


ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE



TEZE K DISERTAČNÍ PRÁCI

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

Fakulta elektrotechnická
Katedra teorie obvodů

Antonín Hlaváček

**STUDIUM NEUROSVALOVÉ AKTIVITY
A SOUVISEJÍCÍCH METOD ZPRACOVÁNÍ
SIGNÁLŮ**

Doktorský studijní program: Elektrotechnika a informatika
Studijní obor: Teoretická elektrotechnika

Teze disertace k získání akademického titulu „doktor“, ve zkratce „Ph.D.“

Praha, únor 2013

Disertační práce byla vypracována v prezenční formě doktorského studia na katedře Teorie obvodů Fakulty elektrotechnické ČVUT v Praze.

Uchazeč:

Ing. Antonín Hlaváček

katedra Teorie obvodů, Fakulta elektrotechnická ČVUT

Technická 2, 166 27 Praha 6

Školitel:

Ing. Václav Hanžl, CSc.

katedra Teorie obvodů, Fakulta elektrotechnická ČVUT

Technická 2, 166 27 Praha 6

Školitel-specialista: -

Oponenti:.....

.....

.....

Teze byly rozeslány dne:.....

Obhajoba se koná dne v hod. před komisí pro obhajobu disertační práce ve studijním oboru teoretická elektrotechnika v zasedací místnosti č. Fakulty elektrotechnické ČVUT v Praze.

S disertací je možno se seznámit na děkanátu Fakulty elektrotechnické ČVUT v Praze, na oddělení pro vědu, výzkum a zahraniční styky, Technická 2, Praha 6.

.....
předseda komise pro obhajobu disertační práce
ve studijním oboru
teoretická elektrotechnika
Fakulta elektrotechnická ČVUT, Technická 2, Praha 6

Obsah

1	Současný stav problematiky	5
2	Cíle disertační práce	7
3	Metody zpracování	8
4	Výsledky	13
5	Závěr	16
6	Literatura	17
7	Vlastní publikace	18
8	Resumé	20
9	Summary	21

Kapitola 1

Současný stav problematiky

V současné době se problematikou zpracování a analýzy elektroencefalografických signálů (EEG) zabývá po celém světě mnoho výzkumných skupin. Motivací k tomuto výzkumu je mimo jiné identifikace specifických signálů příslušející daným projevům mozkové činnosti - rozpoznání různých druhů volních aktivit, například pohybů. Dalším neméně významným motivem je rozpoznávání patologických stavů u nemocných pacientů, např. predikce epileptických záchvatů. Vzhledem k zaměření této práce se však této oblasti nebudeme hlouběji věnovat. Zaměříme se výhradně na analýzu stavu ohledně rozpoznávání volních pohybů v EEG záznamu.

Výsledky výzkumu na tomto poli nám ukazují, že v současné době je možné odlišit od sebe pohyby různých částí těla, pokud jsou tyto pohyby dostatečně odlišné, respektive prováděny jinou svalovou skupinou, například pohyb pravého ramene vs. pohyb pravého ukazováčku [4] při použití klasifikátoru založeného na Skrytých Markovovských Modelech (HMM). Naproti tomu klasifikace pohybů sobě podobných, například pohyb palce vs. ukazováčku jedné ruky selhává [5].

Metody snímání EEG jsou v současné době standarizovány co se týče rozmístění elektrod na skalpu, mezi nejpoužívanější systémy patří mezinárodní systém 10/20 (Jasper, 1958), případně 10/10 [2] pro snímání EEG s vysokým prostorovým rozlišením. Frekvence snímání je používána vzhledem k využitelnému frekvenčnímu rozsahu EEG (0-40Hz) a Nyquistovu teorému 128 až 512 Hz [3].

Podívejme se stručně na metody a vývoj snímání elektrické aktivity mozku. Ponecháme stranou invazivní metody snímání, které se v současné době používají převážně u experimentů s pokusnými zvířaty. V principu existují

tují dvě metody neinvazivního snímání elektrických potenciálů mozku, a to elektroencefalografie (EEG) a magnetoencefalografie (MEG). Tyto metody jsou z hlediska měřené osoby bezpečné a poskytují dostatečné časové rozlišení v řádu milisekund. Obě metody mohou být použity pro kontinuální snímání elektrické aktivity, stejně jako pro zaznamenání reakcí na opakované stimuly (u EEG hovoříme o tzv. ERP, event related potential, u EMG jde o ERF, event related fields). Z hlediska prostorového rozlišení jsou metody limitovány měřením signálu na povrchu lebky, která působí výrazné zeslabení signálů a ztěžuje jejich prostorovou lokalizaci.

Kapitola 2

Cíle disertační práce

S ohledem na analýzu současného stavu problematiky byly stanoveny následující cíle práce:

1. Pořízení EEG záznamu v objemu dostačujícím pro statistické zpracování signálů.
2. Zpracování a ruční klasifikace pořízených signálů.
3. Návrh klasifikátorů umožňujících rozlišení mezi jednotlivými pohyby prstu.
4. Ověření klasifikátorů na reálných datech a zhodnocení jejich praktické použitelnosti.

Kapitola 3

Metody zpracování

Při zpracování dat byl zvolen následující postup, nejdříve byla data filtrována, posléze z očištěných dat byly vypočteny parametry potřebné pro klasifikaci.

Účelem filtrace dat je odstranění rušivých artefaktů a nepotřebných složek signálu. Použitý postup byl následující:

1. Odstranění síťového rušení 50 Hz
2. Omezení frekvenčního pásma
3. Odstranění kolísání izolinie
4. Dekompozice signálu pomocí ICA

Analýzu signálů je možno provádět buďto v časové, nebo frekvenční oblasti. S ohledem na dosavadní výzkumy se pro analýzu EEG preferuje frekvenční oblast, která na rozdíl od časové umožňuje sledovat souběžně probíhající děje o různých frekvencích (viz. kapitola o frekvenčním rozdělení EEG signálu).

Jako první sada parametrů byly zvoleny amplitudy spektrálních čar v rozmezí 1 - 40 Hz s časovým rozlišením cca 200ms a spektrálním 1 Hz. Dané parametry byly určeny s ohledem na předchozí výzkumy [1] a ověřeny při ruční analýze signálů.

Jako druhá sada parametrů byly vypočteny derivace prvního řádu z dříve získaných spektrogramů,

$$D(n) = D(n) - D(n + 1), n \in \langle 1, m - 1 \rangle, \quad (3.1)$$

kde m je délka spektrogramu.

Pro výpočet spektrogramu o požadovaných parametrech (frekvenční a časové rozlišení) byly zvoleny následující parametry: Délka okna pro výpočet DFT byla zvolena jako nejbližší mocnina dvou vzorkovací frekvence, pro $Fs = 250$ Hz je to 256 bodů. Jako váhovací okno bylo využito Hannovo okno

$$w(n) = 0.5 \left(1 - \cos \left(2\pi \frac{n}{N} \right) \right), 0 \leq n \leq N \quad (3.2)$$

o identické délce, tzn. 256 bodů. Tímto způsobem získáme okno o délce cca 1 s. Pro získání časového rozlišení 200 ms je nutné, aby se okna z 80 % překrývala, parametr overlap určující překryv oken je tímto určen na 205 bodů.

Jak plyne z výše uvedeného vztahu pro derivaci, je zřejmé, že derivační parametry budou kratší o jeden bod, což při daném časovém rozlišení znamená zkrácení pozorovaného úseku o 200 ms. Aby mohla být data analyzována za pomoci všech vypočtených parametrů, bylo rozhodnuto vypustit i poslední bod spektrogramu.

Vzhledem k překryvu oken při výpočtu jednotlivých spektrogramů a faktu, že délka okna byla zvolena s ohledem na výše uvedené, nedojde k významné ztrátě dat, bude nevyužito jen posledních 200 ms záznamu.

Použité modely


Z hlediska topologie byl zvolen levo-pravý model. Tato topologie je vhodná vzhledem k charakteru vstupního signálu. Jak je známo, při volních pohybech dochází v EEG signálu k předvídatelným jevům v určeném pořadí, tímto máme na mysli ERD a ERS fáze, kterým předchází, resp. následuje kličový stav.

Vzhledem k fyziologické podstatě těchto jevů nelze předpokládat, že by došlo ke změně v jejich časové souslednosti, proto model neobsahuje zpětné kroky. Analogicky nelze předpokládat, že by došlo k vynechání některého z uvedených jevů, proto jsou přeskoky vpřed ob jeden nebo více stavů vynechány. Topologie základního modelu je uvedena na obrázku 3.1.

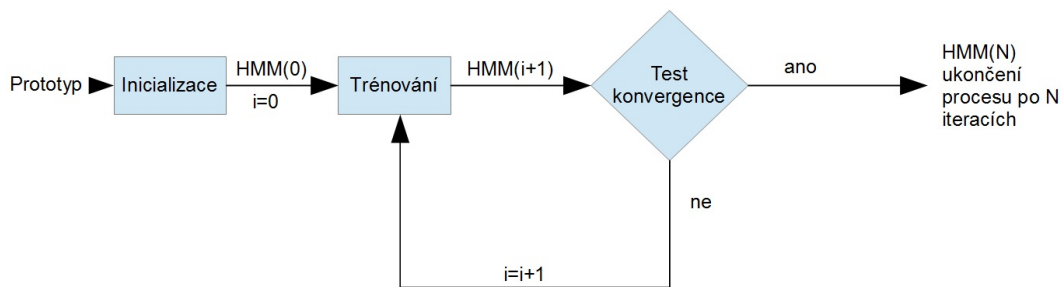
Každý ze stavů sXY je popsán jedním modelem s výše uvedenou topologií, pro kompletní klasifikaci je tedy třeba 9 modelů ($s11, s12, \dots$).

Trénování

Podívejme se blíže na to, jak vypadá proces trénování modelu v HTK Toolboxu.



Obrázek 3.1: Topologie základního modelu



Obrázek 3.2: Proces trénování modelu

Jako první je nutno vytvořit prázdný model, který bude vstupem pro následně použité estimativní algoritmy. V tomto prázdném modelu musí být definována topologie pomocí matice přechodů A a základní parametry každého emitujícího¹ stavu jimiž jsou v případě, že uvažujeme Gaussovské rozdělení pozorovaných dat, střední hodnota (*Mean*) a rozptyl (*Variance*). Pro účely inicializace je vhodné zvolit střední hodnotu nulovou a rozptyl jednotkový [6].

Pro prvotní inicializaci byl použit nástroj HInit. Tento nástroj pomocí Viterbiho algoritmu a ručně označených vstupních dat nastaví počáteční parametry modelu. Nulové prvky matice A zůstanou nulovými², ostatní jsou nastaveny podle charakteru trénovacích dat.

V dalším kroku proběhne iterativní zpřesnění parametrů modelu pomocí

¹Emitujícím stavem rozumíme stav, který není počátečním ani koncovým stavem.

²Topologie modelu se nezmění.

$$\$STAV = s11 \mid s12 \mid s13 \mid s21 \mid s22 \mid s23 \mid s31 \mid s32 \mid s33$$
$$(\{ \$STAV \})$$

Tabulka 3.1: Definice gramatiky

opakovaného použití nástroje HRest. HRest provádí přepočítání modelu podle Baum-Welchova reestimačního algoritmu. Při každé iteraci je vypočtena míra změny mezi novým a původním modelem, jakmile je tato změna limitně blízká nule, můžeme prohlásit, že modely jsou již dostatečně natrénovány.

Tímto způsobem jsou postupně trénovány všechny modely.

Definice úlohy

HTKToolbox je primárně určen pro zpracování a klasifikaci řečových záznamů. Z tohoto důvodu jsou zde jistá specifika co se týče obecného použití pro zpracování jiných signálů. Aby mohla být provedena klasifikace je nutné systému sdělit, jaké jevy a v jakých sekvencích jsou hledány. Při zpracování řeči se jedná o slovník (seznam jevů) a gramatiku (v jakém pořadí a četnosti se jevy mohou vyskytovat).

Mějme seznam jevů $s11, s12, s13, \dots, s33$, které tvoří slovník. Vzhledem k tomu, že pohyby mohou probíhat libovolně na vůli měřené osoby je pozorovaná sekvence (v řeči by šlo například větu) náhodnou posloupností výše uvedených jevů o délce n .

Definice gramatiky je uvedena v tabulce 3.1. STAV může nabývat hodnot $s11$ až $s33$, závorky $\{ \}$ označují nula nebo více výskytů STAVu.

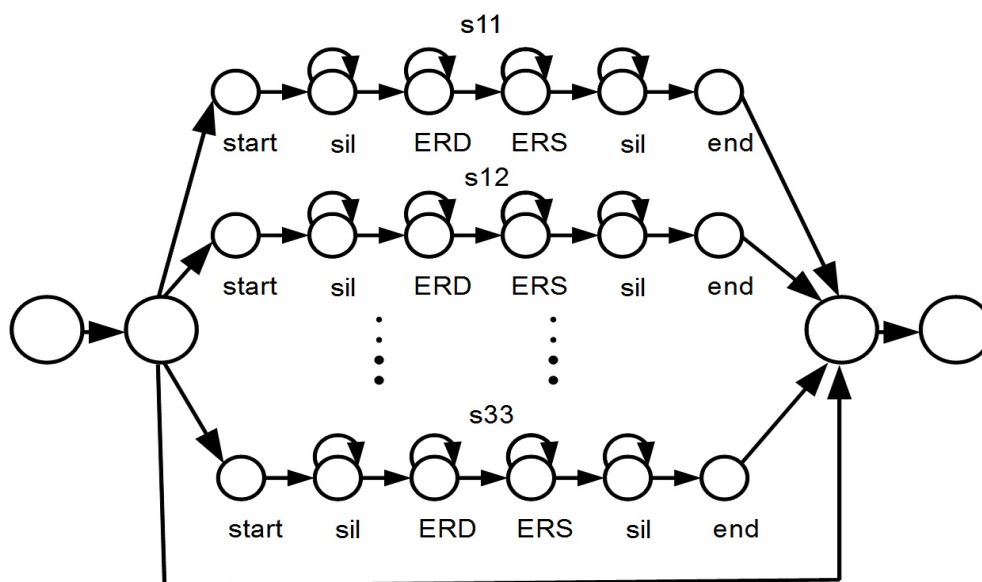
Analogicky je třeba definovat slovník, který určuje, kterému stavu odpovídá který model.

Jak je vidět v tabulce 3.2, názvy modelů byly zvoleny analogicky k názvům jednotlivých jevů, resp STAVů.

Výše vytvořenou gramatiku a slovník je třeba nástrojem HParse přetvořit v síť modelů, která bude použita při samotné klasifikaci.

s11	s11
s12	s12
s13	s13
s21	s21
s22	s22
s23	s23
s31	s31
s32	s32
s33	s33

Tabulka 3.2: Definice slovníku, vlevo název STAVu, vpravo název jevu



Obrázek 3.3: Vytvořený klasifikátor = síť + slovník + HMM

Kapitola 4

Výsledky

S přihlédnutím k dosavadním výzkumům je zřejmé, že problematika rozpoznávání pohybů ze záznamů EEG signálů je velmi rozsáhlá a na tomto poli je stále mnoho neprobádaných oblastí. Z tohoto důvodu se lze domnívat, že každý nový způsob uchopení této problematiky může být dalším krokem k cíli, jímž je prohloubení pochopení funkce lidského mozku.

V předložené disertační práci (zejména v kapitole 3) byl uveden teoretický rozbor řešené problematiky. Je zde uveden způsob snímání a řešení pracoviště pro snímání obrazových dat a EEG signálů. Vzhledem k zadání práce byl kladen důraz na zpracování EEG signálů a jejich klasifikaci, způsob zpracování obrazového záznamu byl uveden pro úplnost, neboť byl součástí celého experimentu, nicméně není těžištěm předložené práce.

V práci byly popsány techniky a nástroje použité pro zpracování získaných dat. Z rozsáhlého matematického aparátu využitelného pro filtraci a zpracování digitálních dat byly stručně představeny pouze ty metody, jenž byly použity v této práci. Jedná se zejména o analýzu nezávislých komponent (ICA), filtry s nekonečnou impulsní odezvou (IIR filtry) a rychlou fourierovu transformaci.

Jako klasifikátory byly zvoleny Skryté Markovovy Modely. Tyto modely byly již ověřeny v předchozích pracích při klasifikaci pohybů z obrazového záznamu [7]. Pro realizaci těchto modelů byl zvolen HTK Toolbox, jde o robustní nástroj pro práci s HMM, původně vyvinutý pro klasifikaci řečových dat. Nicméně vzhledem ke své univerzálnosti bylo rozhodnuto o pokusu jej využít i při klasifikaci EEG. S přihlédnutím k uvedeným výsledkům se lze domnívat, že tento pokus byl úspěšný.

V části zabývající se použitými modely jsou podrobně rozebrány je-

	O1	O2	O2L	O3L
O1	<10%	<10%	<10%	<10%
O2	<10%	81%	35%	61%
O2L	<10%	63%	75%	55%
O3L	<10%	46%	44%	86%

Tabulka 4.1: Výsledky klasifikace, metrika *Correct*, bigramové modely.

	O1	O2	O2L	O3L
O1	<10%	<10%	<10%	<10%
O2	<10%	11%	35%	46%
O2L	<10%	33%	57%	32%
O3L	<10%	43%	44%	65%

Tabulka 4.2: Výsledky klasifikace, metrika *Accuracy*, bigramové modely.

jich vlastnosti, zejména co se týče zvolené topologie a specifik implementace v HTK Toolboxu. Topologie modelů byla zvolena s ohledem na znalost vstupního signálu, jenž je charakterizován sousledností jevů typických pro EEG záznam pohybů. Implementační specifika HTK Toolboxu jsou uvedena proto, aby bylo zřejmé, jakým způsobem systém s modely pracuje a jaké má uživatel možnosti ovlivnění činnosti klasifikátoru¹.

Pomocí HTK Toolboxu lze velmi snadno z jednoduchých modelů vytvořit specificky definovanou síť modelů pouhou změnou několika málo parametrů, aniž bychom se dotkli definice samotných modelů. Definice této sítě má strukturálně odpovídat klasifikovaným datům, což přispívá ke zlepšení kvality klasifikace.

Pro vyhodnocení kvality klasifikace použijeme následující parametry:

$$Correct = \frac{H}{N} \times 100[\%] \quad (4.1)$$

a

$$Accuracy = \frac{H - I}{N} \times 100[\%], \quad (4.2)$$

kde H je počet správně klasifikovaných jevů, N celkový počet jevů a I počet jevů vložených.

¹Nemáme na mysli změnu topologie modelu.

Na základě dosažených výsledků viz. tabulky 4.1, 4.2, se lze domnívat, že volba HMM jako klasifikátorů a nástroje HTK Toolbox pro realizaci těchto klasifikátorů byla vhodná pro zamýšlené využití. Klasifikátor vykazuje uspokojivé výsledky při klasifikaci a odlišení extenzních a flexních pohybů, pro pohyby jenž nejsou čistě extenzní/flexní je však úroveň přesnosti klasifikace signifikantně nižší. Lze se domnívat že je tomu tak z důvodu zapojení více svalových skupin, kde se signály pro jejich aktivaci překrývají a nelze je od sebe dostatečně rozlišit.

Hlavní výsledky práce

Za hlavní výsledky práce lze považovat:

- opakované provedení experimentu zahrnující simultánní snímání obrazových záznamů a EEG signálu,
- vytvoření databáze označených EEG signálů vhodných pro trénování a ověřování klasifikátorů,
- návrh a realizaci klasifikátorů založených na HMM,
- ověření možnosti použití HTK Toolboxu pro klasifikaci EEG záznamů,
- ověření funkčnosti a kvality navržených klasifikátorů.

Kapitola 5

Závěr

V předložené disertační práci byly představeny způsoby zpracování EEG signálu a klasifikátory EEG signálu založené na Skrytých Markovových Modelech implementovaných v HTK Toolboxu.

S ohledem na obtížnost a časovou náročnost při provádění popsaného experimentu byly zvoleny takové metody pro trénování a vyhodnocování klasifikátorů, které nevyžadují rozsáhlé soubory dat.

Výsledky získané z naměřených dat ukazují, že navržené klasifikátory jsou funkční a lze pomocí nich získat relevantní údaje.

Motivací pro vznik této práce byl požadavek ze strany lékaře na zařízení, jež by snadno umožnilo sledovat mozkovou aktivitu pacienta v korelaci s jeho pohybovou aktivitou. Takovéto zařízení by mohlo pomoci při rekonvalescenci po úrazech, případně při jiných poruchách motoriky, případně umožnit lékařům hlubší studium vztahu mezi neurologickou a svalovou aktivitou.

Pochopení vztahu mezi mozkovou a pohybovou aktivitou by také jistě přineslo nové možnosti při vývoji systémů pro komunikaci mezi člověkem a strojem, kupříkladu systémy pro dálkové ovládání bez nutnosti přítomnosti obsluhy na místě (nebezpečné podmínky, radiace, atp.).

Experiment byl navržen za účelem možnosti sledovat korelaci mezi volní pohybovou aktivitou a činností mozku. Vzhledem k tomu, o jak univerzální experiment ve své podstatě jde, se lze domnívat, že navržené řešení je použitelné i pro snímání jiných pohybů (např. celá ruka, noha, atp.). Z hlediska zpracování EEG signálu se jedná pouze o výběr jiných svodů a upravení sítě modelův HTK Toolboxu.

Kapitola 6

Literatura

- [1] Šťastný, J., Sovka, P., Stančák, A.: *EEG Signal Classification Introduction to the Problem*, In Radioengineering
- [2] Oostenveld Robert, Praamstra Peter: *The five percent electrode system for high-resolution EEG and ERP measurements*, In Clinical Neurophysiology 112, 713-719, 2001
- [3] Srinivasan, R., Tucker, D.M: *Estimating the spatial Nyquist of the human EEG*, In Behavior Research Methods, Instruments, & Computers 30(1), 8-19, 1998
- [4] Šťastný, J., Sovka, P., Stančák, A.: *EEG Signal Classification*, In Radioengineering
- [5] Šťastný, J., Sovka, P.: *High-Resolution EEG Classification*, In Hindawi Publishing Corporation, Computational Intelligence and Neuroscience, Volume 2007, Article ID 54925, 2007
- [6] Moreau, N.: *HTK(v.3.1) Basic Tutorial*, URL: www.read.pudn.com, 2.2.2013
- [7] Hlaváček, A.: *Klasifikace pohybů ve videozáznamu*, Diplomová práce, Fakulta Elektrotechnická ČVUT, 2006

Kapitola 7

Vlastní publikace

Publikace vztahující se k disertační práci

Impaktované časopisy: -

Recenzované časopisy:

- Hlaváček, A., Hanzl. V., Havlík, J.: *Using Hidden Markov Models for Movement Classification*, Lékař a technika, červen, s. 121-123, 2006

Patenty: -

Publikace excerpované WOS¹: -

Ostatní publikace:

- Hlaváček, A.: *Klasifikace pohybů lidského těla pomocí markovových modelů implementovaných v HTK Toolboxu a MATLABu*, sborník konference Trendy v biomedicínském inženýrství, vydavatelství ČVUT v Praze, Fakulta biomedicínského inženýrství, Praha, s. 259-261, 2007
- Hlaváček, A., Hanzl. V., Havlík, J.: *Human Body Movements Classification*, Proceedings of the Fifth IASTED International Conference on Biomedical Engineering, Calgary, pp. 326-329, 2006

¹Web of Science

Publikace ostatní

Impaktované časopisy: -

Recenzované časopisy: -

Patenty: -

Publikace excerpované WOS²: -

Ostatní publikace:

- Havlík J., Stöhr J., Hlaváček A.: *Recursive clustering algorithm for thumb motion classification*, In 3rd European Medical and Biomedical Engineering Conference EMBEC'05 [CD-ROM]. Společnost biomedicínského inženýrství a lékařské informatiky ČLS JEP, Prague, 2005
- Hlaváček A., Stohr J.: *Graphical User Interface for Testing Methods of Human Body Movements Classification*, POSTER, 2005
- Hlaváček, A.: *Implementace skrytých Markovových modelů*, Technical Computing Prague 2006 - Sborník příspěvků 14. ročníku konference, Humusoft, Praha, s. 44, 2006

Výše uvedené publikace jsou bez ohlasů a recenzí, u publikací s uvedenými více autory je jejich podíl shodný.

²Web of Science

Kapitola 8

Resumé

Předložená práce se zabývá problematikou studia neurosvalové aktivity a souvisejících metod zpracování signálů.

V první části je uvedeno stručné zadání práce a její cíle, dále je shrnut současný stav problematiky.

Ve druhé části jsou popsány metody snímání a zpracování elektroencefalografických signálů.

Ve třetí části je představena teorie Skrytých Markovových modelů.

Ve čtvrté části je popsán samotný experiment, metodika provedení, způsob snímání dat, jejich zpracování. Dále jsou podrobně popsány použité klasifikátory a nastíněna jejich konkrétní implementace v prostředí HTK Toolboxu. V závěru této části je uvedeno srovnání dosažených výsledků v závislosti na klasifikátoru a implementaci.

V závěrečné části jsou shrnuty dosažené výsledky, jejich vyhodnocení a přínos k řešené problematice a nastín možného směru pokračování ve výzkumu.

Tato práce vznikla jako disertační práce oboru Teoretická elektrotechnika na katedře Teorie obvodů Fakulty elektrotechnické Českého vysokého učení technického v Praze.

Kapitola 9

Summary

This paper deals with the topic of neurological and muscle activity and signal processing.

Section one presents a brief layout of the project as well as its goals and summarizes current state of the research.

Section two briefly describes the method of sensing electroencephalographic signals.

The third part presents theory of the Hidden Markov Models.

The fourth part describes the created classifiers in greater detail. The function and particular implementation of the classifiers in the HTK Toolbox environments are defined. The conclusion to this section comprises a brief comparison of the results achieved depending on the classifier and its implementation. End of this part provides a summary and comments on the achieved results.

The final section introduces the intended future treatment of the assigned topic.

This paper has originated as doctoral degree study in the subject Electrical Engineering Theory at the Department of Circuit Theory of the Faculty of Electrical Engineering of the Czech Technical University.