



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

ŘÍZENÍ AKTIVNÍ PROTÉZY HORNÍ KONČETINY

ACTIVE UPPER LIMB PROSTHESIS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Štěpán Brázdil

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Vratislav Harabiš, Ph.D.

BRNO 2020



Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

Student: Bc. Štěpán Brázdil

ID: 185946

Ročník: 2

Akademický rok: 2019/20

NÁZEV TÉMATU:

Řízení aktivní protézy horní končetiny

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se a proveďte literární rešerši na téma řízení aktivních protéz. 2) Zaměřte se rovněž na pokročilé metody zpracování EMG signálů a signálů dalších senzorů (akcelerometry, gyroskopy atd.) pro rozpoznávání gest. 3) Navrhněte způsob měření a zpracování EMG signálu z horní končetiny pro možnosti ovládní protézy. Jako aktivní protézu prostudujte možnosti open-source projektu InMoov. 4) Implementujte navržené metody ve zvoleném prostředí s využitím vhodně zvoleného hardware. 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: 3.2.2020

Termín odevzdání: 29.5.2020

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

prof. Ing. Ivo Provazník, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové 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 zaměřuje na oblast protetiky, především na problematiku řízení aktivních protéz. Cílem je komplexní analýza, návrh a vyhotovení protetického systému, který na základě analýzy dat ze senzorické části (primárně EMG signál z více kanálů) umožní správnou klasifikaci dle provedeného gesta a následný pohyb vytvořeného modelu horní končetiny. První části práce jsou věnovány především popisu kritických součástí a hlavních parametrů aktivního systému protézy, včetně porovnání a výběru vhodného open source řešení. Dále je uveden návrh propojení a popis jednotlivých hardwarových a softwarových komponent. Součástí je také dokumentace reálného vyhotovení, přičemž bylo využito robotické náhrady InMoov, řídicího členu Raspberry Pi a dalšího příslušenství. Dosažené výsledky jsou kriticky zhodnoceny v poslední části této práce.

Klíčová slova

Aktivní protéza, EMG, InMoov, klasifikace, řízení, Raspberry Pi

Abstract

This thesis focuses on the field of prosthetics, especially the issue of active prosthesis control. The goal is to perform a comprehensive analysis, design and construction of a prosthetic system that, based on the analysis of sensory data (such as an EMG signal from multiple channels), can correctly classify a gesture and a subsequent moving of the limb model. The first parts of the thesis are an important description of the critical components and important parameters of the active prosthesis system, including comparison and selection of available open source solutions. Next is a proposal of interconnection and description of individual hardware and software components. It also includes documentation of the real constructed system, which consists of the InMoov robotic hand, the Raspberry Pi controller and accessories. The results are critically evaluated in the last part of this work.

Keywords

Active prosthesis, EMG, InMoov, classification, control, Raspberry Pi

Bibliografická citace:

BRAZDIL, Štěpán. *Řízení aktivní protézy horní končetiny*. Brno, 2020. Dostupné také z: <https://www.vutbr.cz/studenti/zav-prace/detail/126828>. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Ing. Vratislav Harabiš, Ph.D

Prohlášení

Prohlašuji, že svou závěrečnou práci na téma „Řízení aktivní protézy horní končetiny“ jsem vypracoval samostatně pod vedením vedoucího diplomové 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 11. 4. 2020

.....
podpis autora

Poděkování

Chtěl bych tímto poděkovat svému vedoucímu Ing. Vratislavu Harabišovi, Ph.D. za ochotu a vstřícnost v průběhu vytváření této práce. Vážím si odborných rad, konzultací, přípravy a zajištění tisku na 3D tiskárně. Vzájemná spolupráce byla klíčovým faktorem pro řádné dokončení. Dále bych chtěl také poděkovat nejbližší rodině a snoubence, bez jejichž podpory a zázemí bych nebyl schopný práci zdárně dokončit. V neposlední řadě děkuji také obecně ústavu Biomedicínského inženýrství za znalosti předané v průběhu celého studia.

Obsah

Úvod.....	9
1 Úvod do protetiky	10
1.1 Základní pojmy	10
1.2 Historie a současný vývoj	11
1.3 Model horní končetiny	13
1.4 Open source projekty	15
2 Řízení protézy	18
2.1 Základní princip řízení protéz	18
2.2 Režimy řízení a možné stavy	19
2.3 Významná gesta ovládané končetiny z hlediska pacienta.....	19
2.4 Důležité specifikace v oblasti řízení protéz	21
3 Snímání signálů a klasifikace	23
3.1 Senzory aplikovatelné pro ovládání protézy	23
3.2 EMG signál	24
3.3 Klasifikační přístupy	27
4 Návrh hardwarové a softwarové části.....	32
4.1 Hardwarová část.....	32
4.2 Softwarová část	36
4.3 Popis funkčnosti.....	38
5 Realizace systému.....	40
5.1 Model končetiny.....	40
5.2 Řídící jednotka	41
5.3 Programové kódy	42
6 Testování a výsledky	47
6.1 Popis testování	47
6.2 Výsledky	49
Závěr	53
Literatura.....	54
Seznam symbolů, veličin a zkratk.....	61
Seznam příloh	62

Seznam obrázků

Obrázek 1 – amputace a exartikulací horní končetiny. Převzato a přeloženo z [45].....	10
Obrázek 2 – pasivní typ protézy. Převzato z [53].....	11
Obrázek 3 – aktivní typ protézy řízené vlastním tělem. Převzato z [53].....	12
Obrázek 4 – aktivní typ protézy řízené mikroprocesorem. Převzato z [53]	12
Obrázek 5 – kinematický model horní končetiny, převzato a přeloženo z [12]	14
Obrázek 6 – InMoov robotický model předloktí a ruky	16
Obrázek 7 – OpenBionics Prosthetic Hand, převzato a přeloženo z [30].....	17
Obrázek 8 – ADA hand v1.1, převzato z [2]	17
Obrázek 9 – schématické znázornění principu řízení aktivních protéz [22].....	18
Obrázek 10 – přehled významných gest, převzato a přeloženo z [2]	20
Obrázek 11 – princip vzniku povrchového EMG signálu, převzato a přeloženo z [29].	25
Obrázek 12 – schéma přístrojového vybavení pro snímání EMG	26
Obrázek 13 – znázornění principu SVM pro 2 třídy, převzato a přeloženo z [14].....	31
Obrázek 14 – propojení jednotlivých částí systému	32
Obrázek 15 – Raspberry Pi 2 B, převzato z [54]	33
Obrázek 16 – ADS1115 modul Adafruit, převzato z [4].....	34
Obrázek 17 – EMG zesilovač MyoWare, převzato z [1].....	34
Obrázek 18 – servomotor MG996R, převzato z [37]	35
Obrázek 19 – PWM řadič PCA9685, převzato z [13]	35
Obrázek 20 – Akcelerometr a gyroskop MCU6050, převzato z [17].....	36
Obrázek 21 – propojená řídicí jednotka s modelem končetiny	40
Obrázek 22 – schéma vodičů konektoru pro propojení protézy s řídicí jednotkou	41
Obrázek 23 – kompletní konstrukce InMoov modelu horní končetiny	41
Obrázek 24 – řídicí jednotka.....	42
Obrázek 25 – řídicí jednotka v rozdělaném stavu.....	42
Obrázek 26 – základní propojení programových kódů.....	43
Obrázek 27 – zobrazení trénovacího signálu	47
Obrázek 28 – korelační matice příznaků	48
Obrázek 29 – celková úspěšnost klasifikace na základě validačních dat	51

Seznam tabulek

Tabulka 1 – rozsahy pohybů s referencí na Obrázek 5. Převzato z [12]	15
Tabulka 2 – rozsahy pohybů s referencí na Obrázek 5. Převzato z [58]	16

ÚVOD

Pokročilé techniky řízení spadající do oblasti protetiky jsou v současné době velmi rozšířeným předmětem intenzivního zkoumání. Celá řada světově významných institucí se zabývá vlivem a možnostmi ovládní umělých náhrad končetin člověka s cílem dosažení maximálního stupně mobility. Hlavními předměty zájmu jsou jednak různorodé principy využití EMG signálu pro klasifikaci vykonaných gest, jednak zkoumání reálných možností uplatnění těchto technik v praxi.

Tato práce si klade za cíl uplatnit dostupné poznatky z těchto oblastí a navrhnout sofistikovaný, komplexní systém pro ovládní a manipulaci s umělou náhradou horní končetiny. Součástí této práce je nejen návrh funkčního systému, ale také realizace a vytvoření protézy samotné. Jednou z motivací je vytvoření systému skládajícího se z protézy a řídicího členu, jež na tomto modelu umožní v budoucnu další rozšířené testování a přímé navázání na tuto práci. Výsledky tohoto snažení mohou posloužit jako kritické zhodnocení funkčnosti open source protetických systémů a jejich nasazení do praxe, včetně diskuze o možných vylepšeních a popisu problematických částí.

První kapitola je věnována obecným principům protetiky, především pak uvedení do kontextu historie, současného vývoje a zhodnocení aktuálních trendů. Dále jsou srovnány různorodé open source protetické systémy, přičemž nejvhodnější z nich bude předmětem dalšího zkoumání v této práci.

V následující kapitole jsou představeny režimy řízení protéz horní končetiny, především s ohledem na pacienta. Důraz je kladen na praktickou uplatnitelnost, což zahrnuje detailní analýzu chování a motivaci uživatelů pro využití aktivních protéz. Pouze na základě správného pochopení potřeb uživatelů lze navrhnout a realizovat funkční a optimalizovaný systém.

Třetí kapitola pojednává o různých senzorních částech, jež lze využít v těchto systémech. Velká část je věnována obecnému principu snímání a klasifikace pomocí využití EMG signálu, jež se v současné době velmi využívá.

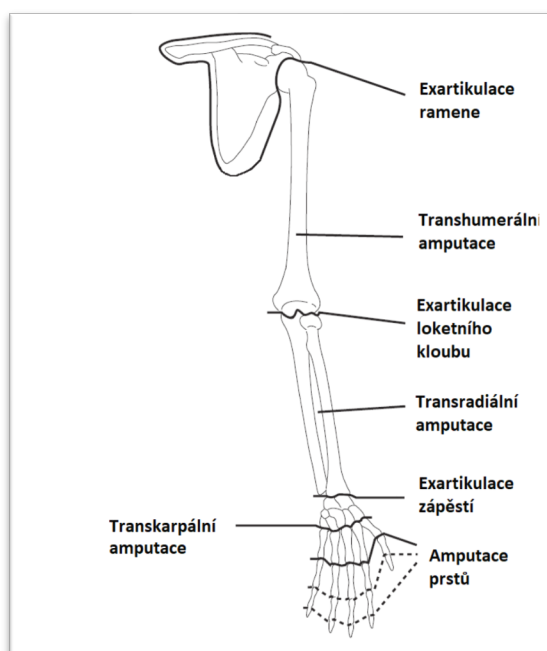
Následující dvě kapitoly jsou zaměřeny na návrh a realizaci funkčního systému, který vychází z předpokladů a poznatků z předchozích kapitol. Navržený systém je podrobně popsán s využitím blokových schémat a vývojových diagramů. Kapitola věnující se realizaci pak představuje popis částí zhotoveného protetického systému.

Poslední kapitoly prezentují dosažené výsledky, včetně podrobného komentáře a způsobu testování. Výsledky zkoumání jsou objektivně zhodnoceny, důraz je kladen na popis kritických částí systému, reálné zhodnocení uplatnitelnosti a budoucí rozšíření.

1 ÚVOD DO PROTETIKY

1.1 Základní pojmy

V první řadě je nutné vymezit základní pojmy z pohledu místa amputace. V běžné praxi jsou amputace horní končetiny rozděleny podle místa poškození do několika kategorií. Situaci nejlépe ilustruje Obrázek 1. Rozlišují se tedy amputace, kdy dochází k přerušení kosti, a exartikulace, kdy dochází k přerušení v kloubu.



Obrázek 1 – amputace a exartikulací horní končetiny. Převzato a přeloženo z [45]

Tato práce je věnována především protézám, které jsou určeny pro transradiální amputaci. Zaměření na tento typ protéz vychází z několika faktů. Hlavním důvodem je incidence amputací právě v této oblasti horní končetiny, která je spolu s amputací prstů a palce nejčastější [23] [52]. Dalším faktorem je možnost měřit EMG signály z předloktí, které mají značnou výpovědní hodnotu a z hlediska možnosti ovládní končetiny nabízí široké možnosti. Právě optimalizace a nalezení nových výpočetních metod pro klasifikaci povrchového EMG patří mezi hlavní cíle současného výzkumu. Navíc z hlediska vytvoření reálného modelu protézy pro demonstrativní účely se jedná o dostupnou variantu. [45] [68]

1.2 Historie a současný vývoj

Pro pochopení významu a návrh aktivních řízených protéz je nutné vzít v úvahu co bylo původním konceptem v oblasti protetiky, v jaké fázi vývoje se nachází v současné době a jaké trendy a vylepšení jsou očekávány do budoucna. Protézy lze dělit z hlediska konstrukce do těchto tříd:

1.2.1 Pasivní protézy

Jedná se o historicky nejstarší a také technologicky nejjednodušší řešení konstrukce protéz. Jsou to především kosmetické náhrady, které nemají pohyblivé části. Neumožňují tedy uživateli manipulaci s předměty, slouží zejména pro zlepšení stability uživatele a kosmetické účely. Z historického hlediska se jedná například o jednoduché dřevěné náhrady. Dnes se používají jakožto cenově dostupné řešení tam, kde není možné využít alternativního typu protézy. Tento typ protézy ilustruje Obrázek 2. [45] [24]



Obrázek 2 – pasivní typ protézy. Převzato z [53]

1.2.2 Aktivní protézy

Druhou velkou skupinu náhrad zaujímají dnes nejrozšířenější aktivní protézy. Z hlediska konstrukce se skládají z pohyblivých kloubů a částí, jež umožňují uživateli vykonávat základní operace. Z technologického hlediska je starším typem náhrada využívající sílu vlastního těla. Záleží na konkrétním typu konstrukce, často se lze ovšem setkat s končetinou předloktí, která využívá sadu táhel, a umožňuje tak uchopení či manipulaci s předmětem. U transkarpální amputace lze využít pohyb zápěstí pro aktivaci úchopu. V případě amputací jdoucí dále distálně lze případně využít aktivaci pomocí zdravé druhé končetiny. Hlavní výhodou tohoto řešení je jednoduchost konstrukce, spolehlivost, nízká váha, téměř bezúdržbový provoz a absence napájení. Z hlediska využitelnosti obvykle

umožňuje pouze jednoduchou flexi a extensi zakončení náhrady, případně rotaci v kloubu. Zakončení náhrady může být formou háku, modelu ruky či speciálně upraveným manipulátorem pro konkrétní aktivitu, například sport či hru na hudební nástroj. Příklad takovéto protézy je znázorněn na Obrázku 3.



Obrázek 3 – aktivní typ protézy řízené vlastním tělem. Převzato z [53]

Díky technologickému pokroku a cenové dostupnosti řídicích zařízení se lze v dnešní době stále častěji setkat se skupinou externě napájených aktivních protéz. Tyto protézy využívají především elektrickou energii k napájení servomotorů, které jsou řízeny pomocí mikroprocesoru. Standartně se využívá snímání EMG signálu nad amputovanou částí končetiny. Mikroprocesor tedy zaznamenává svalovou aktivitu a v případě zapojení dostatečného množství svalových vláken dochází k aktivaci. Přesný popis snímání EMG signálu a principu řízení protézy lze nalézt v následujících kapitolách. Konkrétní realizace je znázorněna na Obrázku 4.



Obrázek 4 – aktivní typ protézy řízené mikroprocesorem. Převzato z [53]

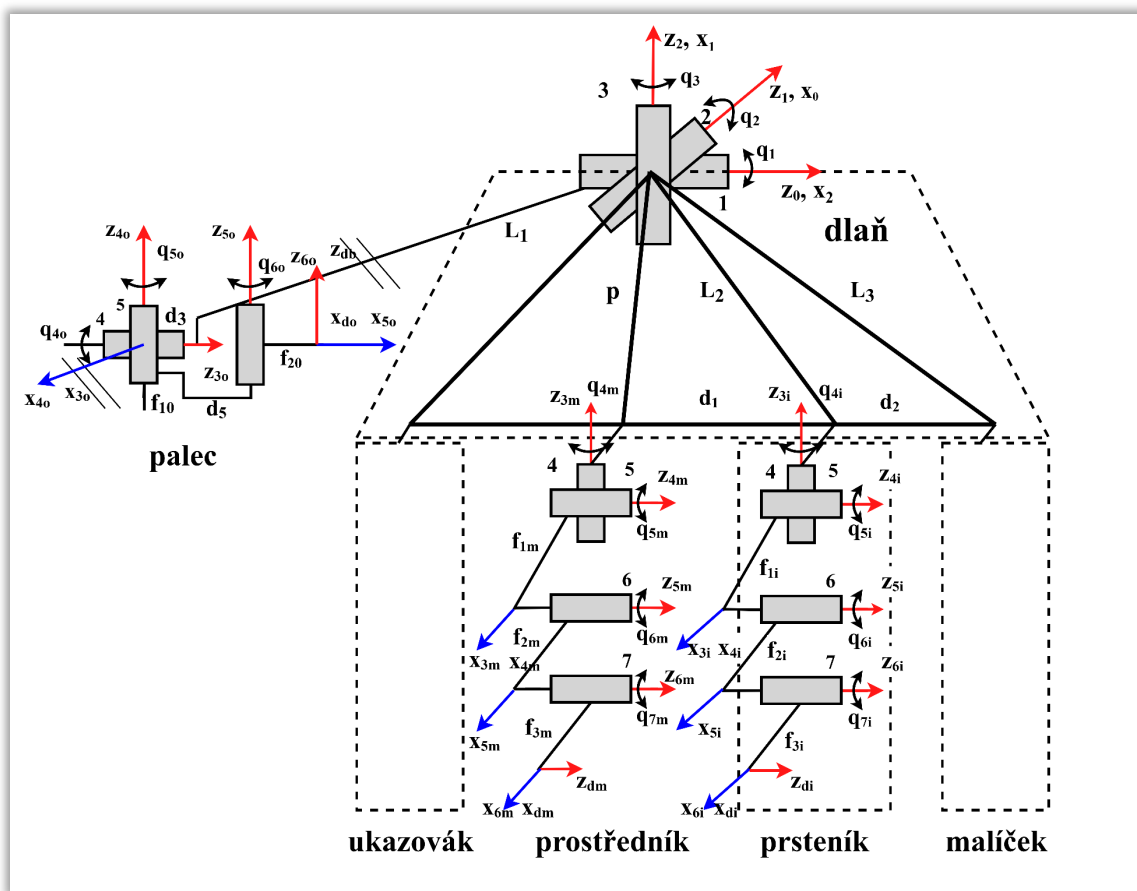
Tato práce se zabývá právě typem protéz řízených mikroprocesorem. Z hlediska budoucího vývoje se jedná o řešení, které díky výpočetnímu výkonu mikroprocesorů, snímání signálů (EMG) a inovativním algoritmům dokáže rozeznat určitá gesta vykonaná uživatelem a na tomto základě přesně řídit pohyb protézy. Tento přístup umožňuje vykonávat složitější operace, zkvalitní život lidí, kteří utrpěli amputaci končetiny, a ulehčí tak vykonávání běžných činností. Trend míří směrem k využití malých, přenosných, a přesto dostatečně výkonných embedded¹ systémů, které dokážou vyhodnocovat a řídit chod protézy. Nevýhodou takového řešení je závislost na přístupu k elektrické síti, vyšší náklady, nutnost dostatečné technické schopnosti uživatele a motivace učit se zacházet s protézou. Nutno podotknout, že se jedná mnohdy o velmi nákladné systémy, proto jsou dnes oblíbené tzv. open source systémy², o kterých bude zmíněno v nastávajících kapitolách. [45] [24]

1.3 Model horní končetiny

Z hlediska modelování a vytváření umělých náhrad končetin s definovanými možnostmi pohybu je podstatné uvést kinematiku a detailní popis modelu vycházející z anatomie člověka. Obecnou snahou je realizace systému, jehož rozsah a možnosti pohybu jsou nejpodobnější lidskému tělu. Teoreticky je možné vytvořit systém, který dokáže uživateli nabídnout rozšířené možnosti trajektorie pohybu protézy ve srovnání s limity končetiny. Pro obecné aplikace je ovšem dostačující dosáhnout parametrů, které korespondují s možnostmi lidského těla. Takový systém náhrady končetiny je znázorněn na schématu na Obrázku 5.

¹ Vestavěný systém, zpravidla využívající mikrokontrolér a další hardwarové a softwarové prostředky sloužící především pro vykonávání konkrétní specializované funkce

² Systémy využívající volně dostupný zdrojový kód algoritmů a dalších prostředků například 3D modely, návody apod.



Obrázek 5 – kinematický model horní končetiny, převzato a přeloženo z [12]

Schéma zobrazuje zjednodušení reálného kinematického systému zápěstí, palce a jednotlivých prstů ruky. Je patrné, že celkový systém obsahuje celkem 22 DOF¹, což vytváří poměrně složitý kinematický systém. Takto popsáný systém je možné využít pro simulaci a definování trajektorie jednotlivých částí systému, což není pro tuto práci důležité. Z hlediska vytváření protézy je ovšem podstatné popsat jednotlivé klouby systému a dovolené rozsahy pohybu lidské ruky. Uváděné hodnoty v Tabulce 1 představují průměrné kinematické schopnosti jedince, reálně se liší dle individuálních anatomických predispozic. Vůči těmto hodnotám lze následně porovnávat kinematické možnosti jednotlivých protéz a jejich schopnost vykonávat různé činnosti v lidském životě. [12] [26] [56]

¹ DOF – Stupeň volnosti

Tabulka 1 – rozsahy pohybů s referencí na Obrázek 5. Převzato z [12]

Zápěstí		Palec		Ukazovák		Prostředník		Prsteník		Malíček	
Index	rozsah pohybu [°]	Index	rozsah pohybu [°]	Index	rozsah pohybu [°]	Index	rozsah pohybu [°]	Index	rozsah pohybu [°]	Index	rozsah pohybu [°]
q1	< -90; 80 >	q4	< -10; 20 >	q4	< -10; 20 >	q4	< -10; 20 >	q4	< -10; 20 >	q4	< -10; 20 >
q2	< -30; 120 >	q5	< 0; 80 >	q5	< -15; 85 >	q5	< -15; 85 >	q5	< -15; 85 >	q5	< -15; 85 >
q3	< -15; 30 >	q6	< 10; 90 >	q6	< 0; 90 >	q6	< 0; 90 >	q6	< 0; 90 >	q6	< 0; 90 >
				q7	< 0; 70 >	q7	< 0; 70 >	q7	< 0; 70 >	q7	< 0; 70 >

1.4 Open source projekty

Vzhledem k dostupnosti a otevřenosti zdrojů informací a široké podpory vývojářů bude v této práci využito jednoho z mnoha open source protetických systémů. V této kapitole bude uveden stručný přehled modelů a také zhodnocení hlavních pozitiv a negativ, na jejichž základě bude pro tuto práci vybrán vhodný typ. Uvedeny jsou systémy, které nabízí dostatečné množství materiálů pro možnosti replikování, tj. vytvoření modelu. Je dostupná celá řada experimentálních modelů s širokými možnostmi uplatnění, ovšem bez řádné dokumentace, proto nejsou brány v úvahu.


1.4.1 InMoov

Jedná se o projekt, který si klade za cíl vytvořit a nabídnout návod na sestavení nízkonákladového robota. Je zde detailně popsán postup výroby jednotlivých robotických částí, pro tuto práci je stěžejní část výroby robotické ruky a předloktí. Navzdory primárnímu účelu a využití pro výrobu kompletního robota lze tuto část využít také pro možnosti protetiky. Vzhledem k využití šesti servomotorů poskytuje tedy celkem 6 DOF, což umožňuje vykonávat řadu základních operací využívaných v běžném životě. Konkrétní rozsahy pohybu jsou uvedeny v Tabulce 2. Umožňují tedy flexi a extensi jednotlivých článků prstů a rotaci v zápěstí. Vzhledem k využití rotačních servomotorů je nutné obsazení značného prostoru pro jejich správné ukotvení, především pak v oblasti předloktí. Z tohoto důvodu by bylo možné využít model jakožto protetickou náhradu v případě transradiální amputace končetiny (co nejvíce distálně). Jedná se tedy o řešení určené pro specifické uživatele. Z hlediska použitých dílů jde o cenově dostupné řešení. Uplatnění tedy nalezne spíše v modelování a testování pro aplikace návrhu a výzkumu protetických systémů než pro reálné nasazení, a to především z již zmíněného důvodu omezení na úzkou skupinu uživatelů s amputací pro celkovou vyšší hmotnost protézy. Systém je uzpůsoben pro zakomponování tlakových snímačů, což může poskytnout další

možnosti pro následné zpracování a klasifikaci signálů. Konkrétní reálnou podobu protézy lze nalézt na Obrázku 6. [19]

Tabulka 2 – rozsahy pohybů s referencí na Obrázek 5. Převzato z [58]

Zápěstí		Palec		Ukazovák a prostředník		Prsteník a malíček	
Index	rozsah pohybu [°]	Index	rozsah pohybu [°]	Index	rozsah pohybu [°]	Index	rozsah pohybu [°]
q1	-	q4	< 0; 40 >	q4	-	q4	-
q2	< -90; 90 >	q5	< 0; 60 >	q5	<0; 100>	q5	< 0; 80 >
q3	-	q6	<0; 60>	q6	<0; 80>	q6	< 0; 80>
				q7	<0; 60>	q7	< 0; 70 >




Obrázek 6 – InMoov robotický model předloktí a ruky

1.4.2 OpenBionics Prosthetic Hand

Cílem navrženého systému bylo snížení celkové hmotnosti a zjednodušení ovládání protézy. Lze jej zařadit do kategorie semi-aktivních systémů, neboť je navržen pro implementaci pouze jednoho servomotoru. Samotný výběr pohybu dané části je dosažen zámkovým systémem článků prstů. Servomotor tedy ovládá pouze flexi a extenzi částí, které jsou na základě výběru uživatele odemknuté. Tento systém tedy na jednu stranu umožňuje snížení výpočetní náročnosti, na stranu druhou zatěžuje uživatele potřebou detailní znalostí zámkového systému a jeho ovládání. Autoři podrobně popisují postup výroby a implementaci, což je velkou výhodou. Může být uplatněn pro transradiální

amputace horní končetiny (bez ohledu na místo amputace). Ilustrační reálnou podobu modelu lze nalézt na Obrázku 7. [30]



Obrázek 7 – OpenBionics Prosthetic Hand, převzato a přeloženo z [30]

1.4.3 ADA hand v1.1

Toto řešení nabízí propracovaný, kompaktní systém, který umožňuje široké možnosti řízení. Originální návrh obsahuje 5 lineárně řízených servomotorů, což snižuje celkovou hmotnost a velikost protézy. Protéza zasahuje pouze po část zápěstí, lze ji tedy s výhodou využít pro všechny druhy transradiální amputace. Projekt nabízí vlastní hardwarové řešení z hlediska návrhu mikroprocesoru a periferních zařízení. Obsahuje podrobný manuál a další potřebné soubory. Z hlediska vlastností se jedná o nejlepší ze všech zmíněných řešení, hlavním problémem pro implementaci je cena. Protéza obsahuje lineární servomotory, které svou cenou mnohonásobně převyšují běžně používané rotační servomotory. [2]

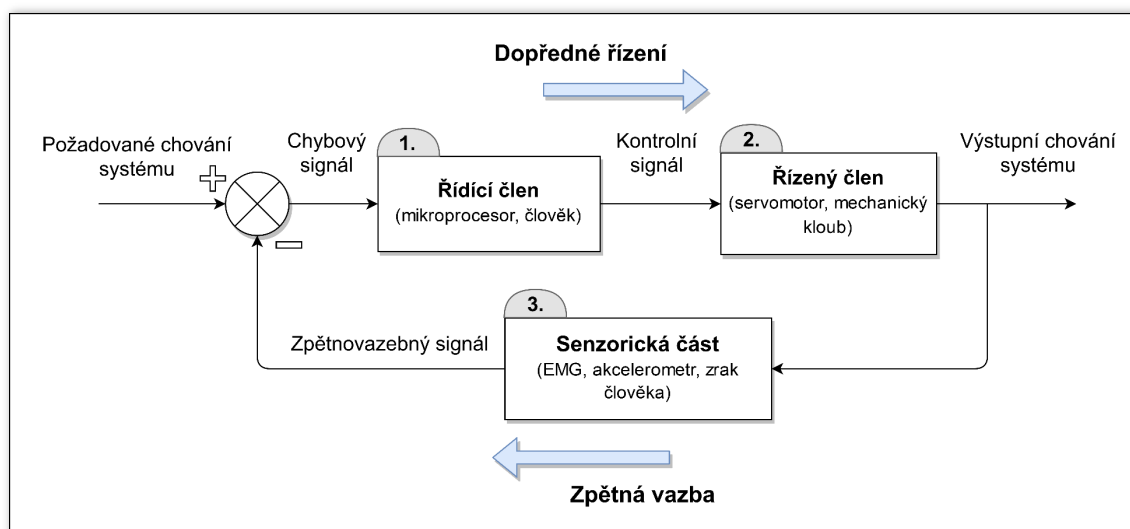


Obrázek 8 – ADA hand v1.1, převzato z [2]

2 ŘÍZENÍ PROTÉZY

2.1 Základní princip řízení protéz

Teorie řízení aktivních protéz se opírá o všeobecné poznatky z robotiky a řídicích systémů. Vychází většinou z uzavřeného zpětnovazebního systému, jehož princip je ilustrován Obrázkem 9. Konkrétní výběr včetně zdůvodnění a detailního popisu jednotlivých členů celého systému bude součástí samostatné kapitoly, jež se zaměřuje na návrh řešení této práce.



Obrázek 9 – schématické znázornění principu řízení aktivních protéz [22]

Jedná se o zjednodušené schéma, které nedefinuje podobu jednotlivých členů systému. Vyplývá tedy, že daný systém může být uplatňován jak u externě napájených aktivních protéz, tak u protéz, jež jsou řízeny pomocí vlastního těla. Rozdíly spočívají ve využití rozdílných řídicích a senzorických jednotek.

Pro případ řízení pomocí vlastního těla je řídicím členem sám člověk (resp. neurální systém), řízeným členem může být mechanický kloub protézy či sada táhel a senzorickou částí pak optický systém uživatele, kdy se na základě vizuálního zhodnocení aktuálního stavu polohy protézy upravuje další krok řízení.

V druhém případě je řídicím členem mikroprocesor, který zpracovává signály z přijatých senzorických částí a na jejich základě vyhodnocuje, jakým způsobem je ovládána akční jednotka, standardně servomotor. Požadované chování systému je klasifikačním problémem, kdy na základě vytvořeného modelu dochází k porovnávání informací mezi naučeným modelem a vnějšími stavy, jež jsou reprezentovány pomocí nasbíraných údajů ze senzorické části. [34] [22]

2.2 Režimy řízení a možné stavy

Z hlediska praktického využití protézy a možnosti zavedení systémů do praxe je nutné definovat dva základní režimy řízení.

2.2.1 Automatický režim

Jedná se o způsob řízení, který nevyžaduje vnější zásah do ovládacího systému. Tento režim je cílovou metou, ke které se veškeré systémy snaží přiblížit. Využívá především systému zpětné vazby, kdy na základě senzorů, které interagují s okolím, dokáže změnit režim řízení. V praktické realizaci tedy využívá vytvořený model (typicky vytvořený pomocí klasifikačních algoritmů). Tento model je natrénovaný na vstupních datech a díky znalosti trénovacích dat je vytvořen soubor tříd, které definují následnou klasifikaci. Ke každé třídě je následně deklarováno chování protézy, tedy její kinematika, jež je řízena typicky pomocí servomotorů. Běžně se jedná o měření EMG signálu (případně dalších) v reálném čase a díky zapojení rozdílných svalových skupin dochází k rozeznávání vykonaných gest na základě předem natrénovaného modelu. Nevýhodou celého systému je určitá míra nestability a závislosti na vnějším prostředí. V případě poruchy či rušení ovládacího signálu dochází k omezení klasifikační schopnosti, případně se zcela znemožňuje ovládání uživatelem. V některých případech je navíc fyziologicky i fyzikálně nemožné využít daný signál pro klasifikaci (z důvodu překryvu v klasifikačním prostoru), proto se využívá buďto pouze manuálního režimu, nebo kombinace obou přístupů.

2.2.2 Manuální režim

Manuální režim se využívá všude tam, kde není možné uplatnit automatickou klasifikaci, nebo pro případ výskytu poruchových stavů. Tento režim se vyznačuje buďto úplným, nebo jen dílčím omezením zpětnovazebné části řídicího systému. Nejčastěji se využívá manuálního nastavení, kdy uživatel ručně nastaví například pomocí přepínače či tlačítka zvolený režim řízení protézy. Mikrokontroler tedy dostává okamžitý příkaz k ovládání motorické části protézy a dochází k jeho provedení. Jedná se standardně o záložní systém řízení. Nevýhodou je jednak diskomfort uživatele, neboť je nutné zadávat řídicí příkazy ručně, jednak lze očekávat snížení funkčnosti protézy.


2.3 Významná gesta ovládané končetiny z hlediska pacienta

Život pacienta po amputaci nabízí omezené možnosti manipulace s předměty a jejich interakci. Jelikož se řízení protézy a částečně také senzorická část odvíjí od náročnosti klasifikace z hlediska množství rozpoznatelných gest, je nutné analyzovat, která gesta jsou zásadní z pohledu pacienta. Důkladnou analýzou lze zjednodušit problém klasifikace a snížit výpočetní náročnost. Větší počet klasifikačních gest zvyšuje chybovost a přispívá

k zhoršení klasifikačních schopností, což dokazují také výsledky práce [25]. Z toho důvodu je tedy nutné systematicky zvolit ta gesta, která skutečně přispějí ke zlepšení manipulačních schopností pacienta.

Práce [47] a [10], u nichž jsou získané poznatky doloženy reálnými daty z vypracovaných dotazníků, dokládají hlavní preference pacientů. Je zvláště preferována robustnost a spolehlivost klasifikátorů ve srovnání s počtem rozpoznatelných gest a rychlostí odezvy. Dále pacienti upřednostňují možnosti pohybu zápěstí před možností ovládat rychlost pohybu protězy či implementování rozšířené zpětné vazby.

Mezi základní využívaná gesta patří cylindrický úchop, jenž umožňuje manipulaci s objekty a úchop cylindrických objektů, například láhve. Gesto laterálního úchopu je využíváno pro specifické úkoly, čímž je úchop a držení plochých předmětů, například pro vkládání platební karty. Podobný účel může mít tzv. trojitý úchop, který se uplatňuje pro držení psacích pomůcek, pomůcek při vaření apod. Opakem těchto úchopových pohybů je extenze článků prstů, což umožní následně vykonávat úchopová gesta. Gesto nataženého ukazováku nabízí možnost manipulace s tlačítky, případně psaní na klávesnici. Mezi další významné pohyby končetiny patří také rotační pohyb v zápěstí (supinace a pronace), případně možnost samostatného ovládnutí palce. Zobrazení těchto gest ilustruje Obrázek 10. [2] [10] [23] [42] [47]



Obrázek 10 – přehled významných gest, převzato a přeloženo z [2]

2.4 Důležité specifikace v oblasti řízení protéz

V rámci řízení protézy pomocí mikrokontrolerů lze vymezit základní pojmy, které jsou nezbytné pro popis a funkčnost protetických systémů.

2.4.1 Doba odezvy

V teorii řízení protéz se daný pojem nejčastěji uvádí jako časový úsek mezi zahájením vykonaného gesta (tzn. počátek svalové kontrakce) a samotným provedením protézou. Tato doba zahrnuje příjem a zpracování dat ze sensorické části, vyhodnocení klasifikace a vykonání daného úkolu pomocí aktivního členu. Tato odezva je závislá jak na výkonu výpočetní jednotky, který nelze regulovat, tak na části zpracování dat. V této části je možné nastavit velikost vstupního okna, které ovlivní dobu odezvy systému. Volba nastavení velikosti okna je kompromisem mezi množstvím informace, a tedy i klasifikační schopnosti, kterou lze ze signálu získat. V praxi tedy malá velikost okna sníží v zásadě zpoždění systému, ovšem za cenu vyšší chyby klasifikace. Je tedy z hlediska uživatele nutné nalézt správnou dobu odezvy, aby bylo zaručeno pohodlné a intuitivní ovládání protézy.

V odborné literatuře [18], [57] je na podložených datech otestováno, že přijatelné časové okno z hlediska správné klasifikace je v rozmezí 150-250 ms. Další práce [16] testuje vliv zpoždění odezvy systému na úspěšnost prováděných úkonů pro jednoduchý protetický systém. Dle dosažených výsledků nelze pozorovat žádný zásadní rozdíl v případě odezvy do 150 ms. V případě zpoždění do 300 ms docházelo k poklesu úspěšnosti uživatele v řádech 10 %. Vlivem zaměření se na jednu konkrétní úlohu uživatele mohou být výsledky pro konkrétní aplikace rozdílné. Systémy, které využívají kratší časová okna, mohou v závislosti na postprocessingových úpravách klasifikace dosahovat podobných výsledků jako v případě zvolení delšího časového okna. V zásadě lze tedy konstatovat, že je snahou o dosažení co nejmenší hodnoty odezvy systému, která je v důsledku limitována pouze výpočetními možnostmi.

2.4.2 Vzorkovací frekvence

Velmi diskutovaným tématem v rámci protetických systémů je vliv vzorkovací frekvence na výsledky klasifikace. V běžné klinické praxi je běžně uvažovaná vzorkovací frekvence pro EMG signály minimálně 1000 Hz. V rámci protetiky je obvykle nutné počítat s nižší vzorkovací frekvencí s ohledem na omezený výkon, paměťové možnosti mikrokontrolerů a počet kanálů EMG signálu. Běžně dostupné komerční produkty využívané na trhu, například Myo Armband od společnosti Thalmic Labs, který je testován v práci [36], využívají vzorkovací frekvenci 200 Hz. V rámci této práce autoři prováděli analýzu, jaký je rozdíl v klasifikaci mezi tímto systémem a systémy využívajícími vzorkovací frekvenci

1000 Hz. Rozdíl v chybě klasifikace se pohybuje přibližně 4 %. Také práce [51] testuje rozdíl v klasifikaci mezi různými vzorkovacími frekvencemi. V zásadě lze v případě vhodně zvolených příznaků klasifikace dosáhnout stejné, nebo podobné úspěšnosti. Běžné příznaky v časové oblasti vykazovaly větší chybovost, proto v rámci této práce autoři vytvořili nové příznaky, které úspěšně kompenzovaly nižší vzorkovací frekvenci. Dále některé typy příznaků vyžadují větší počet vzorků, což v rámci zachování určitého časového okna může zvyšovat dobu odezvy systému, nebo úplně znemožňují použití daného příznaku.

2.4.3 Rychlost komunikace IO (baud rate)

V zásadě souvisí s dobou odezvy protězy. Je nutné zvolit takovou rychlost komunikace jednotlivých modulů, která v rámci přenosu dat a následného zpracování signálů a klasifikace umožní dosáhnout požadované odezvy. V praxi závisí na typu komunikace a nastavení maximální možné rychlosti, která je dána řadou faktorů, mezi než patří například délka přenosových vodičů a možné okolní zarušení.

2.4.4 Přesnost klasifikace

Z důvodu porovnání úspěšnosti jednotlivých klasifikátorů s ohledem na typ použitého klasifikátoru a dalšího nastavení (např. počet použitých elektrod, místo nalepení elektrody) je nutné zavést konkrétní metriku. Mezi základní metriky pro určení přesnosti klasifikace patří:

Přesnost (accuracy):

$$ACC = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

F1 skóre:

$$F1 = \frac{2 * Re * Pr}{Re + Pr} \quad (2)$$

Výpočet vychází z matice záměn (confusion matrix), přičemž TP (true positive) je správná pozitivní hodnota; TN (true negative) je správná negativní hodnota; FP (false positive) falešně pozitivní hodnota; FN (false negative) falešně negativní hodnota; Re (recall) znamená senzitivitu a Pr (precision) pak pozitivní prediktivní hodnotu.

[21]

3 SNÍMÁNÍ SIGNÁLŮ A KLASIFIKACE

3.1 Senzory aplikovatelné pro ovládání protézy

Data ze zpětnovazební části protetického systému jsou esenciální pro možnosti využití automatické klasifikace. Je k dispozici celá řada přístupů využívajících odlišné fyzikální principy. Kombinací dat z těchto různých modalit lze dosáhnout zlepšení klasifikačních schopností a robustnosti celého systému. Lze tak implementovat nové funkce, které by při použití jedné modality nebyly možné. V komerční sféře je využíváno především snímání EMG signálu, což pro potřeby pokročilé analýzy a klasifikace signálu není dostatečné. Jednotlivé typy senzorů budou popsány v následujících podkapitolách. Stručný popis funkce senzoru je doplněn o možnosti uplatnění v protetických systémech včetně uvedení příkladu, pro jaké rozeznání gest jej lze využít. Z důvodu majoritního využití EMG signálu je podrobný popis funkce a principu snímání uveden v samostatné kapitole. [55]

3.1.1 Akcelerometry a gyroskopy

Zařízení, která dokážou detekovat rotační či lineární zrychlení, se nazývají akcelerometry. Pro určení směru natočení senzoru v jednotlivých rovinách x, y, se využívají gyroskopy. V protetických systémech se jedná o hojně využívané elementy. Hlavní uplatnění v rámci dostupných vědeckých prací tkví v možnosti zjišťovat pozici jednotlivých částí protéz v prostoru, případně predikovat chování protézy na základě zjištěných dat o trajektorii pohybu konkrétní části. Jak již bylo zmíněno, převážná většina experimentálních systémů využívala senzory pro vícesegmentové typy protéz, což zahrnuje především transhumerální amputace. [31] [55]

V rámci transardiálních amputací lze uvažovat možné využití především v oblasti vylepšení klasifikace provedených gest. Může se jednat konkrétně o rozpoznání supinace a pronace (proveditelnost měření záleží na rozsahu amputace), případně specifickou úpravu provedených gest v závislosti na poloze protézy. Jako příklad je možné uvést zvýšení síly servomotorů v případě vertikálního natočení protézy pro zdvih předmětů z podložky. Další možností uplatnění může být snížení prahové hodnoty klasifikátoru v případě konkrétního natočení protézy v prostoru, například pro specifitější ovládání protézy v rámci klidové polohy (držení psacích pomůcek apod.).

3.1.2 Tlakové senzory

Pro možnosti detekce uchopení předmětů nebo možnosti úpravy intenzity stisku lze využít tlakové senzory. Existuje řada konstrukčně odlišných senzorů, s výhodou lze

využít například piezorezistivní snímače. Jejich kompaktní rozměry, vysoká odolnost a jednoduchá implementace patří mezi hlavní přednosti. [55] [11] [44]

3.1.3 Ultrazvukové senzory

Z důvodu přizpůsobení držení předmětů a jejich samotné detekce v blízkosti protézy se využívají senzory určující vzdálenost mezi předmětem. Kromě běžně uvedených ultrazvukových senzorů lze samozřejmě využít různých fyzikálně odlišných principů detekce vzdálenosti, např. pomocí laserového paprsku. Z hlediska ceny a možnosti implementace jsou ovšem využívány minoritně. [55] [32]

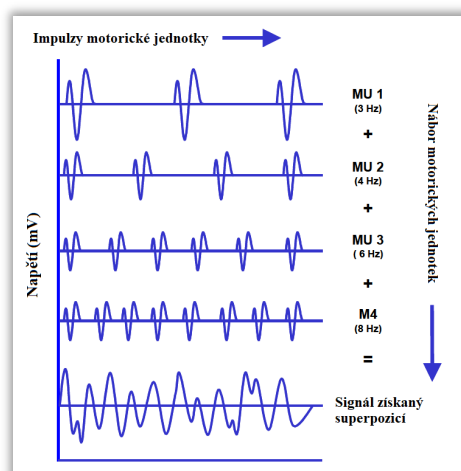
3.1.4 Snímání biologických signálů

V rámci protetických systémů se jedná o nejvíce diskutovanou oblast. Nabízí jednoduchou implementaci v rámci protézy a široké možnosti uplatnění z hlediska rozpoznání gest. V praxi se nejvíce využívá zpracování EMG signálu, existují ovšem experimentální systémy, které využívají dalších modalit, například detekci a analýzu EEG signálu. Nejedná se ovšem o řešení dostupné široké veřejnosti, především z důvodu nízké klasifikační schopnosti, složité implementace a náročnému tréninku. [55] [7] [18]

3.2 EMG signál

Elektromyografie patří k základním diagnostickým metodám využívaným v medicíně pro hodnocení svalové aktivity. S rozvojem výpočetní techniky nabízí stále širší uplatnění napříč různými technickými obory v oblasti řízení a ovládání. Základním stavebním kamenem teorie vzniku EMG signálu je motorická jednotka (MU), která přenáší vzruchy neurální soustavy na akční potenciál, jenž vyvolá kontrakci svalových vláken. V případě povrchové akvizice signálu je snímána řada akčních potenciálů z jednotlivých MU, jejichž superpozicí vzniká výsledný pozorovaný signál. Princip této superpozice je znázorněn na Obrázku 11. Počet MU a frekvence akčních potenciálů ovlivňují výsledné snímané napětí signálu. Z tohoto důvodu lze získat nejen informaci o zapojení určité

svalové skupiny, ale i podrobnosti o síle stahu svalu, případně na základě frekvenční analýzy zkoumat svalovou únavu.

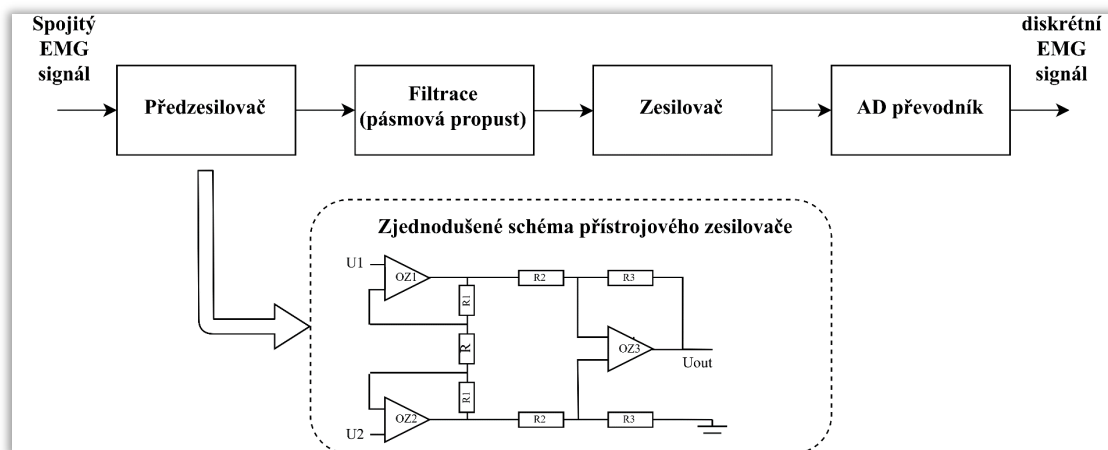


Obrázek 11 – princip vzniku povrchového EMG signálu, převzato a přeloženo z [29]

Kvalita snímaného signálu je závislá na výběru vhodné přístrojové techniky, což zahrnuje správný výběr přístrojového zesilovače, výběr vhodných elektrod a následné digitální zpracování. Základní specifikace a požadavky především na přístrojové zesilovače jsou uvedeny v následující kapitole. [29] [65]

3.2.1 Přístrojové požadavky

Pro správnou akvizici signálu je nutné dodržet několik základních kritérií. Schéma celého přístrojového vybavení včetně detailnějšího znázornění přístrojového zesilovače je na Obrázku 12. V první řadě se zvolí vhodný přístrojový zesilovač. Z hlediska praktického uplatnění je nutné znát celkové zesílení signálu, které závisí na využitých obvodech zapojení OZ. Dále se určí vstupní odpor zesilovače, který musí být maximální, aby neovlivňoval měření napětí svalové aktivity. Výstupní odpor musí být naopak minimální. Dále je hodnoceno CMRR, které vypovídá o schopnosti eliminovat soufázové napětí signálu (rušení). Z dalších bloků je většinou nutné využít filtraci, která může být také provedena v digitální oblasti zpracování signálu. Tato filtrace především omezuje drift signálu, který je způsoben pohybem elektrody na kůži, případně zabraňuje aliasingu, který může být způsoben zvolením nedostatečné vzorkovací frekvence. V případě potřeby lze zvolit pásmovou zádrž pro potlačení síťového brumu. Obecně je snahou omezit filtraci na minimální úroveň, a to především z důvodu zachování originální podoby signálu či zachování nejnížší možné odezvy. [65]



Obrázek 12 – schéma přístrojového vybavení pro snímání EMG

3.2.2 Specifické vlastnosti EMG signálu s ohledem na klasifikaci

Existuje celá řada parametrů, které přímo, či nepřímo ovlivňují kvalitu snímaného signálu, a tedy i klasifikační možnosti. Mezi takové parametry patří vliv pozice končetiny ve fázi učení. V případě učení parametrů klasifikačního algoritmu pouze pro jednu pozici (většinou se jedná o stabilní pozici, která neodpovídá reálné situaci používání protézy) může následně při nedodržení této pozice docházet k poklesu klasifikační úspěšnosti. Je to dáno především odlišným svalovým zatížením (i z hlediska gravitačních sil), a tedy změnou EMG signálu, který nebyl natrénován na dané hladině. Možným řešením těchto problémů je zavést delší trénovací cyklus, který pokryje všechny základní pozice snímání dané končetiny (například ve 3 kolmých osách), případně zavedení přídavného senzoru (gyroskop). Data ze senzoru budou obsahovat informaci o prostorovém umístění a budou součástí příznakového prostoru klasifikátoru. [18] [63] [28]

Dalším důležitým faktorem je síla svalové kontrakce. Výsledná klasifikace je značně ovlivněna trénovacím postupem. V běžné praxi se pak využívá maximálních svalových kontrakcí. Ve fázi vybavování je mnohdy z důvodu svalové únavy nemožné dlouhodobě reprodukovat maximální kontrakci, a tak dochází k poklesu úspěšnosti. V opačném extrémním případě (minimální kontrakce) může docházet opět k poklesu úspěšnosti, a to z důvodu překrývání úrovní signálu pro různá gesta. Z hlediska fáze učení je tedy výhodné využít různé hladiny kontrakce (například 20 % až 80 % maximální kontrakce), což dostatečně pokryje rozptýl signálu. [18] [28]

Existuje celá řada dalších faktorů, mezi něž lze zařadit tzv. cross-talk¹, který z důvodu nevhodného umístění elektrod znemožní odlišit jednotlivé svalové skupiny. Dalším faktorem je pak svalová únava, která byla zmíněna již dříve, a může způsobit změnu tvaru či spektra signálu. Roli hraje také časové hledisko, například z důvodu zvýšení vodivosti tkáně (pocení), změna polohy elektrody či kombinace předchozích faktorů. Prostředkem pro omezení vlivu časového hlediska je pravidelné přetrénování klasifikátoru, či využití progresivních metod online klasifikace, což je ovšem výpočetně náročné. [18]

3.3 Klasifikační přístupy

V případě klasifikačního problému EMG signálu pro rozpoznávání gest lze využít celou řadu metod. Odborné publikace nabízí srovnání běžně používaných metod včetně výběrů parametrů pro daný model. Nevýhodou těchto srovnání je skutečnost, že většina experimentů nebyla vykonána za stejných podmínek, a tak srovnání účinnosti klasifikace nelze pokládat za zcela směrodatné. Je to dáno jednak různým nastavením procedury testování (různý počet elektrod, různé polohy měření a vykonávané činnosti), různým výběrem příznaků získaných ze signálu a odlišným hardwarovým vybavením. Lze ovšem z nepřeberného množství klasifikátorů vybrat ty, které byly otestovány v rámci několika publikací, a na základě vlastního testování pro specifické nastavení protézy (např. počet elektrod) vybrat nejlepší z nich.

Obecný řetězec klasifikace je takový, že se určí vhodný klasifikační model. Z akvizičních dat se následně vyberou vhodné příznaky tak, aby docházelo k nejmenší korelaci mezi nimi. Cílem je tedy získat maximální informační hodnotu z dat tak, aby došlo k úspoře paměťového místa i celkového výpočetního výkonu. Tyto příznaky vstupují do vybraného klasifikátoru a daný model se natrénuje na těchto datech. V poslední fázi je model validován na testovacích datech. [14]

3.3.1 Výběr příznaků

Autoři práce [49], kteří odkazují i na další vědecké studie vytvořili komplexní přehled příznaků využitých pro účely klasifikace EMG signálu. Těchto příznaků jsou desítky, proto je nutné vybrat ty, které umožňují rychlou a efektivní práci s daty. Autoři dále porovnávají několik skupin příznaků a vyhodnocují nejlepší samostatný příznak pro klasifikaci, dále našli nejvhodnější kombinaci různých příznaků. Jak již bylo zmíněno, úspěšnost klasifikace záleží na konkrétním nastavení, což dokazuje odlišnost výsledků ve

¹ Cross-talk – překryv signálu EMG z různých svalových skupin (většinou z důvodu nevhodné pozice elektrod)

srovnání s jinými autory, například v pracích [50], [51] a [40], kde byla neúspěšnější jiná sada příznaků.

Příznaky lze rozdělit do dvou hlavních kategorií, a to na časovou oblast a frekvenční oblast (v některých případech se využívá časově-frekvenční oblasti). Pro možnosti klasifikace EMG jsou nejvhodnější příznaky v časové oblasti, neboť většinou umožňují rychlejší výpočet a ve srovnání s frekvenčními příznaky obsahují stejnou výpovědní hodnotu (viz [50] [49] [48]). Proto následující odstavce budou popisovat právě příznaky z časové oblasti, které v rámci zmíněných publikací představují co největší shodu z hlediska úspěšnosti klasifikace. Samotný výběr nejvhodnější kombinace musí být ovšem vždy stanoven empiricky s ohledem na konkrétní nastavení. Následující příznaky proto představují průřez a doporučení pro následné využití.

MAV (mean absolute value) – velmi využívaný příznak v metodách zpracování signálů. Vyjadřuje informace o energii v časové oblasti a lze jej určit pomocí sumy absolutních hodnot prvků v daném okně. [50] [48]

$$MAV = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (3)$$

WL (waveform length) – příznak vyjadřující míru komplexnosti EMG signálu. Výpočet vychází z kumulace amplitudy v konkrétním segmentu [50] [48]

$$WL = \sum_{n=1}^{N-1} |x_{n+1} - x_n| \quad (4)$$

ZC (zero crossing) – poskytuje informaci o frekvenci signálu v časové oblasti. Výpočet zahrnuje určení počtu průchodů signálu nulovou úrovní (v ose y), většinou se přidává práh pro eliminaci chyby způsobené šumem. [50] [48]

$$ZC = \sum_{n=1}^{N-1} \text{sgn}(x_n \cdot x_{n+1}) \cap |x_n - x_{n+1}| \geq \text{práh}$$

$$\text{sgn}(x) = \begin{cases} 1 & \text{když } x \geq \text{práh} \\ 0 & \text{jinak} \end{cases} \quad (5)$$

WAMP (Willson amplitude) – podobně jako ZC podává informaci o frekvenci v časové oblasti. Z výpočetního hlediska se jedná o počet úseků, jejichž rozdíl je větší než stanovený práh. [50] [48]

$$WAMP = \sum_{n=1}^{N-1} f(|x_n - x_{n+1}|)$$

$$f(x) = \begin{cases} 1 & \text{když } x \geq \text{práh} \\ 0 & \text{jinak} \end{cases}$$

(6)

AR (auto-regressive coefficients) – představuje predikční model, jenž každý vzorek vyjadřuje jako lineární kombinaci předchozích vzorků, navíc přidává složku bílého šumu. Koeficienty vyjadřující tuto kombinaci lze využít jako příznakový vektor. V rámci klasifikačního problému EMG signálu se nejčastěji používají koeficienty do 4. řádu. [50] [48]

$$x_i = \sum_{p=1}^P a_p x_{i-p} + w_i$$

(7)

Kde x_i představuje aktuální vzorek, P představuje řád modelu, a_p koeficienty modelu a w_i složku bílého šumu

SampEn (sample entropy) – představuje nejkompexnější příznak s vyšší výpočetní náročností. Z dosavadních výsledků studií se jedná o slibný prostředek pro možnosti zlepšení klasifikace EMG signálu. Přináší vysokou míru úspěšnosti klasifikace především v případě využití pouze jednoho příznaku, což může usnadnit rychlost klasifikace. Na druhou stranu samotný výpočet je komplikovanější v porovnání s již zmíněnými příznaky. V případě využití klasifikace skupinou příznaků přináší opět mírné zlepšení, ovšem ne příliš markantní. Dle práce [51] dochází k velkému poklesu úspěšnosti v případě nižší vzorkovací frekvence, a tedy snížení počtu vzorků v okně pro výpočet. Z tohoto důvodu je nutné uvažovat o hardwarových možnostech pro konkrétní případ. Samotný výpočet vychází z teorie náhody a dynamických systémů pro popis vzniku informace. [51] [49] [67]

Pro výpočet se vychází z časové řady popsané vzorky $\{x_1, x_2, \dots, x_n\}$ z čehož se určují vektory $x(p)$ pro m rozměrný prostor:

$$x(p) = [x(p+k)]_{k=0}^{m-1}, p = 1, 2, \dots, n - m + 1$$

(8)

Finální výpočet SampEn vychází z pravděpodobnosti $B^m(r)$, která se určí jako průměrný počet párů vektorů, jejichž vzdálenost je menší než parametr r (pro odpovídající m prostor). Následně pravděpodobnost $A^m(r)$ se vypočítá stejně, ovšem pro prostor $m+1$. Kombinací obou pravděpodobností lze určit hodnotu SampEn. V pracích [49] [67] se pro případ výpočtu SampEn z EMG dat uvádí parametr r jako 0,15-0,25násobek směrodatné odchylky a dimenze m nabývá hodnoty 2.

$$\text{SampEn}(x, m, r) = \ln(A^m(r)/B^m(r)) \quad (9)$$

3.3.2 Výběr vhodného klasifikačního algoritmu

Pro výběr vhodného klasifikačního algoritmu nastává stejný problém jako v případě výběru nejvhodnějších příznaků. Je velmi složité porovnat úspěšnosti klasifikace jednotlivých řešení, neboť závisí na konkrétním nastavení (výběr příznaků, počet elektrod atd). Autoři prací [18] (tabulka 3) a [40] (tabulka 7) provedli na základě odkazů dalších autorů a jejich výsledků řádné srovnání jednotlivých metod. Dle výsledků je patrné, že nelze jednoznačně určit nejlepší klasifikátor pro daný problém. Lze ovšem obecně definovat nejpoužívanější a osvědčené klasifikátory pro EMG signály, na jejichž základě lze v případě dodržení zásad strojového učení dosáhnout dostatečné úspěšnosti.

Mezi hlavní používané zástupce patří metody LDA (linear descriptive analyse), SVM (support vector machine), ANN (artificial neural network), FL (fuzzy logic) a DT (decision trees). První dvě metody patří mezi nejpoužívanější, a to díky rychlosti výpočtu, jednoduché implementaci a úspěšnosti klasifikace. Z důvodu již dříve zmiňovaných příznaků, které byly většinou testovány právě na SVM a LDA, budou podrobněji popsány právě tyto typy klasifikátorů.

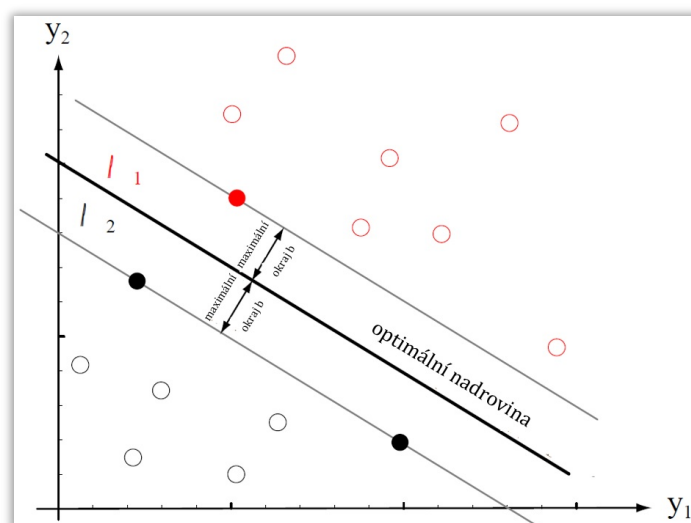
LDA (linear descriptive analyse) – nejedná se o klasifikační algoritmus v pravém smyslu. Hlavní použití této metody je pro vytvoření nového příznakového prostoru, a tedy snížení počtu příznaků. Výhodou tohoto snížení je vyvarování se tzv. „curse of dimensionality“¹ a zvýšení informační výtěžnosti z dat. Základní myšlenkou je vytvoření nových příznaků tak, aby došlo ke snížení rozptylu hodnot v jednotlivých třídách a zároveň k maximalizaci vzdáleností mezi jednotlivými třídami. Tento nový příznakový prostor buďto vstupuje do jakéhokoliv typu klasifikátoru (např. jednoduchý K-means), nebo přímo využívá vlastnosti algoritmu a rozšíření o Bayesovo pravidlo. Toto rozšíření bývá standardně implementováno do knihoven strojového učení. Lze tak přímo určit zařazení do konkrétní třídy. Metoda umožňuje rozšíření na více tříd, je tedy vhodná i pro použití klasifikace

¹ curse of dimensionality – termín, který označuje problém s vysokým počtem příznaků. Čím více je dimenzí, tím větší je požadovaný počet vstupních dat pro řádné rozmístění v prostoru.

gest. Hlavní výhodou je snadné učení i vybavování, není nutné nastavovat hyperparametry. V rámci již zmíněných prací, které porovnávají jednotlivé metody klasifikace, je rozsah úspěšnosti LDA 91,64 % až 98,87 %. [66] [20]

SVM (support vector machine) – jedná se o metodu, která využívá maximalizace hranice oddělující dvě třídy tak, aby šířka zóny vymezená touto hranicí byla co největší (viz Obrázek 13). Dané řešení umožňuje velmi rychle klasifikovat vstupní data, neboť pro samotný výpočet je nutné znát pouze podpůrné vektory (support vectors), což jsou body ležící na této hranici. V případě optimalizace není těchto bodů mnoho a samotný výpočet je tedy velmi rychlý, což je pro případ klasifikace signálu v reálném čase velmi důležité. Řešení je možné rozšířit o klasifikace do více tříd, což je velmi podstatné. Dále je zaveden parametr C , který dokáže měnit míru přísnosti dodržení hranice (nízká hodnota zpřísňuje možnost, aby se nacházel jakýkoliv bod uvnitř hranice). Pro případ klasifikace EMG signálu se většinou nepoužívá klasické lineární podoby, neboť jednotlivé třídy nejsou separabilní v lineárním prostoru. Proto se většinou využívá tzv. kernel tricku, který spočívá v převedení dat do vyšší dimenze. Je možné využít celou řadu dostupných kernelů, které definují tvar výsledné křivky pro klasifikaci. Pro konkrétní aplikaci na EMG signál se většinou využívá RBF kernel (viz Rovnice (10)), kde je jediný parametr γ ovlivňující tvar výsledné hranice. Je tedy nutné v rámci nalezení nejlepší hranice pro klasifikaci využít některou z mnoha optimalizačních metod pro nalezení parametrů SVM, tedy C a γ . Úspěšnost klasifikace EMG signálu se pohybuje v rozmezí 73 % až 96 %. [33] [60] [14]

$$K_R(x_j, x_k) = e^{(-\gamma \|x_j - x_k\|^2)} \quad (10)$$



Obrázek 13 – znázornění principu SVM pro 2 třídy, převzato a přeloženo z [14]

4 NÁVRH HARDWAROVÉ A SOFTWAREVÉ ČÁSTI

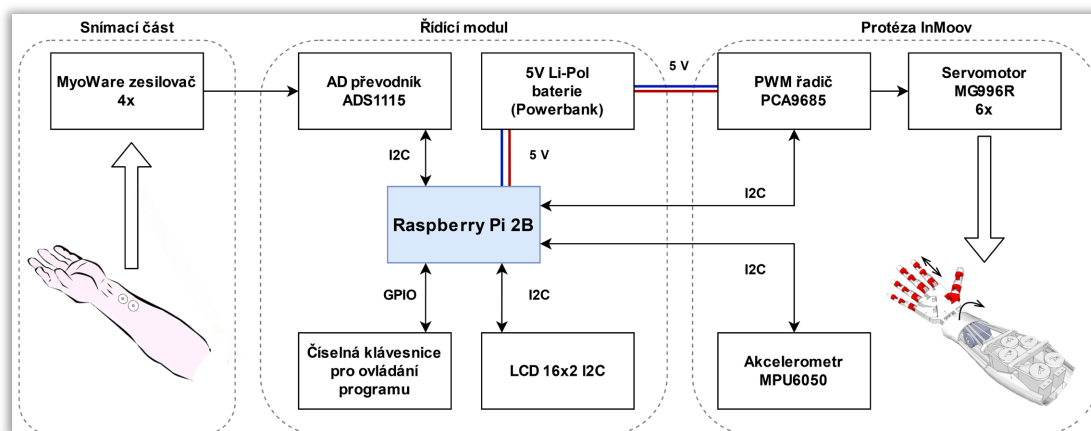
V této kapitole je navržen systém pro akvizici a klasifikaci signálů včetně propojení s protézou a ovládáním pomocí servomotorů. Jednotlivé části systému budou detailněji popsány v rámci uvedených podkapitol.

4.1 Hardwarová část

Hlavním prvkem hardwarové části je samotný model protézy. V kapitole 1.4 byly projednány jednotlivé typy open source protetických modelů včetně hlavních specifikací, výhod a nevýhod. Z uvedených typů byl zvolen robotický model InMoov, který nad ostatními vynikal především detailním postupem pro sestavení a řádným popisem jednotlivých bloků pro tisk. Také z důvodu cenové dostupnosti jednotlivých částí a kinematických možností se jedná o výhodné řešení. Samotná protéza je složena z řady dílů, které je možné tisknout na 3D tiskárně, což je v dnešní době velmi dostupné řešení. Pohyb článků prstů je vyřešen pomocí napnutí táhel, přičemž každý servomotor ovládá navinovací zařízení, které určuje míru flexe a extenze prstů. Celkově se pak jedná o ovládání 5 dvojic táhel pomocí 5 servomotorů, šestý servomotor je vyhrazen pro rotaci v zápěstí.

Druhou nosnou částí navrhovaného řešení je řídicí část složená především z mikrokontroleru. Analyzuje snímané signály a na základě naučeného klasifikátoru řídí další části systému.


Obecné schéma propojení jednotlivých součástí je uvedeno na Obrázku 14. Jedná se o finální podobu navrženého systému.



Obrázek 14 – propojení jednotlivých částí systému

4.1.1 Mikroprocesor

Jako řídicí jednotka byla zvolena rozšířená a dostupná platforma Raspberry Pi, která má kompaktní rozměry a dostatečný výkon na většinu běžných operací. Využívá 32/64bitový mikroprocesor z rodiny ARM, jehož výkon je dostačující na spuštění operačního systému a dalších aplikací. Konkrétní změřený výkon: 1,47 GFLOPS (dle [59]). Tato platforma byla zvolena především s ohledem na využití náročných klasifikačních algoritmů, které jsou dnes snadno implementovatelné v rozšířeném programovacím jazyce Python (což například AVR mikroprocesory neumožňují). Kromě toho umožňuje také snadnou komunikaci a zapojení dalšího přídatného hardwaru. Deska obsahuje řadu vstupních/výstupních portů – GPIO piny, včetně komunikačního protokolu I2C. K napájení se využívá napětí 5 V pomocí portu micro-USB. Systém je uložen na microSD kartě a ovládání systému v prvotní fázi bylo umožněno pomocí zobrazovacího zařízení přes HDMI port a periferních zařízení na portech USB. V pozdních fázích vývoje byl implementován LCD displej a integrovaná klávesnice pro ovládání vytvořeného programu.




Obrázek 15 – Raspberry Pi 2 B, převzato z [54]

4.1.2 AD převodník

Platforma Raspberry Pi nativně neobsahuje AD převodník. Z tohoto důvodu je nutné instalovat externí zařízení. Navrženou součástí je integrovaný obvod ADS1115, který umožňuje snadnou komunikaci pomocí rozhraní I2C (adresa 0x48) a zároveň má vhodné parametry. Jedná se o 16bitový převodník se vzorkovací frekvencí až 860 Hz, což lze považovat za rozumné minimum pro aplikace snímání EMG signálu (viz kapitola 2.4.2).


Umožňuje připojit 4 kanály současně, v případě využití více kanálů je nutné zapojit další modul. Napájecí napětí se pohybuje v rozsahu 2-5,5 V. [6]



Obrázek 16 – ADS1115 modul Adafruit, převzato z [4]

4.1.3 Zesilovač

Pro snímání EMG signálu je požadováno správné nastavení a zapojení OZ. Pro danou aplikaci je vhodné hotové řešení od společnosti Advancer Technologies, zesilovač MyoWare. Mezi hlavní specifikace patří vstupní odpor 110 G Ω , CMRR 110 dB, nastavitelné zesílení a vstupní napětí v rozsahu 3,1-6,3 V. Výstupem zesilovače je buďto originální, nezkreslený signál ze svalů (pin RAW), nebo již vyfiltrovaný a integrální signál (pin SIG). Pro svou kompaktnost a zabudované upevnění pro nalepovací elektrody (integrována také referenční elektroda) se jedná o ideální, cenově dostupné řešení. [1]



Obrázek 17 – EMG zesilovač MyoWare, převzato z [1]

4.1.4 Servomotory

Hlavní součást pro vykonávání pohybů protězy. Pro rotaci zápěstí se využívá servomotor s možností rotace 180°, pro jednotlivé články prstů pak minimálně 90°. Tyto parametry splňují servomotory MG996R, které mají podle dostupné specifikace výrobce rozsah pohybu 0-180°. Maximální točivý moment dosahuje hodnoty 11 kg.cm. Dovolené vstupní napětí je v rozsahu 4,8-7,2 V. Tento servomotor obsahuje kovové převody, je tedy vhodný i pro náročnější aplikace. Ovládán je pomocí PWM, kdy perioda obdélníkového


impulzu musí být 20 ms, střída signálu pak určuje konkrétní polohu servomotoru. Minimální udávaná šířka pulzu pro polohu 0° je 544 μ s, pro polohu 180° pak 2500 μ s. [37]



Obrázek 18 – servomotor MG996R, převzato z [37]

4.1.5 PWM řadič PCA9685

Z důvodu využití celkem 6 servomotorů není možné propojit GPIO piny mikrokontroléru. Z tohoto důvodu byl vybrán řadič PCA9685, který umožňuje využití až 16 kanálů. PWM rozlišení je 12 bit, což je pro dané aplikace zcela dostačující. Komunikace probíhá přes I2C sběrnici na adrese 0x40. Vstupní napětí může být v rozsahu 2,3-5,5 V. Je umožněn výběr frekvence PWM signálu z rozsahu 24-1526 Hz, přičemž servomotory vyžadují frekvenci 50 Hz. Modul také obsahuje ochranu proti opačné polaritě vstupního napětí a filtrační kondenzátor. [46] [13]




Obrázek 19 – PWM řadič PCA9685, převzato z [13]

4.1.6 Akcelerometr a gyroskop MCU6050

Z důvodů následného využití informací o poloze protězy byl zvolen modul MCU6050. Kombinuje tříosý akcelerometr a tříosý gyroskop. Má integrován 16bitový AD převodník, komunikace probíhá opět na standartu I2C (adresa 0x68). Rozsah gyroskopu činí: 250-2000 °/s, rozsah zrychlení pak 2-16 G. Čip obsahuje také digitální pohybový

procesor, který umožňuje velmi efektivně zpracovávat naměřená data. Pracovní napětí je v rozsahu 3-5 V. [38] [17]



Obrázek 20 – Akcelerometr a gyroskop MCU6050, převzato z [17]

4.1.7 Napájení

Pro napájení celého systému bylo zvoleno využití běžně dostupné powerbanky, která slouží pro napájení elektroniky pomocí rozhraní USB. Výstupní napětí použité powerbanky je 5 V, proud 2,1 A DC a kapacita 10000 mAh. S ohledem na přítomnost spínacích prvků bylo bráno v úvahu možné rušení v měřících obvodech, což se následně neprokázalo (vzhledem k funkčnosti celého systému, viz kapitola 6 Testování a výsledky). Nebylo tedy nutné využít přidavných filtračních článků. V případě současného napájení servomotorů i mikrokontroléru bylo při snížení kapacity baterie pozorováno omezení výkonu servomotorů. Je tedy doporučeno v případě dlouhodobého použití protézy využít externí zdroj s vyšší kapacitou baterie.

4.1.8 Další příslušenství

Mezi další příslušenství patří LCD 16x2 pro zobrazení aktuálních informací a ovládání protézy. Komunikace probíhá na sběrnici I2C (adresa 0x3F). V návaznosti pak číselná klávesnice slouží pro základní ovládání v menu. Základní ovládací prvky tedy umožní ovládat protézu ve statickém módu, následně umožní spuštění automatického módu, čemuž předchází trénovací fáze. Je umožněno zobrazovat potřebné informace ze sensorické části, především amplitudu a rozptyl signálu pro snazší rozpoznání chybového stavu.

4.2 Softwarová část

Výběr potřebného softwaru se odvíjí od nutnosti využít sofistikovanějšího klasifikačního algoritmu. Z tohoto důvodu připadá v úvahu velice rozšířený programovací jazyk Python, který z důvodu široké programátorské podpory umožňuje využít řadu podpůrných

knihoven. Navíc lze velmi snadno implementovat na zvolené hardwarové vybavení (ať už Raspberry Pi či přidružené IO). Navržený a vybraný software je tedy uzpůsoben zvolenému hardwarovému řešení a celkové správné funkci pro řešení vybraného problému.

4.2.1 Operační systém

Základním systémem umožňujícím manipulaci se vstupně výstupními periferními zařízeními a dalšími prostředky je operační systém Raspbian. Jedná se o volně šiřitelný, oficiální operační systém k mikrokontroleru Raspberry Pi založený na Debianu. Výhodou tohoto systému je snadné vývojové prostředí a přizpůsobení pro hardwarové prostředky daného mikrokontroleru. Pro následné spouštění aplikací (např. programovacího jazyka Python) lze využít zapnutí aplikace po spuštění systému, odpadá tedy nutnost připojení zobrazovacího zařízení pro ovládání systému. Samotné ovládání zobrazovacího zařízení pak může probíhat přímo v aplikaci (například zobrazení na LCD 16x2). [54]

4.2.2 Python

Jak již bylo dříve zmíněno, z důvodu využití komplexních klasifikačních algoritmů, jejichž samotná implementace a návrh by byly velice náročné, je využito programovacího jazyka Python a podpůrných knihoven. Jedná se v současné době o nejrozšířenější vysokoúrovňový, open source programovací jazyk, který ve velké míře využívá objektové programování. V aktuální podobě existuje ve dvou nezávislých verzích, konkrétně verze 2 a 3, přičemž je snahou prosadit novější verzi Python 3. V této práci jsou veškeré programové kódy a knihovny určeny právě pro tuto verzi. [9] [27]

4.2.3 Knihovny

V rámci programového kódu, který bude podrobně popsán v následující kapitole 5.3, je nutné uvést hlavní rozšiřující knihovny jazyka Pythonu. Některé níže uvedené knihovny patří ke zlatému standardu pro práci v daném jazyce. Řada z nich je ovšem specializována pro komunikaci daného hardwarového prvku na I2C sběrnici, většinou se jedná o méně dostupné knihovny. Z tohoto důvodu je k dispozici citační odkaz na konkrétní programový kód.

NumPy – patří k nejzákladnějším rozšířením. Umožňuje práci s lineární algebrou, vektory a maticemi.

SciPy – tato knihovna přidává rozšířené funkce pro práci s daty (nástroje pro zpracování signálu například Fourierova transformace).

Matplotlib –umožňuje základní vykreslování grafů a animací.

Scikit-Learn – široce větvená knihovna obsahující různorodé nástroje pro strojové učení. Obsahuje nástroje jednak pro předzpracování dat, jednak přednastavené třídy pro trénování a vybavování konkrétního modelu. Zahrnuje celou řadu klasifikačních modelů, včetně již zmíněného SVM a LDA.

Adafruit_ADS1x15 – specifická knihovna umožňující přístup k datům z AD převodníku po sběrnici I2C. [5]

RPi_I2C_driver – další specifická knihovna pro správu a komunikaci na I2C sběrnici pro ovládání LCD 16x2. [15]

Sampen – umožňuje provedení výpočtu příznaku SampEn [8]

Adafruit Python PCA9685 – knihovna vytvářející instanci třídy pro ovládání PWM řadiče [3]

mpu6050 – akvizice a zpracování dat z akcelerometru [39]

pad4pi – implementace klávesnice [43]

[9] [27]

4.3 Popis funkčnosti

Z důvodu přehlednosti a snadného pochopení principu jednotlivých částí a programových kódů jsou zde shrnuty základní možnosti protetického systému. Po připojení všech součástí k řídicí jednotce, konkrétně Myoware sensorů a protetické náhrady, dochází k spuštění menu programu.

První základní možností je ovládání protézy v pasivním režimu. Pomocí číselné klávesnice lze zvolit požadované gesto, které je ihned vykonáno. Hlavní funkcionalitou je ovšem využití aktivního režimu. Před samotným učením je vhodné ověřit variabilitu a amplitudu signálu pomocí implementované funkce, která ověří správnost aplikace EMG zesilovačů.

Nejdříve je nutné získat trénovací data. Je možné zvolit mezi SVM a LDA klasifikátorem, a to pro možnosti rozeznání základních 3 gest (relaxace, flexe a extenze prstů), nebo rozšířený režim pro rozpoznání 6 gest (relaxace, flexe a extenze prstů, extenze palce, ukazováku a trojitý úchop). Po provedení trénovací smyčky a opakovaném vykonávání požadovaných gest nastává optimalizace a natrénování zvoleného klasifikátoru.

Lze následně využít aktivní režim s nekonečnou smyčkou, přičemž pro návrat zpět do menu je nutné vypnout alespoň jeden ze zesilovačů, čímž dojde k zastavení smyčky (v každém cyklu je kontrolována amplituda signálu). V reálném čase probíhá akvizice dat, klasifikace a následné vykonání pohybu připojené protézy. Zpoždění systému je ovlivněno především velikostí nastaveného okna akvizice. Jedná se o kompromis mezi

úspěšností klasifikace a zpožděním celého systému, což bude experimentálně ověřeno v rámci části testování 6.2.2. Pro zachování přirozené zpětné vazby bylo zvoleno okno o velikosti 50 vzorků. Implementace automatické volby jednoduššího klasifikátoru pro tři gesta, a to v případě zaznamenání otřesů protézy, snižuje chybovost v případě intenzivní práce a manipulace s protézou. Při větší námaze a pohybu dochází k driftu a šumu v akviziční části, což v případě rozpoznávání většího počtu gest způsobuje zvýšenou míru nesprávné klasifikace.

Z důvodů validace natrénovaného klasifikátoru je nutné zajistit novou akvizici dat, proto je možné spustit validační režim v rámci aktivní protézy. V každé smyčce algoritmu je náhodně zvoleno gesto, které musí uživatel vykonat. Takto jsou postupně vykonána veškerá gesta, což umožňuje porovnání s ground truth ¹daty. Jedná se o jeden ze způsobů, jak objektivně podložit správnost provedených měření a výsledků.

¹ Ground truth data – skutečná, referenční data

5 REALIZACE SYSTÉMU

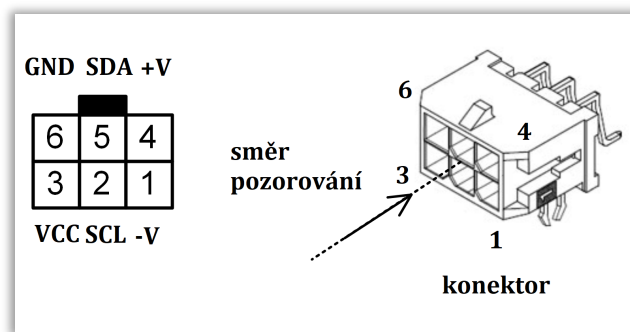
Tato kapitola přímo navazuje na navrhované řešení. V rámci realizace lze rozdělit praktickou část na protetický systém InMoov a řídicí systém, který využívá mikrokontroler Raspberry Pi. Vysvětlení bloků programových kódů včetně vývojových diagramů je také součástí samostatné podkapitoly. Propojení vodičů mezi jednotlivými částmi je schematicky znázorněno v příloze A. Zcela propojený systém je znázorněn na Obrázku 21, jednotlivé části jsou detailně popsány v následujících odstavcích.




Obrázek 21 – propojená řídicí jednotka s modelem končetiny

5.1 Model končetiny

Protetický systém je složen z několika částí. Většina částí byla vytvořena z PLA plastu za pomoci 3D tiskárny. Hlavní díl obsahuje 5 servomotorů a napínací systém vlasců tvoří uzavřený modul. Jednotlivé díly modulu jsou spojeny pomocí lepidla, případně vruty či šrouby. Dalším modulem je zápěstí, které je složeno z PLA převodů a jednoho servomotoru pro rotaci. Posledním modulem je samotná ruka složená z jednotlivých článků prstů a systému vedení vlasce pro následné ovládání. Články prstů jsou tedy napnuty pomocí pevného vlasce, který je veden vodičnými otvory napříč všemi moduly. V hlavním modulu jsou pak vlasce vhodně napnuty a navázány na přípravek servomotoru. V prostoru pod servomotorem zápěstí je implementován PWM řadič včetně akcelerometru. Vodiče pro napájení a komunikaci s řídicí jednotkou jsou vyvedeny do konektoru Molex Mini-Fit 2x3, schématické zobrazení na Obrázku 22. Protéza je v současném stavu zcela funkční a kompletní, umožňuje ovládání jednotlivých článků prstů. Kompletní sestavení je zobrazeno na Obrázku 23.



Obrázek 22 – schéma vodičů konektoru pro propojení protézy s řídicí jednotkou




Obrázek 23 – kompletní konstrukce InMoov modelu horní končetiny

5.2 Řídicí jednotka

Řídicí část byla sestavena s ohledem na konektivitu a snadnou přenositelnost. Box obsahuje samotnou řídicí jednotku Raspberry Pi 2, AD převodník a konektor Molex MiniFit 2x3 pro připojení protézy. Dále čtyři konektory jack 3.5 mm pro napájení zesilovačů, LCD displej a přídatný napájecí konektor pro servomotory. Většina vodičů modulů byla vyvedena na univerzální plošný spoj. Pro jednoduché ovládání je box opatřen 4x4 klávesnicí pro ovládání v menu. Primární napájení je řešeno USB kabelem. Součástí je zjednodušený návod pro snadnou orientaci v menu. Kompletní sestava je zobrazena na Obrázku 24, v rozdělaném stavu pak na Obrázku 25.



Obrázek 24 – řídicí jednotka

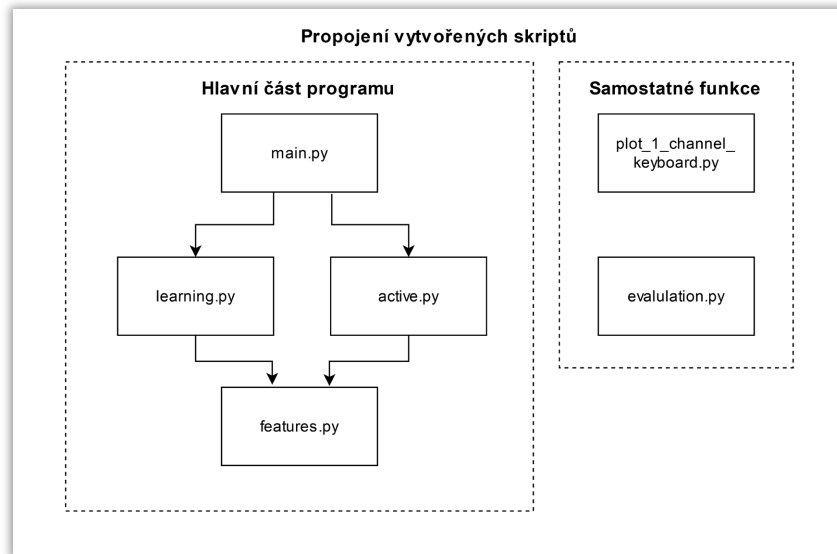


Obrázek 25 – řídicí jednotka v rozdělaném stavu

5.3 Programové kódy

Celá softwarová část se skládá z několika vytvořených skriptů v jazyce Python 3. Hlavní program je spustitelný souborem `main.py`. Následné propojené funkce slouží k natrénování klasifikátoru (funkce `learning.py`), případně využití aktivního módu (`active.py`). Obě funkce využívají funkce `features.py`, která obsahuje kódy pro získání dat z AD převodníku a výpočet matice příznaků. Pro zobrazení snímaného EMG signálu byl vytvořen samostatný skript `plot_1_channel_keyboard.py`. Pro následné vyhodnocení klasifikace včetně vytvoření obrazových výstupů slouží funkce `evaluation.py`. Propojení

komponent vyjadřuje Obrázek 26. Jednotlivé bloky jsou popsány v následujících odstavcích.



Obrázek 26 – základní propojení programových kódů

5.3.1 Main.py

Jedná se o hlavní spouštěcí skript programu. Jsou zde definovány třídy objektů, které umožní následnou komunikaci s hardwarovými prostředky. Je využito již zmíněných specifických knihoven. Jedná se o instance LCD displeje, AD převodníku, PWM řadiče, akcelerometru a klávesnice. Program běží ve smyčce, přičemž se čeká na odezvu klávesnice. Po stisknutí tlačítka je provedena konkrétní úloha podle nastavení. Jsou tedy následně spouštěny specifické funkce, přičemž vstupními proměnnými jsou vytvořené třídy a dodatečné parametry.

5.3.2 Features.py

Tento skript definuje jednotlivé funkce pro výpočet příznaků ze vstupních dat. Výběr příznakového prostoru vychází z poznatků kapitoly 3.3.1. Funkce pro výpočet autoregresního modelu vykazovala chybové hlášení, z tohoto důvodu byl příznak vyřazen z dalšího zkoumání.

Obsahuje dále funkce pro centralizaci vstupních dat na nulovou úroveň, případně možnost normalizace příznakového prostoru.

Součástí jsou funkce pro akvizici dat z ADS1115 a akcelerometru. Tyto funkce umožní extrahovat surová data, počet prvků je určen nastavením velikostí okna a počtem požadovaných příznaků. Z navazujícího testování bylo určeno optimální okno o velikosti 50 vzorků, přičemž pro dané gesto bylo získáno 20 příznaků. V rámci volání jedné funkce

bylo v tomto případě získáno 1000 vzorků. Byla implementována možnost uložení těchto vzorků ve formátu .sav, což umožňuje zpětnou analýzu měření.

Po získání surových dat je možné využít funkci pro výpočet celého příznakového prostoru pro dané gesto. Výstupem je tedy matice příznaků o velikosti $M \times N$, přičemž M je počet vzorků podělených velikostí okna (nativně nastaveno na 20), N pak počet příznaků násobeno počtem kanálů. Funkce MAV, ZC, WL, WAMP generují jeden příznak pro vstupní signál, příznak SampEn generuje celkem šest příznaků. Při využití čtyř kanálů je tedy velikost matice N rovna 40.

Jelikož je učící postup pro jedno konkrétní gesto opakován (z důvodu zvýšení robustnosti a zachování patřičné variability dat), byla implementována podpůrná funkce pro opakování akvizice dat a výpočet příznaků. Pro učení jednoho gesta je tak postup popsán výše opakován v závislosti na nastavení parametru opakování (pro získání směrodatných dat bylo empiricky zvoleno opakování pětkrát). Učící smyčka je doplněna o zobrazení na LCD displeji a počítadlo.

5.3.3 Learning.py

Tento skript je spouštěn v případě výběru funkce učení klasifikátoru. Pro každé gesto jsou volány funkce z features.py, které generují požadované příznaky. V případě již zmíněných nastavení je pro každé gesto generováno 100 vzorků příznakového prostoru. Příznakový prostor je normalizován a uložen včetně parametrů normalizace pro možnosti zpětného vybavení. Dochází také k uložení dat do souboru .sav, konkrétně se jedná o matici příznaků pro klidový režim, režim otřesů, počet využitých elektrod a indexy klasifikace. Díky těmto zálohovaným datům lze kdykoliv model přetrénovat či využít jiný typ klasifikátoru, což bylo vhodné především v počátečních fázích vývoje programu.

Na základě výběru klasifikátoru z menu a počtu rozpoznatelných gest vstupují následně naměřená data do konkrétního algoritmu učení. V případě využití SVM klasifikátoru je využita optimalizace pomocí metody grid search¹, která umožňuje nalézt nejlepší nastavení SVM klasifikátoru (hodnoty gama, C a typ kernelu). Tento způsob optimalizace byl zvolen z důvodu nízkých výpočetních a časových nároků. Metoda LDA nevyžaduje optimalizaci parametrů. Celkem dochází k vytvoření dvou klasifikátorů, jeden pro klasifikaci v případě klidového stavu pro větší počet gest, druhý pro otřesový režim pro základní gesta. Výsledek klasifikace je také zobrazen na displeji.

¹ Grid search – metoda spočívající v nalezení optimálního klasifikátoru pomocí porovnání úspěšnosti na základě parametrů, jejichž rozsah je nastaven explicitně

5.3.4 Active.py

V zásadě existují dvě možnosti spouštění. Režim validace umožní otestovat naučený model na zcela nových datech. Využívá se stejného principu jako ve fázi učení, pouze s rozdílem, že vykonávaná gesta jsou náhodně generovaná. Výstup je uložen opět ve formátu .sav a umožňuje následné vyhodnocení natrénování modelu. Druhou variantou je tzv. nekonečná smyčka. V každém cyklu je nejdříve otestováno, zda amplituda signálu není nižší než nastavený práh. Je tak preventivně testováno, zda nedošlo k odpojení některé elektrody, či špatnému kontaktu. Následně dochází k akvizici dat o velikosti okna, podle nastavení ve fázi učení. Data jsou normalizována podle uložených parametrů a vstupují do natrénovaného klasifikátoru. Index z klasifikátoru je zobrazen na displeji, následně vstupuje do funkce, která ovládá pohyb protézy.

V každém cyklu je naplňován zásobník akcelerometrických dat a také inkrementováno počítadlo, které po dosažení nastavené hodnoty spouští vyhodnocení otřesů. Toto počítadlo bylo nastaveno tak, aby odpovídalo časovému intervalu 5 s. Vyhodnocení pohybu a otřesů protézy spočívá ve výpočtu euklidovské vzdálenosti mezi jednotlivými sousedními dvojicemi hodnot zrychlení v ose x, y, z. Tímto je zaručena všesměrovost akcelerometru.

$$accel(i) = \sqrt{(X_i)^2 + (Y_i)^2 + (Z_i)^2} \quad (11)$$

V případě otřesu směrodatná odchylka takto upraveného signálu přesáhne stanovený práh. Počítadlo je vynulováno a následně cykly využívají klasifikátor pro menší počet detekovatelných gest. [62] [61]

Soubor také obsahuje funkce pro provedení definované rotace servomotorů. Na základě empirického zkoumání byly nastaveny hodnoty otáčení tak, aby pohyb článků prstů odpovídal provedenému gestu. Pomocná funkce převádí vstupní hodnotu otočení ve stupních na hodnotu PWM řadiče. Rozlišení řadiče je 12 bitů, přičemž hodnota pulzu pro počáteční pozici servomotoru byla stanovena na 110 z celkových 4096. Finální pozice byla empiricky stanovena na hodnotu 480 z 4096. Zadané úhly jsou tedy přepočítány na základě tohoto intervalu. Výsledkem je otočení o požadovaný úhel.

Jsou zavedeny 2 varianty pohybu protézy. V případě pasivního režimu je protéza ovládána tak, že pro zadané gesto dochází k okamžitému dosažení stavu servomotorů. Výsledkem je rychlé vykonání pohybu. V případě aktivního režimu dochází k postupnému otáčení servomotorů. Globální proměnná uchovává jejich předchozí stav, což umožňuje po každé detekci gesta otočení servomotoru o nastavený krok. Tímto je zaručeno, že nedochází k rychlým změnám v pohybu servomotorů. Zabraňuje se

poškození napínacího systému a servomotorů. Ovládání pomocí svalové kontrakce je tak přirozenější a umožňuje snazší zpětnou vazbu uživateli.

5.3.5 Plot_1_channel_keyboard.py

Pro zobrazení dat byla využita knihovna matplotlib. Vykreslení všech čtyř kanálů současně zapříčinilo pomalou odezvu aktualizace dat v grafech a celkové zpomalení akvizice. Proto byla implementována možnost volby konkrétního kanálu pomocí klávesnice. Po stisknutí tlačítka 1-4 dochází k zobrazení EMG dat v reálném čase. Tato samostatná funkce byla využita především v prvotní fázi při hledání vhodných nastavení algoritmů (vyžaduje zapojení externího monitoru) a pro snazší nalezení vhodných pozic elektrod.

5.3.6 Evaluation.py


Tato samostatná funkce umožňuje natrénování nového klasifikátoru na základě získaných dat z fáze učení. Je tedy možné snadno porovnávat různé nastavení a typy algoritmů. Testovací data jsou nejen vyhodnocena z hlediska úspěšnosti klasifikace, ale také pomocí řady dalších metod. Výstupem je například grafické znázornění shluků pomocí t-SNE analýzy. Dále funkce zobrazuje surová data, korelační mapu včetně histogramů, ROC křivky a matice záměn. V případě přítomnosti validačních dat zobrazuje také validační úspěšnost včetně matice záměn. To vše slouží k zjednodušení interpretace a hodnocení testovacích dat.

6 TESTOVÁNÍ A VÝSLEDKY

6.1 Popis testování

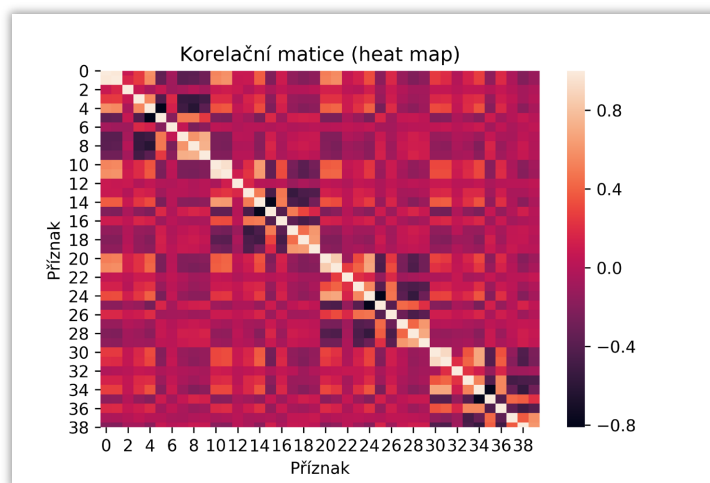
V rámci této práce byla provedena řada testování, jejichž cílem je kompletní otestování systému jednak z hlediska protetické části, jednak klasifikační. Veškeré testování bylo provedeno na jednom zdravém subjektu. Testování nebylo rozšířeno na další osoby, a to z důvodu časového i praktického hlediska. Testovaný subjekt měl cenné zkušenosti v rámci dřívějšího testování EMG klasifikace, což přináší nespornou výhodu v silnější svalové kontrakci v rámci provedení gest. Síla svalové kontrakce a znalost vhodných míst k nalepení elektrod z důvodu akvizice signálu méně zatíženého šumem vedla k rychlejším a relevantnějším výsledkům. V případě rozšíření o další testovací subjekty by postup vedl k dlouhým zaškolovacím procesům. Měření by muselo být dlouhodobé, což neumožňovaly ani časové, ani materiální okolnosti. V případě provedení pouze několika testů na těchto subjektech by výsledky nebyly průkazné a nepřinesly by žádné nové poznatky. Pozornost v rámci testování tak mohla být zaměřena na různorodé nastavení celého akvizičního systému a optimalizaci.

Příprava před měřením zahrnovala důkladné očištění kůže a vytipování oblastí zájmu pro nalepení elektrod. Pozice nalepených elektrod pro jednotlivá měření jsou součástí záznamu (viz příloha C). Proces trénování vyžaduje provedení každého gesta celkem pětkrát. Několikanásobné vykonání gesta zvyšuje robustnost a variabilitu dat pro zvýšení úspěšnosti. Gesta relaxace, flexe a extenze všech prstů, trojitý úchop, extenze ukazováku a palce byly minimálním požadavkem. V některých měřeních bylo snahou dosáhnout navíc klasifikace rotace končetiny, tzn. gesto rotace vlevo a vpravo. Provedení trénovacích gest lze pozorovat na zobrazení signálu (viz Obrázek 27), jedná se o hodnoty z AD převodníku centrované na nulovou úroveň.



Obrázek 27 – zobrazení trénovacího signálu

Výběr vhodných příznaků procházel v průběhu práce obměnami. V počátečních fázích byly měřeny všechny vybrané příznaky (MAV, WL, ZC, WAMP a 6 příznaků SampEn), následně byla zjištěna míra vzájemné korelace. Odstraněním korelovaných příznaků, které byly určeny pomocí korelační matice zobrazené na Obrázku 28, došlo ke zrychlení a zkvalitnění výsledné klasifikace. Z celkem 40 příznaků (pro každý kanál 10 příznaků) bylo odstraněno 12 příznaků překračujících stanovený práh korelace. Jednalo se o příznaky WL a některé SampEn.



Obrázek 28 – korelační matice příznaků

Trénování proběhlo ve stoje, testovací pravá ruka byla držena volně podél těla. Trénovací procedura trvá přibližně 5 minut.

Pro snadnou vizualizaci možností klasifikace byla využita metoda t-SNE. Tato metoda byla zvolena s ohledem na jednoduché grafické porovnání schopnosti klasifikátoru vytvářet shluky. V případě vhodného nastavení akvizičního systému dochází k vytváření ucelených shluků.

Testování a finální hodnocení probíhalo dvojím způsobem. Nejdříve bylo využito nekonečné smyčky programu a pozorování pohybu protézy v reálném čase, což umožní nejlépe hodnotit kvalitu natrénovaného klasifikátoru. Pomocí zpětné vazby z pohybu protézy lze ihned pozorovat míru použitelnosti daného klasifikátoru a nastavení. Jedná se ovšem pouze o subjektivní hodnocení, proto byl vytvořen způsob získání validačních dat. Ve smyčce byl generován náhodný index gesta, přičemž délka probíhající klasifikace byla určena náhodně. Tento způsob umožní nejvíce přiblížit reálnou situaci, kdy jednotlivá gesta jsou spouštěna v různém sledu. Z důvodu reakční doby uživatele zůstal zachován mezi jednotlivými gesty dostatečný časový interval. V rámci jednoho testování je získána predikce 20 gest, která je následně porovnána s vygenerovanými indexy. Zpětně lze považovat za nevýhodu tohoto přístupu nerovnoměrné zastoupení některých gest,

v extrémním případě není určité gesto zastoupeno vůbec. K těmto případům docházelo minimálně, neboť byl zvolen dostatečný počet vzorků. Přesto lze tento jev pozorovat. Řešením by byla permutace rovnoměrně zastoupených indexů. Z důvodu provedení řady testování lze ovšem považovat získaná data za průkazná.

6.2 Výsledky

Celkem bylo provedeno 12 relevantních měření (v rámci prvotní prototypizace byla prováděna další průběžná měření). Detailní zobrazení veškerých výstupů lze nalézt v příloze C.

6.2.1 Klasifikační schopnosti

Největší podíl výsledků testování vychází ze snímání EMG signálů a následné klasifikace. Z dostupných dat vyplývá, že úspěšnost klasifikace je primárně závislá na několika parametrech. Zásadním parametrem z hlediska úspěšnosti klasifikace je velikost okna. Dle dostupných dat (sestavení 3 a 5) je rozdíl úspěšnosti variabilní. V případě vhodného zvolení rozložení elektrod byl pozorován rozdíl v přesnosti klasifikace 5 %, v druhém případě je rozdíl přesnosti na validačních datech dokonce 20 %. Delší časové okno tedy umožní spolehlivější klasifikaci, ovšem za cenu zvýšení odezvy systému (detailněji popsáno v kapitole 6.2.2).

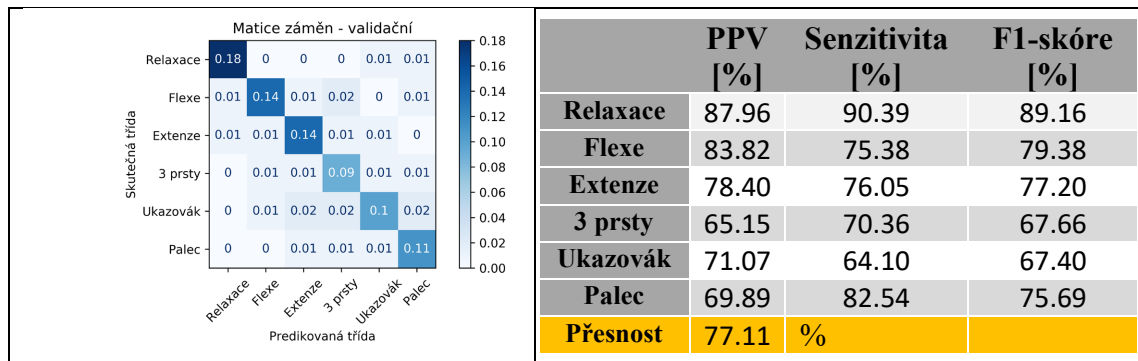
Největší rozdíly úspěšnosti klasifikace vznikají na základě schématu rozložení elektrod. Je velmi složité nalézt optimální schéma tak, aby byly vybraná gesta rozlišitelná. Nalezení vhodných pozic je časově náročné a pro každého jedince individuální. Nelze tedy nalezené pozice s největší přesností považovat za univerzální. V případě člověka s amputací končetiny by bylo nutné provést celkovou analýzu rozložení svalových vláken a možnosti využití. V tomto případě šlo o nalezení konkrétní pozice pro možnosti ovládání protézy zdravým uživatelem. Bylo zjištěno, že úspěšnost klasifikace založená na testovacích datech z procesu učení přispívá k přílišnému optimismu (z dat učební množiny bylo vybráno náhodně 30 % testovacích dat). Z tohoto důvodu byla zahrnuta validační měření, která reflektují skutečnou míru úspěšnosti. Dle zjištěných dat dopadlo nejlépe rozmístění elektrod podle sestavení 1, přičemž relevantnost byla ověřena stejným schématem rozložení elektrod v rámci nového sestavení 5. Míra přesnosti klasifikace v tomto případě dosáhla stabilně 90 %, což v jiných případech nebylo možné. Dle subjektivního hlediska bylo dané sestavení nejvíce stabilní, ovládání protézy bylo intuitivní a přesné. V tomto sestavení bylo možné využít kratšího časového okna při zachování přijatelné úspěšnosti. Ostatní pozice vykazovaly větší míru nestability, což může být způsobeno cross talkem mezi jednotlivými svalovými skupinami.

V rámci sestavení 1 byl otestován vliv počtu kanálů. Dle předpokladu bylo nemožné klasifikovat správně všechna vybraná gesta v případě využití pouze 2 elektrod. Nízkého počtu kanálů lze využít pro snadnou klasifikaci základních tří gest (relaxace, flexe a extenze), což pro jednoduchost implementace může v některých případech dostačovat. Úspěšnost se v takovém případě pohybovala v rozmezí 90-100 %. Dané nastavení pro klasifikaci většího množství gest není použitelné. Rozdíl mezi 3 a 4 kanály už není tak výrazný, v rámci validačního testování vychází úspěšnost téměř identicky. V rámci subjektivního testování byl ovšem zjištěn viditelný rozdíl. Při využití 4 kanálů nedocházelo tak často k falešným klasifikacím, a to v případě pohybu prstů bez viditelného vykonávání svalové kontrakce. Jev je problematický i v případě využití většího počtu kanálů, ovšem míra výskytu je do jisté míry redukována. Pro možnosti redukce takového signálu bylo otestováno několik nastavení, například využití nového trénovacího gesta (gesta šumu), které spočívalo ve volném pohybu článků prstů. Výsledky konkrétního klasifikátoru jsou zobrazeny v rámci měření 2, sestavení 4. V takovém případě ovšem docházelo k výraznému zhoršení míry úspěšnosti, což úplně znemožnilo ovládání protézy. Řešení problému může spočívat v případném využití senzorů připevněných na článcích prstů, které budou zaznamenávat pohyb (akcelerometry). V případě zaznamenání nadprahového pohybu by nedocházelo k akvizici EMG signálu. Daný způsob ovšem není součástí této práce a může být předmětem dalšího zkoumání. Problém nenastane, pokud bude protézu ovládat uživatel s amputací končetiny.

Klasifikace gest rotace protézy (supinace a pronace) naráželo na zásadní problém, a to odlepování připevněných elektrod. Principiálně bylo možné natrénovat klasifikátor tak, aby docházelo k správné klasifikaci, ovšem po provedení několika rotačních pohybů bylo nutné měření ukončit. Nalepovací elektrody nejsou tedy vhodné, řešením je využití jiného typu elektrod. Testování proběhlo v rámci sestavení 2. Z již zmíněných důvodů bylo nutné měření přerušit a validační data tak nebyla získána. Proto nelze považovat měření za příliš průkazné. Alternativní řešení představuje práce [35], která využívá kombinace klasifikace EMG signálu a speciálního tlakového senzoru kolem zápěstí. Využitím přídavného senzoru by bylo možné zcela zásadně zvýšit úspěšnost klasifikace.

Validační výsledky ze všech měření jsou zobrazeny na Obrázku 29. Jedná se o kompletní výsledky ze všech měření. V tomto případě je chyba klasifikace 23 %, což vzhledem k zahrnutí všech měření představuje dobrý výsledek. Dle studie [64] chyba klasifikace <35 % představuje stále použitelný systém z hlediska vykonávání úkonů protézy. V případě zahrnutí všech výsledků je tedy stále možné ovládat protézu. Jedná se ovšem o průměr všech měření v rámci fáze hledání vhodného schématu elektrod.

V případě využití klasifikátoru dle sestavení 1 a 5 lze dosáhnout úspěšnosti klasifikace převyšující 90 %, což dle zmíněné studie představuje vysokou míru ovladatelnosti.



Obrázek 29 – celková úspěšnost klasifikace na základě validačních dat

6.2.2 Odezva systému

Odezva systému byla testována na základě zpoždění mezi začátkem svalové kontrakce a pohybem protézy. Z důvodu nemožnosti testovat zpoždění přímo uvnitř smyčky programu (vlození časovače přinášelo příliš velké zpoždění) bylo zpoždění určeno na základě videokamery. Byl získán obraz ruky vykonávající gesta, ve stejném záběru pak protéza. Z nasnímaného obrazu bylo vytipováno několik úseků, které umožnily snadné odečtení zpoždění. Snímkovací frekvence kamery: 30 snímků/s. Zpoždění v případě zvolení časového okna 50 vzorků se pohybovalo v rozmezí 300-400 ms. V případě zvolení časového okna 100 vzorků bylo zpoždění mnohem větší, typicky 900-1000 ms. Subjektivním pozorováním bylo zjištěno, že delší časové okno není vhodné pro běžné použití protézy, neboť kvůli zpožděné zpětné vazbě přináší uživateli nekomfortní ovládání.

6.2.3 Akcelerometrická data

Bylo provedeno základní otestování funkčnosti akcelerometru. Přehledné zobrazení dat lze pozorovat v příloze Testování akcelerometru. Nejdříve bylo provedeno testování v klidovém režimu. Hodnoty euklidovské vzdálenosti mezi osami akcelerometru přibližně odpovídají zemskému zrychlení. V případě zapnutí servomotorů, dochází k mírným vibracím. Byly zjištěny přibližné průběhy zrychlení v případě provádění otřesů protézy. Při výrazných otřesech dochází k velkému rozptylu dat. Nastavení akcelerometru je tedy správné a na základě jednoduché statistiky je možné rozeznat klidový a otřesový režim. Nad rámec požadovaných dat bylo zjištěno zrychlení při chůze. V tomto případě

je průběh zrychlení velmi podobný otřesovému režimu. Lze tedy správně rozeznat klidový a pracovní režim.

6.2.4 Uplatnění v praxi

Systém byl navržen převážně pro laboratorní, výukové a testovací účely. Pro reálné uplatnění v praxi by bylo nutné upravit protetickou náhradu tak, aby došlo k snížení hmotnosti a zakomponování elektrod do vnitřní strany náhrady. Byla otestována možnost úchopu předmětů a lze konstatovat, že použité servomotory nabízí dostatečnou sílu pro manipulaci s předměty denní potřeby (otestováno na 750 g předmětech). Řídící jednotku lze skutečně využít pro možnosti reálného systému, ať už z důvodu přenositelnosti, či dostačujícího výpočetního výkonu. Z celkových výsledků a zkušeností lze usuzovat, že budoucí trend v oblasti protetických náhrad nebude spočívat ve zvyšování počtu kanálů. Jedním z důvodů může být složitá praktická hardwarová implementace většího počtu zesilovačů, a tedy náročnější údržba a nastavení pro konkrétního uživatele. Hlavním směrem, který byl otestován a implementován v rámci této práce, je automatické přepínání různých režimů. Automatická detekce konkrétní aktivity člověka a výběr daného klasifikátoru je možný způsob, jak zachovat velké množství rozlišitelných gest a značnou míru úspěšnosti. V případě této práce bylo využito pouze detekce klidového a aktivního režimu. Lze uvažovat o rozšíření detekce sportovních aktivit, aktivit v domácnosti či práci. Pro každou činnost by mohl být specifický klasifikátor podle konkrétních požadavků. Navržený protetický systém může být prostředkem k testování a prototypizaci v rámci zmíněného přístupu.

ZÁVĚR

Práce představuje návrh a realizaci funkčního protetického systému, který může sloužit pro budoucí testování, případně výukové či vzdělávací programy. Navíc přináší nové poznatky v rámci provedeného testování. Jednotlivé koncepční části, včetně detailního popisu a zdůvodnění výběru a celkového nastavení jsou součástí jednotlivých kapitol.

Prostředkem pro testování byla zvolena open source protetická náhrada InMoov. Zkonstruovaná protéza umožňuje jednoduché vizuální vyhodnocení úspěšnosti klasifikace EMG signálů a hodnocení odezvy vytvořeného systému. Z hlediska praktického uplatnění pro pacienty s amputací horní končetiny se z důvodu vysoké hmotnosti nejedná o použitelný model.

Vytvořené programové kódy v jazyce Python umožňují univerzální využití napříč mikrokontrolery, zde konkrétně bylo využito Raspberry Pi 2B.

Úspěšnost klasifikace EMG signálu byla otestována na jednom zdravém subjektu. Celkem bylo provedeno 12 komplexních testování. Bylo zvoleno čtyřkanálové provedení. Trénovací postup vyžadoval provedení každého gesta celkem pětkrát, učební čas činil 5 minut. Z pohledu vykonávání základních potřeb pacientů s amputací byla stanovena tato gesta: relaxace, flexe a extenze prstů, trojitý úchop, extenze ukazováku a palce, rotace vlevo a vpravo. Nebylo možné detekovat gesta rotace, a to z důvodu odlepení elektrod při vykonání supinace a pronace.

Průměrná úspěšnost klasifikace 6 gest dosáhla v rámci validačních měření 77,11 %. Výběr vhodného rozložení elektrod je považován za klíčový v rámci hledání optimálního řešení. Toto rozložení bylo nalezeno a opakovanými měřeními dokázáno, že v takovémto případě lze dosáhnout přesnosti převyšující 90 %. V případě zvolení delšího časového okna bylo dosaženo úspěšnosti 95 %. Bylo dokázáno, že výběr delšího časového okna zvyšuje odezvu z původní 300-400 ms na 900-1000 ms, což není dostačující z hlediska zpětné vazby uživateli a reálného využití protetického systému.

V rámci návrhu byl představen inovační koncept automatického výběru klasifikátorů, a to na základě detekce aktivity uživatele. Tento koncept byl implementován a otestován. V případě zaznamenání aktivity uživatele pomocí akcelerometru dochází k využití klasifikátoru pro základní gesta, což umožní využívat alespoň základní funkce protézy pro úchop a manipulaci s předměty. Úspěšnost takové klasifikace dosahuje 99 %. Tento režim je určen pro eliminaci falešných klasifikací, které by v případě fyzické aktivity a pohybu uživatele nastaly.

LITERATURA

- [1] A 3-lead Muscle / Electromyography Sensor for Microcontroller Applications: MyoWare™ Muscle Sensor (AT-04-001) DATASHEET. *Sparkfun* [online]. 2015-2016 [cit. 2019-12-22]. Dostupné z: <https://cdn.sparkfun.com/assets/a/3/a/f/a/AT-04-001.pdf>.
- [2] Ada V1.1 Assembly Instructions. Openbionicslabs [online]. Open bionics, 2016 [cit. 2019-10-08]. Dostupné z: <https://openbionicslabs.com/obtutorials/ada-v1-assembly>.
- [3] Adafruit / Adafruit_Python_PCA9685. In: GitHub [online]. San Francisco: GitHub, 2016 [cit. 2020-04-06]. Dostupné z: https://github.com/adafruit/Adafruit_Python_PCA9685.
- [4] Adafruit 4-Channel ADC Breakouts: Downloads. *Adafruit* [online]. NYC: Adafruit [cit. 2019-12-22]. Dostupné z: <https://learn.adafruit.com/adafruit-4-channel-adc-breakouts/downloads>.
- [5] Adafruit_Python_ADS1x15. In: GitHub [online]. San Francisco: GitHub, 2016 [cit. 2020-04-06]. Dostupné z: https://github.com/adafruit/Adafruit_Python_ADS1x15.
- [6] ADS111x Ultra-Small, Low-Power, I2C-Compatible, 860-SPS, 16-Bit ADCs With Internal Reference, Oscillator, and Programmable Comparator: ADS1113, ADS1114, ADS1115 DATASHEET. *TI* [online]. Dallas: Texas Instruments, 2018 [cit. 2019-12-23]. Dostupné z: <http://www.ti.com/lit/ds/symlink/ads1114.pdf>.
- [7] BANDARA, D.S.V., Jumpei ARATA a Kazuo KIGUCHI. Towards Control of a Transhumeral Prosthesis with EEG Signals. *Bioengineering*. 2018, **5**(2). DOI: 10.3390/bioengineering5020026. ISSN 2306-5354.
- [8] Bergantine / sampen. In: GitHub [online]. San Francisco: GitHub, 2020 [cit. 2020-04-06]. Dostupné z: <https://github.com/bergantine/sampen>.
- [9] COELHO, Luis Pedro a Willi RICHERT. *Building Machine Learning Systems with Python: Get more from your data through creating practical machine learning systems with Python*. 2nd ed. Birmingham: Packt Publishing, 2015. ISBN 978-1-78439-277-2.
- [10] CORDELLA, Francesca, Anna Lisa CIANCIO, Rinaldo SACCHETTI, Angelo DAVALLI, Andrea Giovanni CUTTI, Eugenio GUGLIELMELLI a Loredana ZOLLO. Literature Review on Needs of Upper Limb Prosthesis Users. *Frontiers in Neuroscience*. 2016, **10**. DOI: 10.3389/fnins.2016.00209.
- [11] CRANNY, A., D. P. J. COTTON, P. H. CHAPPELL, S. P. BEEBY a N. M. WHITE. Thick-film force, slip and temperature sensors for a prosthetic hand. *Measurement Science and Technology*. 2005, **16**(4), 931-941. DOI: 10.1088/0957-0233/16/4/005. ISSN 0957-0233.
- [12] DRAGULESCU, Doina, Véronique PERDEREAU, Michel DROUIN, Loredana UNGUREANU a Karoly MENYHARDT. 3D active workspace of

- human hand anatomical model. *BioMedical Engineering OnLine*. 2007, **6**(1). DOI: 10.1186/1475-925X-6-15. ISSN 1475925X.
- [13] Driver servomotorů PCA9685. In: *Arduino návody* [online]. Havlíčkův Brod: ECLIPSERA s.r.o, 2018 [cit. 2020-04-06]. Dostupné z: <https://navody.arduino-shop.cz/navody-k-produktum/driver-servomotoru-pca9685.html>.
- [14] DUDA, Richard O., Peter E. HART a David G. STORK. *Pattern classification*. 2nd ed. New York: Wiley, c2001. ISBN 978-0471056690.
- [15] Emcniece / rpi-lcd: RPi_I2C_driver.py. In: GitHub [online]. San Francisco: GitHub, 2015 [cit. 2020-04-06]. Dostupné z: https://github.com/emcniece/rpi-lcd/blob/master/RPi_I2C_driver.py.
- [16] FARRELL, Todd R. a Richard F. WEIR. The Optimal Controller Delay for Myoelectric Prostheses. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2007, **15**(1), 111-118. DOI: 10.1109/TNSRE.2007.891391. ISSN 1534-4320.
- [17] *Gyroskop + akcelerometr* [online]. Verze 1.0. Havlíčkův Brod: ECLIPSERA, 2016 [cit. 2020-4-6]. Dostupné z: <https://arduino-shop.cz/docs/produkty/0/134/1500635992.pdf>.
- [18] HAKONEN, Maria, Harri PIITULAINEN a Arto VISALA. Current state of digital signal processing in myoelectric interfaces and related applications. *Biomedical Signal Processing and Control*. 2015, **18**, 334-359. DOI: 10.1016/j.bspc.2015.02.009. ISSN 17468094.
- [19] Hand and Forarm. *InMoov open source 3D printed life size robot* [online]. InMoov [cit. 2019-10-08]. Dostupné z: <http://inmoov.fr/hand-and-forarm/>.
- [20] HAOSHI, Zhang, Zhao YAONAN, Yao FUAN, Xu LISHENG, Shang PENG a Li GUANGLIN. An adaptation strategy of using LDA classifier for EMG pattern recognition. *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE, 2013, 4267-4270. DOI: 10.1109/EMBC.2013.6610488. ISBN 978-1-4577-0216-7.
- [21] HOSSIN, M. a M. N. SULAIMAN. A review on evaluation metrics for data classification evaluations. *IJDKP*. 2015, **5**(2). DOI: 10.5121/ijdkp.2015.5201. ISSN 2231007X.
- [22] IBRAHIM, Anood, Reba ALEXANDER, Mohammed SHAHID a Royson DSOUZA. Control Systems in Robotics: A Review. *International Journal of Engineering Inventions*. 2016, **5** (5), 29-38.
- [23] JANG, Chul Ho, Hee Seung YANG, Hea Eun YANG, et al. A Survey on Activities of Daily Living and Occupations of Upper Extremity Amputees. *Annals of Rehabilitation Medicine*. 2011, **35**(6). DOI: 10.5535/arm.2011.35.6.907. ISSN 2234-0645.
- [24] JETTE, Alan M., Carol Mason SPICER a Jennifer Lalitha FLAUBERT, ed. The Promise of Assistive Technology to Enhance Activity and Work Participation. DOI: 10.17226/24740.

- [25] JIRALERSPONG, Trongmun, Emi NAKANISHI, Chao LIU a Jun ISHIKAWA. Experimental Study of Real-Time Classification of 17 Voluntary Movements for Multi-Degree Myoelectric Prosthetic Hand. *Applied Sciences*. 2017, 7(11). DOI: 10.3390/app7111163. ISSN 2076-3417.
- [26] JOHN Lin, Ying WU a T.S. HUANG. Modeling the constraints of human hand motion. *Proceedings Workshop on Human Motion*. IEEE Comput. Soc, 2000, 121-126. DOI: 10.1109/HUMO.2000.897381. ISBN 0-7695-0939-8.
- [27] JOHNSTON, Benjamin a Ishita MATHUR. *Applied Supervised Learning with Python: Use scikit-learn to build predictive models from real-world datasets and prepare yourself for the future of machine learning*. Birmingham: Packt Publishing, 2019. ISBN 978-1-78995-492-0.
- [28] KHUSHABA, Rami N., Ali AL-TIMEMY, Sarath KODAGODA a Kianoush NAZARPOUR. Combined influence of forearm orientation and muscular contraction on EMG pattern recognition. *Expert Systems with Applications*. 2016, **61**, 154-161. DOI: 10.1016/j.eswa.2016.05.031. ISSN 09574174.
- [29] KONRAD, Peter. *The ABC of EMG: A Practical Introduction to Kinesiological Electromyography*. Version 1.4. U.S.A: Noraxon, 2005. ISBN 0-9771622-1-4.
- [30] KONTOUDIS, George P., Minas V. LIAROKAPIS, Agisilaos G. ZISIMATOS, Christoforos I. MAVROGIANNIS a Kostas J. KYRIAKOPOULOS. Open-source, anthropomorphic, underactuated robot hands with a selectively lockable differential mechanism: Towards affordable prostheses. *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2015, 5857-5862. DOI: 10.1109/IROS.2015.7354209. ISBN 978-1-4799-9994-1.
- [31] KRASOULIS, Agamemnon, Iris KYRANOU, Mustapha Suphi ERDEN, Kianoush NAZARPOUR a Sethu VIJAYAKUMAR. Improved prosthetic hand control with concurrent use of myoelectric and inertial measurements. *Journal of NeuroEngineering and Rehabilitation*. 2017, **14**(1). DOI: 10.1186/s12984-017-0284-4. ISSN 1743-0003.
- [32] KUTÍLEK, Patrik, Jan HÝBL, Jakub MAREŠ, Vladimír SOCHA a Pavel SMRČKA. A Myoelectric prosthetic arm controlled by a sensor-actuator loop. *Acta Polytechnica*. 2014, **54**(3), 197-204. DOI: 10.14311/AP.2014.54.0197. ISSN 1805-2363.
- [33] LEON, M., J. M. GUTIERREZ, L. LEIJA a R. MUNOZ. EMG pattern recognition using Support Vector Machines classifier for myoelectric control purposes. *2011 Pan American Health Care Exchanges*. IEEE, 2011, 2011, 175-178. DOI: 10.1109/PAHCE.2011.5871873. ISBN 978-1-61284-915-7.
- [34] LYNCH, Kevin M. a Frank C. PARK. *Modern robotics: mechanics, planning, and control*. Cambridge, UK: Cambridge University Press, 2017. ISBN 978-110-7156-302.

- [35] MCINTOSH, Jess, Charlie MCNEILL, Mike FRASER, Frederic KERBER, Markus LÖCHTEFELD a Antonio KRÜGER. EMPress: Practical Hand Gesture Classification with Wrist-Mounted EMG and Pressure Sensing. In: *Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems*. NY, USA: ACM, 2016. 2332-2342. DOI: 10.1145/2858036.2858093. ISBN 9781450333627.
- [36] MENDEZ, I., B. W. HANSEN, C. M. GRABOW, et al. Evaluation of the Myo armband for the classification of hand motions. *International Conference on Rehabilitation Robotics (ICORR)*. IEEE, 2017. 1211-1214. DOI: 10.1109/ICORR.2017.8009414. ISBN 978-1-5386-2296-4.
- [37] *MG996R servo motor: datasheet* [online]. Havlíčkův Brod: ECLIPSERA s.r.o, 2018, 2018 [cit. 2019-12-22]. Dostupné z: <https://www.gme.cz/data/attachments/dsh.772-293.1.pdf>.
- [38] *MPU-6000 and MPU-6050 Product Specification* [online]. Revision 3.4. Sunnyvale (USA): InvenSense, 2013 [cit. 2020-4-6]. Dostupné z: <https://invensense.tdk.com/wp-content/uploads/2015/02/MPU-6000-Datasheet1.pdf>.
- [39] Mpu6050-raspberrypi 1.1. In: Pypi [online]. Python Software Foundation, 2018 [cit. 2020-04-06]. Dostupné z: <https://pypi.org/project/mpu6050-raspberrypi/>.
- [40] NAZMI, Nurhazimah, Mohd Abdul RAHMAN, Shin-Ichiroh YAMAMOTO, Siti AHMAD, Hairi ZAMZURI a Saiful MAZLAN. A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions. *Sensors*. 2016, **16**(8). DOI: 10.3390/s16081304. ISSN 1424-8220.
- [41] NING Jiang, S. DOSEN, K-R MULLER a D. FARINA. Myoelectric Control of Artificial Limbs—Is There a Need to Change Focus? *IEEE Signal Processing Magazine*. 2012, **29**(5), s. 152-150. DOI: 10.1109/MSP.2012.2203480. ISSN 1053-5888.
- [42] ØSTLIE, Kristin, Ingrid Marie LESJØ, Rosemary Joy FRANKLIN, Beate GARFELT, Ola Hunsbeth SKJELDAL a Per MAGNUS. Prosthesis use in adult acquired major upper-limb amputees: patterns of wear, prosthetic skills and the actual use of prostheses in activities of daily life. *Disability and Rehabilitation: Assistive Technology*. 2012, **7**(6), 479-493. DOI: 10.3109/17483107.2011.653296. ISSN 1748-3107.
- [43] Pad4pi 1.1.5. In: Pypi [online]. Python Software Foundation, 2018 [cit. 2020-04-06]. Dostupné z: <https://pypi.org/project/pad4pi/#description>.
- [44] PARMAR, Suresh, Iryna KHODASEVYCH a Olga TROYNIKOV. Evaluation of Flexible Force Sensors for Pressure Monitoring in Treatment of Chronic Venous Disorders. *Sensors*. 2017, **17**(8). DOI: 10.3390/s17081923. ISSN 1424-8220.

- [45] PASQUINA, Paul F. a Rory A. COOPER. *Care of the combat amputee*. Textbooks of military medicine. Washington, DC: For sale by the Supt. of Docs., U.S. G.P.O., 2009. ISBN 978-016-0840-777.
- [46] *PCA9685: 16-channel, 12-bit PWM Fm+ I2C-bus LED controller* [online]. Rev. 4. Eindhoven: NXP Semiconductors, 2015 [cit. 2020-4-6].
- [47] PEERDEMAN, Bart, Daphne BOERE, Heidi WITTEVEEN, et al. Myoelectric forearm prostheses: State of the art from a user-centered perspective. *The Journal of Rehabilitation Research and Development*. 2011, **48**(6), 719-738. DOI: 10.1682/JRRD.2010.08.0161. ISSN 0748-7711.
- [48] PHINYOMARK, Angkoon, Chusak LIMSAKUL a P. PHUKPATTARANONT. A novel feature extraction for robust EMG pattern recognition. *Journal of Computing*. 2009, **1**(1), 70-80. ISSN 2151-9617.
- [49] PHINYOMARK, Angkoon, Franck QUAINÉ, Sylvie CHARBONNIER, Christine SERVIÈRE, Franck TARPIN-BERNARD a Yann LAURILLAU. EMG feature evaluation for improving myoelectric pattern recognition robustness. *Expert Systems with Applications*. 2013, **40**(12), 4832-4840. DOI: 10.1016/j.eswa.2013.02.023. ISSN 09574174.
- [50] PHINYOMARK, Angkoon, Pornchai PHUKPATTARANONT a Chusak LIMSAKUL. Feature reduction and selection for EMG signal classification. *Expert Systems with Applications*. 2012, **39**(8), 7420-7431. DOI: 10.1016/j.eswa.2012.01.102. ISSN 09574174.
- [51] PHINYOMARK, Angkoon, Rami N. KHUSHABA a Erik SCHEME. Feature Extraction and Selection for Myoelectric Control Based on Wearable EMG Sensors. *Sensors*. 2018, **18**(5). DOI: 10.3390/s18051615. ISSN 1424-8220.
- [52] POMARES, G., H. COUDANE, F. DAP a G. DAUTEL. Epidemiology of traumatic upper limb amputations. 2018, **104**(2), 273-276. DOI: 10.1016/j.otsr.2017.12.014. ISSN 18770568.
- [53] Prosthetics 2017/18, Upper Limb. Duderstadt/Germany: Ottobock, 2017. 256s.
- [54] Raspberry Pi 2 Model B. *Raspberry pi* [online]. [cit. 2019-12-22]. Dostupné z: <https://www.raspberrypi.org/products/raspberry-pi-2-model-b/>.
- [55] SAUDABAYEV, Artur a Huseyin Atakan VAROL. Sensors for Robotic Hands: A Survey of State of the Art. *IEEE Access*. 2015, **3**, 1765-1782. DOI: 10.1109/ACCESS.2015.2482543. ISSN 2169-3536.
- [56] SIDHER, Abhijaat a Yantao SHEN. Improving a 3D-printed artificial anthropomorphic hand using the human hand model. *2017 IEEE International Conference on Real-time Computing and Robotics (RCAR)*. IEEE, 2017, 739-744. DOI: 10.1109/RCAR.2017.8311952. ISBN 978-1-5386-2035-9.
- [57] SMITH, L. H., L. J. HARGROVE, B. A. LOCK a T. A. KUIKEN. Determining the Optimal Window Length for Pattern Recognition-Based Myoelectric Control: Balancing the Competing Effects of Classification Error and Controller Delay. *IEEE Transactions on Neural Systems and Rehabilitation*

- Engineering*. 2011, **19**(2), 186-192. DOI: 10.1109/TNSRE.2010.2100828. ISSN 1534-4320.
- [58] STOPPA, Marcelo H. a João Carlos Mendes CARVALHO. Kinematic modeling of multi-fingered hand prosthesis for manipulation tasks. *Anais do Congresso Nacional de Matemática Aplicada à Indústria*. São Paulo: Editora Edgard Blücher, 2015, 779-788. DOI: 10.5151/mathpro-cnmai-0140.
- [59] The GFLOPS/W of the various machines in the VMW Research Group. *The Weaver Computer Engineering Research Group* [online]. [cit. 2020-04-06]. Dostupné z: http://web.eece.maine.edu/vweaver/group/green_machines.html.
- [60] TOLEDO-PÉREZ, Diana C., Juvenal RODRÍGUEZ-RESÉNDIZ, Roberto A. GÓMEZ-LOENZO a J. C. JAUREGUI-CORREA. Support Vector Machine-Based EMG Signal Classification Techniques: A Review. *Applied Sciences*. 2019, **9**(20), 4402. DOI: 10.3390/app9204402. ISSN 2076-3417.
- [61] TÖRNQVIST, Chalne. *Walking movement detection using stationary stochastic methods on accelerometer data*. Lund, Švédsko, 2017. Bakalářská práce. Lund University, Faculty of Science, Centre for Mathematical Sciences, Mathematical Sciences. Vedoucí práce Maria Sandsten, Anna Clark.
- [62] TWOMEY, Niall, Tom DIETHE, Xenofon FAFOUTIS, Atis ELSTS, Ryan MCCONVILLE, Peter FLACH a Ian CRADDOCK. A Comprehensive Study of Activity Recognition Using Accelerometers. *Informatics* [online]. 2018, 1856-1868, **5**(2). DOI: 10.3390/informatics5020027. ISSN 2227-9709.
- [63] YANG, Dapeng, Yikun GU, Li JIANG, Luke OSBORN a Hong LIU. Dynamic training protocol improves the robustness of PR-based myoelectric control. *Biomedical Signal Processing and Control*. 2017, **31**, 249-256. DOI: 10.1016/j.bspc.2016.08.017. ISSN 17468094.
- [64] YOUNG, A. J., L. J. HARGROVE a T. A. KUIKEN. The Effects of Electrode Size and Orientation on the Sensitivity of Myoelectric Pattern Recognition Systems to Electrode Shift. *IEEE Transactions on Biomedical Engineering*. 2011, **58**(9), 2537-2544. DOI: 10.1109/TBME.2011.2159216. ISSN 0018-9294.
- [65] ZAHAK, Muhammad. Signal Acquisition Using Surface EMG and Circuit Design Considerations for Robotic Prosthesis. *Computational Intelligence in Electromyography Analysis - A Perspective on Current Applications and Future Challenges*. InTech, 2012. DOI: 10.5772/52556. ISBN 978-953-51-0805-4.
- [66] ZHANG, Daohui, Xingang ZHAO, Jianda HAN a Yiwen ZHAO. A comparative study on PCA and LDA based EMG pattern recognition for anthropomorphic robotic hand. *2014 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 2014, 4850-4855. DOI: 10.1109/ICRA.2014.6907569. ISBN 978-1-4799-3685-4.
- [67] ZHANG, Xu a Ping ZHOU. Sample entropy analysis of surface EMG for improved muscle activity onset detection against spurious background spikes.

Journal of Electromyography and Kinesiology. 2012, **22**(6), 901-907. DOI: 10.1016/j.jelekin.2012.06.005. ISSN 10506411.

- [68] ZIEGLER-GRAHAM, Kathryn, Ellen J. MACKENZIE, Patti L. EPHRAIM, Thomas G. TRAVISON a Ron BROOKMEYER. Estimating the Prevalence of Limb Loss in the United States: 2005 to 2050. *Archives of Physical Medicine and Rehabilitation*. 2008, **89**(3), 422-429. DOI: 10.1016/j.apmr.2007.11.005. ISSN 00039993.

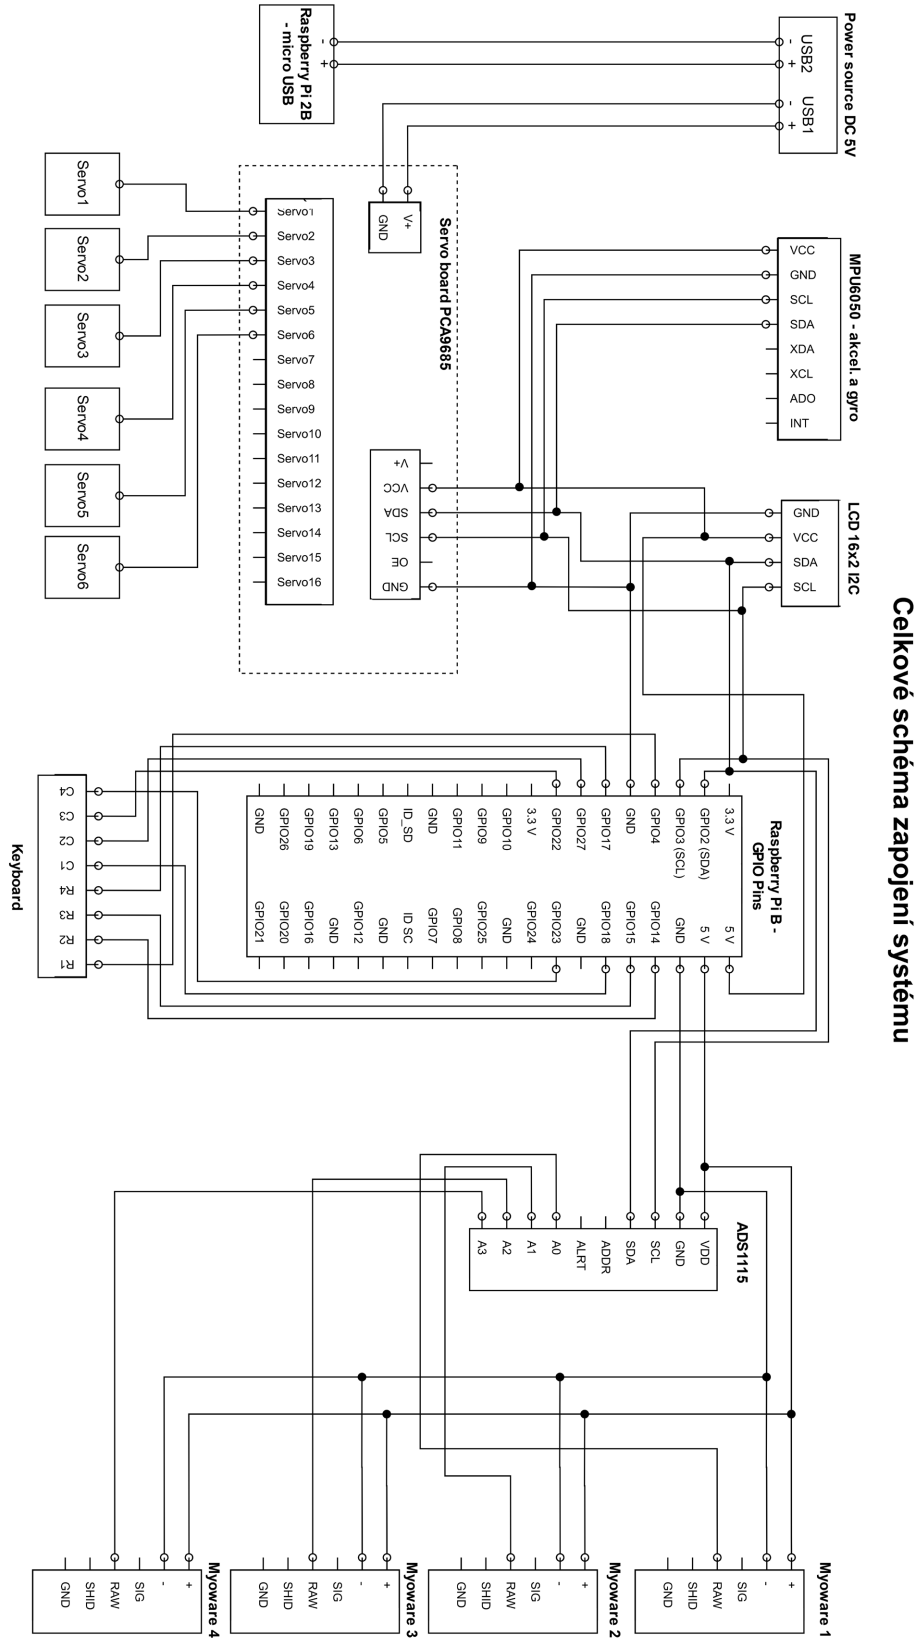
SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK

EMG	–	elektromyografie
DOF	–	stupeň volnosti
Hz	–	hertz
ms	–	milisekunda
ACC	–	přesnost
TP	–	skutečně pozitivní
TN	–	skutečně negativní
FP	–	falešně pozitivní
FN	–	falešně negativní
Re	–	senzitivita
Pr	–	pozitivní prediktivní hodnota
EEG	–	elektroencefalografie
MU	–	motorická jednotka
OZ	–	operační zesilovač
CMRR	–	poměr soufázové a rozdílové složky
MAV	–	průměrná absolutní hodnota
WL	–	vlnová délka
ZC	–	průchod nulou
WAMP	–	Wilsonova amplituda
AR	–	auto regresivní
SAMPEN	–	entropie vzorků
LDA	–	lineární deskriptivní analýza
SVM	–	metoda podpůrných vektorů
ANN	–	umělé neuronové sítě
FL	–	fuzzy logika
DT	–	rozhodovací stromy
LCD	–	displej z tekutých krystalů
I2C	–	sběrnice I2C
V	–	volt
Ω	–	ohm
dB	–	decibel
μ s	–	mikrosekunda
AD	–	analogově-digitální
IO	–	integrovaný obvod

SEZNAM PŘÍLOH

- A Schéma propojení vodičů**
- B Návod k obsluze**
- C Podrobné výsledky klasifikace**
- D Obsah přiloženého DVD**


A Schéma propojení vodičů



B Návod k obsluze

Nastavení před spuštěním řídicí jednotky

Před samotným zprovozněním řídicí jednotky je třeba vykonat základní kroky. V první řadě zkontrolujte integritu jednotlivých částí, především protetické náhrady. Následně připojte veškeré příslušenství k řídicí jednotce. Systém funguje pouze v případě řádného připojení protetické náhrady a EMG zesilovačů. Připojte tedy protetickou náhradu pomocí propojovacího kabelu s Molex konektory. EMG zesilovače Myoware připojte pomocí konektorů jack a zapněte pomocí posuvného přepínače. V případě využití servomotorů protetické náhrady připojte dodatečný napájecí zdroj pomocí dodávaného kabelu. Odpojení komponentů v průběhu zapnutého stavu jednotky může vyvolat neočekávané chybové stavy.



Správné zapojení systému

Zapnutí řídicí jednotky

Připojte konektor USB do 5V zdroje napájení. Následně dochází k inicializaci operačního systému a spuštění vytvořeného programu. Tento krok trvá několik minut, prosím mějte strpení. Připojení napájení lze ověřit podsvícením displeje a svítivostí diod v protéze. Správnost inicializace programu lze ověřit informační hláškou displeje (Menu, choose options). V případě, že nebyly zapojeny potřebné části systému, budete vyzváni provést řádné zapojení konkrétní komponenty.

Ovládání v Menu

Veškeré ovládání vytvořeného programu lze provést pomocí numerické klávesnice. Aktuální informace a zpětná vazba jsou zobrazeny na přiloženém displeji. Pro volbu hlavních funkcí systému slouží klávesy A-D

Menu A – ovládání protézy

Pro ovládání protézy v pasivním režimu zvolte tlačítko A. Následně zvolte číslo požadovaného gesta. Pro skutečný pohyb servomotorů je nutné mít zapojené přídavné napájení.

Menu D – ověření stavu připojených zesilovačů

Je vhodné nejdříve otestovat správnost připojení jednotlivých kanálů pro snímání EMG signálu. V menu stiskněte klávesu D a vyberte číslo požadovaného kanálu. Na displeji se zobrazí amplituda signálu (hodnota z 16bitového převodníku) a odchylka. V případě čistého signálu odchylka nepřesahuje hodnotu 50. Pokud je odchylka vyšší, nelze zaručit správnost následné klasifikace. V případě nesprávného zapojení zesilovače dojde k zobrazení varovné hlášky. Zkontrolujte tedy správnost zapojení jak v části řídicí jednotky, tak zesilovače (a integritu kabelu).

Menu B – režim učení

Pro využití aktivního režimu je nejdříve nutné vytvořit klasifikační model. Zvolte tlačítko B a vyberte počet kanálů (1-4). Následně vyberte požadovaný klasifikátor (SVM pro 6 a 3 gesta či LDA). Budete vyzváni pro každé gesto vykonat požadovaný svalový stah. Tento postup se opakuje pro každé gesto pětkrát. Snažte se zapojovat vždy stejné svalové skupiny a využijte podobnou sílu kontrakce. Výsledkem je naučený klasifikátor, úspěšnost se zobrazí na displeji. Celý postup trvá přibližně 5 minut.

Menu C – aktivní režim

Pro ovládání protézy pomocí svalové kontrakce zvolte tlačítko C. V případě testování a požadavku obdržení validačních dat stiskněte tlačítko 2. K běžným demonstrativním a praktickým účelům funkce protézy vyberte možnost 1. Program běží v nekonečné smyčce, přičemž svalová kontrakce způsobí pohyb protézy (opět nutné připojit dodatečné napájení). Pro zastavení programu vypněte alespoň jeden Myoware zesilovač. Dojde k okamžitému zastavení a návrat do Menu. Aktivní režim vždy kontroluje přítomnost vytvořeného klasifikátoru a v případě nenalezení vypíše chybovou hlášku.

Možné chybové stavy	
Chybový stav	Řešení
Po zapnutí řídicí jednotky je vypsána chybová hláška pro připojení dané komponenty	Zkontrolujte řádné připojení konkrétní komponenty, případně zkontrolujte integritu kabelu. Proved'te restartování systému. Pokud není připojena interní komponenta (AD převodník atd.), rozdělte kryt jednotky a zkontrolujte zapojení.
Nedochází k zobrazení volby Menu (operační systém či program nebyl inicializován)	Pokud po zapojení nedojde k zobrazení Menu, proved'te restart zařízení a vyčkejte několik minut. Dále zkontrolujte, zda je podsvícení displeje aktivní (v případě, že ne, proved'te kontrolu zapojení displeje). Zkontrolujte

	správné zapojení SD karty v zařízení Raspberry Pi. Zkontrolujte napájecí zdroj.
Nedochází k pohybu protézy (v pasivním režimu)	Zkontrolujte zapojení přídavného napájení a dostatečnou kapacitu a vlastnosti napájecího zdroje. Zkontrolujte správnost zapojení PWM řadiče uvnitř protézy a integritu kabelu.
Nelze získat informace o amplitudě a odchylce signálu	Zkontrolujte zapojení Myoware zesilovače a správné připojení elektrod na kůži. Případně zkontrolujte zapojení AD převodníku.
Vytváření klasifikátoru (v režimu učení) trvá dlouho, případně došlo k zamrznutí	Pokud je chyba v akvizičním systému, je možné, že klasifikátor nedokáže rozeznat překrývající se gesta. V tomto případě restartujte zařízení a zkontrolujte kvalitu signálu a správné zapojení.
Nelze spustit aktivní režim protézy	Ověřte, zda byl vykonán režim učení. Zkontrolujte, zda nedošlo k odpojení jakéhokoliv zesilovače či elektrody.
Úspěšnost klasifikace je příliš nízká	Zde je celá řada faktorů ovlivňujících kvalitu výsledné klasifikace. Zvolte vhodné schéma elektrod, dbejte na dodržení zásad ve fázi učení (dostatečná kontrakce, stah konkrétní svalové skupiny). Zkontrolujte zapojení všech částí systému. Je možné, že jste využili zdroj napájení, který způsobuje zašumění signálu. Zkontrolujte vizuálně kvalitu signálu.
Probíhá klasifikace do menšího počtu tříd	V případě vykonávání pohybu (třes) s protézou může docházet k automatickému přepnutí režimu pro klasifikaci do menšího počtu tříd.
Jiný chybový stav či komplikace	Pro snadný debugging celého systému je vhodné využít zapojení monitoru (HDMI konektor) a zkontrolovat jednotlivé části kódů, či využít zobrazení signálu pomocí přiložené funkce. V případě poškození některé komponenty je nutné odstranit kryt protézy či řídicí jednotky a provést výměnu.

C Podrobné výsledky klasifikace

1. Sestavení

Účel měření:

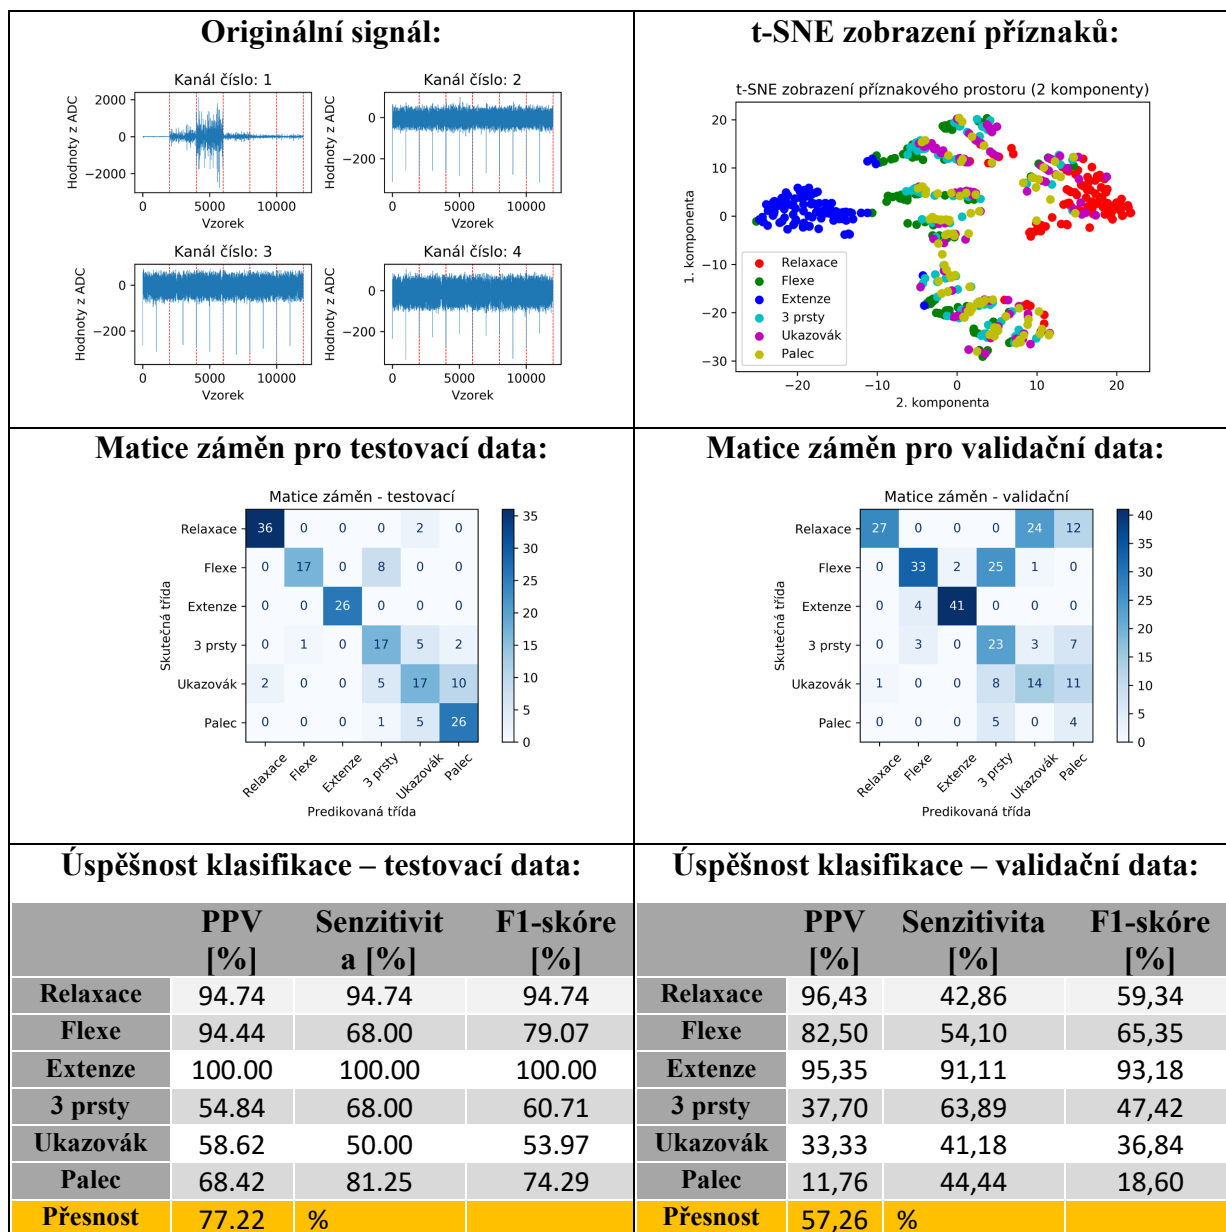
- porovnání úspěšnosti klasifikace dle počtu elektrod
- výpočet úspěšnosti klasifikace pro dané rozložení elektrod

Rozložení elektrod:



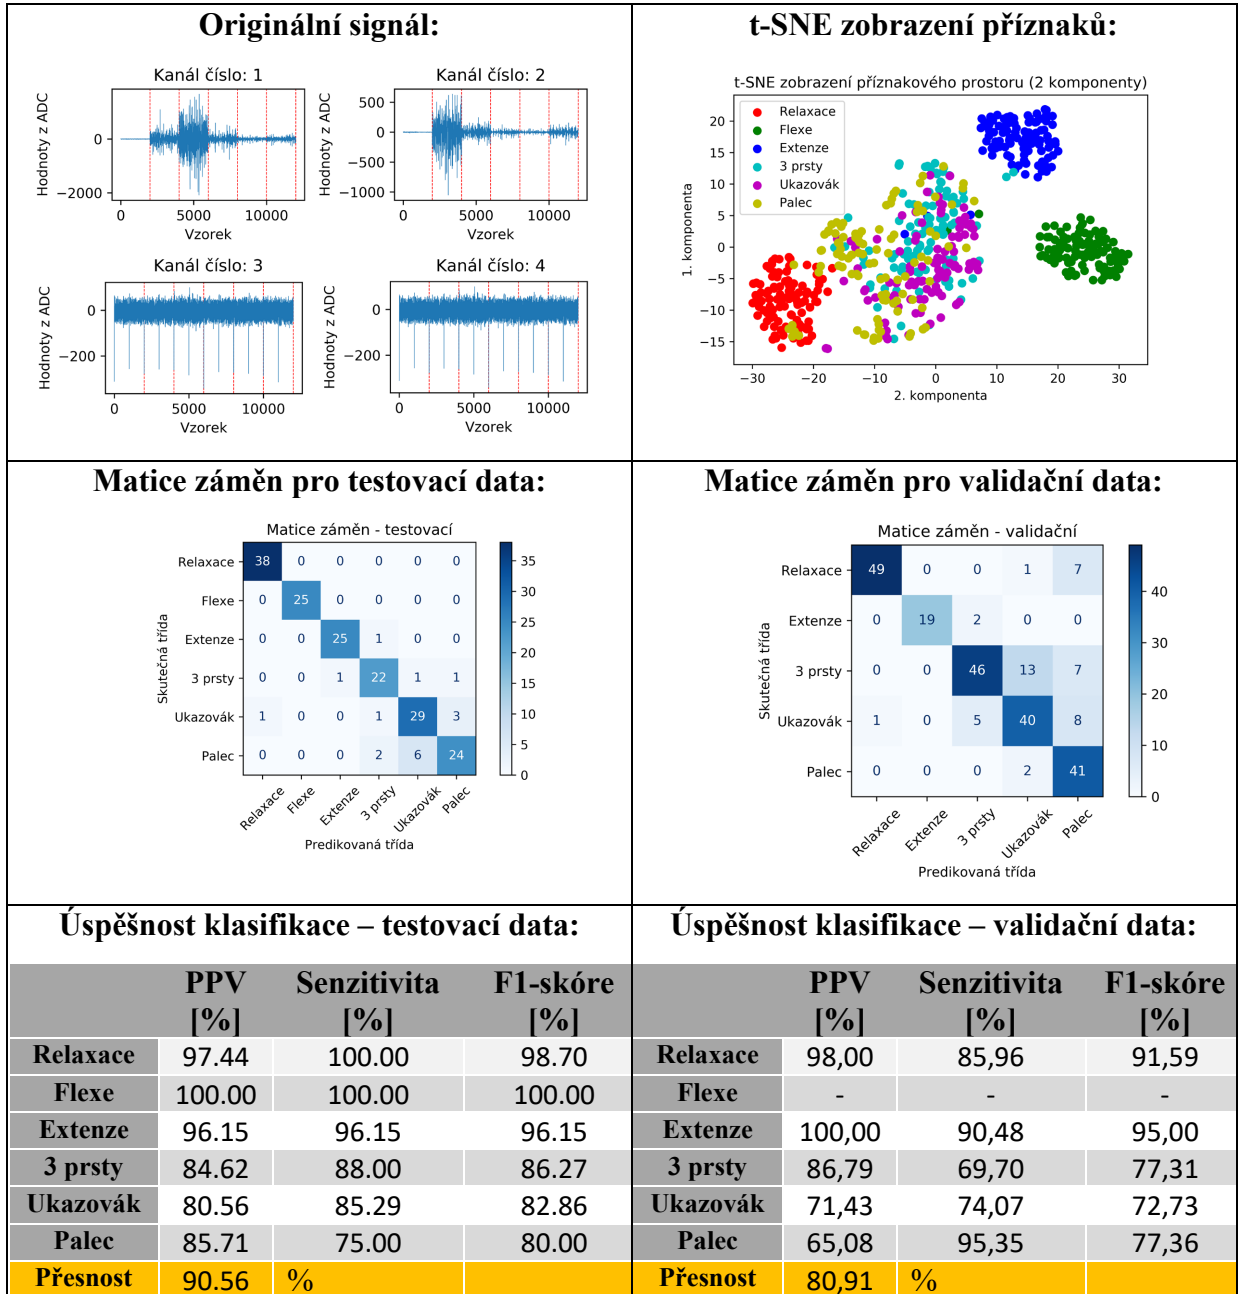
Měření 1

- **Svalové skupiny (čísla dle elektrod):** 1 - extensor digitorum
- **Klasifikátor:** SVM
- **Počet elektrod:** 1
- **Časové okno:** 50 vzorků
- **Počet rozpoznávaných gest:** 6
- **Dodatečné informace:** Využití nekorelovaných příznaků



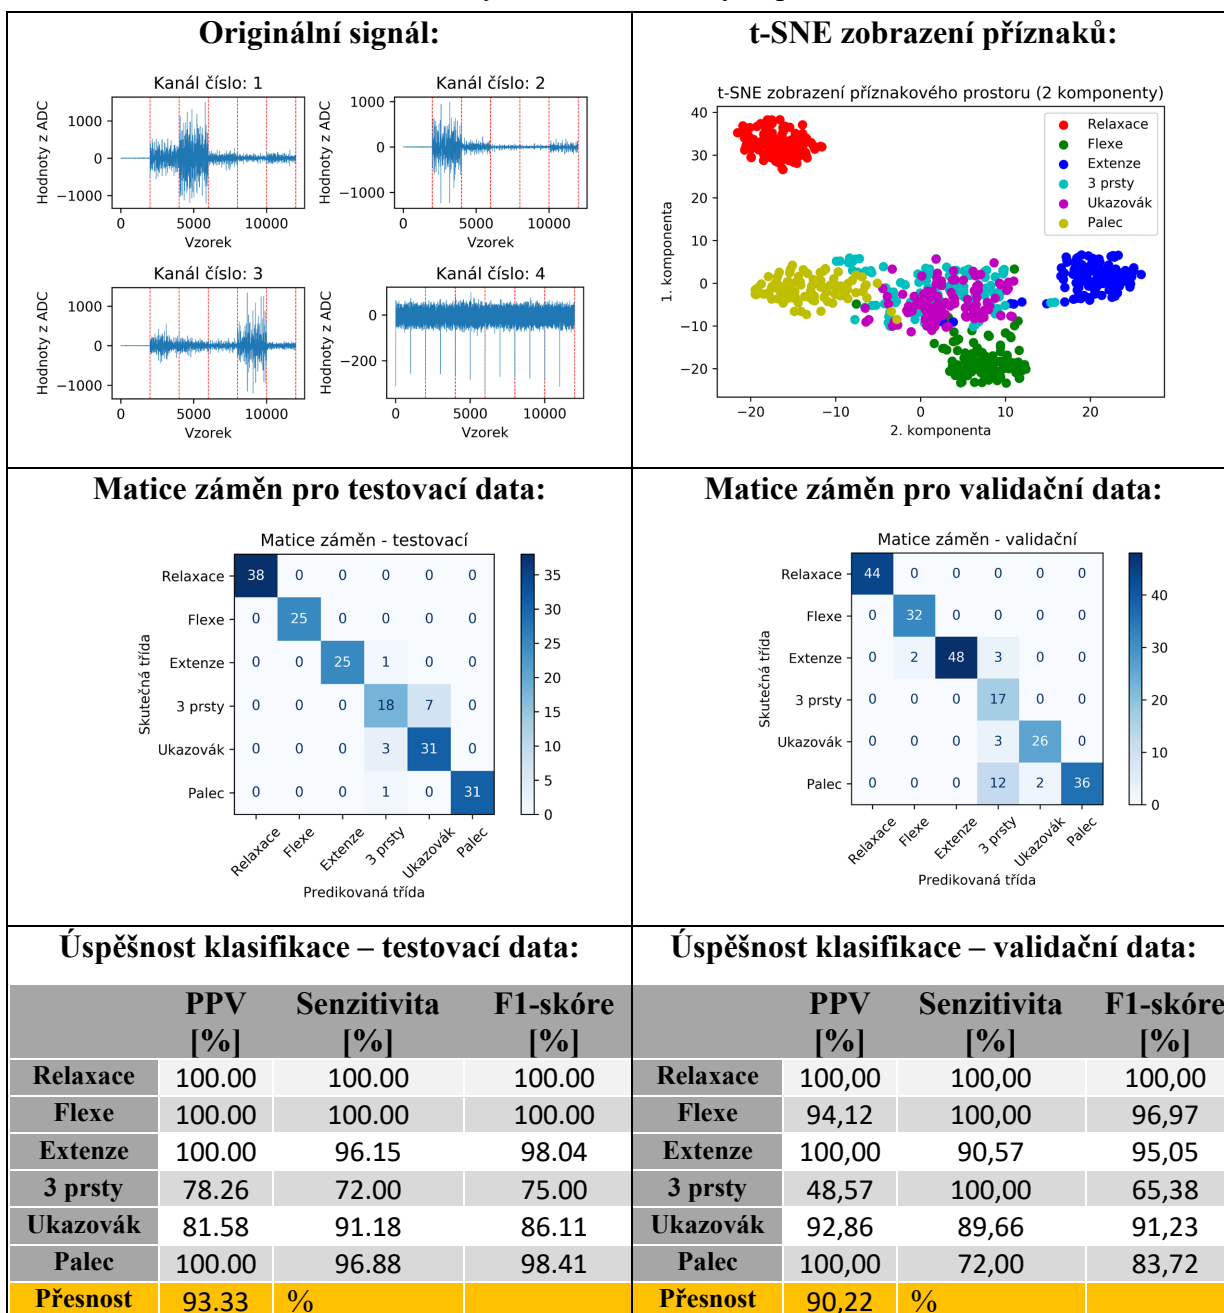
Měření 2

- **Svalové skupiny (čísla dle elektrod):** 1 - extensor digitorum; 2 – flexor digitorum
- **Klasifikátor:** SVM
- **Počet elektrod:** 2
- **Časové okno:** 50 vzorků
- **Počet rozpoznávaných gest:** 6
- **Dodatečné informace:** Využití nekorelovaných příznaků



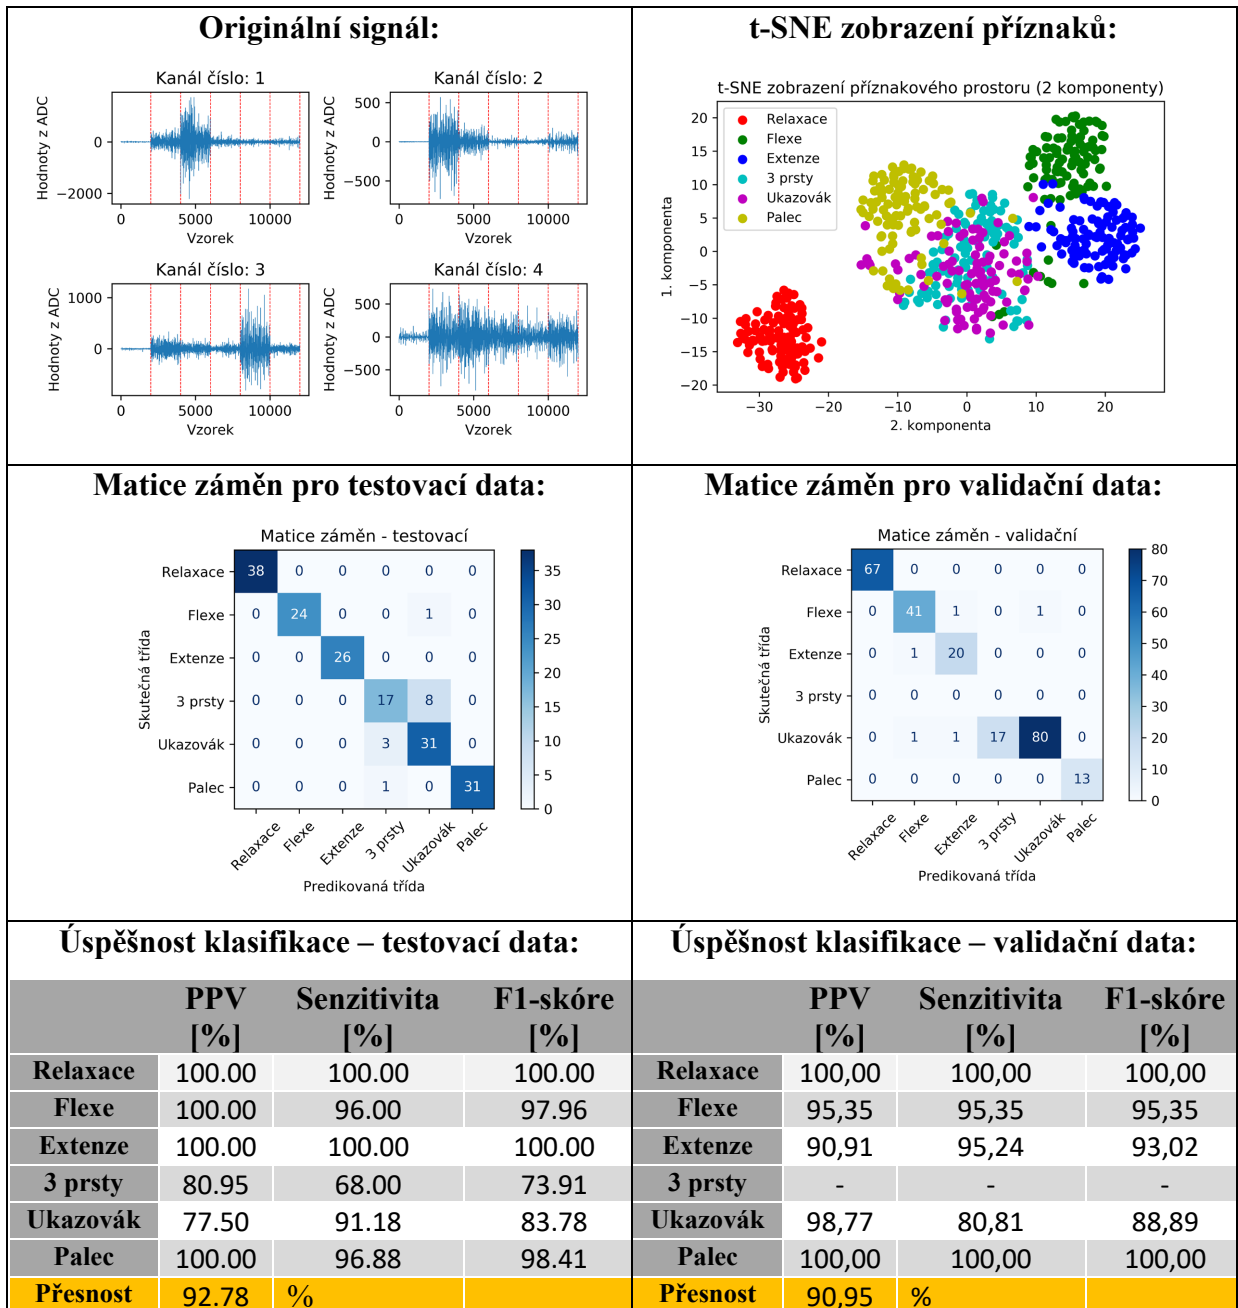
Měření 3

- **Svalové skupiny (čísla dle elektrod):** 1 - extensor digitorum; 2 – flexor digitorum; 3 – extensor indicis
- **Klasifikátor:** SVM
- **Počet elektrod:** 3
- **Časové okno:** 50 vzorků
- **Počet rozpoznávaných gest:** 6
- **Dodatečné informace:** Využití nekorelovaných příznaků



Měření 4

- **Svalové skupiny (čísla dle elektrod):** 1 - extensor digitorum; 2 – flexor digitorum; 3 – extensor indicis; 4 – flexor policis
- **Klasifikátor:** SVM
- **Počet elektrod:** 4
- **Časové okno:** 50 vzorků
- **Počet rozpoznávaných gest:** 6
- **Dodatečné informace:** Využití nekorelovaných příznaků




2. Sestavení

Účel měření:

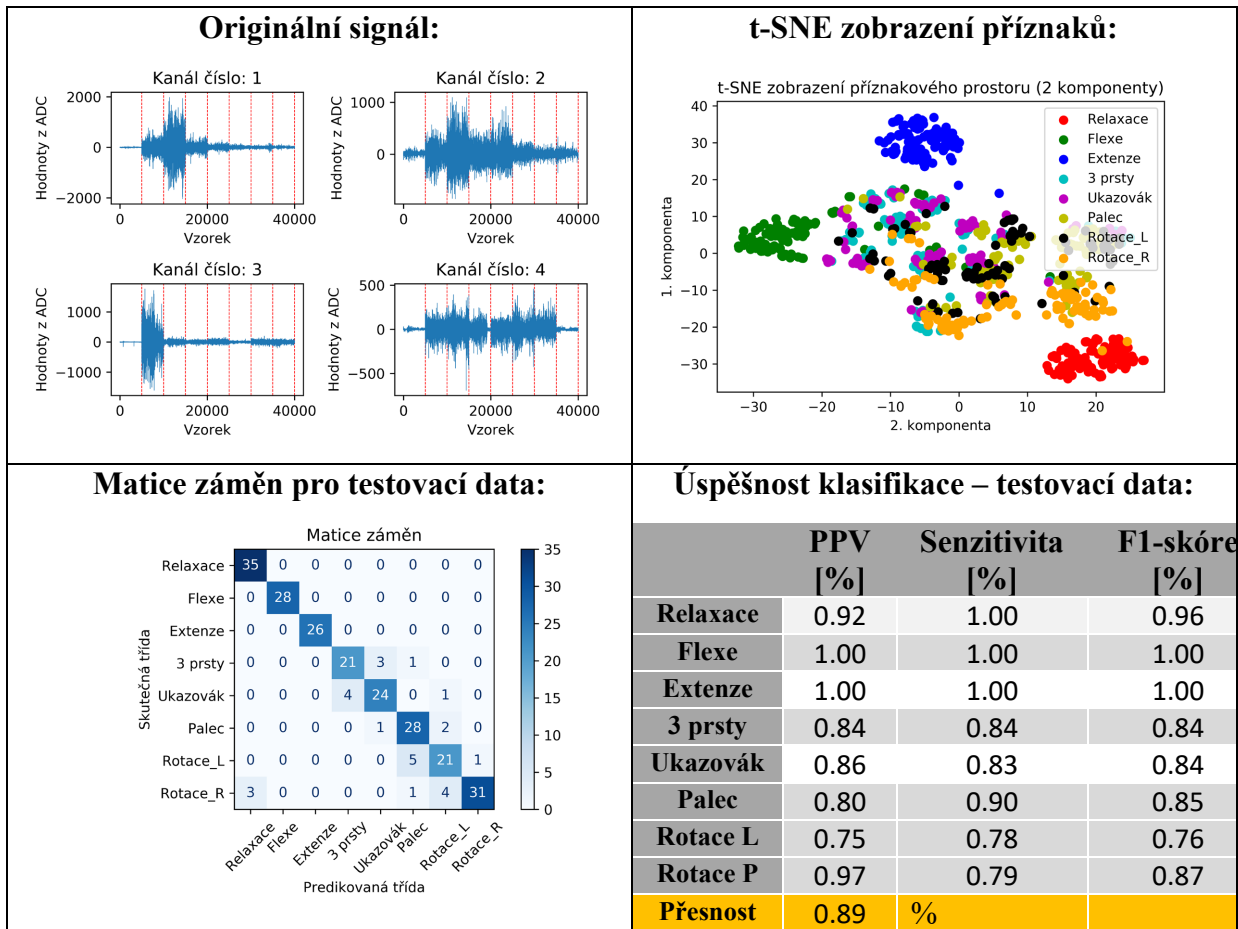
- porovnání úspěšnosti klasifikace v případě implementace gesta rotace
- výpočet úspěšnosti klasifikace pro dané rozložení elektrod

Rozložení elektrod:



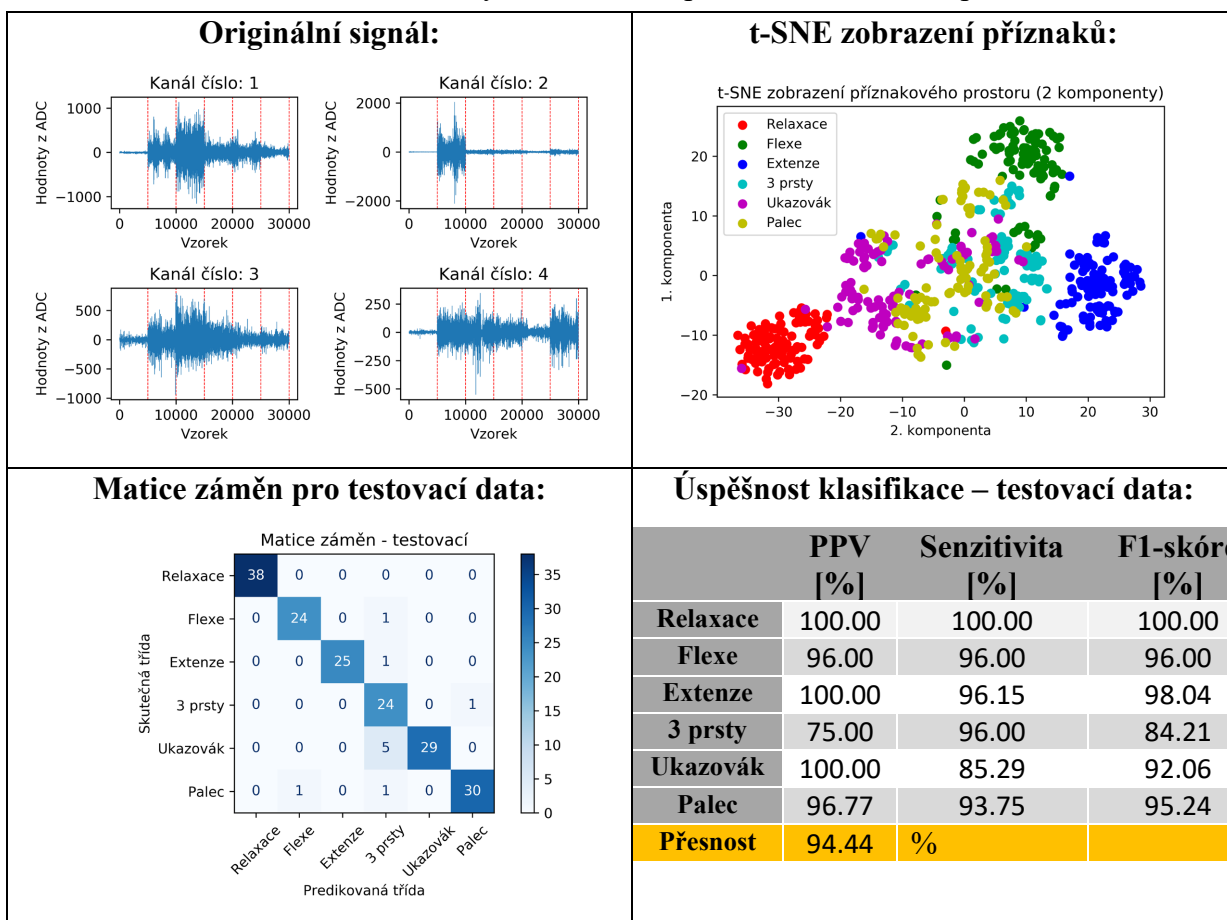
Měření 1

- **Svalové skupiny (čísla dle elektrod):** 1 - extensor digitorum; 2 - extensor indicis; 3 - flexor digitorum; 4 – flexor pollicis
- **Klasifikátor:** SVM
- **Počet elektrod:** 4
- **Časové okno:** 50 vzorků
- **Počet rozpoznávaných gest:** 8
- **Dodatečné informace:** Využití všech 40 příznaků, včetně SampEn



Měření 2

- **Svalové skupiny (čísla dle elektrod):** 1 - extensor digitorum; 2 - flexor digitorum; 3 – extensor indicis; 4 – flexor policis
- **Klasifikátor:** SVM
- **Počet elektrod:** 4
- **Časové okno:** 50 vzorků
- **Počet rozpoznávaných gest:** 6
- **Dodatečné informace:** Využití všech 40 příznaků, včetně SampEn



3. Sestavení

Účel měření:

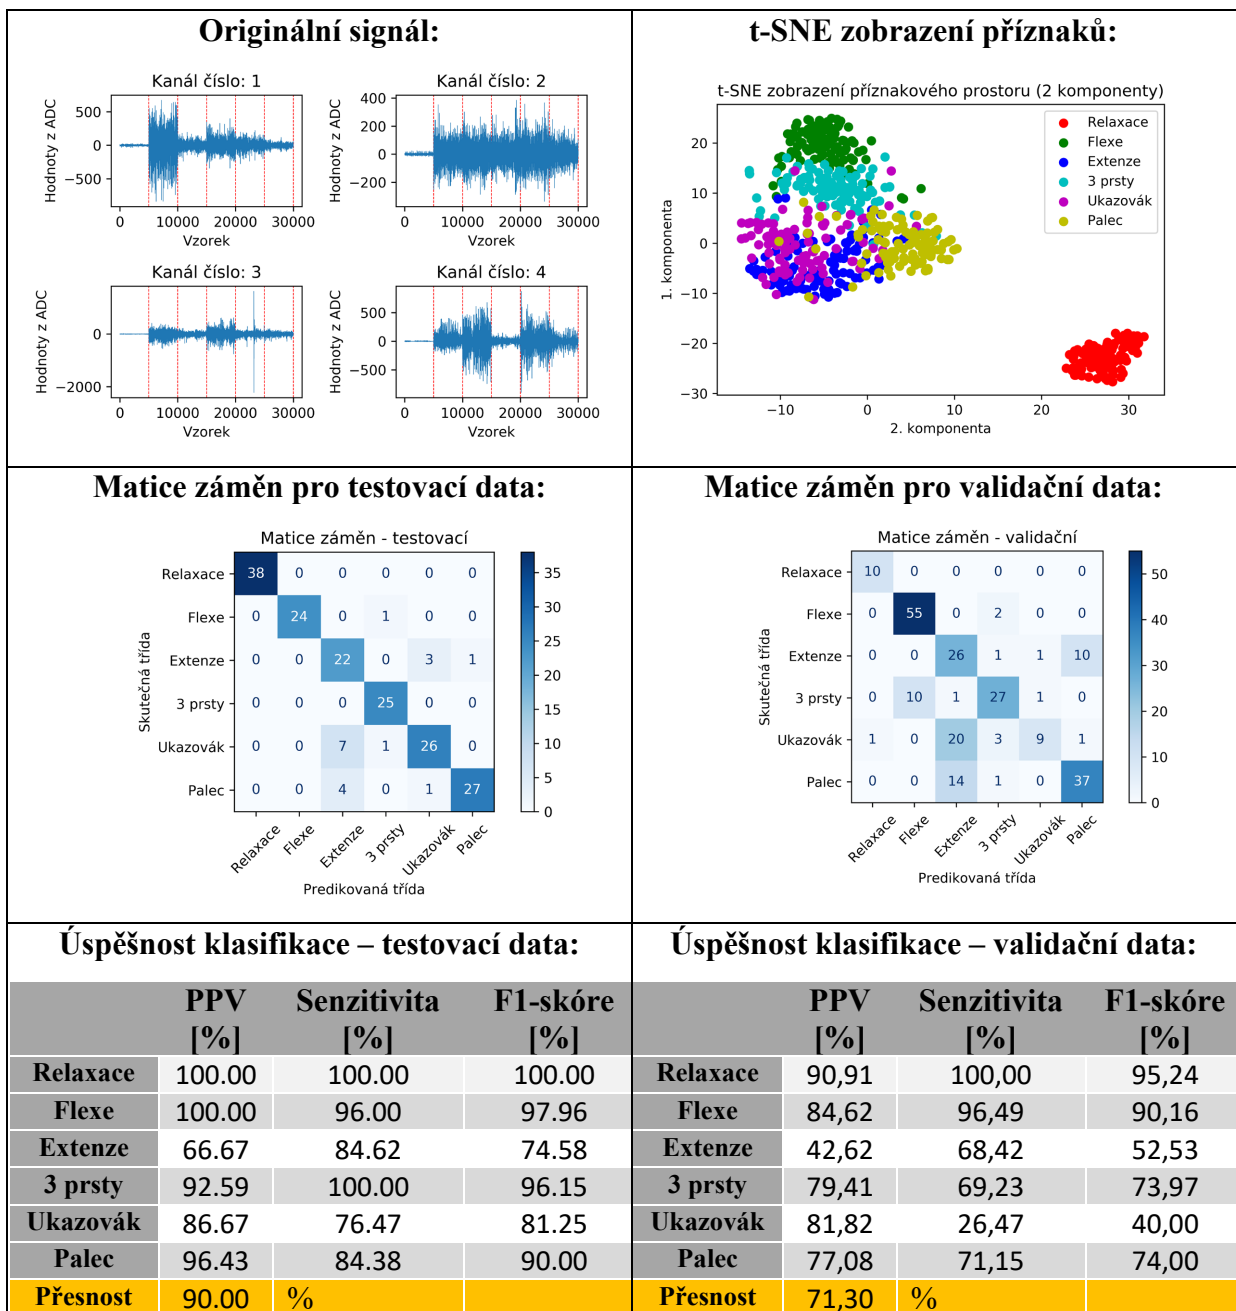
- porovnání úspěšnosti klasifikace v případě využití delšího časového okna
- výpočet úspěšnosti klasifikace pro dané rozložení elektrod

Rozložení elektrod:



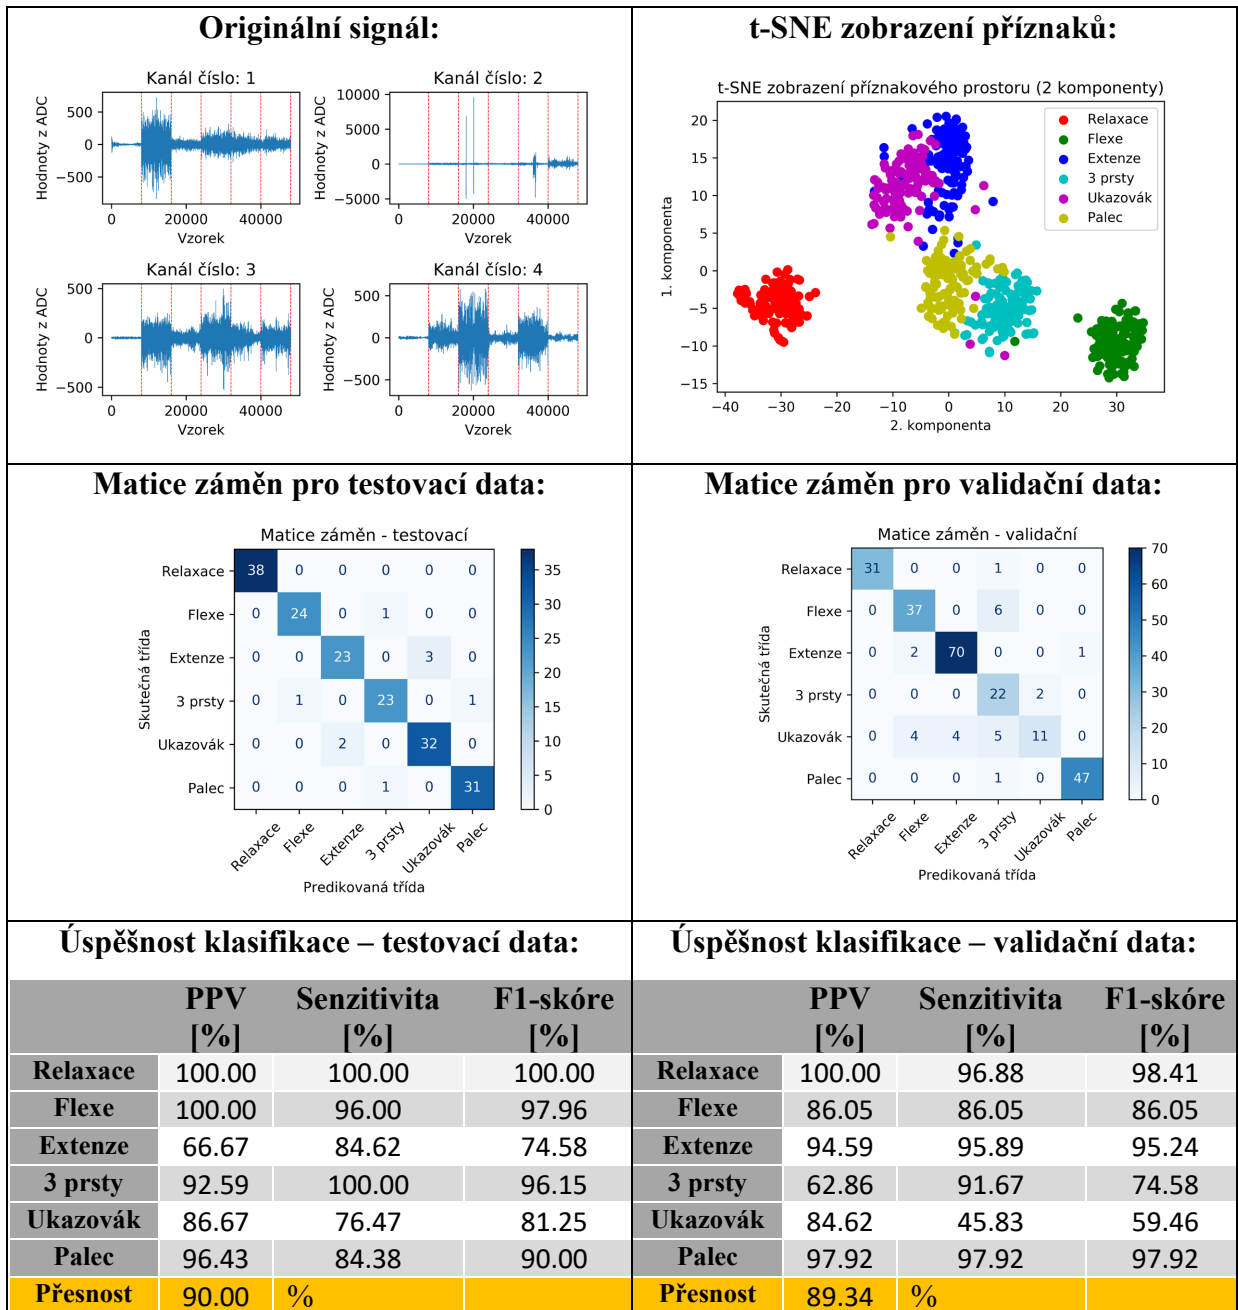
Měření 1

- **Svalové skupiny (čísla dle elektrod):** 1 – flexor digitorum; 2 – flexor pollicis; 3 – flexor indicis; 4 – flexor minimi
- **Klasifikátor:** SVM
- **Počet elektrod:** 4
- **Časové okno:** 50 vzorků
- **Počet rozpoznávaných gest:** 6
- **Dodatečné informace:** Využití všech příznaků



Měření 2

- **Svalové skupiny (čísla dle elektrod):** 1 – flexor digitorum; 2 – flexor pollicis; 3 – flexor indicis; 4 – flexor minimi
- **Klasifikátor:** SVM
- **Počet elektrod:** 4
- **Časové okno:** 100 vzorků
- **Počet rozpoznávaných gest:** 6
- **Dodatečné informace:** Využití všech příznaků



4. Sestavení

Účel měření:

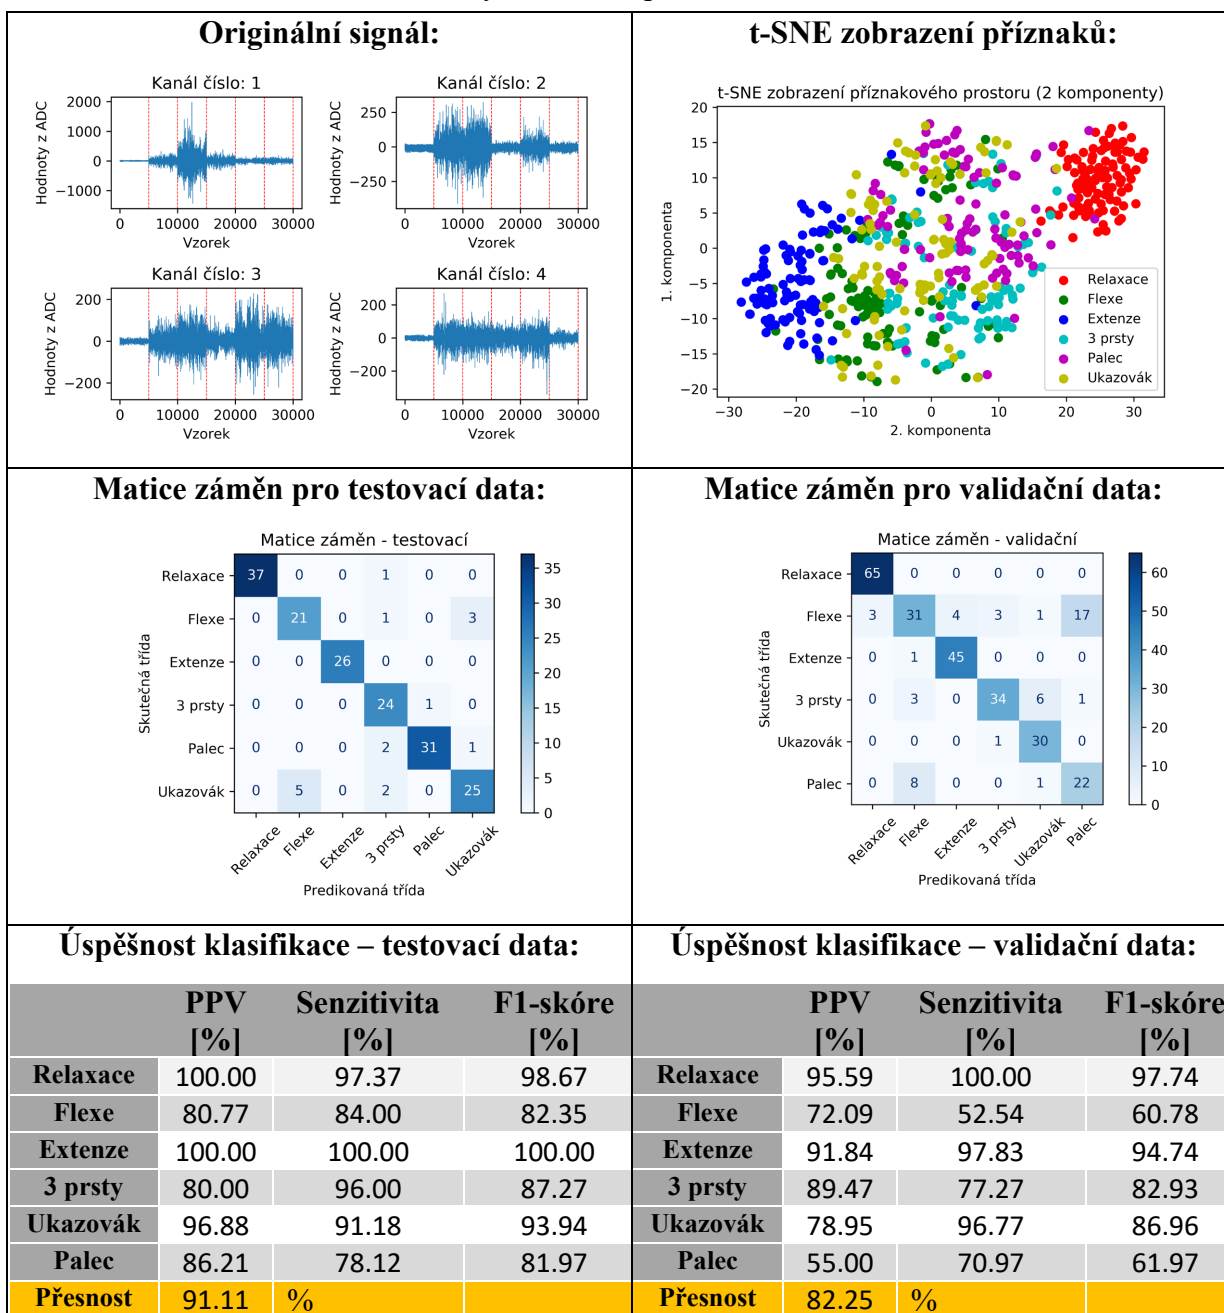
- výpočet úspěšnosti klasifikace pro dané rozložení elektrod
- ověření úspěšnosti v případě přidání gesta šumu (pohyb prstů)

Rozložení elektrod:



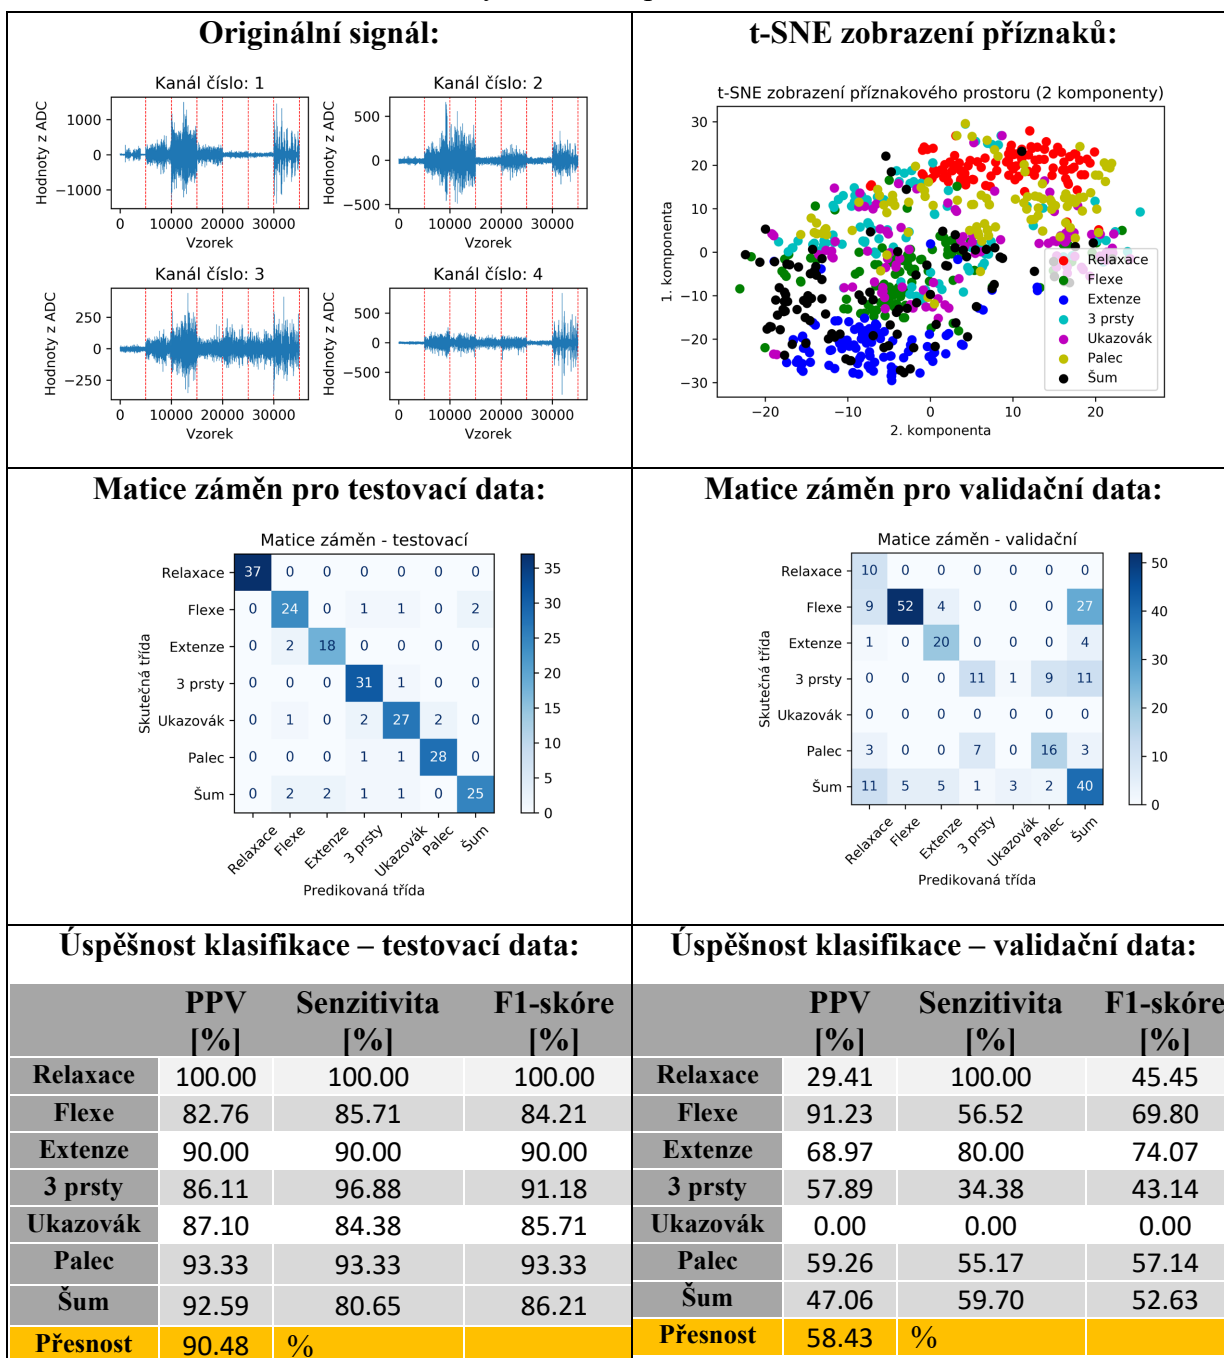
Měření 1

- **Svalové skupiny (čísla dle elektrod):** 1 – extensor digitorum; 2 – flexor digitorum; 3 – flexor policis; 4 – extensor indicis
- **Klasifikátor:** SVM
- **Počet elektrod:** 4
- **Časové okno:** 50 vzorků
- **Počet rozpoznávaných gest:** 6
- **Dodatečné informace:** Využití všech příznaků



Měření 2

- **Svalové skupiny (čísla dle elektrod):** 1 – extensor digitorum; 2 – flexor digitorum; 3 – flexor policis; 4 – extensor indicis
- **Klasifikátor:** SVM
- **Počet elektrod:** 4
- **Časové okno:** 50 vzorků
- **Počet rozpoznávaných gest:** 7
- **Dodatečné informace:** Využití všech příznaků



5. Sestavení

Účel měření:

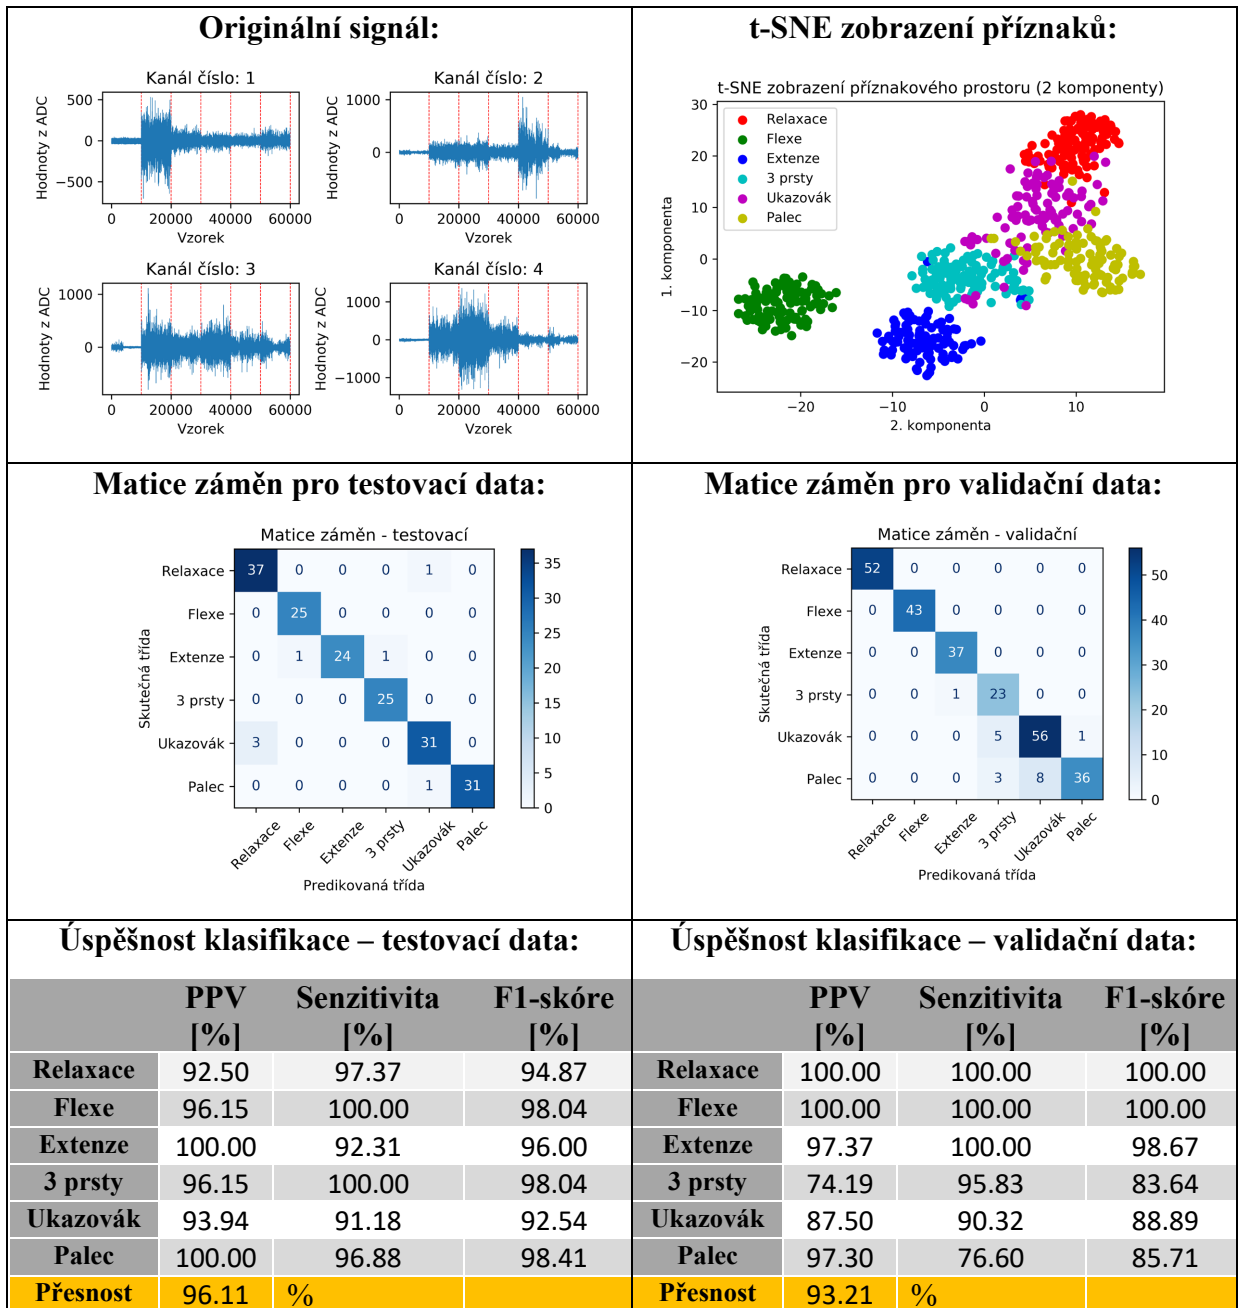
- ověření úspěšnosti klasifikace pro dané rozložení elektrod
- ověření vlivu časového okna

Rozložení elektrod:



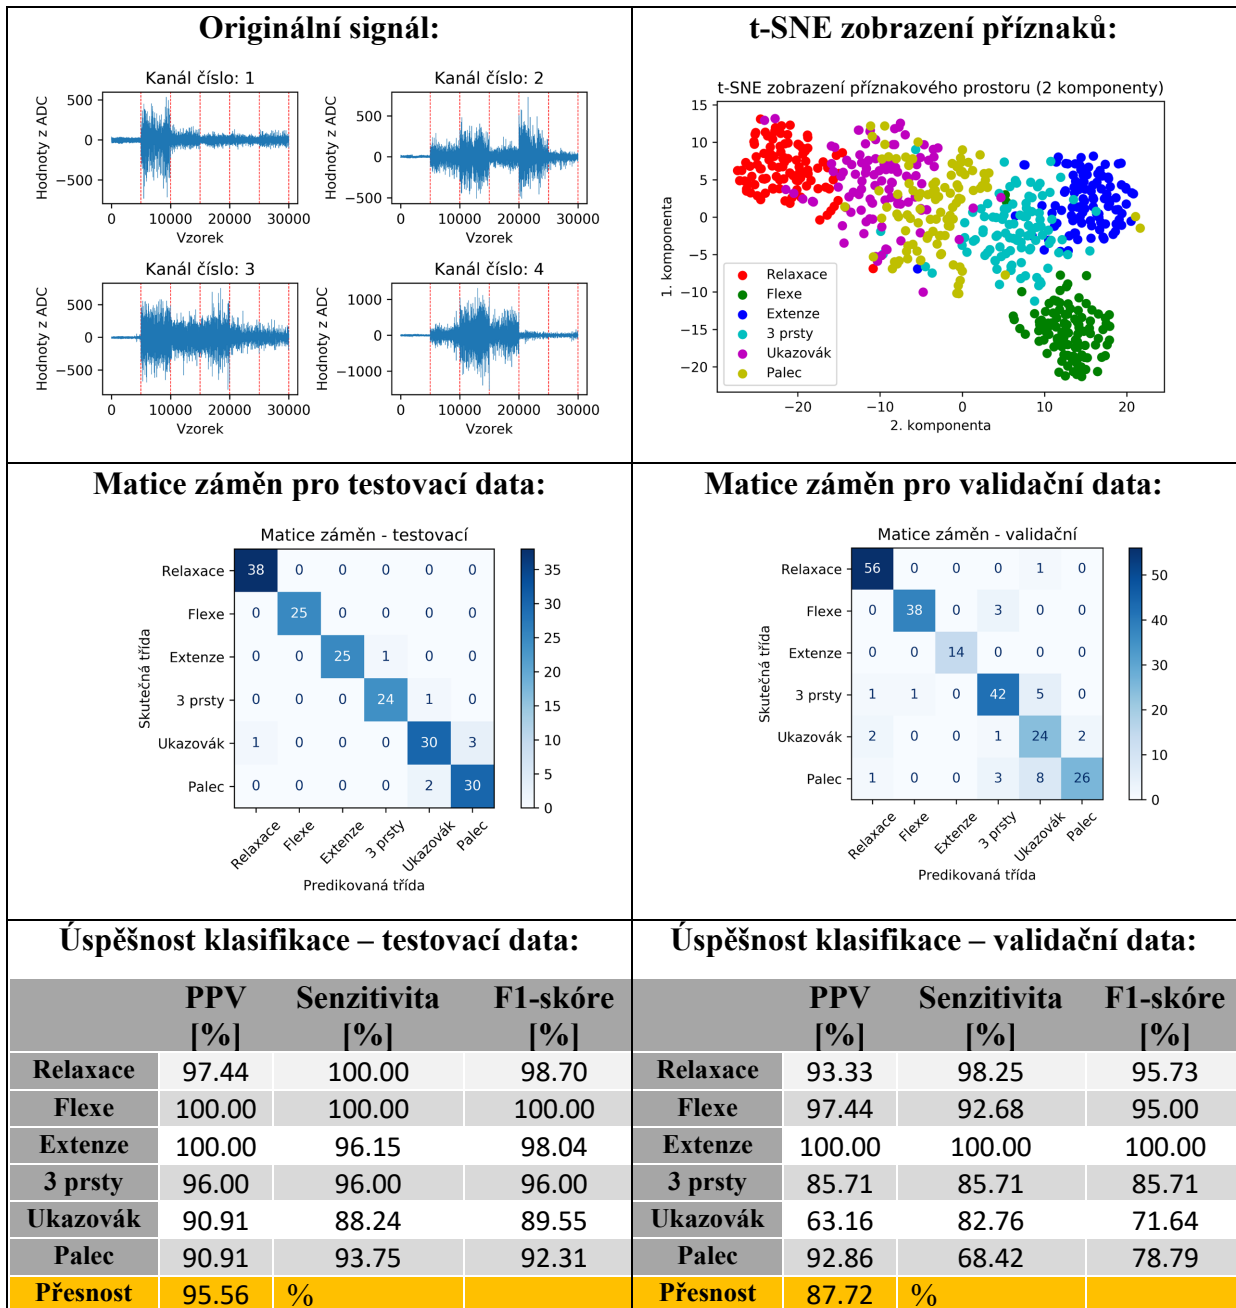
Měření 1

- **Svalové skupiny (čísla dle elektrod):** 1 - flexor digitorum; 2 – extensor indicis; 3 – flexor policis; 4 – extensor digitorum
- **Klasifikátor:** SVM
- **Počet elektrod:** 4
- **Časové okno:** 100 vzorků
- **Počet rozpoznávaných gest:** 6
- **Dodatečné informace:** Využití nekorelovaných příznaků


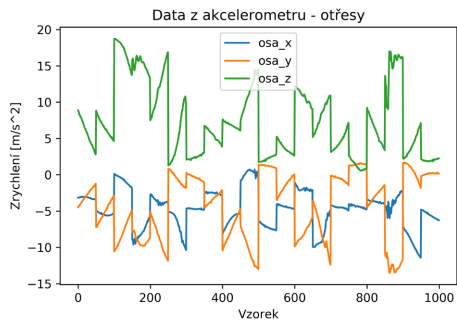
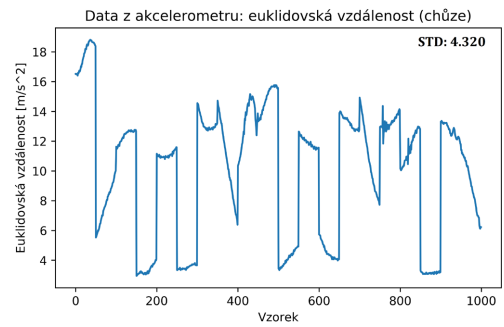
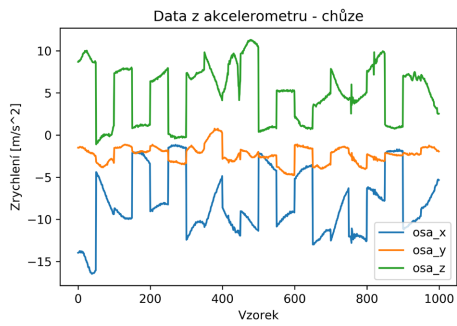



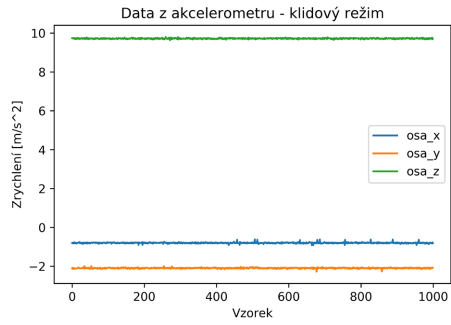


Měření 2

- **Svalové skupiny (čísla dle elektrod):** 1 - flexor digitorum; 2 – extensor indicis; 3 – flexor policis; 4 – extensor digitorum
- **Klasifikátor:** SVM
- **Počet elektrod:** 4
- **Časové okno:** 50 vzorků
- **Počet rozpoznávaných gest:** 6
- **Dodatečné informace:** Využití nekorelovaných příznaků



Testování akcelerometru



D Obsah přiloženého nosiče

- Elektronická verze diplomové práce
- Zdrojové kódy pro spuštění programu
- Surová data z měření
- Videozáznam praktické ukázky funkčnosti systému ve formátu .mp4