


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ
ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ
FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

MOŽNOSTI ŘÍZENÍ MYOELEKTRICKÉ PROTÉZY HORNÍ KONČETINY

CONTROL POSSIBILITIES OF MYOELECTRIC UPPER LIMB PROSTHESES

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS


AUTOR PRÁCE
AUTHOR

DANIEL CHALUPA

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. LUKÁŠ SMITAL, Ph.D.

BRNO 2015



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Bakalářská práce

bakalářský studijní obor

Biomedicínská technika a bioinformatika

Student: Daniel Chalupa

ID: 155578

Ročník: 3

Akademický rok: 2014/2015

NÁZEV TÉMATU:

Možnosti řízení myoelektrické protézy horní končetiny

POKYNY PRO VYPRACOVÁNÍ:

1) Prostudujte problematiku snímání a zpracování povrchových EMG signálů při svalových kontrakcích. Vypracujte literární rešerši zabývající se využitím myoelektrických potenciálů k ovládní protézy horní končetiny. 2) Seznamte se s měřícím systémem BIOPAC a možnostmi přenosu změřeného signálu pro následné zpracování v programovém prostředí Matlab. 3) Popište základní vlastnosti změřených EMG signálů v časové i spektrální oblasti a pokuste se definovat rozdíly EMG signálů při různých pohybech ruky (pokud to bude možné, najděte odlišnosti i při pohybu různých prstů). Stanovte pravidla pro diskriminaci EMG signálů při různých gestech ruky. 4) Navrhněte a realizujte algoritmus pro identifikaci pohybu horní končetiny, který bude založen pouze na zpracování svalových signálů. 5) Otestujte robustnost vytvořeného softwaru na dalších měřených datech např. jiných osob. 6) Proveďte vyhodnocení dosažených výsledků a diskutujte využitelnost navrhovaného měření i vytvořeného softwaru.

DOPORUČENÁ LITERATURA:

- [1] MERLETTI, R. a P. PARKER. Electromyography: physiology, engineering, and noninvasive applications. Hoboken, NJ: IEEE/John Wiley, 2004, 494 p. ISBN 978-0471675808.
- [2] CHEN, X., X. ZHANG, Z.-Y. ZHAO, J.-H. YANG, V. LANTZ a K.-Q. WANG. Multiple Hand Gesture Recognition Based on Surface EMG Signal. 2007 1st International Conference on Bioinformatics and Biomedical Engineering. IEEE, 2007, s. 506-509.

Termín zadání: 9.2.2015

Termín odevzdání: 29.5.2015

Vedoucí práce: Ing. Lukáš Smital, Ph.D.

Konzultanti bakalářské práce:

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

Práce se zabývá návrhem algoritmu pro rozeznání jednotlivých prstů a vzorů v elektromyografickém signálu pro následné řízení protézy horní končetiny. Součástí je také testování a analýza vybraného postupu.

Summary

The purpose of this work is to propose an algorithm to differentiate fingers and patterns in electromyographic signal for further use in upper limb prosthetics control. Testing and analysis of proposed method is included.

Klíčová slova

Končetina, protéza, elektromyografie, řízení, fourierova transformace.

Keywords

Limb, prosthesis, electromyography, control, fourier transform.

CHALUPA, D. *Možnosti řízení myoelektrické protézy horní končetiny*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015. 43 s. Vedoucí Ing. Lukáš Smital, Ph.D.

Prohlašuji, že svoji bakalářskou práci na téma Možnosti řízení myoelektrické protézy horní končetiny 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 semestrální práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Daniel Chalupa

Děkuji vedoucímu bakalářské práce Ing. Lukáši Smitalovi, PhD. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce. Poděkování patří také mé rodině za neutuchající podporu při studiích a mé přítelkyni za její dobrosrdečnost a krásu, které mě vždy budou inspirovat.

Daniel Chalupa

Obsah

1	Úvod	1
2	Svaly předloktí a jejich kontrakce	2
2.1	Fyziologie	2
2.2	Anatomie	4
2.2.1	Povrchové svaly	5
2.2.2	Střední vrstva	6
2.2.3	Hluboké svaly	6
3	Elektromyografický signál a možnosti extrakce informací	7
3.1	Vznik signálu	7
3.2	Vlastnosti signálu	8
3.3	Analýza v časové oblasti	9
3.4	Analýza ve frekvenční oblasti	10
3.4.1	Autoregresivní (AR) modely	11
3.5	Umělá inteligence	11
4	Návrh algoritmu	12
4.1	Cíl	12
4.2	Filtrace	12
4.3	Detekce stahu	14
4.4	Rozlišení prstů	15
4.4.1	Učební fáze	15
4.4.2	Pracovní fáze	18
4.5	Výběr deskriptorů	19
5	Testování a dosažené výsledky	23
5.1	Postup měření	23
5.2	Izometrická kontrakce	24
5.3	Izotonická kontrakce	25
5.4	Gesta	26
6	Závěr	29
	Použitá literatura	i
	Seznam zkratk	iv
	Seznam příloh	v
6.1	Skripty	v
6.2	Signály	v

Seznam obrázků

2.1	Nervosvalová ploténka. Převzato a upraveno z [3]	3
2.2	Stavba svalu. Převzato z [5]	4
2.3	Svaly předloktí. Ventrální strana. Převzato z [6]	5
3.1	Naměřený SEMG signál izometrické kontrakce několika prstů. Použit je <i>1-1-3.mat</i> z přílohy	8
3.2	Proces odhadu amplitudy. Spolu s popisem algoritmu převzato z [9]	9
3.3	Normalizovaný spektrogram signálu <i>1-1-3.mat</i> pomocí STFT. Vzorkovací frekvence 500 Hz. Kolem nulové izolinie si lze povšimnout silného zastoupení driftu a pohybových artefaktů.	10
3.4	Proces vzniku stochastického signálu. Převzato z [12]	11
4.1	Srovnání filtrace IIR filtrem, FIR filtrem a nulováním spektrálních čar v časové oblasti. Rozdíly jsou minimální.	13
4.2	Srovnání filtrace IIR filtrem, FIR filtrem a nulováním spektrálních čar ve frekvenční oblasti kolem mezní frekvence 20 Hz. Nástup IIR filtru je poněkud pomalejší, nepochybně z důvodu nízkého řádu.	13
4.3	Správně detekované počátky a konce kontrakcí. Použitý signál <i>1-1-3.mat</i> .	15
4.4	Vývoj sledovaných parametrů učebního signálu v čase. Parametry vzorů se nachází v oblastech grafu vymezených stahy (Obrázek 4.3). Použitý signál <i>1-1-3.mat</i> .	16
4.5	Rohy představovaných kvádrů. Použitý signál <i>1-1-3.mat</i> .	17
4.6	Schematické znázornění učební fáze.	17
4.7	Ukázka úspěšné klasifikace signálu, pro který byl algoritmus naučen. Cyklus byl: ukazováček, prostředníček, prsteníček, malíček. Vše při 50% volní izometrické kontrakci.	18
4.8	Naznačení významu frekvenčních deskriptorů.	20
5.1	Rozmístění elektrod.	23
5.2	Kumulativní vzdálenosti od vzorů. Z grafu je patrná rozdílnota prsteníčku, který má od všech ostatních vzorů nejvyšší vzdálenost.	25
5.3	Vybraná gesta.	27

Seznam tabulek

4.1	Získané hodnoty deskriptorů.	21
4.2	Normalizované hodnoty deskriptorů.	21
4.3	Výsledná kritéria normalizovaných parametrů, nejlepší hodnoty jsou zvýrazněny červeně.	22
5.1	Úspěšnost rozeznání jednotlivých prstů při izometrické kontrakci.	24
5.2	Úspěšnost rozeznání v závislosti na měřených osobách při izometrické kontrakci.	24
5.3	Úspěšnost rozeznání jednotlivých prstů při izotonické kontrakci.	26
5.4	Úspěšnost rozeznání v závislosti na měřených osobách při izotonické kontrakci.	26
5.5	Úspěšnost rozeznání jednotlivých gest.	27
5.6	Úspěšnost rozeznání v závislosti na měřených osobách při gestech.	27

1. Úvod

Již od dob, kdy Francesco Redi experimentoval s Paúhoři elektrickými, je známo, že sval je schopen generovat elektrické impulzy^[1]. Pozdější experimenty ukázaly, že svaly je možné taktéž elektrickými impulzy aktivovat a Emil du Bois-Reymond dokázal, že při svalové kontrakci lze elektrický signál kteréhokoliv svalu také změřit^[2]. Díky pokroku a minimalizaci v elektrotechnice se v posledních desetiletích rozšiřuje zkoumání elektromyografických (EMG) signálů. Vývoj technik pro jejich zpracování otevřel možnosti využití, například pro terapeutické účely, pro diagnostiku nervosvalových onemocnění, nebo pro řízení náhrad.

Myoelektrická protéza je umělá náhrada chybící části lidského těla, řízená elektrickými signály, generovanými zbývajícími svaly v těle. Podle potřeby pacienta a specifik daného modelu může mít několik stupňů volnosti ve formě umělých kloubů, pohyblivých díky servomotorům.

Cílem této práce je seznámit s možnostmi zpracování povrchových EMG signálů pro účely řízení myoelektrických protéz. Toho se snaží docílit v pěti následujících kapitolách. První kapitola se věnuje fyziologii vzniku svalových elektrických signálů a anatomickému základu pohybu při zaměření na horní končetinu. V druhé kapitole je popsána matematická představa zkoumaného signálu a jsou zde osvětleny klasické metody pro jeho zpracování. Další kapitola je zaměřena na návrh algoritmu pro praktickou část práce. Kapitola „Testování a dosažené výsledky“ obsahuje popis měřících přístrojů, rozmístění elektrod, tvorbu učebního signálu, výběr spektrálních deskriptorů a výsledky třech různých testů. V závěru jsou shrnuty zjištěné poznatky a je diskutována použitelnost metody.


2. Svaly předloktí a jejich kontrakce

Sval je orgán, jehož hlavní schopností je možnost kontrakce a tím konání fyzické práce. Ve fyziologické části této kapitoly bude vysvětlen proces aktivace svalu a jeho kontrakce. Anatomická část se poté zaměřuje pouze na svaly horní končetiny, konkrétně na svaly distálně od loketního kloubení. Tedy svaly, které způsobují různé pohyby předloktí, zápěstí, dlaně a prstů.

2.1. Fyziologie

Aktivace kontrakce svalu může být způsobena předáním vzruchu od neuronu přes nervosvalovou ploténku, nebo externím impulzem. Nervosvalová ploténka (Obrázek 2.1) je struktura, která chemicky zajišťuje přenos akčního potenciálu (AP) z neuronu na sval. Axon neuronu končí 20 - 30 nm od buněčné stěny^[3]. Překlenutí této mezery je zajišťováno mediátorem Acetylcholinem, který je vytvářen a ukládán pro okamžité použití v axonu. Acetylcholin se naváže na specifické receptory na postsynaptické (svalové) části nervosvalové ploténky a způsobí depolarizaci buněčné membrány, která otevře sodné a draselné kanály, pomocí kterých se od místa vzniku začne pohybovat depolarizační vlna a nastane šíření vzruchu k vápníkovým kanálům uvnitř svalu v tzv. T-tubulech, které dále zprostředkují kontrakci^[4]. Inervace několika svalových vláken jedním neuronem se nazývá motorická jednotka.


Axon



Sval

Obrázek 2.1: Nervosvalová ploténka. Převzato a upraveno z [3]


Sval jako celek se sám skládá ze svalových vláken, jejichž větší počet tvoří snopečky a ty se potom dále spojují ve snopce. Soubor všech snopců tvoří svalové břicho. V cytoplasmě svalového vlákna jsou uloženy myofibrily, které jsou tvořeny bílkovinami aktinem a myosinem^[5]. Vzájemný posun těchto bílkovin vůči sobě tvoří fyzikální základ stahu svalu. Kontrakce mohou být izometrické (sval nemění velikost, například zvedání předmětu, který nejsme schopni unést) a dynamické (či izotonické).



Obrázek 2.2: Stavba svalu. Převzato z [5]

2.2. Anatomie

Jak již bylo výše naznačeno, svaly mohou plnit několik funkcí v lidském těle. Svaly předloktí, které mají vliv na pohyby předloktí a ruky jsou převážně flexory (ohybače) a extensory (natahovače). Následuje seznam vybraných svalů předloktí a jejich funkce. Výčet se omezuje pouze na ty svaly, které budou v praktické části v blízkosti měřících elektrod a mají přímý vliv na pohyb prstů.



Obrázek 2.3: Svaly předloktí. Ventrální strana. Převzato z [6]

2.2.1. Povrchové svaly

Brachioradialis - Při pronovaném (rotace předloktí palcem za dlaní) předloktí je flexorem loketního kloubu. Ventrální (dlaňová) strana.

Pronator Teres - Upíná se v polovině kosti vřetenní a slouží k pronaci a ohybu lokte. Ventrální strana.

Flexor Carpi Radialis - Slouží k ohybu a natažení zápěstí. Ventrální strana.

Palmaris Longus - Končí ve dlaní a slouží k ohybu zápěstí. Ventrální strana.

Flexor Carpi Ulnaris - Slouží k ohybu a natažení zápěstí. Ventrální strana.

Musculus extensor digitorum - Natahovač prstů, pracuje proti Flexor digitorum. Dorzální strana.

2.2.2. Střední vrstva

Flexor Digitorum Superficialis - Jeho plochy se štěpí a upínají podél okrajů středních článků prstů (vyjma palce). Slouží k ohybu prstů. Ventrální strana.

2.2.3. Hluboké svaly

Flexor Pollicis Longus - Stará se o ohyb palce, na jehož poslední článek se upíná. Ventrální strana.

Flexor Digitorum Profundus - Úpon šlach je na posledním článku prstů (kromě palce) a slouží k ohybu dlaně. Ventrální strana.

Musculus extensor indicis - Natahuje ukazovák. Dorzální strana.

3. Elektromyografický signál a možnosti extrakce informací

V předchozí kapitole byla popsána komunikace na rozhraní neuron-sval. Postup potenciálových změn, způsobených aktivací svalu lze snímat mimo jiné i povrchovými elektrodami. Samotné snímání povrchovou elektrodou nicméně bez dalšího zpracování nemá vysokou informační hodnotu. Proto vzniklo několik matematických modelů EMG signálu a na jejich základě celá řada metod pro jeho zpracování.

$$x(n) = \sum_{r=0}^{N-1} h(r)e(n-r) + w(n) \quad (3.1)$$

Rovnice 3.1 ukazuje jednoduchý model EMG signálu. $X(n)$ zde označuje modelovaný signál, $e(n)$ je průvodní nervový impulz, $h(r)$ je akční potenciál motorické jednotky a $w(n)$ je aditivní gaussův šum^[7].

3.1. Vznik signálu


Zdrojem signálu jsou depolarizované membrány svalových buněk, přičemž vlna depolarizace se pohybuje od zdroje depolarizace (nervosvalová ploténka) ke šlachovým úponům svalu. Mezi těmito zdroji signálu a elektrodou jsou navíc vrstvy tkáně a elektrolyt mezi epidermis a elektrodou, které mají na výsledný signál vliv ve smyslu horní propusti.

Vzhledem k vrstvám tkáně mezi elektrodou a zdroji signálu povrchová elektroda nesmímá pouze jednu motorickou jednotku, nýbrž výsledný signál je sumací všech motorických jednotek v dosahu. V určitých případech může nastat situace, kdy povrchová elektroda snímá nejen námi vybraný sval, ale i svaly v blízkém okolí.

V závislosti na síle stahu je aktivováno čím dál více motorických jednotek, přičemž jejich přesné rozmístění předem není známo. Navíc je individuální, a proto jej budeme považovat za náhodné. Také se zkracuje časová odmlka mezi jednotlivými AP, rovněž náhodně.

3.2. Vlastnosti signálu

Při aktivaci svalu je možné změřit trifazický signál s amplitudou 20 - 2000 μV s dobou trvání 2 - 15 ms. Dominantní frekvence se nacházejí v rozmezí 20 - 250 Hz^[8]. EMG signál je stochastický, avšak vezme-li se dostatečně krátký úsek, je možné ho považovat za deterministický a použít metody, které determinismus požadují.

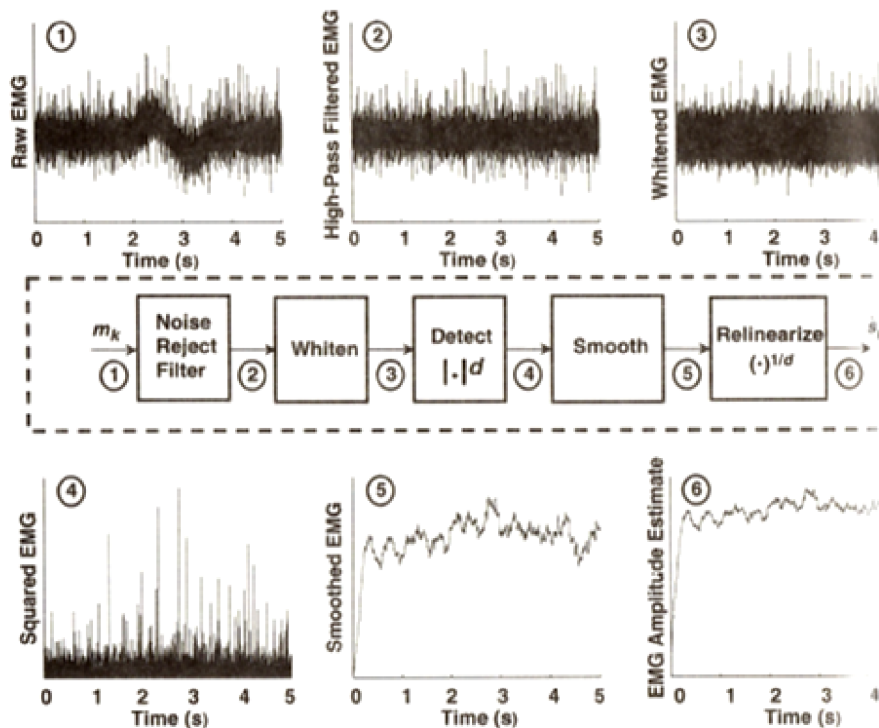


Obrázek 3.1: Naměřený SEMG signál izometrické kontrakce několika prstů. Použit je *1-1-3.mat* z přílohy

Jak lze pozorovat na obrázku 3.1, naměřený signál je výrazně zarušen zejména v oblasti nízkých frekvencí, což se projevuje jako drift celého signálu od nulové izoliny. Je ale patrné i zarušení na místech, kde nebyla žádná ze snímaných částí svalu aktivována. Tato rušení jsou způsobena například výše zmíněnou přeměnou signálu při průchodu tkáňovými vrstvami, které jsou tvořeny aktivními buňkami a jsou časově nestálé. Další zarušení může mít za následek vzájemný pohyb elektrody vůči svalu při dynamické kontrakci, pronikání elektrokardiografických komplexů a externí šum zejména ve formě síťového brumu. V neposlední řadě hraje roli šum zesilovače na EMG přístroji.

3.3. Analýza v časové oblasti

V době počátků analýzy EMG se výzkumníci zaměřovali převážně na časovou oblast. Jeden z hlavních problémů signálu je ten, že nejsme schopni z přímo naměřených impulzů odhadnout sílu stahu^[10]. V digitálních systémech lze použít jednoduchých analýz jako jsou průměrná absolutní hodnota (MAV - Mean Absolute Value), výpočet průchodů nulou, nebo efektivní hodnota (RMS - Root Mean Square). Později byly prozkoumávány i jiné způsoby odhadu amplitudy, na jejichž základě vznikl algoritmus, naznačený na Obrázku 3.2 a popsáný níže.




Obrázek 3.2: Proces odhadu amplitudy. Spolu s popisem algoritmu převzato z [9]

V první řadě je třeba signál zbavit šumu. Toho lze docílit například horní propustí s mezní frekvencí kolem 20Hz (na obrázku bod 2). Bělící filtr (druhý blok v blokovém signálu) má za následek dekorelaci signálu a tím zvětšení jeho statistické výpovědní hodnoty. Prakticky bylo ověřeno, že bělení signálu má podstatný pozitivní vliv na následné zpracování^[11]. Za bělením následuje umocnění absolutní hodnoty signálu, vyhlazení signálu a jeho relinearizace (umocnění na převrácenou hodnotu mocniny ve třetím kroku).

3.4. Analýza ve frekvenční oblasti

Díky popularizaci rychlé fourierovy transformace (FFT - Fast Fourier Transform) se objevila možnost, jak tuto metodu využít i v případě EMG. Zvláště užitečná je metoda krátkodobé FFT (STFT - Short Time Fourier Transform), která zobrazuje vývoj frekvenčního spektra v čase. Ze získaných spekter je poté možné vypočítat deskriptory, jako například střední frekvence (MNF - Mean Frequency), mediánová frekvence (MDF - Median Frequency), nebo poměr vysoké a nízké frekvence.




Obrázek 3.3: Normalizovaný spektrogram signálu *1-1-3.mat* pomocí STFT. Vzorkovací frekvence 500 Hz. Kolem nulové izolinie si lze povšimnout silného zastoupení driftního a pohybových artefaktů.

Pomocí spektrální analýzy lze velice přesně odečíst únavu svalu. Spektrum se totiž s rostoucí svalovou únavou komprimuje a jeho střední frekvence se posouvá směrem k nižším kmitočtům.

3.4.1. Autoregresivní (AR) modely

Jednou z poměrně nových, avšak výpočetně náročnějších možností spektrální analýzy jsou AR modely. Základem takových modelů je odhad výkonového spektra na základě modelu vzniku signálu. Toho lze docílit hledáním takového filtru, který ze vstupního signálu vytvoří bílý šum. Koeficienty a přenosová funkce tohoto filtru poté přímo vypovídají o odhadovaném spektru signálu. Model vychází z jedné z teorií vzniku stochastického signálu, zobrazeného na Obrázku 3.3. AR modely jsou velmi stroze řečeno inverzní proces vzniku.



Obrázek 3.4: Proces vzniku stochastického signálu. Převzato z [12]

3.5. Umělá inteligence

Závěr kapitoly je vyhrazen metodám umělé inteligence, která zde slouží převážně k rozeznávání vzorů pomocí výše popsaných principů. V [13] je například použito FFT k extrakci parametrů spekter z naměřeného signálu. Následně pomocí algoritmu Fuzzy c-means získané parametry rozřadí do shluků. Tím je završena učební fáze algoritmu a jejím výstupem jsou definice shluků. Poté je použita umělá neuronová síť, která je na tyto shluky naučena a dokáže podle nich rozřadit i neznámý signál. Na podobném, avšak jednodušším principu je postavena praktická část práce.

4. Návrh algoritmu

Tato kapitola obsahuje popis algoritmu, který je použit na zpracování SEMG. V první části se lze dozvědět myšlenkový podklad pro vybraný způsob řešení a vytyčené cíle, kterých bude snaha dosáhnout. Další části se týkají konkrétních problémů při řešení dílčích úloh.

4.1. Cíl

Na předem naměřeném a předzpracovaném SEMG signálu bude v první řadě snaha o nalezení počátků a konců stahu svalu, protože pouze v oblastech kontrakce lze nalézt informace užitečné k řízení myoelektrické protězy.


Jako další úkol je stanoveno rozlišení jednotlivých prstů. Vzhledem k měření pouze jedním svodem a omezenému dosahu elektrod se práce nebude věnovat diskriminaci pohybu palce a u ostatních prstů nebude přímo měřena extenze, nýbrž pouze flexe, hlavním měřeným svalem bude tedy Flexor Digitorum Superficialis.

Kvůli přehlednosti, názornosti a v neposlední řadě snaze o omezení náročnosti algoritmu na procesorový čas nebude pro rozeznání vzorů použito neuronových sítí, ani jiných metod umělé inteligence. Místo toho se práce snaží o vyřešení těchto problémů jinými cestami.


4.2. Filtrace

Jak bylo naznačeno v předchozí kapitole, signál je zarušen různými vlivy. Většinu z nich lze odstranit horní propustí s mezní frekvencí kolem 20 Hz. Pohyb této frekvence o několik Hertzů výše, či níže nemá podstatný vliv na úspěšnost algoritmu. Byl tedy zvolen mezní kmitočet 20 Hz.

Z Obrázků 4.1 a 4.2 je patrné, že při použití rozdílných typů filtrů není příliš znatelný rozdíl v časové ani frekvenční oblasti. Ovšem délka impulzní charakteristiky FIR filtru s Hammingovým oknem je rovna 2000 vzorků. IIR byl použit butterworthův filtr pouze 5. řádu. Pro účel této práce bude z důvodu jednoduššího analytického popisu, konstantního přenosu fázové složky signálu, a protože není třeba minimalizovat zpoždění, použit výše popsáný filtr FIR. Zpoždění filtru je nulováno funkcí *filtfilt*, která vstupní signál profiltruje z obou stran. V případě online zpracování by byl mnohem vhodnější filtr IIR i přes jeho nevýhody, a to i v případě jeho vyšších řádů.



Obrázek 4.1: Srovnání filtrace IIR filtrem, FIR filtrem a nulováním spektrálních čar v časové oblasti. Rozdíly jsou minimální.



Obrázek 4.2: Srovnání filtrace IIR filtrem, FIR filtrem a nulováním spektrálních čar ve frekvenční oblasti kolem mezní frekvence 20 Hz. Nástup IIR filtru je poněkud pomalejší, nepochybně z důvodu nízkého řádu.

4.3. Detekce stahu

Nalezení počátku a konce aktivace svalu je důležité pro správnou funkci celého algoritmu, neboť v učebních fázích dílčích úloh se systém učí právě z období, kdy je sval aktivován. Podobně v pracovní části je třeba nalézt body počátku kontrakce.


Stahy svalů nejsou digitálním systémem, nejsou tedy přítomny kdykoliv v jednom stavu ze dvou (vypnuto/zapnuto). Kontrakce může nabývat různých intenzit a stejně tak naměřený signál. To implikuje užití Fuzzy systémů, nicméně jedním z cílů algoritmu je dokázat, že podobných výsledků lze dosáhnout i bez použití těchto metod.

Intuitivně lze prahovou hodnotu zjistit již při pohledu na signál v časové oblasti (Obrázek 4.1). I zde proto prahy stahu odvodíme z odhadu amplitudy signálu. K odhadu amplitudy bude využito Teager-Kaiserova energetického operátoru (TKEO), který se používá v tomto smyslu s vysokou úspěšností^[24].

$$\psi[x(n)] = x^2(n) - x(n+1) * x(n-1) \quad (4.1)$$

Rovnice 4.1 zobrazuje předpis TKEO v jeho diskretní formě. $X(n)$ je n -tý vzorek vstupního signálu.

Z předchozích obrázků naměřených signálu si lze jednoduše domyslet, že i signál po TKEO bude plný vrcholů a údolí, což velice znesnadňuje jakékoliv prahování. Nabízí se dvě možnosti, jednou z nich je tvorba obálky signálu. Tu lze vytvořit například tím, že signál necháme projít analytickým filtrem^[14]. Pro účely práce nicméně postačí, když získaný odhad časového průběhu odhadu energie projde mediánovým filtrem. Velikost okna filtru se bude lišit v závislosti na vzorkovacím kmitočtu a vlastnostech měřeného signálu. Při změně velikosti okna směrem k menšímu se mohou projevit píky v signálu. Větší okno pak může způsobit zpoždění detekce. Práh detekce je pevný pro celý signál a odvozuje se jako násobek prvních padesáti vzorků signálu. Velikost prahu je třeba nastavit individuálně pro každý signál. Jak lze vysledovat z Obrázku 4.3, takto upravený signál lze už rozměřit.



Obrázek 4.3: Správně detekované počátky a konce kontrakcí. Použitý signál *1-1-3.mat*.

4.4. Rozlišení prstů


Po správném rozměření kontrakčních bodů se může přistoupit k extrakci parametrů pro následné rozlišení prstů. Algoritmus se skládá ze dvou dílčích částí. V učební části je snaha o získání jednoznačných parametrů, které stah daného prstu definují. V pracovní části se pak extrahují parametry z testovacího signálu a jednotlivým úsekům aktivace svalu se přiřadí prst s nejbližšími parametry z učební části.

4.4.1. Učební fáze

Jako inspirace posloužil text [15]. Stejně jako tam i v této práci se berou v potaz tři parametry signálu, které lze zobrazit ve trojrozměrném prostoru. Použity však budou rozdílné parametry, jejichž výběr je osvětlen v kapitole 4.5. Autoři také neuvádějí, jakým způsobem je gesto přímo detekováno.

4.4. ROZLIŠENÍ PRSTŮ


Získ parametrů probíhá ve fázi kontrakce vždy zvlášť pro každý vstupní vzor, tedy pro úseky mezi počátkem a koncem kontrakce. Z této části signálu je pomocí STFT získán časový vývoj odhadu frekvenčního spektra. Z těchto spekter jsou získány průběhy parametrů (obrázek 4.4).




Obrázek 4.4: Vývoj sledovaných parametrů učebního signálu v čase. Parametry vzorů se nachází v oblastech grafu vymezených stahy (Obrázek 4.3). Použitý signál *1-1-3.mat*.

Získají se tedy čtyři sady dat (jedna sada pro každý ze čtyř prstů), přičemž sadu si lze představit jako matici velikosti $3 * N$, kde N je počet vzorků, které jsou v řadách pro vybrané parametry. Z každé řady se poté vypočítá medián, který bude symbolizovat střed případného shluku ve trojrozměrném prostoru. Pouze bod by ale kvůli nestejnému rozptylu hodnot různých prstů nedostačoval. V představě trojrozměrného prostoru (Obrázek 4.5) středy rozšíříme v každém ze tří směrů o \pm třetinu směrodatné odchylky. Tím získáme tři magnitudy a jeden střed pro každý z prstů. Výsledek si lze představit jako kvádry, případně lépe jako elipsoid. Schematicky je zobrazena učební fáze na obrázku 4.6.

4.4. ROZLIŠENÍ PRSTŮ



Obrázek 4.5: Rohy představovaných kvádrů. Použitý signál 1-1-3.mat.




Obrázek 4.6: Schematické znázornění učební fáze.

4.4.2. Pracovní fáze

Do pracovní fáze vstupují rozměry a středy parametrů prstů a odfiltrovaný signál pro rozpoznání. Ze signálu se sledované parametry získají obdobným způsobem jako v učební fázi. Provede se STFT a z každé jedné realizace se získá trojice parametrů. Tato trojice reprezentuje souřadnice bodů. V dalším kroku se spočítají euklidovské vzdálenosti těchto bodů od středů pomyslných kvádrů. Nicméně aby se vzala v úvahu i velikost těchto kvádrů, je třeba nejprve zjistit, zda-li daný bod v některém z kvádrů neleží. Pokud ano, místo výpočtu se jako výsledek zapíše 0.

V posledním kroku probíhá sumace vzdáleností vždy jednotlivě mezi jedním počátkem a jedním koncem kontrakce. Minimum ze čtyř sledovaných sumací udává nejpravděpodobnější prst. Úspěšnou diskriminaci prstů lze vidět na Obrázku 4.8.



Obrázek 4.7: Ukázka úspěšné klasifikace signálu, pro který byl algoritmus naučen. Cyklus byl: ukazováček, prostředníček, prsteníček, malíček. Vše při 50% volní izometrické kontrakci.

4.5. Výběr deskriptorů

Pro výběr tří parametrů byl sestaven seznam možných ve frekvenční i časové oblasti. Ve frekvenční oblasti, tedy přímo z odhadu spektra pomocí STFT byly vybrány průměrná frekvence^[22], která je matematický váhovaný průměr, jak naznačuje rovnice 4.2.

$$f_p = \frac{\sum_{i=0}^n I_i * f_i}{\sum_{i=0}^n I_i}, \quad (4.2)$$

kde I_i je intenzita i -té frekvence, f_i je hodnota i -té frekvence a n počet vzorků ve frekvenčním spektru. Jako další možný deskriptor je považována mediánová frekvence, která je oproti tomu frekvence střední (nejčastější), tedy frekvence s maximální intenzitou. Poměry výkonů nízkých a vysokých frekvencí při rozdělení spektra v první desetinu, v pětinu a polovinu jsou dalšími popisnými parametry. U těchto se vždy dělí odhad výkonového spektra, které odpovídá frekvencím nízkým částí odpovídající frekvencím vysokým. Dále byly vypočteny maximální frekvence a širší pásma, kde je třeba zadefinovat minimální prahovou intenzitu. Místa křížení tohoto prahu se samotným výkonovým spektrem ohraničují šířku spektra, kdežto křížení dále od nuly značí maximální frekvenci. Směrodatná odchylka jako frekvenční deskriptor odkazuje na kompaktnost spektra. Obrázek 4.8 naznačuje význam těchto deskriptorů.

V časové oblasti lze sledovat tzv. Hjorthovy parametry^[23], tedy aktivitu, mobilitu a složitost spektra. Aktivita spektra je odhadem celkového výkonu spektra a vypočítá se jako variance signálu. Mobilita je odhadem střední (mediánové) frekvence signálu. Rovnice 4.3 naznačuje výpočet.


$$Mobilita = \sqrt{\frac{Aktivita(x(t) \frac{dx}{dt})}{Aktivita(x(t))}} \quad (4.3)$$

Poslední Hjorthův parametr, tedy složitost spektra lze vypočítat dle Rovnice 4.4

$$Složitost = \frac{Mobilita(x(t) \frac{dx}{dt})}{Mobilita(x(t))}, \quad (4.4)$$

a je používána k odhadu šířky pásma.

Ze signálu sluhkruh, který obsahuje izometrickou kontrakci postupně všech čtyř prstů, byly vybrány úseky odpovídající jednotlivým prstům, a to následovně: ukazováček 655. až 3655. vzorek, prostředníček 7637. až 10120., prsteníček 14410. až 16490. a malíček vzorek 21040 až 24440. Signál byl naměřen přístroji a postupem popsaným v kapitole 5.1.



Obrázek 4.8: Naznačení významu frekvenčních deskriptorů.

V těchto úsecích byly změřeny a zprůměrovány všechny parametry dále popsané. Byla také zaznamenána jejich směrodatná odchylka z důvodu porovnání jednoznačnosti parametru. Samotné hodnoty pro jednotlivé parametry byly poté normalizovány do intervalu $\langle 0;1 \rangle$ dle rovnice 4.5 pro možnost dalšího kvantitativního srovnání. Vypočtené hodnoty a normalizované hodnoty lze shlédnout v tabulkách 4.1 a 4.2.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}, \quad (4.5)$$

kde x_{norm} je normalizovaná hodnota, x je nenormalizovaná hodnota, x_{min} je minimální hodnota v souboru dat a x_{max} hodnota maximální.

4.5. VÝBĚR DESKRIPTORŮ

	Ukazováček	Prostředníček	Prsteníček	Malíček
Průměrná f.	0,5009	0,4383	0,4215	0,8307
Mediánová f.	0,3254	0,2718	0,2152	0,275
Poměr f. 1/10	0,3248	0,4691	0,702	0,4974
Poměr f. 1/5	0,452	0,6186	0,9037	0,6403
Poměr f. 1/2	2,1367	2,7566	3,7569	2,6858
Maximální f.	0,1657	0,0747	0,0792	0,0951
Směrodatná odch.	0,3784	0,5042	0,6647	0,279
Šíře pásma	0,0758	0,053	0,0324	0,0457
Aktivita	4,00E-04	6,30E-04	7,70E-04	1,99E-04
Mobilita	1,0212	1,2347	1,522	1,2529
Složitost	0,6689	0,5876	0,5127	0,5719

Tabulka 4.1: Získané hodnoty deskriptorů.

	Ukazováček	Prostředníček	Prsteníček	Malíček
Průměrná f.	0,1940	0,0411	0,0000	1,0000
Mediánová f.	1,0000	0,5136	0,0000	0,5426
Poměr f. 1/10	0,0000	0,3826	1,0000	0,4576
Poměr f. 1/5	0,0000	0,3688	1,0000	0,4169
Poměr f. 1/2	0,0000	0,3826	1,0000	0,3389
Maximální f.	1,0000	0,0000	0,0495	0,2242
Směrodatná odch.	0,2577	0,5839	1,0000	0,0000
Šíře pásma	1,0000	0,4747	0,0000	0,3065
Aktivita	0,3520	0,7548	1,0000	0,0000
Mobilita	0,0000	0,4263	1,0000	0,4627
Složitost	1,0000	0,4795	0,0000	0,3790

Tabulka 4.2: Normalizované hodnoty deskriptorů.

Jedním z kritérií pro ideální parametr byla zvolena největší možná minimální normalizovaná diference. To zaručí dostatečný rozdíl mezi kterýmikoliv dvěma prsty. Dalším kritériem byla největší možná průměrná diference, která má za následek dostatečný odstup všech hodnot. Posledním sledovaným ukazatelem je co nejmenší maximální směrodatná odchylka. Tabulka 4.3 ukazuje výsledky těchto kritérií u testovaných parametrů.

4.5. VÝBĚR DESKRIPTORŮ

	Minimální rozdíl	Průměrný rozdíl	Směrodatná odchylka
Průměrná f.	0,0411	0,5255	0,3560
Mediánová f.	0,0290	0,5048	0,0196
Poměr f. 1/10	0,0750	0,5125	0,0384
Poměr f. 1/5	0,0480	0,5080	0,0532
Poměr f. 1/2	0,0437	0,5073	0,2415
Maximální f.	0,0495	0,5291	0,5080
Směrodatná odch.	0,2577	0,5544	0,0569
Šíře pásma	0,1682	0,5280	0,2240
Aktivita	0,2452	0,5671	0,0003
Mobilita	0,0363	0,5061	0,1978
Složitost	0,1005	0,5168	0,0563

Tabulka 4.3: Výsledná kritéria normalizovaných parametrů, nejlepší hodnoty jsou zvýrazněny červeně.

Z výsledných kritérií lze tedy vybrat čtyři deskriptory s nejlepšími parametry. Jsou to poměr frekvencí při dělení v jedné desetině spektra (při vzorkovacím kmitočtu 1 kHz je to 100Hz, což odpovídá středu dominantních frekvencí), směrodatná odchylka spektra, a Hjorthovy parametry aktivita a složitost. Na první pohled nejlépeším kandidátem se zdá být právě aktivita, nicméně u kritéria směrodatné odchylky dosahuje relativně vysokých hodnot vzhledem k hodnotám, kterých nabývá. Vezměme z tabulky 4.1 rozdíl hodnot aktivity pro prsteníček a prostředníček. Ta činí 0.00014, směrodatná odchylka tedy odpovídá celým 214% hodnoty. Rozdíl mezi těmito dvěma prsty by tedy byl silně nestabilní. Tímto problémem zbylí tři favorité netrpí.


Závěrem kapitoly je nutno dodat, že výběr pouze tří parametrů je uváděn pouze z důvodu udržení algoritmu v únosných výpočetních mezích při zachování dostatečné detekční účinnosti. V případě dalšího použití je možné využít neomezené množství parametrů pro identifikaci vzorů (prstů) a hypoteticky tak zvýšit detekční citlivost.

5. Testování a dosažené výsledky

Po navržení algoritmu je třeba vytvořit opakovatelné testy na živých subjektech. Jakým způsobem byla naměřena získaná data a výsledky navrženého algoritmu je rozebráno v této kapitole.

5.1. Postup měření

Měření probíhá v sedě při dominantní ruce položené v neutrální poloze na podložce. Snímání probíhá bipolárně se třemi elektrodami. Kladná a záporná elektroda jsou typu EL506^[19] od firmy BIOPAC Systems, Inc. Tyto elektrody jsou páskové, a to z důvodu pokrytí velkého množství svalových vláken, které mají vliv na zkoumaný pohyb. Nevýhodou se může jevit zdánlivá nemožnost rozlišit konkrétní skupiny svalstva, nicméně parametrická analýza popsaná v kapitole 4.5 tento problém zčásti odstraní. Elektroda by měla obepínat celou paži. Kladná elektroda se lepí kolem předloktí ve zhruba 4/5 délky, blíže k loketnímu kloubu. Záporná je zhruba uprostřed předloktí. Neutrální elektroda je typu EL501^[20] od stejné firmy a nachází se v oblasti karpálních kůstek. Rozmístění elektrod je znázorněno na Obrázku 5.1.



Obrázek 5.1: Rozmístění elektrod.

Signál z elektrod je přiveden do akvizičního přístroje MP36^[21] firmy BIOPAC Systems, Inc. Přístroj obsahuje zesilovač a umožňuje nastavení celé řady číslicových filtrů. Dále existují možnosti číslicového zpracování signálu pomocí přiloženého softwaru, nicméně tyto funkce nebudou z důvodu nedostatečné flexibility použity. Akvizice probíhá při vzor-

5.2. IZOMETRICKÁ KONTRAKCE

kovacím kmitočtu 1000 Hz. Nastavené filtry jsou horní propust s mezním kmitočtem 0.05 Hz a úzkopásmová zadrž kolem síťových 50 Hz.

Následné zpracování je formou funkcí a skriptů jazykem MatLab v prostředí MatLab 2011a firmy The MathWorks, Inc. Nastavení skriptů je následující: filtrace horní propustí s mezní frekvencí 20 Hz, nastavení prahu pro detekci stahu dle charakteru signálu, širší pohyblivého okna STFT 1000 vzorků, širší okna pro mediánovou filtraci 400 vzorků.

5.2. Izometrická kontrakce

Při tomto testu je měřená osoba požádána, aby zaujala neutrální polohu ruky tak, aby dlaň volně spočívala na podložce s mírně nataženými prsty. Poté je naměřeno 5 sekund této neutrální polohy, následně osoba zatlačí ukazováčkem zhruba 50% volní kontrakcí proti podložce znovu po dobu 5 sekund. Po této pauze následuje další prst a znovu pauza. Toto se opakuje až do pauzy po malíčku, kdy je měření ukončeno. Celý tento cyklus je naměřen celkem pětkrát pro jednu osobu. Měřených osob bylo 10, celkem tedy bylo naměřeno 50 signálů.

U 47 signálů byly úspěšně detekovány 4 počátky a 4 konce stahů. Zbylé 3 signály byly vyřazeny z důvodu nepříznivého poměru signál šum. Učební signál byl vytvořen ze všech signálů jedné osoby dle postupu v kapitole 4.4.1. Jako vzor prstu se vzal medián vzorů toho prstu jednotlivých signálů.

Prsty	Ukazováček	Prostředníček	Prsteníček	Malíček
do 1 s	72,34%	44,68%	65,96%	53,19%
celkově	85,11%	59,57%	70,21%	63,83%


Tabulka 5.1: Úspěšnost rozeznání jednotlivých prstů při izometrické kontrakci.

Osoba	1	2	3	4	5
Počet vzorů	12	20	16	20	20
do 1 s	83,33%	65,00%	75,00%	75,00%	55,00%
celkově	83,33%	80,00%	87,50%	85,00%	55,00%
Osoba	6	7	8	9	10
Počet vzorů	20	20	20	16	20
do 1 s	30,00%	60,00%	55,00%	43,75%	70,00%
celkově	65,00%	60,00%	65,00%	56,25%	80,00%

Tabulka 5.2: Úspěšnost rozeznání v závislosti na měřených osobách při izometrické kontrakci.

5.3. IZOTONICKÁ KONTRAKCE

Celkově bylo rozeznáno 59,04% prstů do jedné sekundy a 69,68% bylo rozeznáno do konce kontrakce. Nejúspěšněji detekovaným prstem byl ukazováček, nejméně prostředníček, který trpí nejvíce kolísajícími hodnotami deskriptorů. Prsteníček je nejvíce rozdílným prstem (viz Obrázek 5.2). To je zřejmě způsobeno relativně vysokým množstvím svalových vláken, která se do jeho kontrakce zapojují. První pokusná osoba dopadla nejlépe při rychlém rozeznání. Pokud se ovšem vezme v potaz konečná úspěšnost detekce, pak nejlepší výsledky ukazuje osoba číslo 3. Naopak nejhůře dopadla osoba číslo 6 v rámci rychlého rozeznání a osoba 5 při rozeznání konečném.



Obrázek 5.2: Kumulativní vzdálenosti od vzorů. Z grafu je patrná rozdílnost prsteníčku, který má od všech ostatních vzorů nejvyšší vzdálenost.

5.3. Izotonická kontrakce

Při izotonické kontrakci jsou signály získány stejným způsobem a stejně probíhá i vytvoření parametrů učebních vzorů. Neutrální poloha ruky je tentokrát dlaní nahoru a na rozdíl od izometrické kontrakce žádáme osobu o udržení konstantního tonu svalu za pohybu prstu. Naměřeno bylo 50 signálů, z toho 13 bylo vyřazeno. Toto vysoké číslo je

způsobené subjektivním pocitem potřebné vyšší síly pro tlačení, než pro pohyb. Dále se také uplatňuje vliv pohybových artefaktů elektrod, které filtrace není schopna vždy odstranit. Nakonec lze říci že pohyb při tomto testu je trifazický (pohyb ke dlaní, tlačení do dlaně, pohyb od dlaně), a tím se zapojují minimálně dvě skupiny vždy antagonistických svalů dynamicky v čase jednotlivých kontrakcí.

Prsty	Ukazováček	Prostředníček	Prsteníček	Malíček
do 1s	56,76%	56,76%	62,16%	40,54%
celkově	72,97%	67,57%	72,97%	48,65%

Tabulka 5.3: Úspěšnost rozeznání jednotlivých prstů při izotonické kontrakci.

Osoba	1	2	3	4	5
Počet vzorů	16	20	16	20	16
do 1s	18,75%	30,00%	50,00%	65,00%	56,25%
celkově	43,75%	55,00%	68,75%	75,00%	75,00%
Osoba	6	7	8	9	10
Počet vzorů	0	12	8	20	20
do 1s	-	91,67%	25,00%	75,00%	65,00%
celkově	-	91,67%	25,00%	75,00%	65,00%


Tabulka 5.4: Úspěšnost rozeznání v závislosti na měřených osobách při izotonické kontrakci.

Celkově bylo rozeznáno 54,05% kontrakcí do jedné sekundy a 65,54% do konce kontrakce. Nižší úspěšnost je dána zaprvé výběrem deskriptorů, protože kritéria pro výběr byla získána ze signálu s izometrickými kontrakcemi a dále obecně nižší amplitudou signálu. Nejhůře detekovaným prstem byl malíček, což je pravděpodobně způsobeno nemožností samotného ohybu malíčku některých osob. Většina měřených při ohnutí malíčku ohne i prsteníček, tudíž se k sobě tyto dva vzory přiblíží. Nejlépe dopadl opět ukazováček spolu s prsteníčkem. Zajímavá možná korelace je u osob 1, 5 a 9 ve smyslu opačných úspěšností než jak se očekávalo.

5.4. Gesta

Stejně jako u předchozích testů, i nyní jsou signály tvořeny jako 5 sekund pauza, 5 sekund vzor, 5 sekund pauza a tak dále. Rozdíl je ovšem v pohybu, který je měřenou osobou vykonáván. Byla vybrána čtveřice gest, a to postupně: pistole, palec nahoru, spock a metal. Jak gesta vypadají, je znázorněno na obrázku 5.3. Naměřeno bylo 50 signálů, vyřazen 1.

5.4. GESTA



Obrázek 5.3: Vybraná gesta.

Prsty	Pistole	Palec nahoru	Spock	Metal
do 1s	32,65%	38,78%	30,61%	32,65%
celkově	51,02%	63,27%	46,94%	36,73%

Tabulka 5.5: Úspěšnost rozeznání jednotlivých gest.

Osoba	1	2	3	4	5
Počet vzorů	20	20	20	20	20
do 1s	45,00%	20,00%	30,00%	20,00%	30,00%
celkově	55,00%	45,00%	60,00%	30,00%	55,00%
Osoba	6	7	8	9	10
Počet vzorů	20	20	16	20	20
do 1s	30,00%	25,00%	31,25%	60,00%	45,00%
celkově	40,00%	30,00%	50,00%	75,00%	55,00%

Tabulka 5.6: Úspěšnost rozeznání v závislosti na měřených osobách při gestech.

Celkově bylo rozeznáno 33,67% kontrakcí do jedné sekundy a 49,49% do konce kontrakce. Nižší přesnost je dána podobně jako u izotonických kontrakcí vícefazickým pohybem s různými průběhy kontrakce jednotlivých svalů. V tomto případě však mají na měření ještě vyšší vliv z důvodu složitější kombinace aktivací svalstva. Nejlépe se rozeznával palec nahoru, pravděpodobně z důvodu zapojení všech svalů jedním směrem. Toto tvrzení potvrzuje i nejhorší výsledek pro metalové gesto, kde polovina aktivovaného svalstva působí k flexi a druhá polovina k extenzi. Z měřených osob bylo nejvíce gest rozeznáno u subjektu 9. Jinak není patrná žádná korelace s výsledky osob z předchozích měření.

6. Závěr

Podářilo se navrhnout algoritmus pro sledování počátků a konců stahu a pro diskriminaci vzorů v SEMG signálu. Bylo rozeznáno 69,68% izometrických kontrakcí, 65,54% izotonických a 49,49% gest, při vyřazení signálů, u kterých nešlo úspěšně rozeznat počátky a konce všech stahů. Těchto signálů bylo 11,33%. K výsledkům lze konstatovat, že izometrické kontrakce mají minimální využití jak v terapeutice, tak i při řízení myoelektrických končetin. Z tohoto pohledu je nejdůležitějším parametrem schopnost rozeznat složitější pohyby, tedy gesta.

Srovnají-li se výsledky s [15], kde úspěšnosti dosahují vždy nad 90% a to i v případě rozeznání až šestnácti gest, je patrný prostor pro zlepšení. Postup [15] zahrnoval například získání 100 učebních signálů pro každý detekovaný vzor. Další možné chyby při návrhu algoritmu se mohou týkat také výběru deskriptorů, kde kritéria pro jejich výběr byla získána pouze z jednoho signálu, který se navíc sestával z izometrických kontrakcí. V rámci SEMG signálu je patrná individuální variabilita napříč měřenými subjekty a tedy i algoritmus jako celek by měl být schopen se adaptovat, což navržený algoritmus nesplňuje. V tomto velikou měrou může pomoci umělá inteligence v kombinaci s fuzzy přístupy, jak ukazuje například práce [16]. Použití algoritmu v praxi při online režimu také znesnadňují veškerá zpoždění jako délka impulzní charakteristiky FIR filtru, délka okna pro mediánovou filtraci po TKEO, či délka okna pro STFT.

Nakonec lze dodat již jen zamyšlení nad použitelností povrchové elektromyografie u řízení protéz celkově. S narůstajícími znalostmi o funkci nervů a samotné inervace svalů^[17] se nabízí možnosti, jak využít tento biosignál pro řízení protéz. Problém s takovými možnostmi je ovšem zřejmý, hledání stabilních biokompatibilních materiálů schopných nějakým způsobem přenést signál mimo tělo zatím pouze probíhá. Dalším problémem je samozřejmě invazivita. Otázkou také zůstává, jestli i po překročení tohoto problému dokážeme využít elektroneurografický signál lépe než elektromyografický, jako se to podařilo firmě Steeper, Inc. s protézou bebionic3^[18].

Použitá literatura

- [1] BASMAJIANN JV, DE LUCA CJ. *Muscles Alive - The Functions Revealed by Electromyography*. The Williams & Wilkins Company; Baltimore, 1985
- [2] CRAM R. J., DURIE M. *The History of Muscle Dysfunction and SEMG*. [online] <<http://biofeedbackinternational.com/semg4.htm>> [cit. 2014-11-27].
- [3] IQBAL A. *Neuromuscular Junction*. [online] <<http://www.mananatomy.com/basic-anatomy/neuromuscular-junction>> [cit. 2014-11-28]
- [4] MOUREK J. *Fyziologie: učebnice pro studenty zdravotnických oborů. 2., dopl. vyd.* Praha: Grada, 2012, 222 s. Sestra (Grada). ISBN 978-802-4739-182.
- [5] JELÍNEK J., ZICHÁČEK V. *Biologie pro gymnázia: teoretická a praktická část. 4. rozš. vyd.* Olomouc: Nakladatelství Olomouc, 2000, 559 s., [38] s. obr. příl. ISBN 80-718-2107-1.
- [6] NETTER F. H. *Anatomický atlas člověka: překlad 3. vydání. 2., rozš. vyd.* Praha: Grada, 2005, 32 v. ISBN 80-247-1153-2.
- [7] RAEZ M. B. I., HUSSAIN M. S., MOHD-YASIN F. (2006). Techniques of EMG signal analysis: detection, processing, classification and applications. *Biological Procedures Online*, 8, 11–35. doi:10.1251/bpo115
- [8] KOLÁŘ, R. *Lékařská diagnostická technika*. Brno, 2014. Elektronické skriptum. VUT v Brně.
- [9] MERLETTI R., PARKER A. P. *Electromyography: physiology, engineering, and non-invasive applications*. Hoboken, NJ: IEEE/John Wiley, c2004, xxii, 494 p. ISBN 04-716-7580-6.
- [10] CHANGMOK Ch., JUNG K., “A new surface electromyography amplitude estimation method”, *14th Annual Conference of the International Functional Electrical Stimulation Society (IFESS)*, 2009

- [11] LIU L., LIU P., CLANCY E. A., SCHEME E., ENGLEHART K. B. Whitening of the electromyogram for improved classification accuracy in prosthesis control. *Conf Proc IEEE Eng Med Biol Soc.* 2012;2012:2627-30. doi: 10.1109/EMBC.2012.6346503. PubMed PMID: 23366464.
- [12] JAN J. *Číslíková filtrace, analýza a restaurace signálů*. Vyd. 2. Brno: VUTIUM, 2002, 427 s. ISBN 80-214-1558-4.
- [13] DEL BOCA A., PARK D.C. Myoelectric signal recognition using fuzzy clustering and artificial neural networks in real time. *Proceedings of 1994 IEEE International Conference on Neural Networks (ICNN'94)* [online]. IEEE, 1994, s. 3098-3103 [cit. 2014-12-06]. DOI: 10.1109/ICNN.1994.374728.
- [14] MINOR, A., GONZALEZ C.A., LEIJA L. Low frequency envelopes analysis approach to regulate EMG A/K prosthesis. Proceedings of the 19th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 'Magnificent Milestones and Emerging Opportunities in Medical Engineering' (Cat. No.97CH36136) [online]. IEEE, 1997, s. 1278-1281 [cit. 2014-12-09]. DOI: 10.1109/IEMBS.1997.756608.
- [15] CHEN, X., X. ZHANG, Z.-Y. ZHAO, J.-H. YANG, V. LANTZ a K.-Q. WANG. Multiple Hand Gesture Recognition Based on Surface EMG Signal. *2007 1st International Conference on Bioinformatics and Biomedical Engineering*. IEEE, 2007, s. 506-509.
- [16] KHEZRI, M., M. JAHED a N. SADATI. Neuro-Fuzzy Surface EMG Pattern Recognition For Multifunctional Hand Prosthesis Control. In: *2007 IEEE International Symposium on Industrial Electronics* [online]. 2007 [cit. 2015-05-19]. DOI: 10.1109/isie.2007.4374610.
- [17] WARWICK, Kevin, Mark GASSON, Benjamin HUTT, Iain GOODHEW, Peter KYBERD, Brian ANDREWS, Peter TEDDY a Amjad SHAD. The Application of Implant Technology for Cybernetic Systems. *Archives of Neurology* [online]. 2003, vol. 60, issue 10 [cit. 2015-05-19]. DOI: 10.1001/archneur.60.10.1369.
- [18] Steeper Inc. *Bebionic prosthetic hand*. [online] <http://bebionic.com/the_hand> [cit. 2015-05-19]

- [19] Biopac Systems, Inc. *EL506* [online] <<http://www.biopac.com/disposable-bioimpedance-strip-electrode-8>> [cit. 2015-05-19]
- [20] Biopac Systems, Inc. *EL501* [online] <<http://www.biopac.com/foam-electrode-50>> [cit. 2015-05-19]
- [21] Biopac Systems, Inc. *MP36* [online] <<http://www.biopac.com/MP363R-Developer-Bundle>> [cit. 2015-05-19]
- [22] BALESTRA, G., M. KNAFLITZ a R. MERLETTI. Comparison between myoelectric signal mean and median frequency estimates. In: *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society* [online]. 1988 [cit. 2015-05-19]. DOI: 10.1109/iembs.1988.94932.
- [23] MOUZÉ-AMADY, M. a F. HORWAT. Evaluation of Hjorth parameters in forearm surface EMG analysis during an occupational repetitive task. *Electroencephalography and Clinical Neurophysiology/Electromyography and Motor Control* [online]. 1996, vol. 101, issue 2, s. 181-183 [cit. 2015-05-19]. DOI: 10.1016/0924-980x(96)00316-5.
- [24] LI, Xiaoyan a A.S. ARUIN. Muscle Activity Onset Time Detection Using Teager-Kaiser Energy Operator. In: *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference* [online]. 2005 [cit. 2015-05-19]. DOI: 10.1109/iembs.2005.1616259.

Seznam zkratek

AP - akční potenciál

EMG - elektromyografie

FT - fourierova transformace

FFT - rychlá fourierova transformace

FIR - konečná impulzní charakteristika

IIR - nekonečná impulzní charakteristika

MDF - mediánová frekvence

SEMG - povrchová elektromyografie

STFT - krátkodobá fourierova transformace

TKEO - teager-kaiserův energetický operátor

Seznam příloh

6.1. Skripty

main.m - hlavní spouštěcí skript

filterEMG.m - filtrace signálu

detektorStahu.m - detekce stahu pomocí TKEO

extrahujPrsty.m - pomocný skript pro segmentaci vstupního signálu

slickSpect.m - STFT v klouzajícím okně

prahuj.m - vytvoření parametrů vzorů

emgVectorize3.m - přepočet časového vývoje spektra do parametrů

vzdalenosti.m - výpočet vzdáleností parametrů spektra testovaného signálu od vzorů

boxes.m - pomocný skript pro zobrazení rozmístění kvádrů a teček znázorňujících testovaný signál ve trojrozměrném prostoru

isInside.m - pomocný skript pro *vzdalenosti.m*, který zjišťuje, zda je bod uvnitř kvádrů

6.2. Signály

x-y-z.mat, kde *x* je číslo od 1 do 10 a označuje testovanou osobu, *y* je číslo od 1 do 3 a označuje postupně testy izometrické, izotonické a gesta, *z* je číslo od 1 do 5 a označuje pokus.

s1u2kruh.mat - obsahuje signál, ze kterého byly vypočteny kritéria pro výběr parametrů