonlinear system identification with reduced number of parameters. *Neurocomputing*. 2013, vol. 101, s. 170-180.

VAZ, Sharmila, et al. The case for using the repeatability coefficient when calculating test-retest reliability. *PLoS One*. 2013, vol. 8, iss. 9: e73990.

WANG, Shuihua, et al. Fruit classification by wavelet-entropy and feedforward neural network trained by fitness-scaled chaotic ABC and biogeography-based optimization. *Entropy*. 2015, vol. 17, iss. 8, s. 5711-5728.

WU, Zhizheng, Oliver WATTS a Simon KING. Merlin: An open source neural network speech synthesis system. *9th ISCA Speech Synthesis Workshop*. 2016, s. 218-223.

YANG, Su a F. DERAVID. On the Effectiveness of EEG Signals as a Source of Biometric Information. *2012 Third International Conference on Emerging Security Technologies*. 2012.

YEOM, Seul-Ki, Heung-II SUK, Seonz-Whan LEE, Venu GOVINDARAJU, Zhixin SHI, John SCHNEIDER, Norman POH, Jerzy KORCZAK, Chiraz BENABDELKADER, Ross CUTLER, Harsh NANDA a Larry DAVIS. Eeg-based person authentication using face stimuli: Motion-Based Recognition of People Using Image Self-Similarity. *2013 International Winter Workshop on Brain-Computer Interface (BCI)*. 2013a, s. 284-294.

YEOM, Seul-Ki, Heung-II SUK a Seong-Whan LEE. Person authentication from neural activity of face-specific visual self-representation. *Pattern Recognition*. 2013b, vol. 46, iss. 4, s. 1159-1169.

ZHANG, Lei a Fengchun TIAN. Performance study of multilayer perceptrons in a low-cost electronic nose. *IEEE Transactions on Instrumentation and Measurement*, 2014, vol. 63, iss. 7, s. 1670-1679.

ZHANG, Xu-Yao, et al. Drawing and recognizing chinese characters with recurrent neural network. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017, vol. PP, iss. 99.

ZUO, Wangmeng, Peng WANG a David ZHANG. Comparison of three different types of wrist pulse signals by their physical meanings and diagnosis performance. *IEEE journal of biomedical and health informatics*. 2016, vol. 20, iss. 1, s. 119-127.



## SEZNAM OBRÁZKŮ

Obr. 1.: Emotiv EPOC Neuroheadset (Emotiv, 2017).....	9
Obr. 2.: Rozložení elektrod zařízení Emotiv EPOC Neuroheadset.....	9
Obr. 3.: Ukázka EEG signálu.....	9
Obr. 4.: Obecný princip systému BCI.....	10
Obr. 5: Schéma umělého neuronu.....	17
Obr. 6: Příklad průběhu sigmoidy.....	18
Obr. 7: Příklad průběhu Gaussovi funkce.....	18
Obr. 8: Obecná struktura vícevrstvé neuronové sítě.....	19
Obr. 9: Schéma vícevrstvého perceptronu.....	20
Obr. 10: Schéma vícevrstvého perceptronu s přidanými přímými propojeními mezi vstupy a výstupním neuronem (čárkovaná čára).....	21
Obr. 11: Rekurentní neuronová síť se dvěma vstupy .....	22
Obr. 12: Kanonická forma rekurentní neuronové sítě .....	23
Obr. 13: Blokové schéma algoritmu zpracování EEG záznamu .....	31
Obr. 14: Ukázka normalizace pro úsek kanálu AF3 o délce 1 s.....	34
Obr. 15: Algoritmus pro převod EEG záznamu na vzor s bipolárními stavy. 35	
Obr. 16: Architektura Hopfieldovy sítě .....	38
Obr. 17: Obecné schéma Spider–Hopfieldovy sítě.....	42
Obr. 18: Testovací vstup do Spider–Hopfieldovy sítě v rámci testu na úloze rozpoznávání znaků.....	43
Obr. 19: Průběh klasifikačního procesu Spider–Hopfieldovy sítě na úloze rozpoznávání znaků. Jsou zobrazeny pouze výsledky jednotlivých kroků nikoliv inicializační stav. Trénovací množina na začátku obsahovala všechny znaky anglické abecedy .....	43
Obr. 20: Ukázka výstupu při použití Hopfieldovy sítě trénované na 10 vzorů .....	44
Obr. 21: Ukázka výstupu při použití Spider–Hopfieldovy sítě trénované na 10 vzorů.....	45
Obr. 22.: Závislost hodnoty nejvyšší korelace na délce signálu.....	48
Obr. 23: Pozice elektrod s nejvyšší korelací pro subjekt 1 .....	49
Obr. 24: Pozice elektrod s nejvyšší korelací pro subjekt 2.....	51
Obr. 25: Pozice elektrod s nejvyšší korelací pro subjekt 3.....	51
Obr. 26: Ukázka výstupu v aplikaci Emotiv TestBench.....	53
Obr. 27: Průběh úspěšnosti identifikace v závislosti na počtu trénovacích vzorů.....	59

## SEZNAM TABULEK

Tabulka 1. Výsledky analýzy pro tři vybrané dobrovolníky.....	47
Tabulka 2. Výsledky analýzy pro subjekt 1 .....	48
Tabulka 3. Výsledky analýzy pro subjekt 2 .....	50
Tabulka 4. Výsledky analýzy pro subjekt 3 .....	50
Tabulka 5. Vliv posunu testovacího záznamu na úspěšnost identifikace mezi deseti subjekty (délka vzorů nastavena na 16 768 hodnot).....	54
Tabulka 6. Vliv délky vzorů na úspěšnost identifikace mezi deseti subjekty.	55
Tabulka 7. Vliv odstupu testovacího záznamu od trénovacích záznamů na úspěšnost identifikace mezi deseti subjekty. Délka vzorů nastavena na 12 000 hodnot .....	56
Tabulka 8. Vliv odstupu testovacího záznamu od trénovacích záznamů na úspěšnost identifikace pro tři skupiny vzorů s pěti subjekty. Délka vzorů nastavena na 12 000 hodnot .....	56
Tabulka 9. Závislost počtu trénovacích vzorů na úspěšnosti identifikace .....	59
Tabulka 10. Vliv rozdílnosti délek trénovacích a testovacích záznamů na úspěšnost identifikace .....	60

## SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

AD	Analog - Digital
ADALINE	ADaptive LInear NEuron
AR	Autoregressive model
BCI	Brain – Computer Interface
BMI	Brain – Machine Interface
CAP	Cycling Alternating Pattern
CSV	Comma Separated Values
ECoG	Electrocorticography
EDF	European Data Format
EEG	Elektroencefalografie / Elektroencefalogram
EER	Equal Error Rate
EKG	Elektrokardiography
EMG	Electromyography
EOG	Electrooculography
ERP	Event Related Potential
FAE	False Accept Error
FRE	False Reject Error
FFT	Fast Fourier Transformation
fMRI	Functional Magnetic Resonance Imaging
HS	Hopfieldova Síť
IEEE	Institute of Electrical and Electronics Engineers
IIR	Infinite Impulse Response

INNS	International Neural Network Society
LVQ	Linear Vector Quantizer
MCN	Modiffied Combinatorial Nomenclature
MLPs	Multi Layer Perceptrons
PIN	Personal Identification Number
RBF	Radial Basis Function
RC	Remote Control
REC	Resting with Eyes Closed
REO	Resting with Eyes Open
SVM	Support Vector Machine
VEP	Visual Evoked Potential

## PUBLIKAČNÍ AKTIVITY AUTORA

SVEJDA, Jaromir, Roman ZAK a Roman JASEK. Zpracování mozkové aktivity v bci systémech. *Odborný vědecký časopis Trilobit*. 2012, č. 1. ISSN 1804-1795.

SVEJDA, Jaromir, Roman ZAK a Roman JASEK. Systémy identifikace vstupu a biometrické systémy. *Odborný vědecký časopis Trilobit*. 2012, č. 2. ISSN 1804-1795.

POKORNY, Pavel, Roman ZAK a Jaromir SVEJDA. The Design and Realization of Ascii Art Software. *Advances in Sensors, Signals, Visualization, Imaging and Simulation. Sliema : WSEAS*. 2012, s. 159-162. ISSN 1790-5117. ISBN 978-1-61804-119-7.

PLUHACEK, Michal, Jaromir SVEJDA, Hana TALANDOVA, Roman ZAK a Roman JASEK. Artificial intelligence in biometrical identification systems. *Bezpečnostní technologie, Systémy a Management 2013: Sborník příspěvků 4. mezinárodní konference*. Univerzita Tomáše Bati ve Zlíně Fakulta aplikované informatiky, 2013, s. 5. ISBN 978-80-7454-289-3

SVEJDA, Jaromir, Roman ZAK, Roman JASEK a Roman SENKERIK. On the Simulation of the Brain Activity: A Brief Survey. *Modern Trends and Techniques in Computer Science*. Springer, Cham, 2014, s. 105-115.

ZAK, Roman, Jaromir SVEJDA, Roman SENKERIK a Roman JASEK. Analysis of EEG signal for using in biometrical classification. *ECMS*. 2014, s. 377-381.

SVEJDA, Jaromir, Roman ZAK, Roman SENKERIK a Roman JASEK. Complex Analysis of EEG Signal for Biometrical Classification Purposes. *Nostradamus 2014: Prediction, Modeling and Analysis of Complex Systems*. Springer, Cham, 2014, s. 449-459.

JASEK, Roman, Lukas KRALIK, Jaromir SVEJDA a Alena KOLCAVOVA. Differences between ITIL® V2 and ITIL® V3 with Respect to Service Strategy and Service Design. *AIP Conference Proceedings*. AIP Publishing, 2015, s. 550016.

SVEJDA, Jaromir, ZAK, Roman a Roman JASEK. Concept of software interface for BCI systems. *AIP Conference Proceedings*. AIP Publishing, 2016, s. 120022.

ZAK, Roman, Jaromir SVEJDA, Roman JASEK a Roman SENKERIK. The Architecture of Software Interface for BCI System. *Intelligent Systems in Cybernetics and Automation Theory*. Springer, Cham, 2015, s. 307-316.

SVEJDA, Jaromir, Roman ZAK, Roman SENKERIK a Roman JASEK. Using brain - Computer interface for control robot movement. *ECMS*. 2015, s. 475-480.

ŠAUR, David, Roman ŽÁK a Jaromír ŠVEJDA. Data Mining from Radar Precipitation Measurement of the CZRAD Network. *19. International Conference on Systems (CSCC '15), Special Session: Informatics in Control Theory and its Applications – Control Applications. Recent Advances in Systems*. Zakynthos Island, Greece, July 16-20, 2015, s. 280-285. ISBN: 978-1-61804-321-4. ISSN: 1790-5117

SVEJDA, Jaromir, Roman ZAK, Roman SENKERIK a Roman JASEK. Research on Processing the Brain Activity in BCI System. *Pattern Recognition and Classification in Time Series Data*. IGI Global, 2016. s. 152-178.

# ODBORNÝ ŽIVOTOPIS AUTORA

OSOBNÍ ÚDAJE Švejda Jaromír



📍 Ovocná 2792/4,  
76701 Kroměříž (Česká republika)

☎ (+420) 732203582

✉ svejda@fai.utb.cz

Pohlaví Muž | Datum narození 29. 12. 1986

Státní příslušnost/i Česká republika

## PRACOVNÍ ZKUŠENOSTI

---

2015–dosud Učitel odborných předmětů  
Střední škola filmová, multimediální a počítačových  
technologií s.r.o., Zlín (Česká republika)

2014 Web developer  
iTech21. s.r.o., Zlín (Česká republika)  
- Kódování a programování frontendu webových stránek  
- Vývoj mobilních aplikací přes Framework Phonegap  
a Angular.js

2012–2013 Programátor mobilních aplikací  
Nakladatelství Fraus, Plzeň (Česká republika)  
- Účast na projektu vývoje mobilních aplikací v HTML 5,  
jquery a CSS 3 pro firmu Nakladatelství Fraus

2011–2014 Pedagogická činnost  
Univerzita Tomáše Bati ve Zlíně, Zlín (Česká republika)  
Vedení kurzů v rámci výuky na Fakultě aplikované  
informatiky.

VZDĚLÁNÍ,  
 ODBORNÁ  
 PŘÍPRAVA A KURZY

- 2014 University of Algarve, Faro (Portugalsko), studijní stáž
- 2009–2011 Vysokoškolské vzdělání v oboru: Informační technologie (Ing.)  
 Univerzita Tomáše Bati ve Zlíně, Fakulta Aplikované Informatiky
- 2006–2009 Vysokoškolské vzdělání v oboru: Informační technologie (Bc.)  
 Univerzita Tomáše Bati ve Zlíně, Fakulta Aplikované Informatiky
- 2002–2006 Středoškolské vzdělání v oboru: Slaboproudá elektrotechnika  
 Střední Škola - Centrum Odborné Přípravy Technické

OSOBNÍ  
 DOVEDNOSTI

Mateřský jazyk čeština

Další jazyky	POROZUMĚNÍ		MLUVENÍ		PÍSEMNÝ PROJEV
	Poslech	Čtení	Ústní interakce	Samostatný ústní projev	
angličtina	B2	B2	B2	B1	B2

Úrovně: A1/A2: Začátečník - B1/B2: Nezávislý uživatel - C1/C2: Způsobilý uživatel

Společný evropský referenční rámec pro jazyky

Organizační/manažerské dovednosti Organizace tří ročníků univerzitního šachového přeboru (rok 2010, 2012, 2014)

Webové stránky přeboru: <http://rzweb.cz/sachy>



Odborné dovednosti	Znalosti programovacích, značkovacích a dotazovacích jazyků: C/C++, C#, HTML & CSS 3, Java, JavaScript, Python, SQL, UML, XML
Počítačové dovednosti	velmi dobré dovednosti v uživatelských, vývojových a grafických prostředích: Codelite, Eclipse, Inkscape, Microsoft Office, Microsoft Visual Studio, PSPad, Wolfram Mathematica, QTcreator
Řidičský průkaz	B

## DOPLŇUJÍCÍ INFORMACE

Citace Rozhovor v pořadu: Leonardo Plus | Stanice: Český rozhlas Plus  
 ZÍTA, Dalibor a Ondřej ČIHÁK. Chcete ovládat přístroje myšlenkou? Zkuste zlínský Brain – Computer Interface.  
 In: *Český rozhlas Plus* [online]. 2015. Dostupné z: [www.rozhlas.cz/plus/ranniplus/\\_zprava/1457922](http://www.rozhlas.cz/plus/ranniplus/_zprava/1457922)

Ing. Jaromír Švejda

**Návrh algoritmu pro biometrickou identifikaci osob pomocí  
analýzy EEG signálu**

Design of algorithm for biometric person identification using EEG signal  
analysis

Disertační práce

Vydala Univerzita Tomáše Bati ve Zlíně,  
nám. T. G. Masaryka 5555, 760 01 Zlín.

Náklad: výtisků

Sazba: autor

Publikace neprošla jazykovou ani redakční úpravou.

Rok vydání 2017

ISBN 978-80-.....