

Návrh algoritmu pro biometrickou identifikaci osob pomocí analýzy EEG signálu

Ing. Jaromír Švejda, Ph. D.

Teze disertační práce



Univerzita Tomáše Bati ve Zlíně

Fakulta aplikované informatiky

Teze 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: P3902 Inženýrská informatika
Studijní obor: 3902V023 Inženýrská informatika

Školitel: doc. Ing. Roman Šenkeřík, Ph.D.

Oponenti: prof. Ing. Jiří Dvořák, DrSc.
prof. Ing. Vladimír Strakoš, DrSc.
prof. RNDr. Ing. Miloš Šeda, Ph.D.

Zlín, září 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 978-80-7454-683-9

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, jenž 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

ABSTRAKT	III
ABSTRACT	III
OBSAH.....	IV
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	9
4.3 Historie a současný stav biometrie	9
4.3.1 Snímání biometrických dat	10
4.3.2 Reprezentace dat	10
4.3.3 Využití biometrie	10
4.4 Neuronové sítě	10
4.4.1 Historie.....	10
4.4.2 Teoretický popis.....	10
4.4.3 Aplikace neuronových sítí	11
5. ZVOLENÉ METODY ZPRACOVÁNÍ.....	12
6. POPIS ALGORITMU PRO IDENTIFIKACI OSOB POMOCÍ EEG SIGNÁLU	13
6.1 Měření EEG záznamů.....	14
6.2 Normalizace dat	14
6.3 Předzpracování dat.....	14
6.4 Klasifikace	16
6.4.1 Hopfieldova síť	16
6.4.2 Spider–Hopfieldova síť.....	16

6.5 Softwarová realizace	18
7. EXPERIMENTÁLNÍ ČÁST	19
7.1 Korelační analýza EEG signálu	19
7.2 Identifikace subjektů pomocí EEG signálu	21
7.2.1 Testování s REC EEG záznamy	22
7.2.2 Testování s CAP EEG záznamy	23
8. PŘÍNOS PRÁCE PRO VĚDU A PRAXI.....	25
8.1 Přínos pro vědu	25
8.2 Přínos pro praxi	25
9. ZÁVĚR.....	27
SEZNAM POUŽITÉ LITERATURY	30
SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK.....	33
PUBLIKAČNÍ AKTIVITY AUTORA	34
ODBORNÝ ŽIVOTOPIS AUTORA	35

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, 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, 1999) a čtyřmi (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 rozpoznány 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 výzkumů 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).

I přes velké množství doposud popsaných 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; 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, 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, 2013).

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. 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

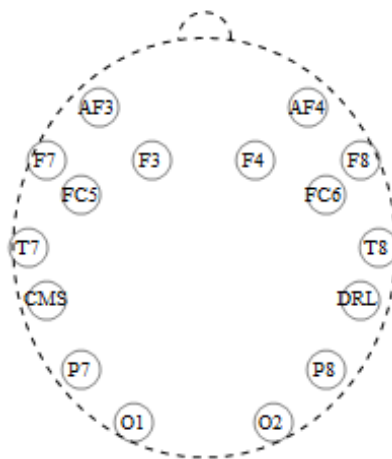
Lidský mozek obsahuje přibližně 10^{10} až 10^{11} nervových buněk. Při své činnosti vytváří tyto buňky elektrické a magnetické pole (Paranjape, 2001; Forstmann, 2015). Tato pole jsou způsobena součtem elektrických signálů pocházejících z proudění iontů neurony. Toto proudění se objevuje především v 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 (EEG) a reprezentuje sumu elektrické aktivity v jednotlivých oblastech mozku. EEG je tedy záznam časové změny elektrického potenciálu způsobeného mozkovou aktivitou. Plná verze disertační práce obsahuje podrobnější informace o technologii EEG.


V rámci disertační práce je k měření EEG signálu využíváno zařízení od společnosti Emotiv (Obr. 1). Rozložení elektrod tohoto zařízení je zobrazeno a popsáno na Obr. 2. Označení jednotlivých elektrod vychází ze standardizovaného 10-20 systému (Homan, 1987) a jeho modifikace MCN (Oostenveld, 2001). 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.



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



Obr. 2.: Rozložení elektrod zařízení Emotiv EPOC Neuroheadset



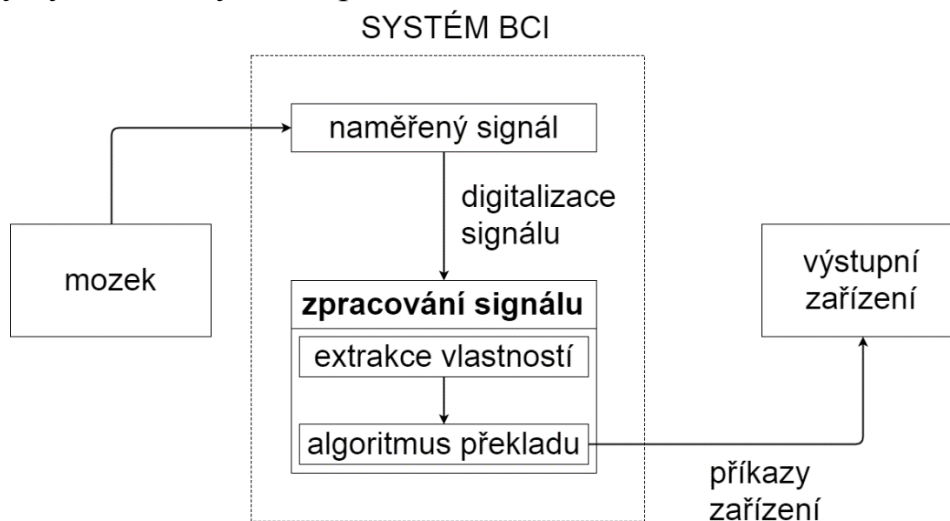
Obr. 3.: Ukázka EEG signálu

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.

Pro běžné technické aplikace se nejčastěji používají neinvazivní metody snímání mozkové aktivity, zejména zařízení, jež jsou založená na EEG technologii.

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.



Obr. 4.: Obecný princip systému BCI

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).

4.3.1 Snímání biometrických dat

V plné verzi práce je v této kapitole popsána problematika snímání biometrických dat pro jednotlivé biometrické vlastnosti člověka (otisk prstu, dynamika podpisu, geometrie tváře, duhovka, sítnice, geometrie ruky, struktura žil na zápěstí, tvar ucha, hlas a DNA).

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

Tato kapitola diskutuje možnosti využití biometrie v praxi a uvádí výčet praktických aplikací, ve kterých biometrie obvykle nachází uplatnění.

4.4 Neuronové sítě

Kapitola popisuje teorii 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 této kapitole jsou shrnuty důležité historické milníky v oboru neuronových sítí.

4.4.2 Teoretický popis

Popis neuronových sítí začíná u vlastností neuronu coby základního prvku sítě. Jsou zde diskutovány možnosti parametrizace přenosové funkce neuronu.

Následně je uvedeno obecné rozdělení neuronových sítí do dvou základních kategorií: dopředně a rekurentní neuronové sítě. U každé kategorie je uveden i matematický popis doprovázený ukázkovým schématem propojení neuronů. Dále jsou popsány možnosti realizace učení obou typů neuronových sítí. Na závěr jsou obecně vymezeny typy úloh, na které je vhodné nasadit algoritmy založené na neuronových sítích.

4.4.3 Aplikace neuronových sítí

V plné verzi práce tato kapitola pojednává o praktických aplikacích neuronových sítí rozdělených do jednotlivých kategorií.

Je zde uvedeno uplatnění neuronových sítí při návrhu tzv. black box modelu, jenž má být sestaven pouze na základě dostupných měření (Papernot, et al, 2016). Kromě toho následuje zmínka o využití při návrhu tzv. grey box modelů, sestavených jak na základě matematického popisu, tak i na základě naměřených dat ze zkoumaného procesu (Socher et al, 2013, Du, 2014).

Dále je text rozdělen podle jednotlivých typů neuronových sítí. Nejprve jsou diskutovány úlohy vhodné pro dopředné neuronové sítě s učitelem. Tyto jsou vhodné zejména pro případy, kdy parametry modelu mají být nastaveny na základě vzorů tak, aby výsledný model co nejpřesněji simuloval vztah mezi vstupem a výstupem zkoumaného procesu. Obecně poskytují neuronové sítě nejlepší využití dostupných dat pro modely s více jak dvěma vstupy (Bahdanau, 2014; Mnih, 2014). Dalším typem úlohy, u níž se s výhodou využívá dopředných neuronových sítí s učitelem, je klasifikace (Collobert et al, 2011; Wu, 2016).

Poté se text zaměřuje na dopředné neuronové sítě bez učitele, které patří mezi výkonné metody pro realizaci projekce vícedimenzionálních dat do prostoru s nižší dimenzí (Priam, 2016).

Aplikace rekurentních neuronových sítí s učitelem jsou zaměřeny na dynamické modelování na základě vzorů, tj. nalezení diferenčních rovnic z naměřených záznamů vstupu a výstupu, které popisují zkoumaný proces (Bengio et al, 2015).

Posledním diskutovaným typem jsou rekurentní neuronové sítě bez učitele. V jejich matematickém popisu 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; Chen et al, 2014).


5. ZVOLENÉ METODY ZPRACOVÁNÍ

Dosažení uvedeného cíle bylo realizováno za pomoci následujících metod:

- 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, provádí se 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. 5, jehož cílem je na základě předloženého naměřeného záznamu určit osobu, které záznam přísluší.



Obr. 5: 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 nimiž 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 disertační 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. Podrobný popis algoritmu se nachází v plné verzi disertační práce.

6.1 Měření EEG záznamů

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.

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 negeneroval nežádoucí zvukový vjem.

6.2 Normalizace dat

Proces normalizace signálu se může lišit v závislosti na konkrétním měřicím zařízení. Pro zařízení Emotiv EPOC headset byl použit IIR filtr, pomocí něhož je z naměřeného signálu odstraněna plovoucí stejnosměrná úroveň signálu, která se pohybuje přibližně kolem hodnoty 4200 μV .

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.

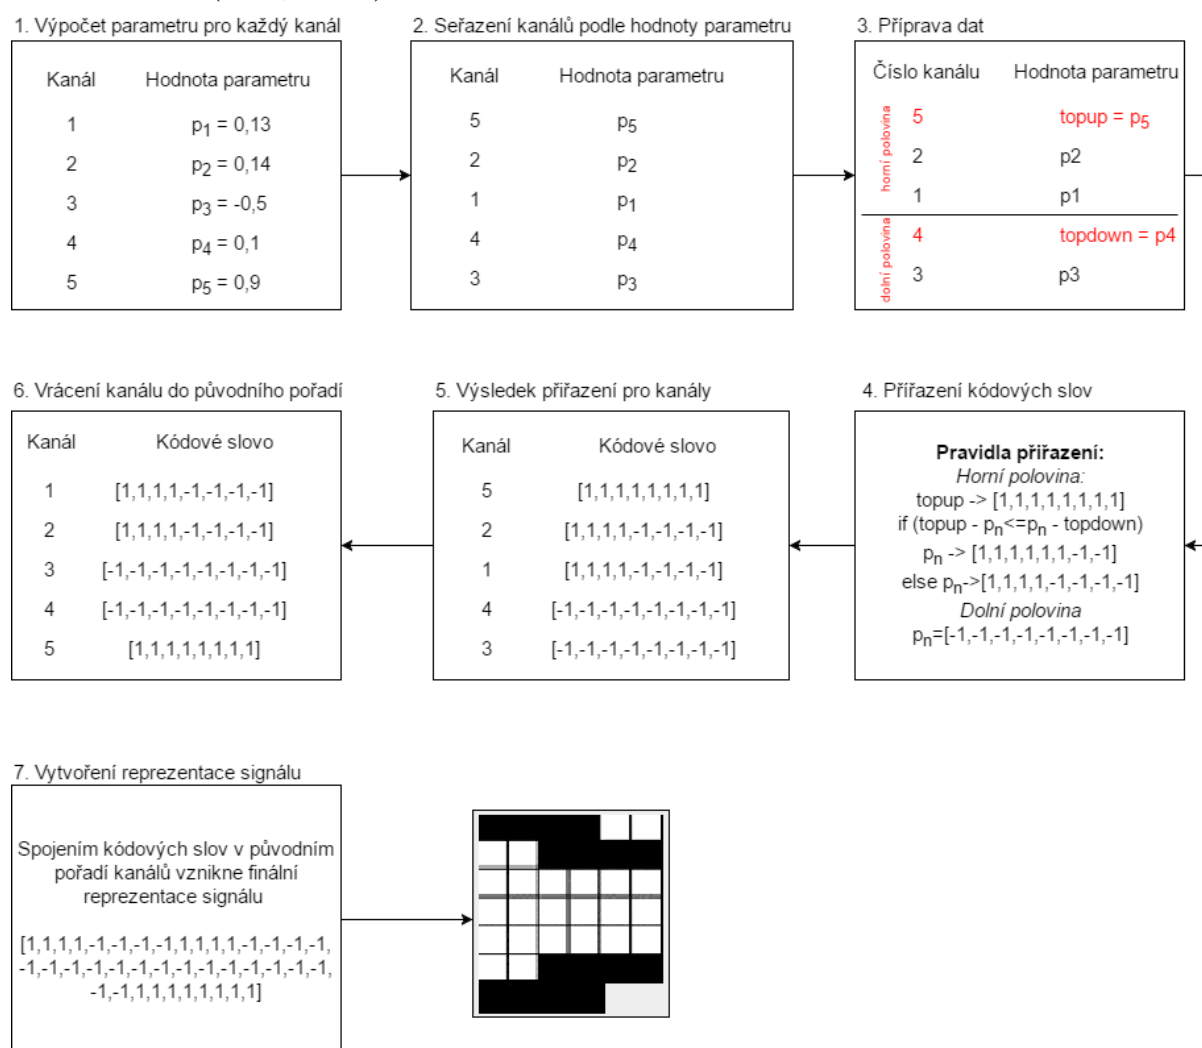
V případě zařízení Emotiv EPOC headset je v EEG záznamu celkem 14 kanálů, nicméně průběh algoritmu předzpracování dat je zcela nezávislý na konkrétním počtu kanálů. Při vyšším počtu kanálů se pouze prodlouží délka vzorku o předem definovaný počet bitů.

Pro algoritmus předzpracování dat je klíčová volba charakteristiky EEG záznamu, kterou bude celý proces převodu řízen. Průběh celého algoritmu je ilustrován na Obr. 6. 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).



Obr. 6: Algoritmus pro převod EEG záznamu na vzor s bipolárními stavy

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) vznikla v roce 1982. Jejím autorem je John Hopfield, který při návrhu 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).

V současnosti se HS používá zřídka. Důvodem je 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 nepříjemné 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.

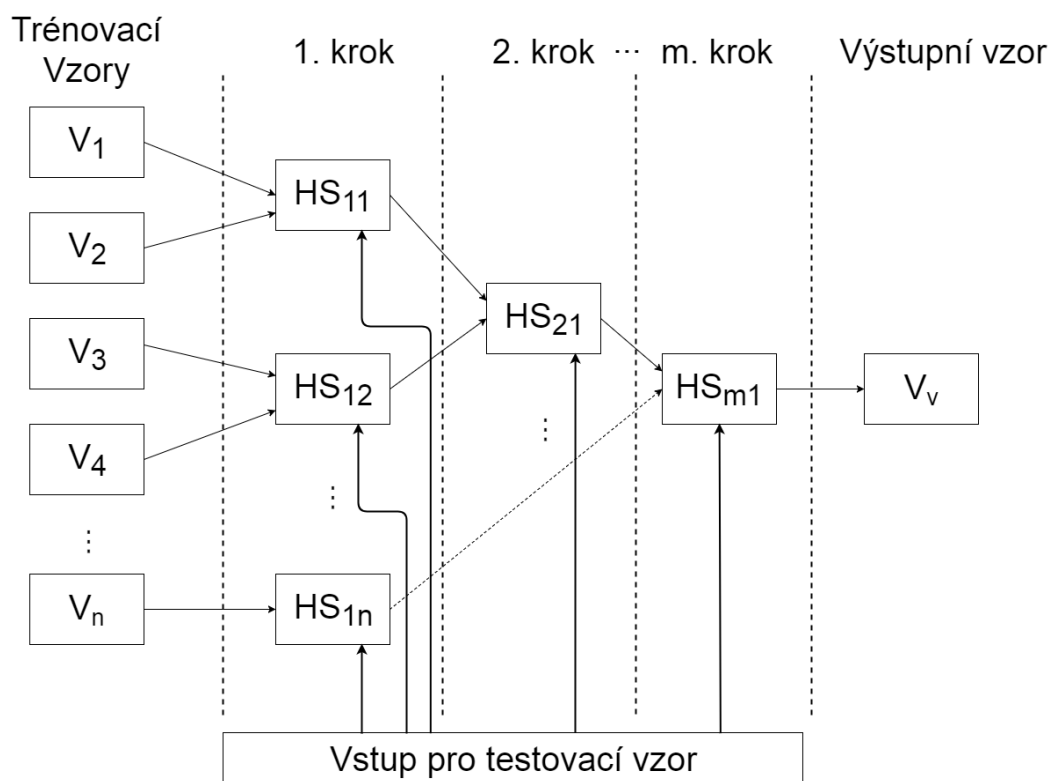
6.4.2 Spider–Hopfieldova síť

V průběhu testování bylo zjištěno, že si Hopfieldova síť začíná vytvářet fantomové vzory mnohem dříve, než jak vyplývá z teoretických vzorců. 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. 7. 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. 7: Obecné schéma Spider–Hopfieldovy sítě


Rozhodovací proces pak probíhá v několika na sebe navazujících krocích, 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 neprojevují 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. 7.

Průběh klasifikačního procesu ilustruje výsledek testování Spider–Hopfieldovy sítě na úloze rozpoznávání písmen viz Obr. 8 a Obr. 9.



Obr. 8: Testovací vstup do Spider–Hopfieldovy sítě v rámci testu na úloze rozpoznávání znaků



Obr. 9: 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.

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, s cílem 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, jež 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 byly odhaleny 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.

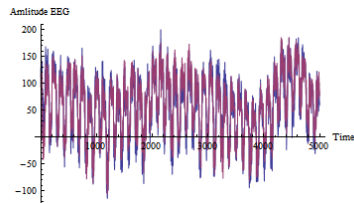
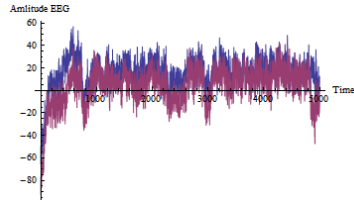
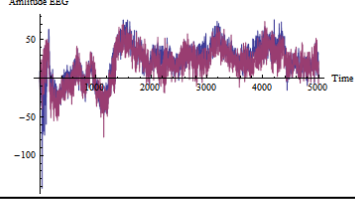
Kompletní přehled výsledků jednotlivých testů je uveden v plné verzi disertační práce.

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

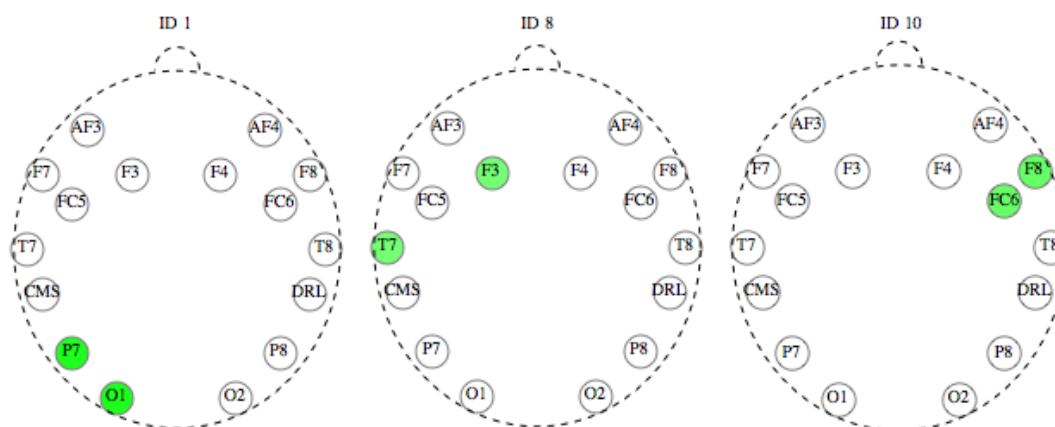
subjekty zajištěny stejné laboratorní podmínky, konečné výsledky se mezi jednotlivými dobrovolníky výrazně liší.

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. Dalším cílem korelační analýzy bylo 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). Opět 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). Výsledky této analýzy pro jednoho vybraného dobrovolníka jsou zobrazeny na Obr. 10. Zvýrazněné pozice jsou ty, mezi nimiž byla získána hodnota nejvyšší korelace. Konkrétní hodnoty pak uvádí Tabulka 2. Výsledky se mezi jednotlivými dobrovolníky značně lišily, i když všichni dobrovolníci prováděli stejnou činnost. Výsledky dále ukazují, že je z hlediska detekce odlišností mezi jednotlivými subjekty důležitá i poloha oblastí, mezi nimiž se objevila nejsilnější přímá závislost.

Uvedené analýzy 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.



Obr. 10: Pozice elektrod s nejvyšší korelací pro subjekt 3

Tabulka 2. 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

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.

Každý EEG záznam obsahoval pouze hodnoty naměřené ze 14 elektrod se vzorkovací frekvencí 128 Hz. 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.

V průběhu jednotlivých testů byl pro deset subjektů zkoumán vliv posunu testovacího záznamu, délky vzorů a odstupů testovacího záznamu od trénovacích záznamů na úspěšnost identifikace. Vliv odstupů testovacího záznamu od trénovacích záznamů byl zkoumán také pro tři různé skupiny vzorů s pěti subjekty. Výsledky tohoto testu obsahuje Tabulka 3.

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. 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.

Tabulka 3. 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				
Číslo subjektu	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
Průměrná úspěšnost identifikace [%]	83,64					61,82					94,55				


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. 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. 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.

Průběh úspěšnosti identifikace v závislosti na počtu trénovacích vzorů je zobrazen na Obr. 11.



Obr. 11: Průběh úspěšnosti identifikace v závislosti na počtu trénovacích vzorů

Nejúspěšnější identifikace byla pro dva a tři vzory, nejméně pak pro 20 vzorů. Svou roli v jednotlivých testech hrála 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.

V průběhu výzkumu byla uvažována i otázka, zda je možné použít jinou délku pro trénovací a testovací záznamy. 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 4. 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. Kompletní výsledky testu jsou uvedeny v plné verzi práce.

Tabulka 4. 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
27000	3000	25	12000	18000	75
25000	5000	50	10000	20000	75
23000	7000	50	8000	22000	75
21000	9000	50	6000	24000	0
19000	11000	50	4000	26000	25
17000	13000	50	2000	28000	25
15000	15000	75			

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, jež 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 zdlouhavého 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 také nabízí jako námět k dalšímu výzkumu.

SEZNAM POUŽITÉ LITERATURY

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.

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

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.

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

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/>

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.

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.

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.

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.

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.

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. 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.

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. RANGOSSI, 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. 1999, vol. 1, s. 283-286. IEEE. ISBN 0-7803-5682-9

POULOS, M., M. RANGOSSI, 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.

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 forenzních 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.

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.

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.

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.

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.

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

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

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

AR	Autoregressive model
BCI	Brain – Computer Interface
BMI	Brain – Machine Interface
CAP	Cycling Alternating Pattern
CSV	Comma Separated Values
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
FRE	False Reject Error
HS	Hopfieldova Síť
IIR	Infinite Impulse Response
LVQ	Linear Vector Quantizer
MCN	Modified Combinatorial Nomenclature
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 Jaromir SVEJDA. 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 [cit. 2015-02-24].
 Dostupné z: 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

Teze disertační práce

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

Náklad: vyšlo elektronicky

Sazba: autor

Publikace neprošla jazykovou ani redakční úpravou.

Rok vydání 2017

ISBN 978-80-7454-683-9

