



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

MULTIKANÁLOVÉ ZPRACOVÁNÍ EMG SIGNÁLU PRO ROZPOZNÁVÁNÍ GEST

MULTICHANNEL EMG SIGNAL PROCESSING FOR GESTURE RECOGNITION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Štěpán Brázdil

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Vratislav Harabiš, Ph.D.

BRNO 2018

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Štěpán Brázdil

ID: 185946

Ročník: 3

Akademický rok: 2017/18

NÁZEV TÉMATU:

Multikanálové zpracování EMG signálu pro rozpoznávání gest

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se a proveďte literární rešerši na téma měření EMG signálu. 2) Seznamte se s Robot Toolboxem pro Matlab 3) Navrhněte způsob měření a zpracování EMG signálu z horní končetiny pro možnosti ovládání základních gest protěže. 4) Implementujte navržené metody ve zvoleném prostředí. Pro vizualizaci využijte Robot Toolbox. 5) Navržené a implementované metody vhodným způsobem otestujte. 6) Zhodnoťte navržené řešení z hlediska funkčnosti i výpočetní náročnosti.

DOPORUČENÁ LITERATURA:

[1] MERLETTI, Roberto. a Philip PARKER. Electromyography: physiology, engineering, and noninvasive applications. Hoboken, NJ: IEEE/John Wiley, c2004. ISBN 9780471675808.

[2] DAMELIN, Steven B. a Willard. MILLER. The mathematics of signal processing. New York: Cambridge University Press, 2012. Cambridge texts in applied mathematics, 48. ISBN 9781107601048.

Termín zadání: 5.2.2018

Termín odevzdání: 25.5.2018

Vedoucí práce: Ing. Vratislav Harabiš, Ph.D.

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Tato práce se zabývá komplexním řešením problému týkajícího se návrhu a realizace systému pro sběr, klasifikaci a vizualizaci dat EMG signálu. Práce je vytvořena s ohledem na možné budoucí aplikace, tzn. implementace reálného modelu končetiny ovládané právě pomocí navrženého systému. V úvodní části jsou rozebrány teoretické znalosti vzniku EMG signálu a možnosti snímání, včetně anatomické struktury horní končetiny. V dalších částech je diskutována možná realizace měření pomocí systému BITalino, využití zpracování a klasifikace dat pomocí programu Matlab. Výstupem této práce je funkční programový kód, který umožňuje vizualizaci gest horní končetiny v grafickém uživatelském rozhraní.

Klíčová slova

EMG, klasifikace, BITalino, Matlab, gesta horní končetiny

Abstract

This work deals with the complex solution of the problem concerning the design and implementation of the system for the collection, classification and visualization of EMG signal. The thesis is designed with respect to possible future applications like implementation of a real limb model controlled by the proposed system. In the introductory part the theoretical knowledge of EMG signal generation and sensing possibilities, including the anatomical structure of the upper limb, are revealed. In the other parts, the possible realization of measurements using the BITalino system and the use of data processing and classification using the Matlab program are discussed. The output of this work is a functional program code that allows visualization of upper limb gestures in the graphical user interface.

Keywords

EMG, classification, BITalino, Matlab, gestures of upper limb

Bibliografická citace:

BRÁZDIL, Š. *Multikanálové zpracování EMG signálu pro rozpoznávání gest*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2018. 59 s. Vedoucí bakalářské práce Ing. Vratislav Harabiš, Ph.D.

Prohlášení

Prohlašuji, že svou závěrečnou práci na téma „Multikanálové zpracování EMG signálu pro rozpoznávání gest“ jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne 20. května 2018

.....
podpis autora

Poděkování

Chtěl bych tímto poděkovat svému vedoucímu Ing. Vratislavu Harabišovi, Ph.D. za odbornou pomoc při vytváření této práce. Jsem mu vděčný za cenné rady ohledně daného tématu (především hardwarové části) udělené v rámci konzultačních hodin a poskytnutí materiálního zázemí nutného pro dokončení práce. Také mou práci vedl v soutěži studentské konference EEICT 2018, kde jsem i díky jeho podpoře a radám dosáhl druhého místa. Dále bych chtěl poděkovat Ing. Marině Ronzhině, Ph.D. za poskytnutí cenných rad a materiálů týkajících se klasifikačních algoritmů, především pak problematiku klasifikace pomocí support vector machines. Velký dík patří také mé rodině za celkovou podporu a zázemí v období studia. Děkuji také dobrovolníkům, kteří byli ochotni participovat v testovací fázi práce.

Obsah

Úvod.....	9
1 Teorie snímání EMG signálu.....	10
1.1 EMG signál	10
1.2 Charakteristické vlastnosti EMG	11
1.3 Přístrojové vybavení pro akvizici dat.....	12
1.4 Anatomie horní končetiny.....	14
2 Návrh měřicí techniky a vizualizace.....	17
2.1 Rozbor existujících řešení	17
2.2 Schéma vzájemného propojení	19
2.3 BITalino	19
2.4 Vizualizační prostředí	22
3 Návrh zpracování signálu	25
3.1 Předzpracování signálu	25
3.2 Extrakce příznaků.....	26
3.3 Klasifikační algoritmy.....	28
4 Realizace hardwarové a softwarové části	32
4.1 Hardwarová část.....	32
4.2 Softwarová část	34
5 Testování a výsledky	40
5.1 Popis testování	40
5.2 Výsledky	41
Závěr	44
Literatura.....	45
Seznam symbolů, veličin a zkratk.....	48
Seznam příloh	49

Seznam obrázků

Obrázek 1 – grafické znázornění vzniku EMG, převzato a přeloženo z [14].....	11
Obrázek 2 – schématické vyjádření základních bloků při akvizici a zpracování EMG .	12
Obrázek 3 – svaly předloktí, dorzální skupina [19].....	15
Obrázek 4 – svaly předloktí, přední skupina [19].....	16
Obrázek 5 – schéma navrhovaného propojení komponent.....	19
Obrázek 6 – MCU BITalino [18].....	21
Obrázek 7 – EMG modul BITalino [7].....	22
Obrázek 8 – grafické znázornění DH parametrů, převzato a přeloženo z [28]	24
Obrázek 9 - znázornění principu SVM, převzato a přeloženo z [6]	30
Obrázek 10 – vytvořený modulární systém	32
Obrázek 11 – ukázka připojení elektrod a uchycovacího mechanismu pro volný pohyb	33
Obrázek 12 – vizualizace gest v robotické soustavě.....	35
Obrázek 13 – ukázka napěťové úrovně signálu pro jednotlivá gesta	39
Obrázek 14 – příklad grafické reprezentace pro vyhodnocování (scatter plot).....	40

Seznam tabulek

Tabulka 1 – DH parametry	23
Tabulka 2 – základní příkazy Matlab robot toolbox.....	24
Tabulka 3 – přehled základních příkazů pro práci s knihovnou BITalino toolbox	36
Tabulka 4 – tabulka indexů odpovídající konkrétním gestům.....	37
Tabulka 5 – základní příkazy pro práci s klasifikátorem SVM	38
Tabulka 6 – přehled úspěšnosti klasifikace	41
Tabulka 7 – průměrné časy zpoždění programu	43

ÚVOD

Cílem této práce je vytvoření počítačového modelu pro možnosti monitorování elektrické aktivity svalů a simulaci pohybu horní končetiny, konkrétně prstů ruky. Je snahou docílit optimálního řešení, které umožní na základě snímání elektrické aktivity svalů z více kanálů současně kategorizovat prováděné pohyby, a získat tak vizualizační a testovací prostředek, který by bylo možné použít pro následnou analýzu a tvorbu konkrétního modelu protetické končetiny. Budoucí uplatnění výstupu této práce při realizaci skutečné končetiny je jednou z hlavních motivací bakalářské práce. V současné době není k dispozici volně dostupný produkt, jenž by takového testování umožňoval.

V první kapitole lze nalézt stručný přehled informací, které jsou elementární k pochopení celého problému elektromyografie. Jedná se například o teorii vzniku signálu, vliv impedance kůže a elektrod na měření a teoretické informace týkající se přístrojového vybavení potřebného k získání dat. Je také uvažována anatomie horní končetiny (konkrétně předloktí), na které bude systém optimalizován a testován. Využití snímání dat z předloktí je vhodné pro teoreticky možnou implementaci systému na pacienty s amputovanou rukou nad předloktím. Další motivací při tvorbě práce je právě možnost využít poznatků ke zlepšení života těchto hendikepovaných lidí.

Druhá a třetí část je zaměřena na konkrétní možnou realizaci měřicího aparátu jak ze softwarové, tak hardwarové stránky. V úvahu připadají nízkonákladové systémy, které jsou uzpůsobeny k měření biologických signálů. Dále jsou objasněny funkce vizualizačního prostředku Robot toolbox v programu Matlab, díky němuž je možné simulovat reálný pohyb končetiny. Nechybí také teoretický úvod do klasifikačních algoritmů.

Čtvrtá kapitola již prakticky navazuje na předchozí části, což znamená ukázky ze skutečné realizace celého měřicího systému. Je demonstrováno, jakým způsobem je možné sestavit akviziční systém a způsob propojení s počítačem, včetně konkrétních způsobů realizace programových kódů. Celá sekce tedy popisuje systém, který je výstupem této práce a na němž proběhlo sofistikované testování.

Navazující část pojednává právě o způsobech testování vytvořeného systému, vlastnosti a klasifikační schopnosti jsou podloženy výsledky z naměřených dat. Je otestováno jednak výpočetní zatížení, dále pak celková schopnost klasifikace.

Závěrem bakalářské práce je reálné zhodnocení dosud nabytých poznatků a funkčnosti celého systému.

1 TEORIE SNÍMÁNÍ EMG SIGNÁLU

1.1 EMG signál

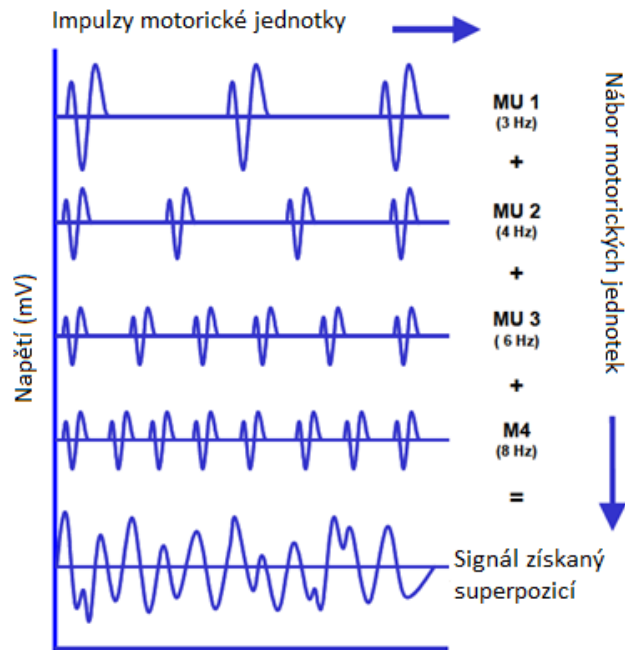
EMG (elektromyografie) je jednou z již standardně zavedených metod při posuzování svalové aktivity. Využívá se měření svalových elektrických napětí na povrchu, nebo uvnitř svalu. Informace o elektrickém napětí je klíčové pro stanovení svalové únavy, popisu změny pohybu či rozpoznání různých svalových onemocnění.

Na rozdíl od jiných typů biologických signálů (např. EKG), které se vyznačují jistou mírou uspořádanosti a stacionarity, která umožňuje signál vyjádřit pomocí jednoduššího modelu a následně poskytnout snadnou interpretaci, musíme nahlížet na signál elektromyografický poněkud odlišně. Akvizice elektrického napětí v případě povrchového snímání bere v úvahu aktivitu celé řady svalových vláken. Z tohoto důvodu můžeme výsledný signál považovat za sumarizaci jednotlivých příspěvků konkrétní svalové jednotky.

Celý proces od vzniku podnětu k vyvolání stahu svalu může vypadat následovně. Řídící impulzy z neuronů jsou vlákna vedeny až k neurosvalové ploténce, kde dochází pomocí složitých procesů k převodu akčního napětí na svalová vlákna. Soubor, který zprostředkovává komunikaci mezi neurony a svaly pomocí motoneuronu a jím inervovaných svalových vláken se nazývá motorická jednotka (MU). Jelikož každá MU obsahuje jinou skupinu svalových vláken, a protože je každé napojení umístěno v různé vzdálenosti a hloubce od místa měření, výsledný detekovaný signál je právě superpozicí řady akčních potenciálů motorické jednotky (tzv. MUAP). Zde se dostáváme k jádru problému při snímání EMG. Právě z důvodu různého rozmístění MU a polohy elektrod nelze v praktických aplikacích nasnímat identické signály, a nalézt tak v signálu stacionaritu. To může být problém, pokud je nutné hledat v signálu různé patologické procesy, nebo únavu svalu. V případě detekce počátku svalové aktivity, který v případě této práce je stěžejním pro klasifikaci z jednotlivých kanálů, není tento problém náhodnosti signálu klíčový. Pro nalezení složitých vnitřních vazeb, které se snaží algoritmy založené na neuronových sítích či podobných prostředcích, je ovšem tato znalost výhodou. Vzorec, který vyjadřuje podstatu EMG signálu lze vyjádřit takto:

$$x(n) = \sum_{r=0}^{N-1} h(r)e(n-r) + w(n) \quad (1)$$

kde $x(n)$ je prvek výsledného EMG signálu, N je počet motorických jednotek, $h(r)$ je akční potenciál konkrétní motorické jednotky, $e(n)$ představuje impulzy z motoneuronů, což vystihuje časový posun mezi jednotlivými MUAP, $w(n)$ představuje nežádoucí bílý šum. [14], [24]



Obrázek 1 – grafické znázornění vzniku EMG, převzato a přeloženo z [14]

Celá záležitost týkající se samotného vzniku akčního napětí je velmi složitá a vyžadovala by znalosti stavby svalových vláken, iontovou skladbu vnitřního a vnějšího prostředí buněk a prostupnosti iontových kanálů. Pro tuto práci a následné aplikace ovšem nejsou podstatné.

1.2 Charakteristické vlastnosti EMG

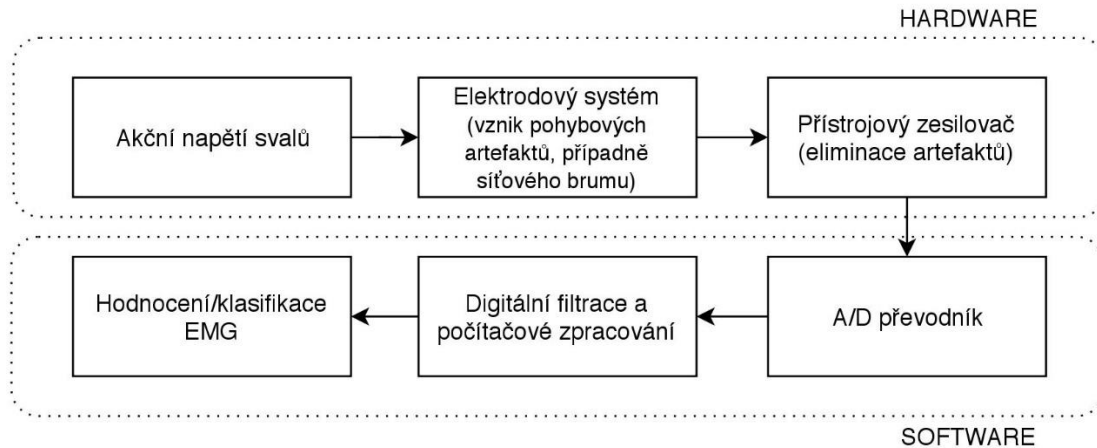
Je důležité také zmínit důležité parametry EMG signálu, které jsou potřebné pro technické zpracování problému. Typický **napětíový rozsah** je: od -5 do 5 mV. **Majoritní frekvence** leží v rozsahu: od 20 do 150 Hz (celkový rozsah je přibližně od 6 do 500 Hz). Faktory, které znatelně ovlivňují kvalitu výsledného signálu jsou:

- **Impedance kůže** – snaha snížit impedanci kůže pomocí vhodných prostředků (gely s obsahem iontů) pro dosažení největšího poměru signál/šum.
- „**Cross talk**“ – naměření signálů z více svalových skupin současně. Lze eliminovat zvolením menší elektrody, případně vhodnější prostorovou orientací elektrod.
- **Okolní šum** – elektromagnetické rušení z okolí, síťový brum apod. Je možné jej redukovat vhodným stíněním, případně filtrací.

[14], [5], [24]

1.3 Přístrojové vybavení pro akvizici dat

Před provedením jakékoliv analýzy EMG je nutná akvizice dat. Ta se neobejde bez těchto důležitých částí, které je možné vyjádřit pomocí diagramu níže.



Obrázek 2 – schématické vyjádření základních bloků při akvizici a zpracování EMG

1.3.1 Elektrodotový systém

Jelikož je v dalších částech manipulováno a měřeno pomocí elektrod, je vhodné uvést jejich základní dělení a konkrétní vlastnosti.

Elektroda je fakticky zprostředkovatelem vedení signálu mezi zdrojem napětí (v našem případě svalová vlákna) a měřícím systémem. Dochází zde k přechodu od vodiče (elektrolyt), který zprostředkovává vedení elektrického proudu pomocí iontů k vodiči (kov), který vede proud pomocí elektronů. Existují 2 způsoby aplikace. Jednak existují vpichové elektrody, které dokáží velmi přesně a specificky měřit MUAP, jednak povrchový typ elektrod (tzv. sEMG). Jehlové elektrody vykazují mnohem větší zdravotní rizika, proto se většinou pro komerční použití pracuje právě s povrchovými elektrodami.

Standardně je využíváno bipolárního zapojení. Elektrické napětí je tak vztaženo přímo na měření potenciálů mezi 2 elektrodami (na rozdíl od unipolárního zapojení, kdy se měří rozdíl napětí vůči zvolenému referenčnímu bodu). Pro akvizici dat z jednoho kanálu je tedy standardně využito dvou měřících elektrod (pro získání difference signálu) a jedné referenční elektrody, vůči které lze napětí snímat. V případě vícekanalové akvizice můžeme následně celkový počet vyžadovaných elektrod vyjádřit takto:

$$\text{počet elektrod} = 2 \times \text{počet kanálů} + 1 \quad (2)$$

Na základě konstrukce povrchových elektrod je možné dělení do 2 kategorií:

- **Elektrody suché** – méně používaný systém, z důvodu vysoké impedance je nutné použít další zesilovací obvod, čímž narůstají požadavky na kvalitu přístrojového zesilovače. Hlavní výhodou je možné opětovné použití.

- **Elektrody gelové** – standardně užívaný elektrodový systém. Obsahuje vrstvu gelu mezi kůží a elektrodou, která umožňuje lepší průchodnost iontů, a tím snižuje impedanci a zajistí lepší přenos signálu. Tradiční systém počítá s kombinací elektrod Ag-AgCl, kdy stříbrno-chloridová elektroda zabraňuje nežádoucí polarizaci elektrod a tím snižuje případné rušení. Elektrody jsou určeny jen pro jedno použití.

[14], [5]

1.3.2 Přístrojový zesilovač

Přístrojový zesilovač je jednou z hlavních komponent, na níž klademe vysoké nároky, co se týče kvality zpracování. Přístrojový zesilovač je vlastně komplexním zařízením, které kombinuje řadu obvodů, převážně operačních zesilovačů. Většina přístrojových zesilovačů obsahuje obvod pro filtraci nízkých kmitočtů signálu, pro potlačení rušení z nedostatků elektrod a jejich pohybu na kůži. Dále většinou zahrnuje obvod pro potlačení síťového rušení. Musí oddělovat napájení elektroniky a části pro snímání, aby byla zaručena stoprocentní bezpečnost uživatele. Řada podpůrných obvodů zajišťující vysokou vstupní a nízkou výstupní impedanci je samozřejmostí. V dnešní době je součástí zařízení i složitá elektronika a A/D převodník, který analogová data dokáže převést na digitální. Data jsou buď rovnou analyzována v zařízení a zobrazena na implementovaném monitoru, případně posílána přes specifickou sběrnici do dalšího zařízení (např. PC) pro další zpracování. Nyní si uvedeme základní parametry zesilovačů, které při výběru zohledňujeme:

- **Rozlišení A/D převodníku [bit]** – udává, kolik napěťových úrovní je mikroprocesor schopný zpracovat. Typická dostačující hodnota pro běžné aplikace je 10 bitů.
- **Vzorkovací frekvence [Hz]** – udává počet zpracovatelných vzorků za sekundu. Z Nyquistova teorému je známo, že vzorkovací frekvence musí být minimálně dvojnásobná od maximální požadované snímané frekvence. Pro EMG signály je dostatečná vzorkovací frekvence 1000 Hz (hlavní pásmo signálu je totiž 20-150 Hz).
- **CMRR (common mode rejection ratio) [dB]** – důležitý údaj operačních zesilovačů, který udává, s jakým poměrem dokáže zesilovač potlačit soufázovou složku napětí ve srovnání s rozdílovou složkou.

[14], [5], [27]

1.4 Anatomie horní končetiny

Znalosti základních anatomických struktur končetiny jsou klíčové pro správnou akvizici dat. Pozornost bude věnována skladbě svalu a popisu svalové struktury horní končetiny, konkrétně předloktí. S ohledem na aplikační účel této práce budou pečlivě vybrány a popsány ty části struktur, které mají dopad na měření povrchového EMG z předloktí pro rozpoznávání gest prstů.

1.4.1 Charakteristika kosterního svalstva

Příčně pruhovaný kosterní sval (lat. musculus) se skládá ze svalového bříška¹, šlach pro upnutí na kosterní soustavu (počáteční šlacha – origo, úponová – insertio) a svalové povázky (fascie), která obaluje povrch svalu. Za součást svalu se často pokládají i výživové (cévy) a inervační (nervová vlákna) struktury.

Z hlediska pohybových a funkčních vlastností svalů je vhodné uvést tato značení, podle kterých lze snadno odvodit účel jednotlivých svalů:

- **Flexory (ohýbače)** – slouží k ohýbání dané anatomické struktury, např. prstu.
- **Extensory (natahovače)** – antagonistou² flexorů, slouží pro natažení struktur, např. prstů či zápěstí.
- **Supinátoři** – vykonávají pohyb spějící k supinaci (dlaň směřující dopředu).
- **Pronátoři** – vykonávají pohyb spějící k pronaci (hřbetní strana směřuje dopředu).
- **Adduktory (přitahovače)** – účelem je přitahování dané struktury vůči celku, např. přitahovač palce.
- **Abduktory (odtahovače)** - účelem je odtahování dané struktury vůči celku, např. odtahovač palce. [19], [12]


1.4.2 Svaly předloktí a prstů

Svaly předloktí lze rozdělit do 3 kategorií. Svaly přední skupiny slouží především pro flexi zápěstí, prstů a pronaci předloktí. Laterální skupina obsahuje svaly, jejichž funkcí je extenze a supinace předloktí. Poslední dorzální skupina zahrnuje svaly pro extenzi zápěstí a prstů. Z hlediska této práce budou důležité především skupiny přední a dorzální


¹ Lokalizace svalového bříška je důležitým faktorem pro snímání EMG signálu. Elektrody se vždy snažíme uložit právě na střed svalového bříška. Je to z důvodu snížení vlivu již zmíněného „cross talkingu“. Navíc nedochází tolik k zarušení pohybovými artefakty, neboť v případě přiložení elektrody na úpon svalu může docházet k pohybu elektrody na pokožce.

² Sval, který vykonává opačnou funkci

skupiny. Na následujících obrázcích jsou vyznačeny všechny důležité svaly předloktí a prstů, podtržené pak svaly esenciálně důležité pro náš konkrétní případ bakalářské práce.



Obrázek 3 – svaly předloktí, dorzální skupina [19]



Obrázek 4 – svaly předloktí, přední skupina [19]

2 NÁVRH MĚŘÍCÍ TECHNIKY A VIZUALIZACE

V této kapitole bude proveden návrh vzájemného propojení a výběr jednotlivých prvků pro sběr, komunikaci, zpracování a vizualizaci dat. Nejdříve bude zmínka o existujících řešeních snímání EMG signálů, které se v praxi používají právě za účelem následného ovládání protetické končetiny. Boudou rozebrány jednak komerčně používané systémy, dále pak výstupy z experimentálních měření. Následně budou podrobně popsány jednotlivé komponenty, na kterých bude tato práce založena a v praktické části realizována.

2.1 Rozbor existujících řešení

V současné době lze nalézt po celém světě řadu výzkumných institucí, které se soustředí právě na realizaci umělé končetiny, snímání a zpracování dat. V zásadě můžeme rozlišovat dvě skupiny těchto řešení, které budou rozebrány v samostatných podkapitolách.

2.1.1 Funkční systémy

V zásadě se jedná o systémy, které jsou již v nějaké formě nasazeny do praktického provozu. V dnešní době jsou zpravidla populární tzv. open source systémy, které jsou uzpůsobeny pro možnosti volného přístupu k informacím, programovým kódům a schématům. Zpravidla se jedná o jednodušší systémy, které jsou zaměřeny převážně na celkovou funkčnost náhrady končetiny a jednoduchou implementaci všech součástí. Je zde snaha zpřístupnit tyto technologie široké veřejnosti, neboť se běžně jedná o specializované a finančně nákladné řešení. Navíc díky přístupu k zdrojovým kódům je možné dané systémy rozšiřovat a případně využívat znalosti a návrhy v odborných pracích.

Obecně se tyto systémy skládají z náhradní končetiny vytvořené převážně na 3 D tiskárně, krokových motorů pro ovládání jednotlivých prstů, základní desky umožňující napájet krokové motory a zpracovávat EMG signály (většinou se jedná o kompaktní čip s nízkou spotřebou například Arduino) a potřebného zdrojového kódu. Z hlediska této práce je zajímavá část týkající se měření a zpracování signálu.

Jako konkrétní případ bude uvedena protetická končetina ADA V1.1 od společnosti Open Bionics. Končetina je v základu uzpůsobena pro měření maximálně dvěma kanály. Proto je možné rozpoznat pouze základní gesta, v závislosti na použitém algoritmu. Dle přiloženého softwarového řešení Artichoke je zpracování signálu založeno na prahových

hodnotách bez použití klasifikačních algoritmů. Tímto způsobem je možné rozpoznat jen základní gesta, sevření a natažení prstů ruky, v případě vhodně umístěných elektrod sevření ukazováku a palce. Samotná protéza má pět stupňů volnosti, tzn. lze ovládat každý prst zvlášť. V případě vhodně zvoleného algoritmu by bylo možné dosavadní možnosti ovládání rozšířit. [20]

2.1.2 Experimentální systémy

Pod pojmem experimentální systém se rozumí takový návrh zařízení či implementace, který nebyl zařazen do praktického provozu a testování. Jedná se především o výzkumné práce zahraničních pracovníků a studentů specializovaných vysokých škol. Cílem těchto prací je nalézt inovativní způsoby v oblasti klasifikace měřených EMG signálů. Společnou vlastností většiny těchto návrhů je přístup k výkonné výpočetní technice (kterou v současné době nelze u protetických končetin z důvodu mobility použít) a také metodika zpracování dat, která ve většině případů neprobíhá v reálném čase. Je tedy předpokládáno, že mnohé přístupy nebude možné použít z důvodu vizualizace gest v reálném čase.

Práce [16] spočívá ve využití klasifikačního algoritmu SVM (pojednání v samostatné kapitole). Cílem bylo otestování klasifikačních možností EMG signálu ve srovnání s jinými druhy dostupných algoritmů (například s neuronovou sítí). Pro snímání signálu bylo využito čtyř párů elektrod, přičemž snahou bylo dosažení klasifikace pro devět různých pohybů, především pro pohyby v zápěstí. Dosažená úspěšnost klasifikace přesahovala 90% hranici a ve srovnání s ostatními algoritmy bylo dosaženo nejlepších výsledků. Je nutno poznamenat, že nejsou popsány detailní nastavení jednotlivých klasifikátorů, je tedy otázkou, v jaké míře jsou data relevantní. Dále je nutné opět připomenout, že zpracování dat neprobíhalo v reálném čase.

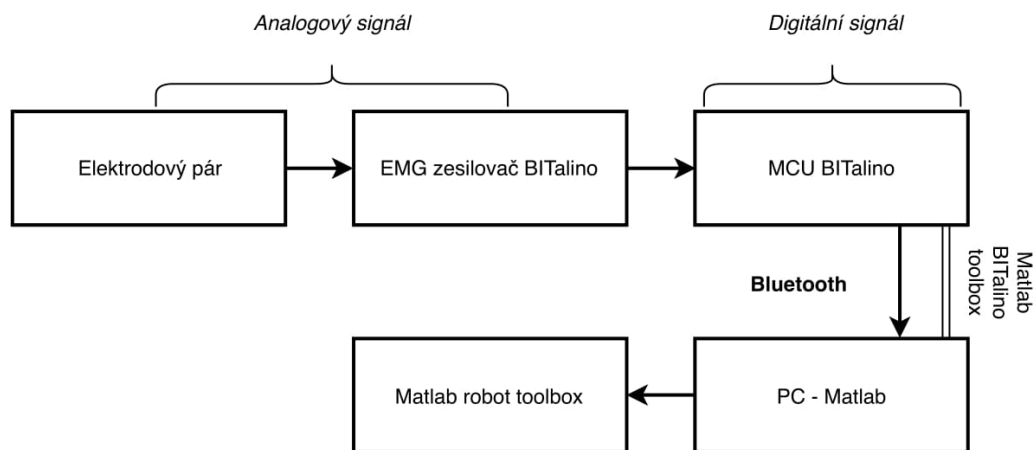
Přístup další skupiny autorů v článku [23] odhaluje možnosti využití vlnkové transformace pro dosažení lepších popisných vlastností signálu. Akvizice dat probíhala ze 2 kanálů za účelem rozlišení šesti pohybů zápěstí. Nabyté informace ohledně klasifikace nejsou podrobně testovány, pouze je představeno srovnání jednotlivých parametrů použité transformace. Dle výsledných grafů je možné předpokládat, že za využití vhodného klasifikačního algoritmu by bylo možné dosáhnout lepších výsledků klasifikace než z původního signálu EMG.

Nejjednodušší z již zmíněných přístupů představuje práce č. [30]. Cílem autorů článku bylo rozpoznat tři gesta ruky (kámen-nůžky-papír). Využili přitom pouze vhodnou pozici tří elektrod pro snímání svalů podílejících se na konkrétním pohybu a na základě jednoduché úpravy signálu pomocí průměrovacího okna obdrželi z každého kanálu binární hodnotu klasifikace – aktivní/neaktivní sval. Na základě rozhodovacích algoritmů

tak dokázali získat informace o aktuálním stavu končetiny. Nevýhodou tohoto přístupu je fakt, že úspěšnost klasifikace je velmi ovlivněna výběrem vhodného prahu klasifikace a velikostí okna. Zdlouhavé testování pro získání vhodných parametrů a nízká robustnost je shledáno hlavním problémem tohoto řešení.

2.2 Schéma vzájemného propojení

V následujícím diagramu je schematicky naznačen způsob integrace jednotlivých komponent, jež budou rozebrány v navazujících podkapitolách, dohromady tvořící celý měřicí a vizualizační systém této práce. Jedná se o jeden z možných návrhů, který je možno v případě potřeby rozšířit či upravit. Z hlediska požadovaných parametrů pro snímání a zobrazení pohybu končetiny se jedná o kompaktní, výpočetně dostupný systém.



Obrázek 5 – schéma navrhovaného propojení komponent

2.3 BITalino

BITalino je komerčně dostupný set hardwarového příslušenství, určený především pro získávání biologických dat. Celý systém byl vyvinut portugalskou společností Plux|Wireless Biosignals. Hlavním cílem společnosti je nabídnout široce dostupný, levný, kompaktní, a přitom kvalitně zpracovaný kompaktní systém, který bude schopen interagovat s již dostupnými technologiemi, nabídne pohodlné a jednoduché ovládání pro snímání a úpravu biologických signálů. Umožňuje také široké přizpůsobení uživatelem. Základní sada BITalino Board Kit již nativně obsahuje vše potřebné pro provoz zařízení, nabízí ovšem také revoluční design, který umožňuje jednotlivé moduly uvolnit, dle uživatele upravit a otevřít tak možnosti například pro nositelnou elektroniku.

Základní dodávaný set obsahuje desku plošného spoje, který již v základu propojuje všechny dodávané moduly. Není tedy nutné jakkoliv zasahovat do hardwarové části. Z hlediska této práce došlo k upravení celého setu pro možnosti snímání dat z více kanálu současně, popis celého návrhu a nutných úprav je předmětem samostatné kapitoly týkající se konkrétní realizace systému. Základní set se tedy skládá z těchto částí:

- Mikrokontrolér
- Bluetooth modul
- EMG senzor
- EKG senzor
- Senzor světla
- Akcelerometr
- Napájecí modul včetně 3,7 V baterie
- Senzor elektro-dermální aktivity
- Příslušenství (elektrodové svody)


[2]

2.3.1 Mikrokontrolér¹ BITalino

Základní specifikace dodávaného mikrokontroléru jsou následující:

- Vzorkovací frekvence – 1, 10, 100 a 1000 Hz
- Počet analogových portů – 6 vstupních (porty A1-A6) a 1 výstupní (PWM)
- Počet digitálních portů – 4 vstupní (I1-I4) a 4 výstupní (O1-O4)
- Rozlišení – 10 bitové (porty A1-A4) a 6 bitové (A5-A6)
- Komunikační rozhraní – UART
- Napětí – operační: 3,3 V; vstupní: 3-5,5 V
- Spotřeba – 5 mA

Za povšimnutí stojí především 10 bitové rozlišení, které je pouze pro 4 první analogové porty. Z tohoto důvodů je omezen maximální počet snímaných kanálů EMG na 4, neboť rozlišovací schopnost 6 bitového převodníku je pouze 64 napěťových hladin, což není pro rozpoznávací schopnosti gest dostačující. Jedna z hlavních vlastností kontroléru je možnost zpracovávat a odesílat data v reálném čase, což je pro akvizici biologických signálů nutné. [18]



Obrázek 6 – MCU BITalino [18]

¹ Jako mikrokontrolér je možné využít jakýchkoliv komerčně dostupných setů, které dokáží zpracovat analogové signály s dostatečnou vzorkovací frekvencí a rozlišením. V úvahu připadá např. široce dostupný mikrokontrolér Arduino UNO, který byl jednou z možností při navrhování akvizičního systému této práce. Oproti MCU BITalino ovšem postrádá nativně bluetooth modul (z hlediska uživatelské bezpečnosti výhodné řešení).


2.3.2 EMG modul BITalino

Jelikož se jedná o základní stavební kámen této práce, je vhodné uvést konkrétní specifikace:

- Zesílení – 1009krát
- Rozsah napětí – $\pm 1,64$ mV (při $V_{CC} = 3,3$ V)
- Frekvenční rozsah – 25-480 Hz
- Vstupní impedance – 7.5 G Ω
- CMRR – 86 dB
- Spotřeba – 0.17 mA

Napájení volíme v rozsahu mikrokontroléru, při použití BITalino v rozmezí 2-3.5 V. Kladný pól napájení je veden na vstup označený VCC, záporný pól na GND. Výhodou tohoto operačního zesilovače je fakt, že není nutné využívat symetrické napájení. Proto je možné využít napájení nesymetrické například použitím pouze jedné baterie. Při využití takového nesymetrického napájení je ovšem nutné vytvořit středové napětí, které je rovné polovině napětí vstupního ($V_{CC}/2$). Při nedodržení tohoto napětí dojde k posunu nulové linie signálu, a tím ke zkreslení průběhu signálu.

Pro snímání biologických signálů je nutné použít třísvodové uspořádání, konkrétně kladnou, zápornou a referenční elektrodu. Při použití více EMG modulů je vyžadována pouze jedna referenční elektroda. [7]



Obrázek 7 – EMG modul BITalino [7]

2.4 Vizualizační prostředí

2.4.1 Matlab

Pro zpracování signálu a zobrazení bylo zvoleno programové prostředí Matlab. Programovací jazyk umožňuje jednoduchou implementaci potřebných složek hardwaru. Navíc již v základu obsahuje všechny v budoucnu možné využitelné funkce, jako je například implementace vlnkové transformace, neuronové sítě apod. Základní balíčky pro

tyto výpočetní algoritmy lze navíc rozšířit o již zmíněné hardwarové řešení. Tímto způsobem lze přímo v programu pracovat a volat funkce, které načítají data z mikrokontroléru. Právě pro práci s BITalinem je nutné mít obsažený BITalino Toolbox dostupný na oficiálních stránkách MathWorks. Prostředí Matlabu bylo dále doplněno o prostředí pro vizualizaci robotické soustavy, konkrétně se jedná o Matlab robot toolbox. [17]

2.4.2 Matlab robot toolbox


Za účelem zobrazení pohybu ruky, resp. gest horní končetiny je navrženo použití tohoto přídatného nástroje pro prostředí Matlab. Toolbox má nativně implementovanou grafickou sadu, kterou je možné využít pro modelování nejrůznějších robotických systémů. Navíc již v základu obsahuje navržený model robotické ruky, který lze s jistými úpravami použít. Pro možnost modelování robotických systémů je ovšem nutné seznámení se základními parametry, které tento systém určují. Nejdříve je nezbytné dané robotické spojení namodelovat, následně pak úpravou již vytvořených parametrů zobrazovat pohyb a kinematiku soustavy. V tomto prostředí se nepracuje s klasickým kartézským systémem souřadnic, místo toho se využívá specializované Denavit-Hartenbergovy reprezentace, která byla vytvořena právě pro popis robotických soustav.

Denavit-Hartenbergova reprezentace, jak již bylo zmíněno, představuje specializovaný systém souřadnic. V této soustavě je každý robotický kloub popsán vlastním souřadnicovým systémem okna s osami x , y , z . Osa z vždy odpovídá ose otáčení daného kloubu, osa x odpovídá normále k osám z mezi dvěma klouby a osa y je doplněna dle pravotočivého systému. Pro exaktní určení souřadnic byly zavedeny tyto čtyři parametry:

Tabulka 1 – DH parametry

Typ parametru	Značka	Význam parametru
Délka spojení	a_i	Vzdálenost mezi z_i a z_{i+1} podél osy x_i (tj. normála mezi sousedními osami z)
Otočení spoje	α_i	Úhel mezi z_i a z_{i+1} okolo osy x_i (tj. vzájemné natočení sousedních os z)
Úhel kloubu	Θ_i	Úhel okolo osy z (tj. otočení kloubu kolem vlastní osy)
Zdvih kloubu	d_i	Vzdálenost mezi x_{i-1} a x_i podél osy z_i (tj. normála mezi sousedními osami x)

Ze znalostí těchto čtyř parametrů lze vyjádřit libovolný dovolený pohyb v dané soustavě. V robotice se tato reprezentace využívá z důvodů snazšího návrhu a jednoduché interpretace soustavy. Obrázek níže udává grafické znázornění parametrů. [21]



Obrázek 8 – grafické znázornění DH parametrů, převzato a přeloženo z [28]

Pro vytvoření robotické souřadné soustavy a možnost vizualizace pohybů po předem definované trajektorii slouží základní sada příkazů, s níž Matlab robot toolbox pracuje. Výčet nejdůležitějších příkazů a parametrů je uveden v Tabulka 2 – základní příkazy Matlab robot toolbox. [21]

Tabulka 2 – základní příkazy Matlab robot toolbox

Příkaz	Význam
<code>R = robot (DH, typ)</code>	Vytvoření robotického objektu s názvem R. Vstupními parametry jsou: vektor udávající DH parametry a typ spojení (r – jako rotační kloub, d – válcový kloub).
<code>robot_complex (R1, R2, ...)</code>	Vytvoření komplexního robotického objektu, kdy vstupními parametry jsou samostatné objekty (například znázornění končetiny vytvořeno spojením jednotlivých robotických prstů).
<code>robot_plot (R, typ)</code>	Vizualizace vytvořeného systému. R představuje vykreslovaný objekt, typ může nabývat parametrů dle požadovaného typu vykreslování (surf – 3 D zobrazení; mesh – zobrazení pomocí mřížky; line – zobrazení pomocí přímek).
<code>robot_motion (R, [DH1, ...])</code>	Vizualizace pohybu objektu R dle nastavené trajektorie (pomocí úpravy DH parametrů).

3 NÁVRH ZPRACOVÁNÍ SIGNÁLU

V této kapitole bude teoreticky pojednáno, jakým způsobem lze provádět potřebné předzpracování signálu v digitální oblasti. Dále budou analyzovány jednotlivé typy klasifikačních algoritmů, které lze použít k účelu rozpoznávání naučených vzorů. Budou uvažovány výhody a nevýhody jednotlivých typů.

3.1 Předzpracování signálu

Signál získaný pomocí diferenčního zesilovače a potřebné výpočetní jednotky je navzorkován a převeden do digitální podoby. Takto surový, nezpracovaný signál se v odborné zahraniční literatuře označuje jako RAW signál. Obsahuje jednak informace vypovídající o aktivitě svalových jednotek, jednak nežádoucí šum. Proto je vhodné signál upravit do podoby, kdy získáme co možná největší poměr signálu ku šumu (tzv. SNR). Jednotlivé kroky, které jsou téměř vždy prováděny před dalšími procedurami zpracování signálu, budou popsány v podkapitolách.

Při návrhu těchto kroků musí být brán ohled na fakt, že je nutné provádět úpravy téměř v reálném čase. V literatuře je často brán v úvahu již nasnímaný celý úsek signálu, následné úpravy jsou tedy mnohem jednodušší již z principu teorie signálu (například filtrace zavádí menší zkreslení při využití delšího časového úseku). Proto je snahou této práce navrhnout takové řešení, které bude možné využít při akvizici signálu v reálném čase, respektive v předem definovaném časovém okně. Data jsou po sobě posílána do zásobníku, který postupně dle definovaného časového intervalu načítá signál. Délku okna (zásobníku) lze měnit dle požadavků uživatele. Je kladen důraz na výpovědní hodnotu, která by byla při zvolení malého časového okna nízká. Naproti tomu v případě zvolení dlouhého okna by byla odezva systému na svalovou aktivitu dlouhá a nemohla by reflektovat změny prováděných gest. Cílem je tedy nalézt optimální délku okna. Dle již provedených výzkumů byla ideální délka okna stanovena na 256 ms. Pro ovládání protetických končetin není vhodné, aby délka okna přesáhla 512 ms, a to z důvodu zachování přirozené odezvy pacienta na požadovaný pohyb končetiny. [1], [8], [32]

Dále je nutné pro potřeby klasifikačních algoritmů rozčlenit signál na aktivní část, kdy je daný sval aktivovaný, a pasivní část, kdy signál obsahuje pouze nulové hodnoty či hodnoty blízké nule díky šumu. Toho lze docílit například nastavením prahu vyhlazeného signálu. Z takto rozčleněného signálu lze získat požadované vektory příznaků, které uplatňujeme v rámci klasifikačních algoritmů.

3.1.1 Filtrace

Jako každý běžně nasnímaný biologický signál, i EMG signál obsahuje složku šumovou. Může se jednat o síťový brum, který je přítomný na frekvenci 50 Hz, nebo o drift signálu způsobený pohybem elektrod na kůži, nebo indukované elektromagnetické rušení. To vše lze částečně potlačit digitální filtrací. Vždy je třeba uvážit, do jaké míry je šumová složka obsažena v signálu, a podle toho volit jednotlivé filtry. Jelikož je pracováno se signálem v reálném čase, je vhodné omezit filtraci na minimum (pokud není v nadměrné míře přítomen šum, což lze hodnotit například SNR), neboť často používaná filtrace typu FIR zavádí časové zpoždění a v takto malém časovém okně (256 ms) může přinést neadekvátní zkreslení. Pokud je filtrace nezbytná, využijeme co možná nejkratší impulzní charakteristiku filtru a omezíme počet využitých filtrů, například jen pásmovou zádrž v případě síťového rušení. [1], [14], [25]

3.1.2 Rektifikace

Dalším krokem po provedené filtraci je jeho rektifikace. Jedná se o převedení negativní části EMG signálu na pozitivní hodnoty. Dosáhne se tím větší výpovědní hodnoty z hlediska počátku svalové aktivity. Lze využít buďto převedení čísel reprezentujících signál na absolutní hodnoty, nebo pouhé odstranění negativních složek a nahrazení nulovými hodnotami. [1], [14], [25]

3.1.3 Vyhlazení

Může se jednat o samostatný krok, nebo je součástí procedury filtrace. Většinou se využívá propuštění dolních frekvencí rektifikovaného signálu a získání obálky signálu. Výhodou je menší oscilace číselných hodnot za cenu vyššího zkreslení. Je vhodné především pro klasifikaci signálu na základě nastavení pevného prahu a tím rozlišení aktivity svalu. Tímto způsobem je možné rozdělit signál na oblasti neaktivní a svalově aktivní a tyto rozčleněné úseky dále zpracovávat. Je také možné využít jiných postupů, například průměrování hodnot v okně. [1], [25]

3.2 Extrakce příznaků

Z každého úseku EMG signálu lze získat určité specifické informace, ať už se jedná o informace v časové, frekvenční, či časově-frekvenční oblasti. Tyto konkrétní informace popisující daný úsek signálu se nazývají vektory příznaků. Na základě rešerše byly vybrány základní příznaky, jež dodávají největší výpovědní hodnotu o daném signálu. Vybráním vhodných vektorů příznaků lze dosáhnout lepší úspěšnosti následné

klasifikace. Výpočet je prováděn z již předzpracovaného signálu. Dle prací [23], [32], [4], [22] jsou nejvhodnější pro úkoly rozpoznání gest tyto příznaky:

- Root mean square (RMS) – jedná se o tradičně používaný příznak v časové oblasti EMG signálu. Vyjadřuje aktuální míru výkonu signálu v časové oblasti. Výpočet probíhá v předem definovaném okně podle vztahu:

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \quad (3)$$

kde N je velikost okna a x_n je aktuální prvek v okně

- Mean absolute value (MAV) – další z tradičních příznaků v časové oblasti. Je velmi podobný RMS, ovšem výpočetně jednodušší. Dle zmíněných prací je úspěšnost klasifikace obdobná s RMS. Výpočet je následovný:

$$MAV = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (4)$$

- Průměrná a mediánová frekvence (MNF a MDF) – jedná se o příznaky ve frekvenční oblasti, kdy po vypočítání výkonového spektra pomocí Fourierovy transformace a umocnění je určena průměrná, resp. mediánová frekvence z amplitudového spektra signálu.

$$MNF = \frac{\sum_{i=1}^N f_i P_i}{\sum_{i=1}^N P_i}$$

$$MDF = \frac{1}{2} \sum_{i=1}^N P_i \quad (5 \text{ a } 6)$$

kde N je polovina vzorkovací frekvence, P_i je hodnota výkonové spektra pro danou frekvenci f_i

- Koeficienty vlnkové transformace – vlnková transformace představuje ideální prostředek pro zpracování EMG signálu, neboť dokáže pracovat v časově-frekvenční oblasti i pro nestacionární signály, kde má klasická Fourierova transformace v okně (spektrogram) problémy. V tomto případě se využívá buďto tzv. DWT (discrete wavelet transform), nebo CWT (continuous wavelet transform).

CWT je v podstatě obdobou klasických spektrogramů, pouze s rozdílem využití rozkladu signálu na vlnky. Z důvodů výpočetní náročnosti (počet koeficientů je mnohem větší než délka zpracovávaného úseku signálu) se pro aplikace v reálném čase nevyužívá. Naproti tomu DWT umožňuje získat specifické koeficienty vlnkové transformace, jejichž počet je roven délce signálu, což je pro potřeby rychlého zpracování vhodnější. DWT v podstatě můžeme chápat jako filtraci typu horní propusti, kdy v každé úrovni dekompozice obdržíme detailní část frekvenčního pásma. Následnou úpravou dekomponovaného signálu na koeficienty lze jednak odstranit šumovou složku, jednak nalézt složité vazby v datech. Rozklad signálu na vlnky lze obecně vyjádřit takto:

$$S(\mathbf{b}, \mathbf{a}) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \psi' \left(\frac{t-b}{a} \right) s(t) dt \quad (7)$$

kde b je koeficient vyjadřující posun v čase, a je koeficient vyjadřující změnu měřítka vlnky, $s(t)$ je signál, který analyzujeme a ψ je funkce popisující mateřskou vlnku.

[23], [11], [26]

3.3 Klasifikační algoritmy

Pro účely klasifikace EMG signálu využíváme přístupu tzv. učení s učitelem. Tento postup nám umožní klasifikovat data do jednotlivých předem zvolených skupin. Pro účely zařazení nových dat do jednotlivých kategorií však musíme nejdříve daný klasifikátor natrénovat na připravených datech. Samotné trénování probíhá iteračně, kdy dochází k postupnému snižování chyby klasifikátoru. Vstupní trénovací data musí mít přiřazené numerické číslo, které představuje zařazení do konkrétní kategorie. [6]

Před možností využití programu pro rozpoznání gest je tedy nutné provést trénování na konkrétním jedinci. Trénování by mělo probíhat tak, aby bylo k dispozici dostatečné množství dat pro následnou klasifikaci. Jednotlivé kategorie budou představovat konkrétní gesta ruky. Trénovací program bude tedy spočívat ve vykonávání předem definovaných svalových kontrakcí a pohybů prstů a ukládání naměřeného signálu do připravené databáze pro konkrétní gesta. Takto připravená data je nutné předzpracovat, standardizovat a získat z nich vektory příznaků, jež budou zastupovat informace obsažené v signálu a povedou k redukci vstupních proměnných. Tyto příznaky jsou podány na vstup klasifikátoru a pomocí konkrétního algoritmu dojde k natrénování. Vždy je snahou dosáhnout co nejlepších výsledků, proto je nutné daný klasifikátor optimalizovat pomocí změny parametrů

klasifikátoru (buďto na základě empirických pozorování, nebo využití specifických algoritmů například gradientní metody). Po finálním natrénování a obdržení nejlepších výsledků (tzn. minimální chyby) můžeme daný systém implementovat na nová reálná data, což umožní rozpoznávat gesta při pohybu končetiny a téměř v reálném čase je přiřazovat do daných kategorií a pohyb vizualizovat. [6]

Pro klasifikaci EMG signálu se nejčastěji využívá dvou přístupů. První z nich je klasifikace pomocí neuronových sítí. Neuronová síť je vlastně soubor jednotlivých umělých neuronů, kde na vstup jsou přivedena data a výstup z daného neuronu přechází na další neurony. Dochází tedy k postupnému předávání informace. Výstup z poslední vrstvy je porovnán s reálnou hodnotou, která numericky představuje zařazení do konkrétní kategorie. Parametry neuronů jsou iterativně měněny tak, aby se výstup neuronu shodoval s přiřazenými kategoriemi. [16], [6], [31]

Druhým přístupem je využití tzv. support vector machines. Podrobnější popis tohoto klasifikátoru bude v samostatné podkapitole, neboť tímto způsobem bude provedena klasifikace v této práci. Oproti neuronovým sítím přináší řadu výhod. V první řadě umožňuje snazší a rychlejší trénování na vstupních datech a celkově vyžaduje menší výpočetní sílu. Další a zásadní výhodou je snadnější volba optimálních parametrů, neboť v případě neuronových sítí je nutné vyzkoušet data na desítkách typů sítí a nalézt tak optimální řešení. V případě SVM je nutné nastavit jen několik parametrů, což usnadňuje optimalizaci. Výstupem SVM je globální řešení problému. Nehrozí tedy nalezení lokálního řešení jako v případě využití neuronových sítí. Nevýhodou však může být složitější matematický princip klasifikace, a tudíž pochopení problematiky klasifikace (například převod vstupních příznaků do vyšších dimenzionálních prostorů).


[6], [31]

3.3.1 Support vector machines

Tento klasifikační přístup byl vyvinut na konci minulého století, ovšem v praxi se začíná používat poslední desetiletí. Algoritmus umí řešit složitý problém klasifikace, který obzvláště dnes v době výkonných počítačů nalézá obrovské uplatnění.

Matematicky můžeme v nejjednodušším případě formulovat úlohu tak, že máme 2 proměnné, kdy každý bod v souřadnicovém systému je zařazen do jedné z kategorií. Cílem je nalézt takovou přímku, aby byla vzdálenost od dvou lišících se skupin co největší. K tomu, aby bylo možné takovou přímku nalézt, je nutné využít složitých matematických operací, včetně Lagrangeova násobitele, a nalézt tak optimum funkce. Funkce k nalezení požadované přímky vychází z jednotlivých bodů na vstupu. Jsou hledány vektory, které leží kolmo k finální hledané přímce a přispívají tak

k maximálnímu řešení úlohy. Tyto vektory vychází z původních vstupních bodů a pomocí nich jsou po natrénování klasifikátoru zařazena nová data. Tyto vektory se odborně nazývají support vectors, z čehož vyplývá název celé metody. Výhodou je, že z dat podaných na vstupu pro natrénování dochází k optimalizaci ve smyslu výběru pouze malé části bodů, které představují tyto podpůrné vektory. Výpočetní náročnost pro zařazení nových dat je tedy nízká i pro obrovské množství trénovacích dat. Graficky je možné znázornit popsany problém takto:



Obrázek 9 - znázornění principu SVM, převzato a přeloženo z [6]

V reálné úloze je ovšem problém daleko složitější. Popsané řešení je možné takto znázornit v případě, že se jedná o množinu dat, kterou lze lineárně separovat. Ve většině případů to ovšem není možné, a tak připadají v úvahu alternativní možnosti řešení. Využívá se tzv. kernel triku (kernel = jádro), kdy jsou vstupní data převedena do vyšších dimenzionálních prostorů a je možné data lineárně separovat. Takto je možno vyřešit jakýkoliv reálný problém. Na uživateli zůstává rozhodnutí, jaký typ funkce jakožto jádra zvolí. [6], [1], [29], [13]


Za zmínku stojí také fakt, že v původním případě byl algoritmus využit pouze pro rozčlenění dat do 2 kategorií. V dnešní době však existují přístupy, které umožní algoritmus rozšířit pro možnosti zařazení do více kategorií (princiálně neomezený počet kategorií, prakticky omezeno výpočetním výkonem). V zásadě se rozlišují dva přístupy. První možností je tzv. one versus all, kdy datům z aktuálně vybrané skupiny je přiřazen jeden typ indexu (např. 1) a všem zbylým datům ze všech skupin pak druhý typ indexace (např. 0). Takto se určí dělicí nadroviny pro každou skupinu zvlášť. Druhou možností je tzv. one versus one. V tomto případě dochází k určení pomocných vektorů a nadrovin pro všechny kombinace skupin. Výhodou je vyšší přesnost klasifikace a nezávislost na symetrii dat, nevýhodou pak výpočetní náročnost (například v případě 5 skupin je nutné provést výpočet parametrů 10x). [6]

4 REALIZACE HARDWAROVÉ A SOFTWAREVÉ ČÁSTI

V této části je probrána konkrétní forma realizace zapojení celého akvizičního systému. V textu je definováno, pro jaká konkrétní gesta je algoritmus vytvořen, včetně popisu důležitých částí programového kódu. Byl definován konkrétní postup, který je optimalizovaný pro obdržení nejlepších možných výsledků na základě dosavadního testování. Podrobný návod k vytvořenému programu a schématické znázornění algoritmu je součástí přílohy.

4.1 Hardwarová část

V předchozích kapitolách byly podrobně popsány technické parametry systému BITalino. Z hlediska vlastní implementace bylo nutné původní kompletní zakoupenou základní desku se zesilovači pro různé typy biologických signálů upravit. Všechny tyto nepotřebné součásti byly odstraněny, zachován byl pouze hlavní modul mikrokontroleru, bluetooth modul a napájecí část. Dále došlo k úpravě samotné desky plošného spoje, kde byly napájeny piny pro snadné propojení s navazujícím systémem se zesilovači. Druhá základní prototypová deska je vytvořena přímo na míru celého systému. Bylo využito univerzálního plošného spoje pro snadnou úpravu a propojení. Jednotlivé zesilovače pro snímání třech kanálů jsou zapojeny dle Obrázek 7 tak, aby byly všechny konektory pro napájení a vstupy do systému BITalino vyvedeny na propojovací piny. Opačná část základní desky obsahuje konektory typu jack 3.5 mm pro snadnou manipulaci s elektrodami a celkové modulární možnosti. Samotné elektrody musely být upraveny pro takové zapojení.



Obrázek 10 – vytvořený modulární systém

Navržená základní deska je připravena pro dodatečné rozšíření pro snímání dat ze čtvrtého kanálu.

Po všech základních testováních, jež byly provedeny v rámci semestrální práce, bylo nutné vybrat konkrétní svalové pohyby, které budou vizualizovány. Na základě řady měření byly nejdříve otestovány gesta pro sevření prstů ruky, natažení jednotlivých článků prstů a stav svalové nečinnosti. Tuto kombinaci bylo možné snímat pomocí dvou kanálů, přičemž výsledky pro následnou klasifikaci dosahovaly téměř 99% úspěšnosti klasifikace. Základní binární klasifikace byla v rámci práce rozšířena o vizualizaci pohybu palce horní končetiny a gesta nasimulovaného pod názvem nůžky. V rámci finální verze je systém uzpůsoben pro stanovení těchto 4 základních gest + určení relaxovaného stavu. Pro možnosti takového ovládní je nutné zapojení tří kanálů snímače EMG. Každý kanál je zvolen na základě snímání konkrétní svalové skupiny. První pár nalepovacích elektrod je nutný upevnit na místa svalové skupiny flexor digitorum superficialis. Následující sada elektrod je připevněna na sval extensor digitorum a poslední pár na oblast abduktoru polci. Nelze opomenout poslední samostatnou elektrodu, která slouží pro uzemnění testovaného subjektu. Samotný výběr vhodných pozic elektrod byl zvolen na základě empirického testování pro jednotlivá nastavení a anatomických znalostí svalových skupin. Další inspirace a potvrzení správného rozložení elektrod byla čerpána především z práce [30].



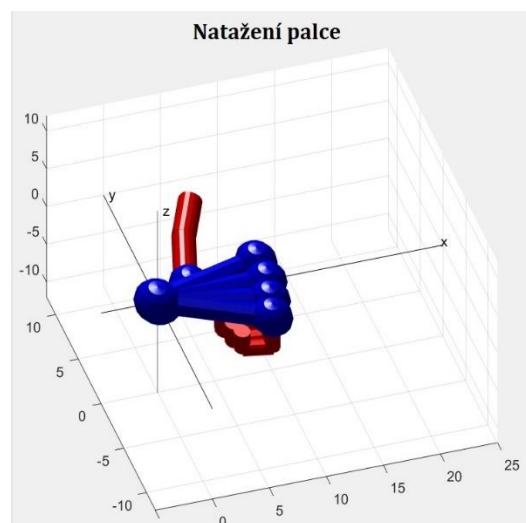
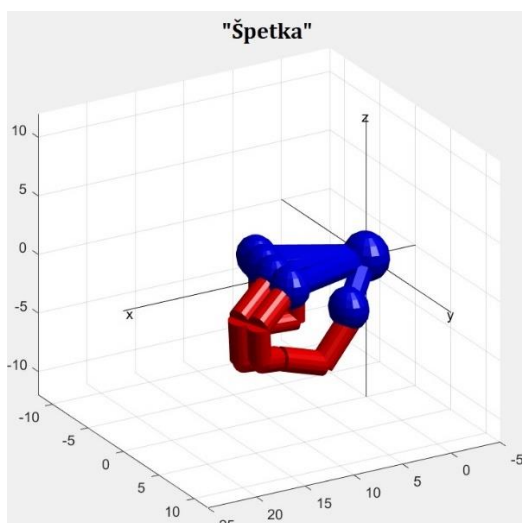
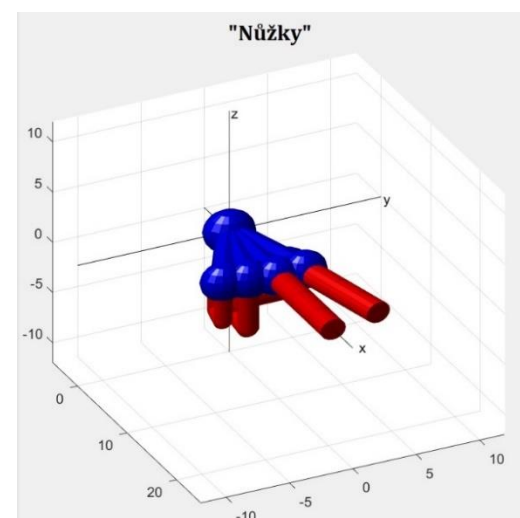
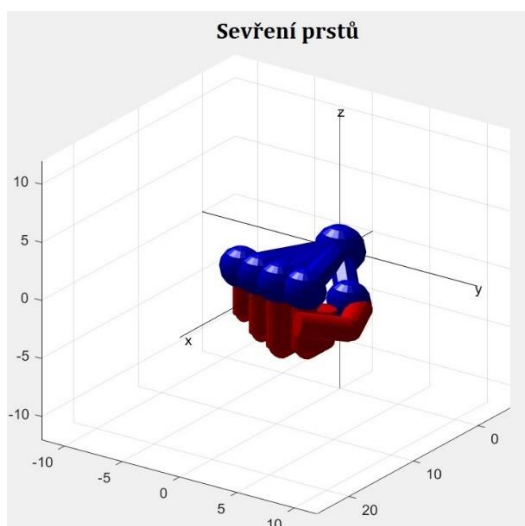
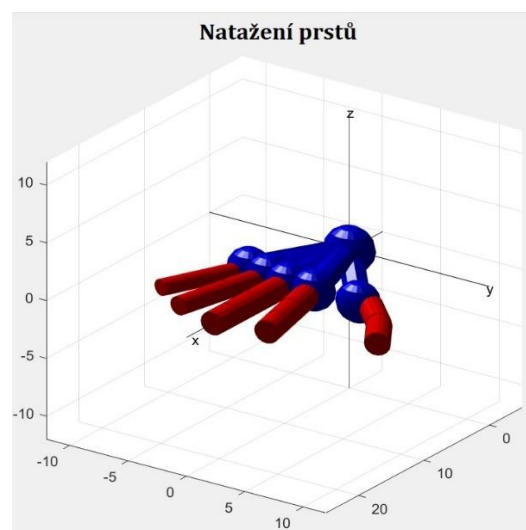
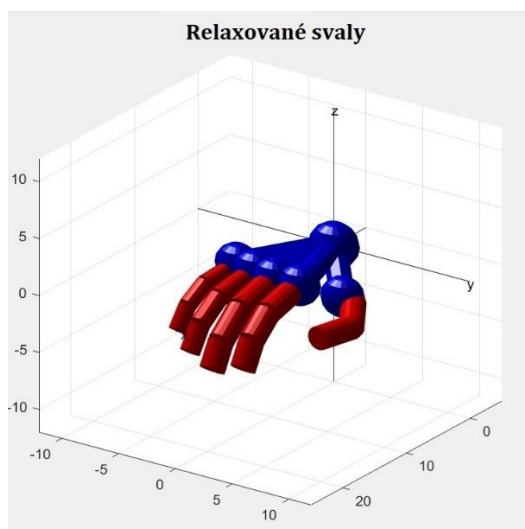
Obrázek 11 – ukázka připojení elektrod a uchycovacího mechanismu pro volný pohyb

4.2 Softwarová část

Celý programový celek lze rozdělit na několik částí, které budou probrány v samostatných kapitolách. Při realizaci celé práce byly jednotlivé úseky vyřešeny samostatně a následně spojeny do jednoho celku. Toto řešení umožňuje jednoduché ladění celého kódu. Výsledný program je vytvořený pro ovládání v grafickém uživatelském rozhraní, přičemž podrobný návod k samotnému programu lze nalézt v příloze. Spustitelný soubor nese název Hand_Prototyper.m, který zahrnuje většinu algoritmických úkolů, včetně kódů pro funkčnost GUI, propojení s MCU a klasifikace. Jediná samostatná funkce s názvem Learning_universal_02 slouží pouze pro provedení učicí fáze klasifikačního algoritmu, což zjednodušuje práci pro získání trénovacích dat pro konkrétní gesta. Výstupem celého programu jsou jednak uložené soubory s trénovacími daty pro daná gesta, jednak soubor s výsledky vyhodnocení úspěšnosti vykonání náhodných gest.

4.2.1 Vizualizace horní končetiny

Celá vizualizační část vychází z robotického modelu, který je přiložen v práci [21] v rámci ukázkového příkladu. Model byl upraven do podoby, která lépe popisuje jak skutečnou lidskou končetinu, tak protetickou náhradu. Úpravy zahrnovaly odstranění jednoho článku palce, který vytvářel model nerealistickým, drobné úpravy počátečních rozložení kloubů a nastavení maximálních hodnot úhlů sevření článků prstů. Dále byly na základě vizuálního testování vytvořeny trajektorie pohybů soustav pro jednotlivá gesta. Celkem bylo namapováno šest základních gest, jsou ovládány pomocí sady tlačítek pro jednoduché testování. Konkrétně se jedná o gesta relaxovaného svalů, sevření a rozevření článků prstů, gesto „nůžek“, ovládání palce a poslední gesto „špetka“. Vizuální zpracování modelu se nachází na následujících obrázcích.



Obrázek 12 – vizualizace gest v robotické soustavě

4.2.2 Akvizice signálu v reálném čase

Pomocí rozhraní bluetooth je zaručeno propojení počítače s mikrokontrolérem. Následující sada příkazů slouží k ovládání mikrokontroléru přímo v rozhraní programu Matlab. [3]

Tabulka 3 – přehled základních příkazů pro práci s knihovnou BITalino toolbox

Příkaz	Význam
b=Bitalino;	Vytvoření figury
b.startBackground;	Zapnutí snímání dat z MCU na pozadí programu
b.stopBackground;	Vypnutí přenosu dat
b.read;	Přenesení dat ze zásobníku MCU do PC a následné vyprázdnění

V cyklu, který časově odpovídá délce nastaveného okna (pro zachování dostatečné odezvy je doporučeno okno 256 ms), dochází k načtení a vyprázdnění dat ze zásobníku MCU. Takto krátký záznam je nejdříve převeden z bezrozměrných jednotek na hodnoty v mV podle vzorce:

$$EMG [V] = \frac{\left(\frac{ADC}{2^n} - \frac{1}{2}\right) * VCC}{G_{EMG}} \quad (8)$$

Přičemž ADC jsou nativní hodnoty z MCU, n je počet bitů převodníku, VCC je operační napětí a G_{EMG} je zesílení zesilovače. [7]

Pro možnosti vykreslování signálu dochází k postupnému spojování takto krátkých úseků signálu, přičemž nový záznam se projeví se zpožděním délky trvání okna. Z důvodů krátkého úseku signálu není možné vylepšit kondici signálu pomocí filtrace, neboť dochází k příliš velkému zkreslení v každém taktu cyklu. Navíc je potřebné zaručit co nejrychlejší zpracování přijatého signálu. Dále byly otestovány možnosti použití vlnkové transformace a frekvenčních charakteristik. Dle pozorování nedocházelo k lepší klasifikace, pouze byl prodloužen výpočetní čas. V případě vlnkové transformace můžeme hovořit o odstranění nepotřebných složek signálu a k částečné komprimaci. Pro možnosti klasifikace jsou však tyto přístupy nepříliš vhodné a vhodným příznakem byl zvolen parametr RMS, který nejvíce vypovídá o aktuální svalové aktivitě svalu a zároveň představuje jednoduchý výpočetní prostředek.

4.2.3 Realizace klasifikačního algoritmu

Učící fáze se skládá z několika kroků. Nejdříve je nutné získat časový úsek signálu EMG (většinou v řádech desítek sekund). Princip je naprosto stejný, jako v případě snímání signálu v reálném čase. Z hlediska učení je výhodnější, aby uživatel mohl vykonat gesta dle vlastní vůle a nebyl limitován vykonání konkrétního gestu na přesně definovaný časový úsek, neboť v případě odchylky a nerespektování této podmínky dojde ke špatnému natrénování klasifikátoru. Proto je výhodnější ponechat toto rozhodnutí na uživateli, pouze s podmínkou dodržení časových intervalů tak, aby polovina nasnímaného signálu obsahovala nulovou linii signálu. Z tohoto přístupu je patrné, že je nutné data rozdělit na aktivní část a pasivní část nečinnosti svalu. Rozdělení probíhá tak, že je signál procházen v definovaném časovém okně a následně průměrován. Pokud daný úsek vykazuje hodnot nad průměrem, je následně zařazen do aktivní skupiny. Výsledkem jsou skupiny signálů, které odpovídají jednak relaxovanému, tak aktivnímu svalu.

Je tedy nutné tento postup opakovat pro každé vykonané gesto a získat tak signály ze všech kanálů. V případě implementace tří kanálů a klasifikaci čtyř gest tak získáme 15 příznaků RMS (pro každé gesto 3 + šumová složka pro každý kanál). Tyto parametry je nutné rozdělit do matice, kde v každém sloupci je zahrnut jeden akviziční kanál a pod ním seřazeny postupně vypočítané hodnoty RMS. V tomto konkrétním případě vznikne matice o třech sloupcích a počet řádků odpovídá všem hodnotám RMS pro všechny gesta. Čtvrtý sloupec je vyhrazen pro přiřazení indexu na základě znalosti, pro jaké gesto byl příznak vypočítán. Číselné indexy jsou v daném programu nastaveny takto:

Tabulka 4 – tabulka indexů odpovídající konkrétním gestům

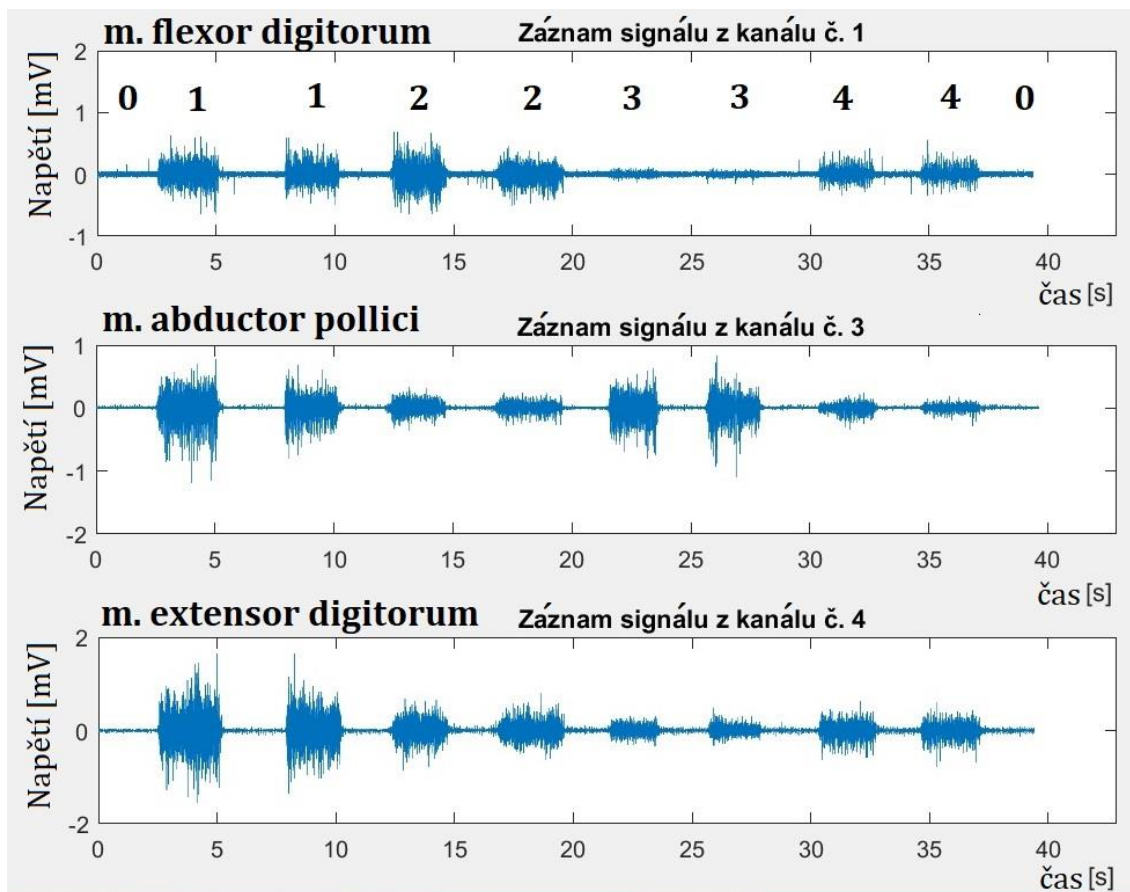
Číslo indexu	Odpovídající gesto
0	Relaxovaný sval (=šum)
1	Natažení prstů
2	Sevření prstů
3	Natažení palce
4	Gesto „nůžky“

Posledním krokem je vstup dat do vybraného klasifikátoru, v tomto případě do SVM. V rámci programu Matlab jsou dostupné již nativně implementované toolboxy pro výpočet a určení parametrů klasifikátoru. V následující tabulce je výčet všech základních příkazů a nastavení, které byly použity pro zavedení klasifikátoru.

Tabulka 5 – základní příkazy pro práci s klasifikátorem SVM

Příkaz	Význam
<code>t = templateSVM ('Standardize', 1, 'KernelFunction', 'gaussian');</code>	Vytvoření základního bloku SVM včetně standardizace vstupních hodnot a nastavení klasifikátoru na gausovskou funkci.
<code>SVM = fitcecoc (data, index,'Learners', t,'FitPosterior',1,'ClassNames', [0,1,2,3,4]);</code>	Vytvoření finálního modelu SVM ze vstupní matice dat a samostatného vektoru indexů. Je vyžadován základní blok t. Parametr „FitPosterior“ umožní výpočet pravděpodobnosti zařazení do dané kategorie. Parametr „ClassNames“ upřesňuje názvy kategorií.
<code>label=predict (SVM, data);</code>	Samotný výpočet SVM po natrénování. Vstupem je natrénovaný model a vektor vstupních dat (pro 3 kanály 3 vstupy). Výstupem je konkrétní index zařazení.

Je dále možno využít celou řadu dalších podrobných nastavení klasifikátoru. V případě této práce je navíc program uzpůsoben tak, že je možné využít automatickou optimalizaci některých parametrů klasifikátoru pro přesnější klasifikaci. Konkrétně se jedná o Bayesovskou optimalizaci, která na základě pravděpodobnosti určí následující optimalizační krok. Toto nastavení je volitelné a vyžaduje potřebný výpočetní výkon a dostatečné časové možnosti. Konkrétní optimalizované parametry SVM pro Gausovskou funkci jsou: **KernelScale** – měřítko „kernelové“ funkce, v zásadě se jedná o rozpětí gausovské křivky, a tudíž úpravy transformační funkce. **BoxConstraint** – udává toleranci jednotlivých bodů vstupujících do klasifikátorů z hlediska vytvoření klasifikační hyperroviny (tzv. měkká hranice). [9]



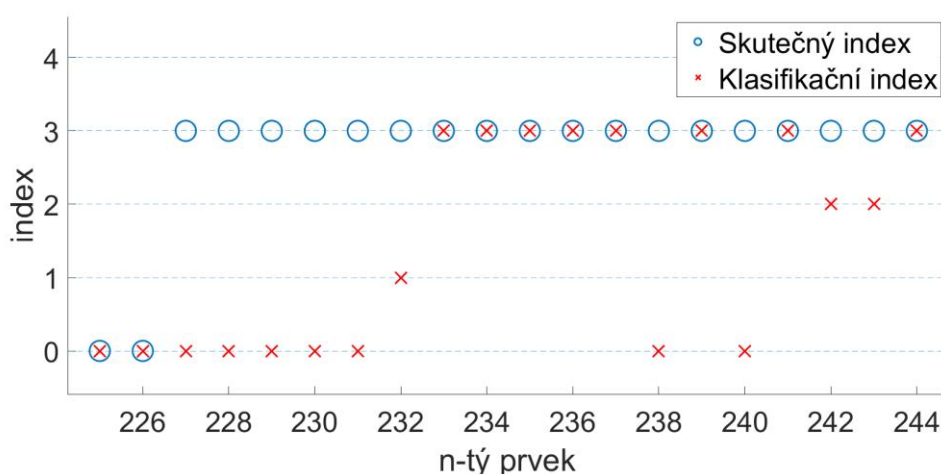
Obrázek 13 – ukázka napěťové úrovně signálu pro jednotlivá gesta

5 TESTOVÁNÍ A VÝSLEDKY

5.1 Popis testování

Pro účely testování byl vytvořen konkrétní mechanismus pro získání relevantních dat. Z hlediska klasifikace je možné pozorovat výsledky konkrétního subjektu v reálném čase, a tak ihned zjistit informace o úspěšnosti klasifikace. Většina testování probíhala na autorovi této práce a na základě okamžité zpětné vazby bylo možné celý program a klasifikaci optimalizovat.

Pro účely základního porovnání výsledků a interpretace finálního nastavení bylo ovšem nutné vytvořit univerzální protokol pro dosažení objektivních výsledků. Do samotného programu byla přidána možnost spustit opakující smyčku. Ta náhodně vybírá index, který se následně zobrazuje na obrazovce ve formě textu. Uživateli dává zpětnou vazbu, jaké gesto má vykonat. Zaručena je objektivita, neboť testovací subjekt musí reagovat co nejrychleji, spontánně a nemůže se na vykonávané gesto připravit. Index náhodně generovaného čísla a také index klasifikace je postupně ukládán do vektoru pro následnou analýzu. Nevýhodou tohoto systému je fakt, že dochází ke zpoždění mezi aktuálně zobrazeným indexem a vykonaným pohybem. Zároveň jsou výsledky částečně závislé na psychickém stavu subjektu. Proces vyhodnocování je časově náročný a vyžaduje ruční prohledávání výsledků pomocí grafického porovnání průběhu jednotlivých indexů. Grafické porovnávání lze snadněji interpretovat ve srovnání procházením číselných hodnot obou vektorů indexů a hledání shody/neshody. K zobrazení bodů indexů je využita funkce scatter.



Obrázek 14 – příklad grafické reprezentace pro vyhodnocování (scatter plot)

Celkem byly vybrány 4 testovací subjekty. U každého bylo provedeno měření na pravé končetině v poloze opření paže o pevnou podložku, čímž se dosáhlo maximálního

zajištění stejných podmínek měření. Bylo vyžadováno, aby byla gesta prováděna vždy stejně, dle stavu natrénování. Bylo využito 15 cyklů optimalizační funkce klasifikačního algoritmu. Testována byla schopnost klasifikace pro již zmíněná čtyři gesta a relaxovaný sval. Pro každé měření bylo graficky porovnáváno jednotlivé správné a špatné zařazení indexů a na základě těchto statistických dat byly vytvořeny tabulky úspěšnosti klasifikace. Data jsou zobrazena v trojrozměrném prostoru, čímž lze na základě pozorování stanovit možnosti separability příznaků. Ke každému klasifikátoru byly vytvořeny mapy klasifikací, na jejichž základě klasifikátor třídí data do jednotlivých kategorií. Výsledky odráží stav systému, kdy došlo k nejlepšímu natrénování jedince, neboť z důvodů postupné optimalizace a komunikace s dobrovolníkem docházelo ke zlepšení klasifikace a data z počátku testování by zcela neodrážela klasifikační schopnosti.

V neposlední řadě je systém testován také z hlediska výpočetní náročnosti a zatížení procesoru. Byl sledován dopad na celý počítačový systém a průběžná hodnota času jednoho cyklu programu, což vypovídá o celkovém zpoždění jednoho taktu v rámci programu Matlab. K celkové odezvě akvizičního systému je nutné připočítat dobu zpracování dat mikrokontrolerem a přenos přes rozhraní bluetooth.

5.2 Výsledky

5.2.1 Klasifikační schopnosti

Podrobný přehled výsledků pro každý testovací subjekt je uveden v příloze této práce. Základní přehled je uveden v tabulce níže.

Tabulka 6 – přehled úspěšnosti klasifikace

Číslo měření	Počet klasifikací ¹	Výsledky klasifikace (ACC ²) [%]
1	1952	93,5
2	1173	96,4
3	-	-
4	1155	85,1
5	593	83,8

Z výsledků je patrné, že na základě získaných dat z měření konkrétních svalových skupin je možné věrohodně rozeznat a klasifikovat čtyři základní gesta. Měření č. 1 a 2 proběhlo na autorovi této práce, v různém časovém rozpětí a lokalizací elektrod. Z dosavadních poznatků je patrné, že existuje určitá korelace mezi celkovou dobou

¹ Jedna klasifikace odpovídá časovému oknu 256 ms

² ACC – správnost klasifikátoru (resp. přesnost – accuracy) určuje podíl správně zařazených subjektů vůči celkovému počtu subjektů

zacházení s daným systémem a úspěšností klasifikace. V případě pravidelného testování na daném subjektu dochází pravděpodobně ke zvýšení měřitelného signálu z dané svalové skupiny, a tudíž lze lépe rozeznat a klasifikovat konkrétní gesta. Měření číslo tři nemohlo být provedeno z důvodů problému v akvizičním systému. Měřený signál vykazoval příliš velký šum, což bylo pravděpodobně způsobeno příliš velkým odporem kůže a špatnou lokalizací elektrod. Na základě vysokého rušení nebylo možné provést řádné natrénování klasifikátoru. Pro správnou funkci daného systému je tedy nutné dodržet podmínku velmi nízkého zašumění a správné lokalizace elektrod. Tento požadavek byl ověřen na dalším testovacím subjektu č. 4, u kterého se po správném procesu učení a časově náročným vybráním vhodných míst pro přesnou lokalizaci svalové skupiny podařilo dosáhnout úspěšnosti klasifikace 85,1 %. Bylo následně otestováno, že v případě využití stejných trénovacích parametrů pro klasifikaci pouze tří gest byla získána úspěšnost klasifikace 95 %. Poslední subjekt byl opět natrénovaný pro klasifikaci všech čtyř gest. Celková klasifikační schopnost na tomto subjektu byla 83,8 %. Pokud jsou brány v úvahu detailní výsledky, lze konstatovat, že nebylo téměř možné správně vykonávat gesto č. 2 (gesto sevřené pěsti). Hodnoty RMS této svalové skupiny byly příliš malé na to, aby došlo k správnému rozlišení. Klasifikační schopnost tohoto gesta byla zachována pouze po usilovném svalovém vypětí.

Z globálního hlediska lze pozorovat tendenci, že již z logiky věci nejlepší klasifikační výsledky lze nalézt v případě záznamu relaxovaného svalu, neboť odchylky od natrénovaných dat jsou minimální. Srovnání úspěšnosti dalších pohybů a korelace mezi jednotlivými testovanými subjekty není zcela jasná a jednoduše interpretovatelná. Mezi jedinci dochází vždy ke změně nejlépe klasifikovatelného gesta. S největší úspěšností se však daří klasifikovat gesta natažení prstů a „nůžek“, což je pravděpodobně způsobeno snížením větší svalové aktivity ve všech kanálech. Konkrétní zprůměrované hodnoty ze všech klasifikačních ukazatelů dosahují v případě gesta „nůžky“ hodnot úspěšnosti klasifikace 93,1 %, gesto natažení prstů pak 90,6 %. Gesto sevření prstů a natažení palce vykazuje mnohem větší variabilitu napříč subjekty. Průměrné hodnoty v případě gesta sevření prstů činí 85,8 % a gesta natažení palce pak 91,6 %, ovšem při detailním rozboru lze nalézt velké rozdíly mezi klasifikačními ukazateli, v případě gesta sevření prstů lze například pro páté měření nalézt velmi malou hodnotu pozitivní prediktivity, konkrétně se jedná o hodnotu 18 %. Naopak nízkou hodnotu specificity lze nalézt v případě gesta natažení palce u čtvrtého a pátého měření, kdy hodnoty dosáhly 66,4 % a 75,1 %. Tyto výkyvy napříč subjekty vznikají v důsledku nízké svalové aktivity, která je typická pro dané gesto. V případě sevření prstů by mělo docházet ke snížení největší aktivity v kanále pro snížení ze svalové skupiny flexor digitorum, což v případě

pátého měření neodpovídalo realitě. Větší variabilita byla tedy pozorována u netrénovaných jedinců.

Získaná data z měření dále potvrdila fakt, že s postupným časem měření dochází k svalové únavě testovaného dobrovolníka a zhoršené míře klasifikace. Tuto chybu lze eliminovat opětovným natrénováním klasifikátoru na hodnoty svalových aktivit odpovídajících postupné únavě.

Pro komplexní analýzu by bylo nutné pravidelné trénování dobrovolníků a získání dat z dlouhodobého časového horizontu. To by skutečně ověřilo, zda pravidelné trénování jedince dokáže zlepšit klasifikační schopnosti systému, a umožní tak návyk dobrovolníka na budoucí implementaci protetické končetiny. Tato analýza přesahuje rozsah této práce a je možným budoucím námětem pro další vědecké bádání.

5.2.2 Výpočetní náročnost

Zpracování dat vyžaduje externí zařízení, tj. osobní počítač s nainstalovaným programem Matlab. Z hlediska výpočetního výkonu je nutný běžný stolní počítač s alespoň základním grafickým akcelerátorem, který je již dnes běžnou součástí procesoru počítače.

Z hlediska výpočetních operací samotného programu můžeme uvažovat několik parametrů. Přehled nejdůležitějších je uveden v Tabulka 7 – průměrné časy zpoždění programu.

Tabulka 7 – průměrné časy zpoždění programu

Parametr	Výsledek
Průměrná doba jedné smyčky akvizice ¹	0,105 s
Průměrné zpoždění cyklu při vykonání gesta (odezva modelu) ²	0,412 s
Průměrné zpoždění celého akvizičního systému ³	0,550 s

¹ Průměrná doba zpoždění jednoho cyklu programu z hlediska zpracování signálu a klasifikace

² Jedná se o zpoždění systému, které je způsobeno pouze grafickou částí softwarové části

³ Kompletní zpoždění zahrnující jak přenos dat přes rozhraní bluetooth, tak softwarovou část

ZÁVĚR

Tato práce byla vypracována na základě bodů vstupního zadání bakalářské práce. Jednotlivé body zahrnovaly zpracování literární rešerše, získání znalostí v oblasti zpracování a vyhodnocení EMG signálu, návrh a vytvoření konkrétní formy zpracování problému, včetně závěrečného komplexní zhodnocení.

Z hlediska hodnocení celkové úspěšnosti a funkčnosti systému, je nutné vzít v úvahu několik aspektů. Co se týče materiální stránky, navržené řešení přináší levný a variabilní přístup snímání elektromyografického signálu s dobou odezvy 0,55 s, což je zcela dostačující pro zachování přirozené zpětné odezvy uživateli a teoretické možnosti uplatnění do podoby biofeedbacku či ovládání protetické končetiny (případně elektronických systémů).

Samotné testování proběhlo celkem na čtyřech subjektech, různých věkových kategoriích po dobu několika minut (minimálně požadováno 1000 klasifikačních cyklů, resp. u jednoho subjektu méně z důvodu svalové únavy). Bylo využito celkem tříkanálového uspořádání pro rozpoznání pěti základních gest. První dvě měření byly provedeny na pravidelně testovaném subjektu, u něhož je po dvoutýdenním testování dosaženo úspěšnosti klasifikace 93,5 % správného zařazení, resp. 96,4 % v druhém případě měření. Třetí měření vykazovalo příliš velké abnormality v měřeném signálu, což neumožnilo měření dokončit. Předposlední testování vykazovalo klasifikační schopnosti 85,2 %. Poslední měření s průměrnou úspěšností klasifikace 83,8 % vykazovalo falešně pozitivní výsledky v případě klasifikace druhého gesta (sevření prstů), prediktivní hodnota této klasifikační třídy byla pouze 18 %. Důkladnější testování by dokázalo, zda je možné pravidelným trénováním jedince dosáhnout uspokojivějších výsledků či nikoliv.

Cíl této práce vytvořit akviziční systém včetně možnosti vizualizace a klasifikace pro další možnosti implementace byl splněn. Prototypová verze vytvořené akviziční desky a správné rozmístění elektrod se zdá být hlavním kritickým článkem celého systému, což vyplývá ze získaných dosavadních výsledků. Vytvořený programový kód implementovaný v programovém prostředí Matlab nabízí intuitivní uživatelské prostředí a jednoduchou správu.

LITERATURA

- [1] BISHOP, C. M. *Pattern recognition and machine learning*. New York: Springer, c2006. Information science and statistics. ISBN 978-0387-31073-2.
- [2] BITalino – *Biomedical Equipment* [online]. [cit. 2017-11-04]. Dostupné z: <http://bitalino.com/en/>
- [3] BITalino Toolbox. *MathWorks* [online]. USA: MathWorks, c1994-2018 [cit. 2018-04-05]. Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/53983-bitalino-toolbox>
- [4] BOOSTANI, R. a M. H. MORADI. *Evaluation of the forearm EMG signal features for the control of a prosthetic hand. Physiological Measurement* [online]. 2003, 24(2), 309-319. DOI: 10.1088/0967-3334/24/2/307. ISSN 0967-3334.
- [5] DAY, S. *Important Factors in Surface EMG Measurement* [online]. Calgary (Kanada): Bortec Biomedical [cit. 2017-10-14]. Dostupné z: <http://www.bortec.ca/Images/pdf/EMG%20measurement%20and%20recording.pdf>.
- [6] DUDA, R. O., P. E. HART a D. G. STORK. *Pattern classification*. 2nd ed. New York: Wiley, c2001. ISBN 978-0471056690.
- [7] *Electromyography (EMG) Sensor Data Sheet*. Lisabon, 2016. Dostupné také z: http://bitalino.com/datasheets/EMG_Sensor_Datasheet.pdf
- [8] ENGLEHART, K., B. HUDGIN a P.A. PARKER. *A wavelet-based continuous classification scheme for multifunction myoelectric control. IEEE Transactions on Biomedical Engineering* [online]. 2001, 48(3), 302-311. DOI: 10.1109/10.914793. ISSN 00189294.
- [9] Fit multiclass models for support vector machines or other classifiers - Matlab fitcecoc. *MathWorks* [online]. USA: MathWorks, c1994-2018 [cit. 2018-04-05]. Dostupné z: <https://www.mathworks.com/help/stats/fitcecoc.html>
- [10] GANESH, R. N. *Computational Intelligence in Electromyography Analysis – A Perspective on Current Application and Future Challenges*. RIJEKA (CHORVATSKO): INTECH, 2012. ISBN 978-953-51-0805-4.
- [11] GRAPS, A. *An introduction to wavelets. IEEE Computational Science and Engineering* [online]. 1995, 2(2), 50-61. DOI: 10.1109/99.388960. ISSN 10709924.
- [12] HOLIBKOVÁ, A. a S. LAICHMAN. *Přehled anatomie člověka*. 4. vydání. Olomouc: Univerzita Palackého v Olomouci, 2006. ISBN 80-244-1480-5.
- [13] HSU, C., C. CHANG a C. LIN. *A Practical Guide to Support Vector Classification* [online]. National Taiwan University: Department of Computer Science, 2003, 2003, 1-16. Dostupné z: <https://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>

- [14] KONRAD, P. *The ABC of EMG: A Practical Introduction to Kinesiological Electromyography*. Version 1.4. U.S.A: Noraxon, 2005. ISBN 0-9771622-1-4.
- [15] KRAJČA, V. a J. MOHYLOVÁ. *Zpracování biologických signálů*. Ostrava: Ediční středisko VŠB – TUO, 2006. ISBN 978-80-248-1491-9.
- [16] LEON, M., J. M. GUTIERREZ, L. LEIJA a R. MUNOZ. *EMG pattern recognition using Support Vector Machines classifier for myoelectric control purposes*. Pan American Health Care Exchanges [online]. IEEE, 2011, 175-178. DOI: 10.1109/PAHCE.2011.5871873. ISBN 978-1-61284-915-7.
- [17] *Mathworks* [online]. The MathWorks, ©1994-2017 [cit. 2017-11-28]. Dostupné z: https://www.mathworks.com/?s_tid=gn_logo
- [18] *Microcontroller Unit (MCU) Block Data Sheet*. Lisabon, 2016. Dostupné také z: http://bitalino.com/datasheets/MCU_Block_Datasheet.pdf
- [19] NETTER, F. H. *Netterův anatomický atlas člověka*. Překlad 6. vydání. Brno: CPress, 2016. ISBN 978-80-264-1176-5.
- [20] Open Bionics [online]. Open Bionics, ©2017 [cit. 2017-12-09]. Dostupné z: <https://www.openbionics.com/>
- [21] PAJAŁ, I. *The Matlab Toolbox for Modeling Complex Mechanisms*. *International Journal of Applied Mechanics and Engineering* [online]. 2014, 19(2), 285-301. DOI: /10.2478/ijame-2014-0019. ISSN 1734-4492.
- [22] PHINYOMARK, A., A. NUIDOD, P. PHUKPATTARANONT a C. LIMSAKUL. *Feature Extraction and Reduction of Wavelet Transform Coefficients for EMG Pattern Classification*. *Electronics and Electrical Engineering* [online]. 2012, 122(6). DOI: 10.5755/j01.eee.122.6.1816. ISSN 2029-5731.
- [23] PHINYOMARK, A., C. LIMSAKUL a P. PHUKPATTARANONT. *Application of Wavelet Analysis in EMG Feature Extraction for Pattern Classification*. *Measurement Science Review* [online]. 2011, 11(2). DOI: 10.2478/v10048-011-0009-y. ISSN 1335-8871.
- [24] RAEZ, M. B. I, M. S. HUSSAIN a F. MOHD-YASIN. *Techniques of EMG signal analysis: detection, processing, classification and applications*. *Biological Procedures Online* [online]. 2006, 2006(8), 11-35. DOI: 10.1251/bpo115
- [25] RICARDO, L., J. LUIZ, M. BIGLIASSI, T. F. D. KANTHACK, A. C. DE MORAES a T. ABRAO. *Influence of Different Strategies of Treatment Muscle Contraction and Relaxation Phases on EMG Signal Processing and Analysis During Cyclic Exercise*. *Computational Intelligence in Electromyography Analysis – A Perspective on Current Applications and Future Challenges* [online]. InTech, 2012, 2012-10-1. DOI: 10.5772/50599. ISBN 978-953-51-0805-4.

- [26] RIOUL, O. a M. VETTERLI. *Wavelets and signal processing*. *IEEE Signal Processing Magazine* [online]. 1991, 8(4), 14-38. DOI: 10.1109/79.91217. ISSN 1053-5888.
- [27] SHARMILA, K., T. V. SARATH a K. I. RAMACHANDRAN. *EMG controlled low cost prosthetic arm*. *2016 IEEE International Conference on Distributed Computing, VLSI, Electrical Circuits and Robotics (DISCOVER)* [online]. 2016, 169-173. DOI: 10.1109/DISCOVER.2016.7806239.
- [28] SINGH, A., A. SINGLA a S. SONI. *D-H parameters augmented with dummy frames for serial manipulators containing spatial links*. *The 23rd IEEE International Symposium on Robot and Human Interactive Communication* [online]. IEEE, 2014, 975-980. DOI: 10.1109/ROMAN.2014.6926379. ISBN 978-1-4799-6765-0.
- [29] THEODORIDIS, S. *Introduction to pattern recognition: a MATLAB approach*. Burlington, MA: Academic Press, c2010. ISBN 978-0-12-374486-9
- [30] TSUJIMURA, T., S. YAMAMOTO a K. IZUMI. *Hand Sign Classification Employing Myoelectric Signals of Forearm*. *Computational Intelligence in Electromyography Analysis - A Perspective on Current Applications and Future Challenges* [online]. InTech, 2012. DOI: 10.5772/51080. ISBN 978-953-51-0805-4.
- [31] TUČKOVÁ, J. *Vybrané aplikace umělých neuronových sítí při zpracování signálu*. Praha: České vysoké učení technické v Praze, 2009. ISBN 978-80-01-04229-8.
- [32] VEER, K. a T. SHARMA. *A novel feature extraction for robust EMG pattern recognition*. *Journal of Computing* [online]. 2016, 40(4), 149-154. DOI: 10.3109/03091902.2016.1153739. ISSN 0309-1902.

SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK

EMG	-	elektromyografie
EKG	-	elektrokardiografie
MU	-	motor unit (motorická jednotka)
MUAP	-	motor unit action potential (akční napětí motorické jednotky)
sEMG	-	surface EMG (povrchové EMG)
CMRR	-	common mode rejection ratio (diskriminační činitel)
A/D	-	analogově digitální
MCU	-	microcontroller unit (mikrokontroler)
PC	-	personal computer (osobní počítač)
PWM	-	pulse width modulation (pulzně šířková modulace)
VCC	-	napětí na kolektoru
GND	-	zemní vodič
DH	-	Denavit-Hartenbergovy parametry
SNR	-	signal noise ratio (poměr signál šum)
RMS	-	root mean square (odmocnina průměru čtverců)
MAV	-	mean absolute value (průměr absolutních hodnot)
MNF	-	mean frequency (průměrná frekvence)
MDF	-	median frequency (mediánová frekvence)
DWT	-	discrete wavelet transform (diskrétní vlnková transformace)
CWT	-	continuous wavelet transform (spojitá vlnková transformace)
Hz	-	hertz
dB	-	decibel
SVM	-	support vector machines
ACC	-	správnost (accuracy) klasifikátoru
SE	-	senzitivita klasifikátoru
SP	-	specificita klasifikátoru
PPV	-	positive predictive value (hodnota pozitivní prediktivity)

SEZNAM PŘÍLOH

A - Manuál k programu Hand_Prototyper

B - Podrobné výsledky klasifikace

C - Vývojový diagram hlavní části kódu

D - Obsah přiloženého DVD

A Manuál k programu Hand_Prototyper

Tento text slouží především ke snadnějšímu pochopení jednotlivých částí programu a potřebných kroků k maximálnímu využití.


Prvním předpokladem pro správnou funkci programu je instalace dodatečných toolboxů: The Robot Toolbox for Matlab V 2.0 a BITalino toolbox. Celý program se spouští skrz matlabový skript Hand_Prototyper.m. Pro správnou funkci je nutné mít ve složce přiloženy dodatečné soubory, které jsou dodávány k programu.

Popis jednotlivých částí

V levém horním rohu je možné využívat prvky matlabovské vizualizace, což znamená rotaci, kurzor a přiblížení/oddálení vykreslovaného objektu. Tyto funkce jsou vhodné jednak pro detailnější zobrazení signálu, dále pak pro natočení modelu končetiny. V následujících odstavcích budou detailně popsány jednotlivé záložky grafického rozhraní.

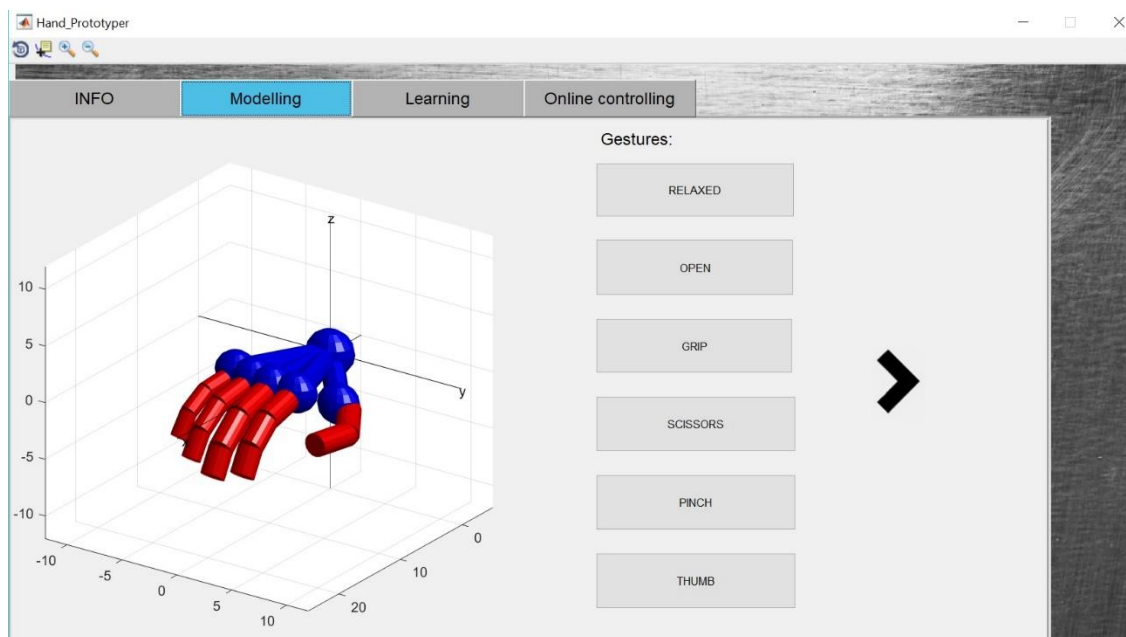
Záložka INFO

Obsahuje pouze základní informace k programu po stisknutí tlačítka pro nápovědu. Jedná se o shrnutí tohoto textu.



Záložka Modelling

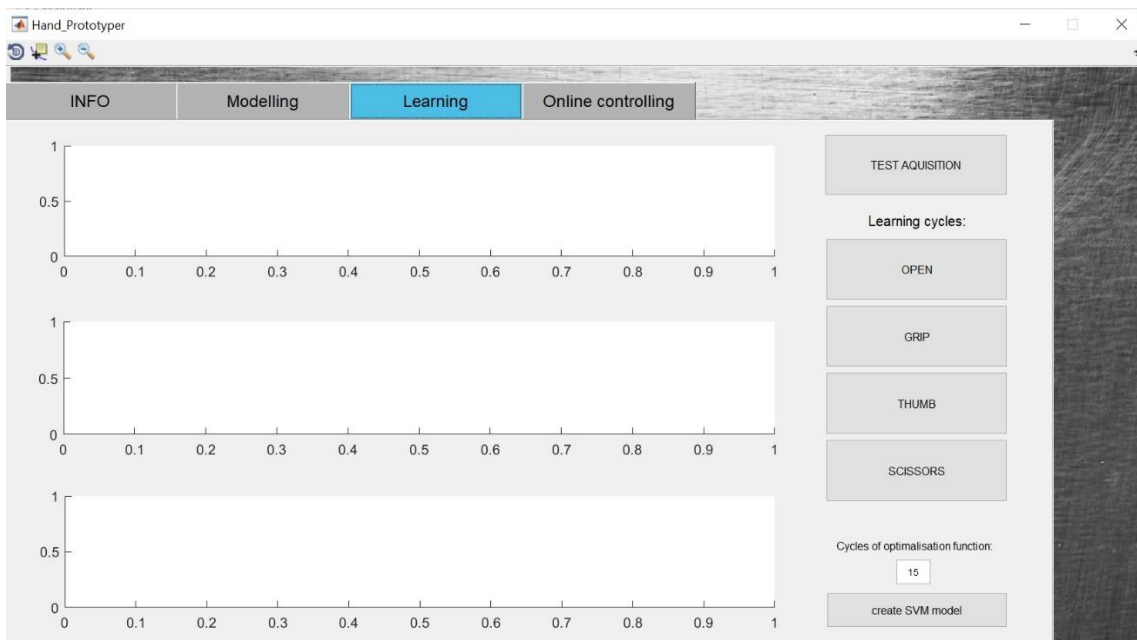
Tato karta zahrnuje pouze vizuální ovládání modelu končetiny pomocí předdefinované sady tlačítek. Tento nástroj je velice vhodný při vytváření nové trajektorie robotické soustavy. Po rozkliknutí černé šipky dojde k otevření panelu pro ovládání jednotlivých robotických prvků, což usnadňuje následnou implementaci do programového kódu. V základním nastavení obsahuje 6 tlačítek pro zobrazení základních gest končetiny.



Záložka Learning

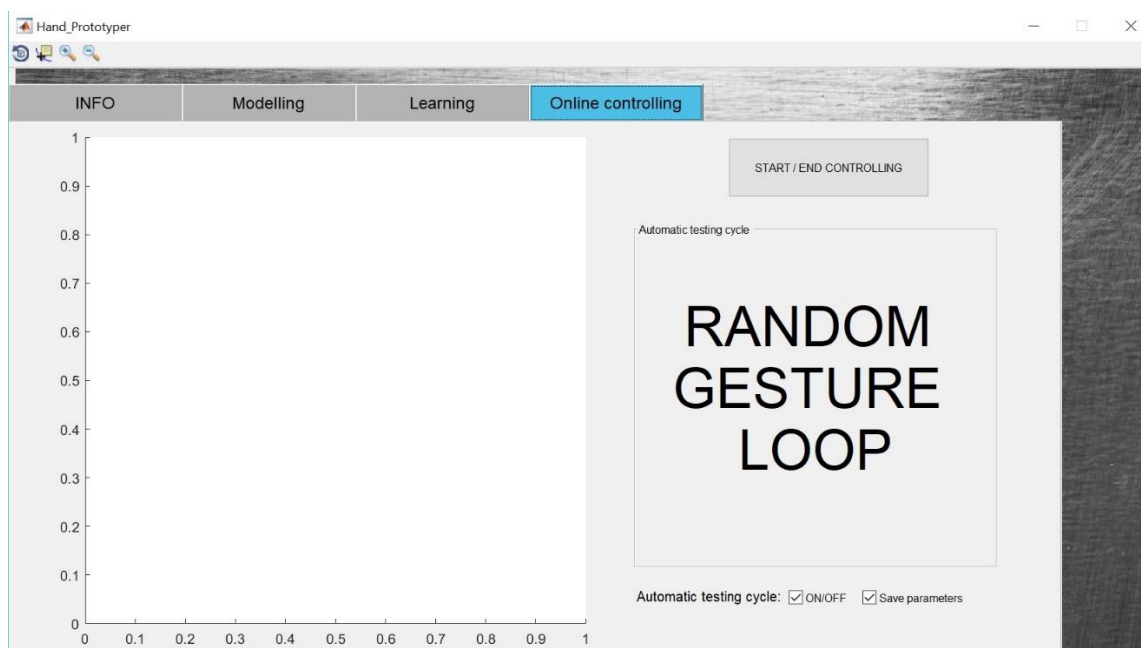
Pro práci s následujícími prvky je nutné mít propojený akviziční systém BITalino s kartou se zesilovači, včetně připevnění nalepovacích elektrod pro všechny tři kanály. Následně zapněte AVR BITalino a po stisknutí tlačítka TEST AQUISITION několik vteřin vyčkejte. Pokud je propojení správné, dojde bezprostředně k zobrazení signálů ze všech třech kanálů v levé části okna, a tudíž snímání EMG aktivity. Pokud signál vykazuje známky přílišného šumu (hodnoty nad 0,3 mV při neaktivním svaly), zkontrolujte prosím akviziční systém, včetně možných zdrojů rušení. Je možné, že v průběhu snímání dojde k výpadku signálu z mikrokontroléru. V tomto případě restartujte mikrokontrolér a případně celý program. Další tlačítka slouží pro zapnutí učící sekvence pro jednotlivá gesta. Po kliknutí na tlačítko počkejte, dokud nedojde k zobrazení signálu v levé části. Následně vykonajte požadované gesto, nejlépe v časových intervalech 5 s aktivity a 5 s neaktivity. Takto pokračujte do časového úseku 20 s kdy dojde k ukončení cyklu. První gesta jsou nutná pro natrénování modelu. Gesta palec nahoru a nůžky jsou volitelným rozšířením modelu (horší rozpoznávací schopnosti). Údaje potřebné k natrénování modelu se uloží do samostatných souborů s koncovkou .mat. Poslední části ovládacích

prvků zahrnují vytvoření modelu SVM. Je nutné nastavit počet optimalizačních cyklů algoritmu pro správné natrénování (nativně 15 cyklů, v případě zadání číselné hodnoty 0 dojde k vypnutí optimalizační Bayesovy funkce a model nebude tímto způsobem optimalizován -> nižší časová náročnost za cenu horší klasifikace).



Záložka online controlling

Opět je vyžadováno propojení se zařízením BITalino. Tlačítkem START/STOP buďto zapnete, nebo vypnete snímání signálu. V reálném čase dochází k vyhodnocení klasifikace signálu a na základě prahových hodnot je přiřazen svalový pohyb ke konkrétnímu gestu, které je zobrazováno v levé části obrazovky. V případě, že je požadováno statistické vyhodnocení úspěšnosti klasifikace, zapněte funkci automatic testing cycle včetně uložení parametrů do souboru results.mat. Tato funkce slouží pro náhodné generování textových řetězců pro snadnější testování klasifikace. Výstupem v souboru jsou jednak indexy náhodných požadovaných gest a indexy samotné klasifikace. Součástí souboru jsou hodnoty RMS z jednotlivých kanálů.



Důležité informace


Před spuštěním jakéhokoliv snímání signálu je nutné se ujistit, že současně není spuštěná jiná akvizice. V tomto případě je program nestabilní a může docházet k chybám. Proto při přepínání karet programu je doporučeno zkontrolovat, že nedochází k snímání signálu a v případě že ano, počkat na dokončení trénovacího cyklu nebo opětovně stisknout polohovatelné tlačítko pro zapnutí/vypnutí snímání. Špatná klasifikace signálu může být způsobena jednak špatným připevněním elektrod (včetně špatně zvolené polohy z hlediska svalu), špatným propojením zesilovače a mikrokontroléru případně špatně natrénovaným SVM. Vyzkoušejte jinou úroveň aktivity svalu při trénování, případně jiné nastavení pro optimalizační funkci.

B Podrobné výsledky klasifikace

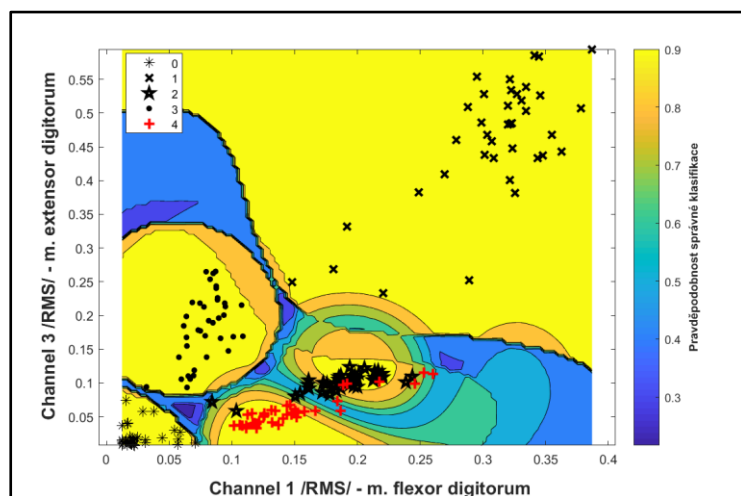
1. měření

		Skutečná třída					
		0	1	2	3	4	
Klasifikovaná třída	0	848	4	3	17	9	881
	1	0	284	0	0	0	284
	2	5	6	229	25	0	265
	3	0	1	0	246	0	247
	4	3	51	2	0	219	275
		856	346	234	288	228	1952

Třída	Sp	Se	PPV	ACC
0	0,991	0,970	0,963	0,935
1	0,821	1,000	1,000	
2	0,979	0,979	0,864	
3	0,854	0,999	0,996	
4	0,961	0,968	0,796	
		0,921	0,983	0,924



obr 1 – 3D zobrazení příznaků RMS (1. měření)

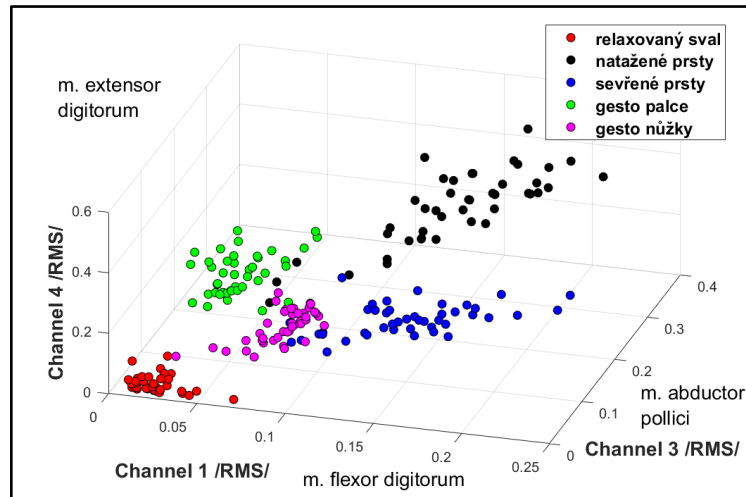


obr 2 – mapa klasifikátoru (1. měření)

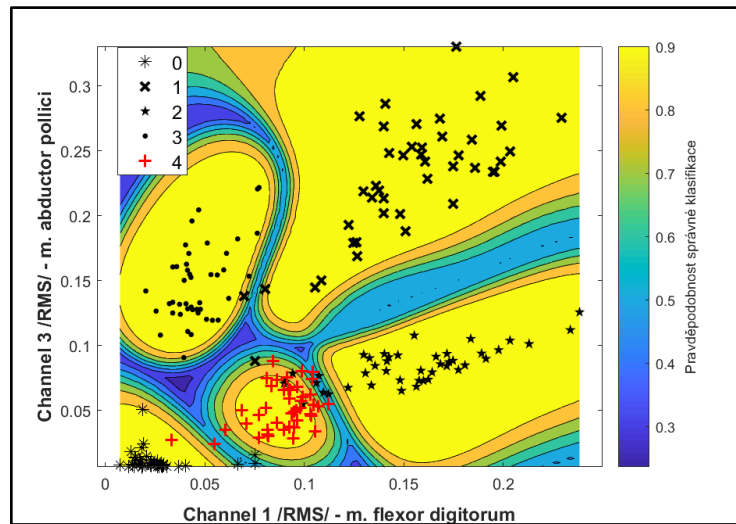
2. měření

		Skutečná třída					
		0	1	2	3	4	
Klasifikovaná třída	0	501	0	0	2	0	503
	1	0	193	6	1	0	200
	2	0	1	125	0	14	140
	3	0	3	5	202	0	210
	4	1	6	2	1	110	120
		502	203	138	206	124	1173

Třída	Sp	Se	PPV	ACC
0	0,998	0,997	0,996	0,964
1	0,951	1,000	0,965	
2	0,906	0,999	0,893	
3	0,981	0,997	0,962	
4	0,887	0,992	0,917	
		0,944	0,997	0,946



obr 3 - 3D zobrazení příznaků RMS (2. měření)

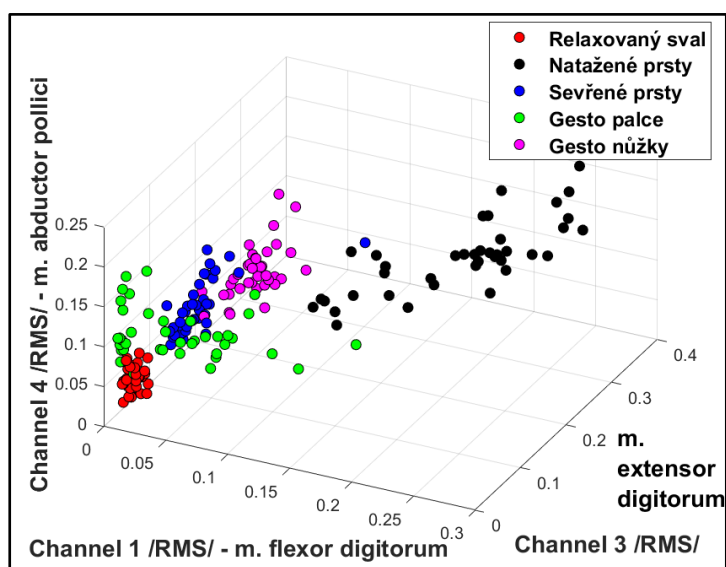


obr 4 - mapa klasifikátoru (2. měření)


4. měření

		Skutečná třída					
		0	1	2	3	4	
Klasifikovaná třída	0	417	14	19	7	0	457
	1	2	72	0	22	0	96
	2	11	2	164	16	21	214
	3	29	0	0	142	5	176
	4	11	10	0	2	189	212
		470	98	183	189	215	1155

Třída	Sp	Se	PPV	ACC
0	0,887	0,942	0,912	0,852
1	0,735	1,000	0,750	
2	0,896	0,970	0,766	
3	0,751	1,000	0,807	
4	0,879	0,978	0,892	
		0,8297	0,978	0,825



obr 5 - 3D zobrazení příznaků RMS (4. měření)

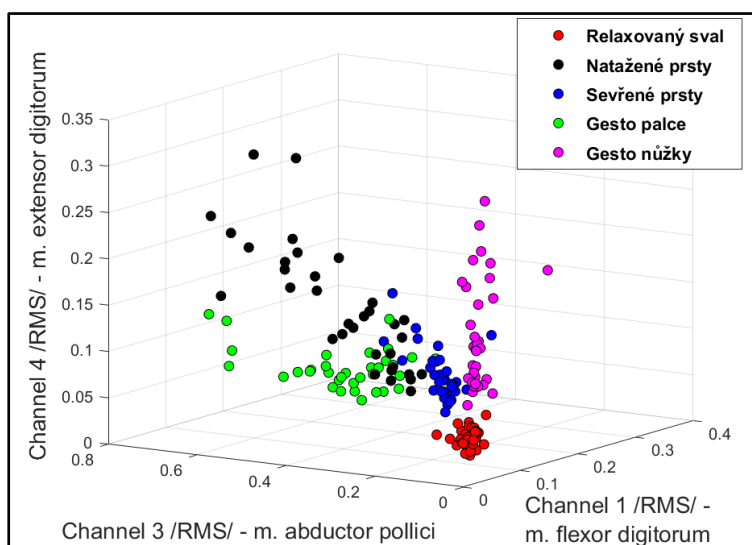


obr 6 - mapa klasifikátoru (4. měření)

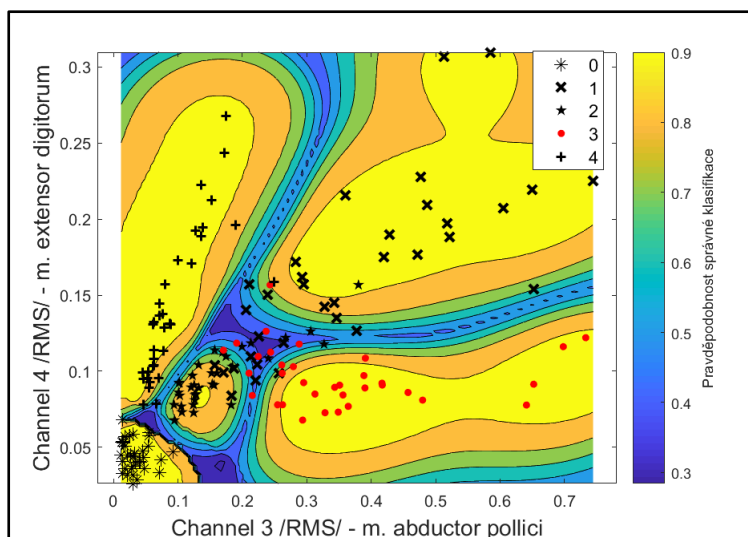
5. měření

		Skutečná třída					
		0	1	2	3	4	
Klasifikovaná třída	0	221	0	0	0	0	221
	1	3	69	0	3	0	75
	2	21	24	18	34	3	100
	3	1	0	0	73	0	74
	4	7	0	0	0	116	123
		253	93	18	110	119	593

Třída	Sp	Se	PPV	ACC
0	0,874	1,000	1,000	0,838
1	0,742	1,000	0,920	
2	1,000	0,863	0,180	
3	0,664	1,000	0,986	
4	0,975	0,985	0,943	
				0,851
				0,97
				0,8059

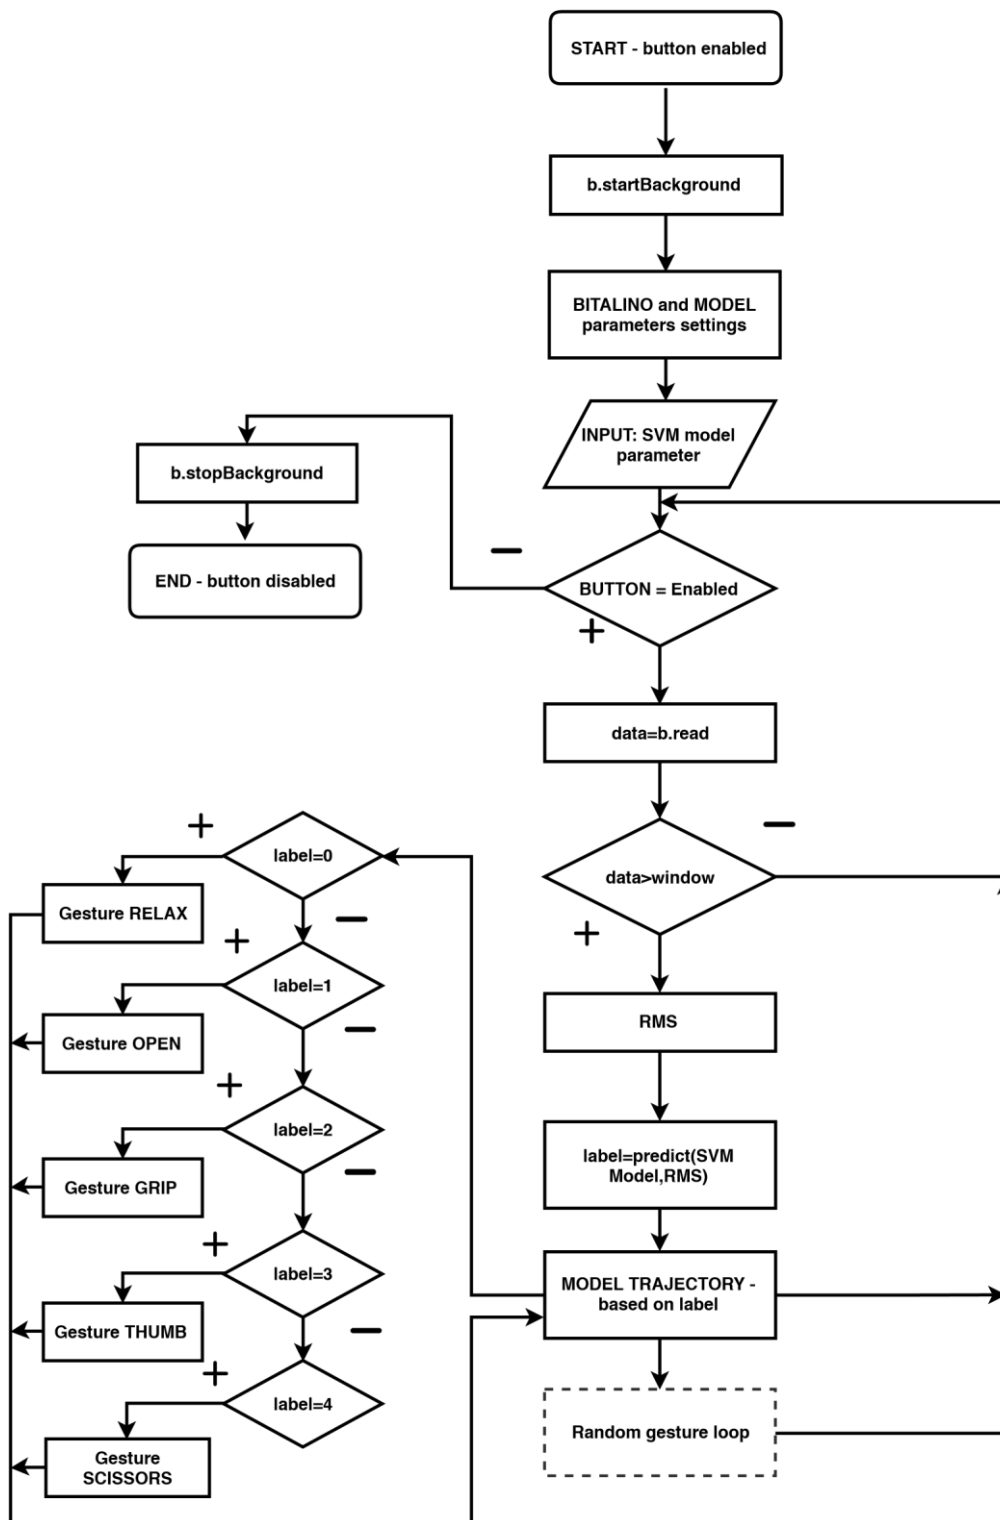


obr 7 - 3D zobrazení příznaků RMS (5. měření)



obr 8 - mapa klasifikátoru (5. měření)

C Vývojový diagram hlavní části kódu



D Obsah přiloženého DVD

- Elektronická verze bakalářské práce
- Zdrojové kódy pro spuštění programu – složka Hand_Prototyper
- The Robot Toolbox for Matlab včetně dokumentace
- BITalino Toolbox
- Výsledky měření
- Videozáznam praktické ukázky funkčnosti systému ve formátu .mp4