

VŠB-Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky

DIPLOMOVÁ PRÁCE

2017

Bc. Filip Marynčák

VŠB-Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Klasifikace myopotenciálů gest ruky pro ovládání aplikací

Classification of myopotentials of hand's motions to control
applications

2017

Bc. Filip Marynčák

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání diplomové práce

Student: **Bc. Filip Marynčák**
Studijní program: N2649 Elektrotechnika
Studijní obor: 3901T009 Biomedicínské inženýrství
Téma: **Klasifikace myopotenciálů gest ruky pro ovládání aplikací**
Classification of Myopotentials of Hand's Motion to Control Applications
Jazyk vypracování: čeština

Zásady pro vypracování:

1. Teoretický rozbor měření myopotenciálů a vliv na svalovou činnost.
2. Rešerše stávajícího stavu.
3. Návrh a realizace měřicího řetězce pro měření myopotenciálů.
4. Klasifikace myopotenciálů na základě fuzzy algoritmů.
5. Provedení testovacího měření a zpracování naměřených dat.
5. Softwarová optimalizace měřicího řetězce pro real-time měření.
6. Zhodnocení dosažených výsledků.

Seznam doporučené odborné literatury:


- [1] KELLER, Otakar. *Obecná elektromyografie: Fyziologické základy a elektrofyziologická vyšetření*. Praha: Triton, 1999. ISBN 80-7254-047-5.
[2] CRISWELL, Eleanor. *Cram's introduction to surface electromyography*. Sudbury, MA: Jones & Bartlett Publishers, 2010. ISBN 978-0763732745.
[3] KUCKLICK, Theodore R. (ed.). *The medical device R&D handbook*. Boca Raton: CRC Press, 2012. ISBN 978-1439811894.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.


Vedoucí diplomové práce: **Ing. Lukáš Peter**

Datum zadání: 01.09.2016

Datum odevzdání: 28.04.2017


doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry




prof. RNDr. Václav Snášel, CSc.
děkan fakulty

Prohlášení

*Prohlašuji, že jsem tuto práci vypracoval samostatně. Uvedl jsem všechny literární
prameny a publikace, ze kterých jsem čerpal.*



.....
Filip Marynčák

Datum odevzdání diplomové práce: 25. 4. 2017

V Ostravě

dne 25. 4. 2017

Poděkování

Velmi rád bych na prvním místě poděkoval mé matce, Aleně Marynčákové, která mě vždy a za každých okolností velmi podporovala ve studiu. Mé velké poděkování patří vedoucímu mé diplomové práce panu Ing. Lukáši Peterovi, především za jeho cenné rady při tvorbě práce. Jeho vždy vstřícný a pozitivní přístup značně přispěl úspěšnému dokončení práce.

Abstrakt

V této diplomové práci je realizován systém pro klasifikaci myopotenciálů gest ruky. Prvním cílem bylo vytvořit hardware, který by byl schopen přenést nezarušený a správně zesílený signál myopotenciálů svalů ke zpracování do PC. Druhým cílem bylo naprogramovat algoritmus, který myopotenciály klasifikuje do určených gest ruky.

Kombinací filtrů 2. řádu a správného zesílení byl vytvořen hardwarový prototyp obsahující čtyři měřící kanály pro snímání myopotenciálů. Z důvodu použití aktivních elektrod je uživatel galvanicky oddělen od zdroje.

Pro digitalizaci a přenos dat byl vybrán mikrokontrolér Arduino Nano a naprogramován dle vytvořeného komunikačního protokolu. Programování počítačové aplikace je realizováno v jazyce C#. Zpracování signálu a grafické zobrazení měřeného signálu probíhá v reálném čase. Dle algoritmu adaptivní segmentace je zjišťována hranice provedeného gesta. Pomocí navržených fuzzy množin a systému váhování je určeno jedno z pěti (nebo žádné) gest ruky, které bylo provedeno.

Klíčová slova

EMG, myopotenciály, fuzzy, adaptivní segmentace, C#

Abstract

Realization of the system for classification of hand's gestures is described in this master's thesis. The first goal was to create hardware that would be able to measure signal of myopotentials for computer analysis without external noise and with right amplification. The second goal was to program an algorithm which could classify specific gestures of hand.

Hardware prototype of four measuring channels was created by combination of 2nd order filters and right amount amplification. The user is isolated from the power source using galvanic isolation because of usage of active electrodes.

For digitizing the data, the Arduino Nano microcontroller was selected and programed using defined communication protocol. The computer software is programed in C# programming language. Signal processing and drawing to user interface is in real time. The one of five possible gestures that user made is chosen using fuzzy logic and designed system of scaling.

Key words

EMG, myopotentials, fuzzy, adaptive segmentation, C#

Obsah

Seznam použitých zkratek.....	8
Seznam obrázků	9
Seznam tabulek.....	10
1 Úvod.....	11
2 Vznik EMG a jeho šíření.....	12
2.1 Nervový přenos	12
2.1.1 Nervová buňka	12
2.1.2 Synapse.....	12
2.2 Klidový a akční potenciál.....	13
2.3 Sval.....	14
2.3.1 Motorická jednotka.....	14
2.3.2 Kontrakce kosterního svalu	15
2.3.3 Svaly předloktí	15
3 Elektromyografie.....	18
3.1 Elektrody pro neinvazivní snímání EMG.....	18
3.2 Elektromyograf.....	19
3.2.1 Technické vybavení elektromyografu	19
3.3 Hodnocení elektromyografického signálu.....	20
3.3.1 Analýza amplitudy	20
3.3.2 Frekvenční analýza.....	21
4 Rešerše	23
4.1 Úvod.....	23
4.2 Články	23
4.3 Závěr rešerše	30
5 Návrh a realizace měřicího řetězce	31
5.1 Návrh měřicího kanálu pro snímání myopotenciálů	31
5.1.1 Napájení.....	31
5.1.2 Přístrojový zesilovač	32
5.1.3 Filtrace.....	33
5.1.4 Výsledné zesílení.....	36
5.2 Přenos naměřených dat do PC.....	37
5.3 Návrh DPS.....	37

6	Softwarové zpracování dat	39
6.1	Komunikační protokol.....	39
6.1.1	Skladba paketu	39
6.1.2	Zpracování dat v Arduino Nano	39
6.1.3	Přijetí a zpracování paketu v PC	40
6.2	Vykreslování měřených dat.....	43
6.3	Adaptivní segmentace	43
6.3.1	Realizace	43
6.4	Výpočet příznaků segmentu	45
6.5	Návrh fuzzy množin	46
6.5.1	Příklad návrhu fuzzy množiny.....	47
6.6	Klasifikace gest	49
6.6.1	Klasifikace dle míry příslušnosti ve fuzzy množině.....	49
6.6.2	Dodatečné váhování gest v jednotlivých kanálech.....	51
7	Testovací měření	52
7.1	Umístění elektrod a demonstrace gest.....	52
7.2	Testování obecné funkčnosti programu a tlačítek	54
7.3	Testování přesnosti rozlišování gest.....	54
7.4	Návrhy na zvýšení přesnosti měření	55
8	Závěr	56
	Literatura	57
	Seznam příloh.....	60

Seznam použitých zkratk

ATP – adenosintrifosfát

AVR – průměr rektifikovaných hodnot (z angl. Average Rectified Value)

CMAP – sumární akční potenciály svalu (z angl. Compound Muscle Action Potential)

EMG – Elektromyografie

FFT – rychlá Fourierova transformace (z angl. Fast Fourier Transformation)

LBP – logaritmický výkon pásma (z angl. Logarithmic Band Power)

MUAP – akční potenciál motorické jednotky (z angl. Muscle Unit Action Potential)

RMS – střední kvadratický průměr (z angl. Root Mean Square)

SFEMG – EMG jednoho svalového vlákna (z angl. Single Fiber EMG)

Seznam obrázků

Obr. 2-1 Stavba neuronu [3] (upraveno)	12
Obr. 2-2 Znárodnění chemické synapse [3] (upraveno)	13
Obr. 2-3 Průběh ideálního akčního potenciálu kosterního svalu. 1 – klidový membránový potenciál, 2 – depolarizace, 3 – repolarizace, 4 – hyperpolarizace (refrakterní doba)	14
Obr. 2-4 Motorická jednotka [7] (upraveno)	15
Obr. 2-5 Svaly předloktí [9]	16
Obr. 3-1 Plovoucí elektroda ve dvou různých provedeních.	18
Obr. 3-2 Ohebná multielektroda typu mřížka s ohebnými konektory. [13]	19
Obr. 3-3 Blokový diagram elektromyografu	19
Obr. 3-4 Příklad rektifikace (full wave rectification)	21
Obr. 3-5 Rektifikovaný signál (žlutě), RMS (černě). [18]	21
Obr. 3-6 Využití FFT pro frekvenční analýzu EMG získané z biceps brachii. [19]	22
Obr. 4-1 Blokové schéma zařízení	23
Obr. 4-2 Prototyp náramku pro snímání EMG	24
Obr. 4-3 Algoritmus pro prahové rozhodování	26
Obr. 4-4 Umístění elektrod	29
Obr. 4-5 Umístění elektrod	30
Obr. 5-1 Blokový diagram galvanického oddělení	31
Obr. 5-2 Schéma zapojení galvanického oddělení	31
Obr. 5-3 Osazovací předpis DPS pro galvanické oddělení	32
Obr. 5-4 Symetrizátor napětí	32
Obr. 5-5 Zapojení přístrojového zesilovače INA126	33
Obr. 5-6 Návrh hornopropustného filtru 20 Hz	34
Obr. 5-7 Frekvenční a fázová charakteristika hornopropustného filtru	34
Obr. 5-8 Návrh dolnopropustného filtru 500 Hz	35
Obr. 5-9 Frekvenční a fázová charakteristika dolnopropustného filtru	35
Obr. 5-10 Pásmová zádrž 50 Hz	36
Obr. 5-11 Výsledné zesílení $A_U = 341$	36
Obr. 5-12 Arduino Nano [30]	37
Obr. 5-13 Osazovací předpis horní strany desky	38
Obr. 5-14 Osazovací předpis spodní strany desky	38
Obr. 6-1 Diagram zpracování dat do paketu v Arduinu	40
Obr. 6-2 Uživatelské rozhraní při spuštění programu	41
Obr. 6-3 Chybová hláška při nezdaření se připojení k portu	41
Obr. 6-4 Stavový diagram příjmu dat do PC	42
Obr. 6-5 Vykreslování měřeného signálu v reálném čase	43
Obr. 6-6 Princip adaptivní segmentace na základě dvou spojených oken [31]	44
Obr. 6-7 Blokový diagram nalezení segmentů v signálu	45
Obr. 6-8 Neupravený návrh fuzzy množiny; zleva: žádné gesto, nahoru, vlevo, pěst, dolů, vpravo, žádné gesto	48

Obr. 6-9 Upravený návrh fuzzy množiny; žádné gesto, nahoru, vlevo, pěst, dolů, vpravo, žádné gesto	48
Obr. 6-10 Zjednodušený diagram klasifikace gest	50
Obr. 6-11 Diagram vyhodnocení finálního gesta	51
Obr. 7-1 Umístění elektrod na předloktí	52
Obr. 7-2 Záznam testovacího měření	54

Seznam tabulek

Tab. 4-1 Tabulka aktivity svalů při jednotlivých gestech. ○:sval je aktivní, ×:sval není aktivní.....	25
Tab. 4-2 Umístění elektrod.....	27
Tab. 6-1 Skladba paketu.....	39
Tab. 6-2 Octet stuffing	39
Tab. 6-3 Tabulka středních hodnot příznaků pro jednotlivá gesta v jednotlivých kanálech.....	47
Tab. 6-4 Tabulka směrodatných odchylek příznaků pro jednotlivá gesta v jednotlivých kanálech.....	47
Tab. 6-5 Tabulka hodnot pro návrh fuzzy množiny příznaku DIFF ve IV. kanále	48
Tab. 6-6 Označení gest.....	49
Tab. 6-7 Tabulka vah jednotlivých gest	51
Tab. 7-1 Demonstrace gest pro klasifikaci.....	53
Tab. 7-2 Tabulka přesnosti určování gest	54

1 Úvod

Stále více rozšiřující se trend nositelných komplexních zařízení, vedl ke tvorbě této práce. V dnešní době je cílem nositelných technologií, co nejvíce zjednodušovat každodenní aktivity uživatelů anebo kontinuální získávání informací v průběhu dne. Pod kontinuálním získáváním informací je možné si představit například hodinky, které nám po celý den měří tep, počítají kroky a vyhodnocují tím celkovou fyzikou aktivitu. Co kdyby bylo možné ovládat zvolené aplikace v počítači či telefonu, pouze pomocí provedením gesta ruky? Právě tímto tématem se zabývá níže popsána práce.

V první kapitole je popsán obecný princip vzniku myopotenciálů na úrovni buňky. Jak fungují synapse, co to je motorická jednotka, jak dochází ke kontrakci svalu a v neposlední řadě jsou také popsány svaly předloktí, ze kterého budou myopotenciály snímány. Princip snímání myopotenciálů popisuje následující kapitola elektromyografie. Zde jsou popsány elektrody používané k neinvazivnímu měření EMG, jejich konstrukce a materiály. Dále je popsán obecný funkční diagram elektromyografu a následné hodnocení elektromyografického signálu.

Část rešerše shrnuje poznatky, které byly v této oblasti doposud objeveny. Cílem rešeršní části bylo zjistit, jaký je optimální návrh hardwaru pro snímání myopotenciálů. Jaké typy filtrů bývají použity, velikost zesílení a konstrukce samotného hardwaru. Druhou hledanou informací bylo, jaké autoři použili algoritmy pro samotné zpracování a hodnocení snímaných signálů, jejich porovnání a hlavně úspěšnost dosažená jednotlivými metodami.

V části zabývající se hardwarem je popsán přesný postup návrhu prototypové desky pro měření myopotenciálů. Je zde popsána tvorba symetrizátoru napětí pro napájení operačních zesilovačů a také návrh galvanického oddělení USB. Následuje popis návrhu filtrů pro měřicí kanály a také zesílení potřebné k převodu analogového signálu na digitální.

Softwarová část se zabývá tvorbou algoritmu pro správnou klasifikaci gesta. Nejprve je popsán komunikační protokol, skladba paketu a zpracování přijatých dat. Princip adaptivní segmentace, která nám automaticky hledá v signálu segmenty gest, je popsán v kapitole spolu se vzorci pro její aplikaci. Poslední kapitola softwarové části je zaměřena na samotnou klasifikaci gest, ke které je využito fuzzy množin a systému váhování.

2 Vznik EMG a jeho šíření


V této kapitole bude rozebrána anatomie a kineziologie příčně pruhovaných (kosterních) svalů. Zejména bude zaměřena na svaly horní končetiny, jejich dynamiku a aktivitu jednotlivých svalů při různých pohybech ruky.

2.1 Nervový přenos

2.1.1 Nervová buňka

Nervová buňka (*lat. neuron*) je základní anatomickou a funkční jednotkou nervové soustavy. Neuron tvoří tělo a výběžky (viz Obr. 2-1). Výběžky vedoucí vzruch dostředivým směrem jsou nazývány dendrity a výběžky vedoucí vzruch odstředivým směrem jsou nazývány axony. Dendritů je zpravidla větší počet a bývají kratší. Oproti tomu axony mohou mít délku od několika milimetrů až po metr, proto se využívají pro přenos informace na větší vzdálenost. Neurony, které přímo inervují kosterní svaly jsou nazývány motoneurony.

[1][2]




Obr. 2-1 Stavba neuronu [3] (upraveno)

2.1.2 Synapse

Synapsí je nazýváno spojení dvou buněk, kde alespoň jedna z nich je neurálního původu. V lidském těle je synaptický přenos nejčastěji tvořen chemickou synapsí pomocí mediátoru. Neurony se v synapsi přímo nedotýkají, ale je mezi nimi tzv. synaptická štěrbina o šířce asi 20-30 nm. Do této štěrbině je vyloučen neurotransmitter při přichozím akčním potenciálu, který způsobí vznik synaptického potenciálu na druhém neuronu. Znázornění principu tohoto procesu je zřetelně viditelné na Obr. 2-2.

[4]



Obr. 2-2 Znárodnění chemické synapse [3] (upraveno)

Nervosvalová ploténka je zvláštní typ chemické synapse, kterou se zajišťuje přenos informace z neuronu na vlákno kosterního svalu. Pomocí ploténky je přenášen signál pro vznik akčního potenciálu na sarkolemě¹. Vznik akčního potenciálu závisí na velikosti ploténky, množství aktivovaných receptorů a počtu otevřených Na⁺ kanálů v okolí ploténky.

[4]


2.2 Klidový a akční potenciál

V klidovém stavu je potencionální rozdíl mezi intracelulární a extracelulárním prostorem přibližně -90 mV. Tento potenciál vzniká nerovnoměrnou distribucí iontů na obou stranách membrány. Toto je způsobeno semipermeabilitou membrány, která je v klidovém stavu málo propustná pro kationty Na⁺ a vysoce propustná pro kationty K⁺. Nervové a svalové buňky mohou však membránový potenciál měnit. Při nárůstu propustnosti membrány pro Na⁺ ionty dochází ke změně klidového potenciálu, který se stává méně negativní. Při dosažení tzv. prahové hodnoty (-50 mV až -70 mV) se prudce zvýší propustnost membrány pro Na⁺ ionty, které začnou proudit do nitra buňky. Tato fáze se nazývá depolarizace, jelikož prudce klesá membránový potenciál. Membránový potenciál klesá natolik, že je na zlomek milisekundy kladný. Odezvou na to je zvýšení propustnosti pro K⁺ ionty a snížení propustnosti pro Na⁺ ionty, čímž se buňka navrácí do klidového stavu. Na okamžik je dokonce polarizace vyšší, než byl v původním stavu, což je způsobenou prudkou změnou propustnosti pro výše uvedené ionty.

Těsně po vzniku akčního potenciálu je membrána v absolutní refrakterní době. To znamená, že na membráně není možné vyvolat akčním potenciál žádným podnětem. Po odeznění této doby přechází buňka do relativní refrakterní doby. Což znamená, že akční potenciál může být vyvolán, ale pouze

¹ Sarkolema – cytoplazmatická membrána svalových buněk.

stimulem vyšším než je obvyklé za klidového stavu. Průběh ideálního akčního potenciálu kosterního svalu může být pozorován na Obr. 2-3.



Obr. 2-3 Průběh ideálního akčního potenciálu kosterního svalu. 1 – klidový membránový potenciál, 2 – depolarizace, 3 – repolarizace, 4 – hyperpolarizace (refrakterní doba)

Vznik akčního potenciálu se řídí dle zákona vše nebo nic. To znamená, že pokud podnět dosáhne prahového nebo vyššího potenciálu, tak odpovědí bude akční potenciál.

[1][4]

2.3 Sval

Svalstvo je elastickou tkání, která se vyznačuje schopností kontrakce a následné relaxace. Sval se skládá ze svalových vláken a vaziva, které spojuje a obaluje svalová vlákna. Obecně svalstvo dělíme na:

- svalstvo příčně pruhované
- hladkou svalovinu
- srdeční svalovinu

Jelikož cílem této práce je snímat elektromyografické signály z předloktí, bude se zabýváno pouze svalstvem příčně pruhovaným.

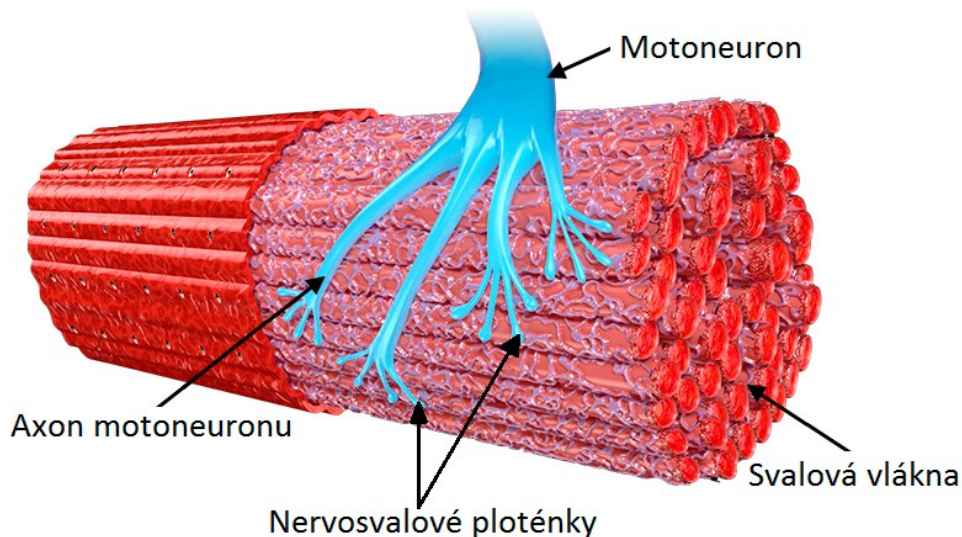
[5]

2.3.1 Motorická jednotka

Motorická jednotka sestává míšní motoneuron, jeho axon a všechna svalová vlákna, která jsou tímto motoneuronem inervována. Je také nejmenší částí svalového systému, kterou jde samostatně aktivovat. Počet svalových vláken, která vytváří motorickou jednotku, se liší dle požadavku na sílu a přesnost kontrakce jednotlivých svalů.

Na motoneuronech je velké množství synapsí z aferentních drah periferních nervů, ale hlavně synapsí ze spinálních descendentních drah. Každá z těchto synapsí může způsobit na motoneuronu buď excitační nebo inhibiční postsynaptický potenciál. Pokud součet postsynaptických potenciálů překročí prahovou hodnotu, vznikne akční potenciál. Ten se šíří po axonu motoneuronu do nervosvalové ploténky, přes kterou aktivuje všechna svalová vlákna v motorické jednotce. Ilustrace přenosu je zobrazena na Obr. 2-4.

[2][6]



Obr. 2-4 Motorická jednotka [7] (upraveno)

2.3.2 Kontrakce kosterního svalu

Každé svalové vlákno se skládá až z tisíců dlouhých vláken nazývané myofibrily. Myofibrily jsou tvořeny polymery aktinu a myozinu. Tyto proteiny tvoří společně molekulární aparát pro svalovou kontrakci. Při té dochází ke zkrácení svalu, přičemž objem zůstává stejný.

Pokud vyšle motoneuron adekvátní podnět pro kontrakci, dochází skrze nervosvalovou ploténku k depolarizaci buněčných membrán a poté i celého svalového vlákna. Při depolarizaci dojde k uvolnění Ca^{2+} iontů, což způsobí pohyb aktinových a myozinových vláken. Tento celý proces spustí rozklad ATP, z něhož vznikne energie, díky které se vlákna aktinu a myozinu zasunou do sebe a vzniká kontrakce svalu.


Síla kontrakce je přímo úměrná jak počtu aktivovaných motorických jednotek, tak frekvenci jejich aktivity. Jeden akční potenciál může aktivovat pouze jednu motorickou jednotku. Čím větší je potřebná výsledná síla, tím více se zapojuje dalších motorických jednotek a zvyšuje se frekvence jejich činnosti. Tento jev se nazývá nábor motorických jednotek.

[2][4][8]

2.3.3 Svaly předloktí

Svaly předloktí se dělí na tři skupiny a to přední skupina, laterální skupina a dorsální skupina. Níže uvedené svaly jsou výběrem z celé svalové skupiny předloktí. Tyto svaly byly vybrány na základě teoretických předpokladů nabytých ze znalostí anatomie a fyziologie. Je očekáváno, že právě tyto svaly

budou hrát nejdůležitější roli při snímání EMG signálu při jednotlivých gestech ruky. Jednotlivé svaly předloktí jsou zobrazeny na obrázku Obr. 2-5.



Obr. 2-5 Svaly předloktí [9]

Extensor digitorum communis

Tento sval patří do dorsální skupiny svalů předloktí. Je to takzvaný natahovač prstů, jelikož je upnut ke šlachám 2.-5. prstu. Je inervován nervem nervus radialis a zvýšenou elektrickou aktivitu svalu je možné pozorovat při natahování prstů a flexi zápěstí.

Extensor carpi ulnaris

Tento sval taktéž patří do dorsální skupiny svalů předloktí. Je nazýván natahovačem zápěstí, protože je jeho funkcí dorsální flexe a ulnární dukce zápěstí. Při těchto pohybech můžeme detekovat elektrickou aktivitu svalu a inervaci zajišťuje nervus radialis.

Extensor carpi radialis longus

Sval řadíme do laterální skupiny svalů předloktí a jinak ho nazýváme dlouhý zevní natahovač zápěstí. Jeho primární funkcí je dorsální flexe a radiální dukce zápěstí, při nichž může být pozorována největší elektrická aktivita toho svalu. Sval je inervován nervem nervus radialis.

Flexor digitorum profundus

Sval patří do přední skupiny svalů předloktí a též je nazýván hluboký ohybač prstů. Každá šlacha se upíná na bázi distálního článku 2.-5. prstu a ohýbá prsty ve všech kloubech, které přebíhá. Je inervován nervy nervus medianus a nervus ulnaris. Elektrickou aktivitu můžeme pozorovat při ohýbání prstů.

Flexor carpi ulnaris

Tento sval se řadí do přední skupiny svalů předloktí. Je nazýván ohybačem zápěstí, jelikož jeho hlavní funkcí je flexe zápěstí a také napomáhá flexi loketního kloubu. Sval je inervován nervem nervus ulnaris a elektrickou aktivitu můžeme pozorovat právě při flexi zápěstí.

Flexor carpi radialis

Sval je zařazen do skupiny předních předloketních svalů a je jinak nazýván zevní ohybač zápěstí. Je inervován nervem nervus medianus. Jeho hlavní funkcí je flexe a radiální dukce zápěstí a také napomáhá flexi loketního kloubu.

[5][10]

3 Elektromyografie

Elektromyografie (zkr. EMG) je diagnostická metoda, pomocí které jsou snímány bioelektrické signály kosterního svalstva. Výsledný záznam bioelektrického signálu nazýváme elektromyogram. Touto metodou lze získat cenné informace o stavu svalového aparátu, popřípadě jeho poruch. Samotné snímání EMG lze provádět invazivně či neinvazivně. Při invazivním snímání lze měřit elektrickou aktivitu na úrovni jediného svalového vlákna, přičemž při neinvazivním snímání je nejčastěji měřena aktivita celého svalu.

[11]

3.1 Elektrody pro neinvazivní snímání EMG

V dnešní době je na trhu dostupných mnoho typů elektrod, proto je důležité zvolit správné elektrody pro danou aplikaci. Jedním z důležitých faktorů je samotná velikost elektrod. Malé elektrody s průměrem 0,5 cm a rozstupem 1 cm by se například využili pro snímání obličejových svalů s vysokou selektivitou. Naopak elektrody o průměru 1 cm a rozstupu 2-3 cm mohou být použity pro snímání signálu z větších svalů. Čím více se zvětšuje rozstup mezi jednotlivými elektrodami, tím se stává měření více regionální a méně selektivní.

Plovoucí elektrody jsou jedním z nejpoužívanějších typů elektrod. Tento typ najde nejlepší využití při snímání dynamických pohybů. V malé dutince je umístěna elektroda, která je přibližně 1 mm nad povrchem kůže. Tato dutinka je poté naplněna elektrolytickým médiem pro zajištění přenosu potenciálu ze svalu na snímací elektrodu (viz Obr. 3-1). Elektrody jsou vyráběny v provedení Ag/AgCl. Díky tomuto konstrukčnímu řešení, je tento typ elektrod méně náchylný na pohybové artefakty.


[12]



Obr. 3-1 Plovoucí elektroda ve dvou různých provedeních.

Pro snímání EMG nad určitou oblastí mohou být elektrody sdruženy do tzv. multielektrod. Tyto elektrody sdružují větší počet elektrod do určité geometrické konfigurace. Nejčastěji to bývá buďto pásek (*angl. strip*) nebo mřížka (*angl. grid*). Elektrody na pásku jsou umístěny vedle sebe s určitým rozstupem. Tento rozstup je dán právě tím, jak velkou oblast je požadováno snímat a s jakou selektivitou. Pásek menších rozměrů s malým rozstupem elektrod bude disponovat velkou selektivitou a možností měřit potenciál například jednoho svalu nebo jeho části. Kdežto pásek s většími rozměry a rozstupy elektrod bude použit na měření elektrické aktivity větších svalů nebo svalových skupin. Stejně pravidlo platí u multielektrody typu mřížka, pouze s rozdílem v geometrickém uspořádání jednotlivých elektrod. Jak již napovídá název, elektrody jsou zde rozmístěny do tvaru 2-D mřížky. Jednotlivé elektrody jsou nejčastěji umístěny na povrchu ohebné silikonové podložky nebo na podložce v prohlubních. Demonstraci ohebnosti multielektrody a rozmístění jednotlivých elektrod je znázorněno na Obr. 3-2. Při použití se aplikuje vodivý gel, čímž se multielektroda stává plovoucí a jsou zde významně potlačeny pohybové artefakty.

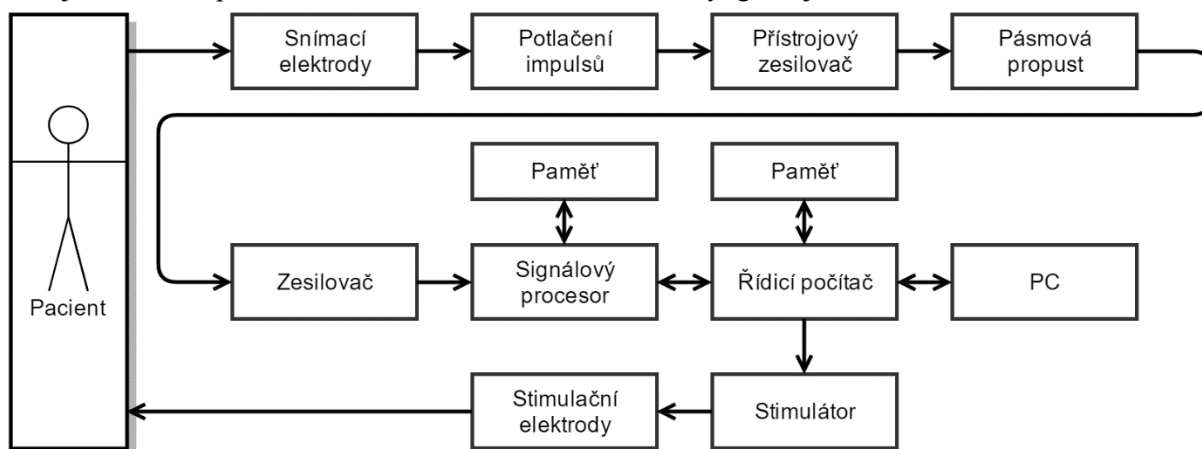
[11][12]



Obr. 3-2 Ohebná multielektroda typu mřížka s ohebnými konektory. [13]

3.2 Elektromyograf

Elektromyograf je zdravotnický elektrický přístroj pomocí kterého snímáme elektrickou aktivitu svalů. Výstupem elektromyografu je elektromyogram na kterém hodnotíme stav neuromuskulárního systému. EMG signál můžeme také zpracovat pro vyhodnocování gest obličeje nebo určité končetiny, což je cílem této práce. Základní blokové schéma elektromyografu je zobrazeno na obrázku Obr. 3-3.



Obr. 3-3 Blokový diagram elektromyografu

3.2.1 Technické vybavení elektromyografu

Každý elektromyograf musí být sestaven s určitých elektrických součástí volených tak, aby zajistily co nejideálnější zpracování signálu, pro jeho nejlepší vyhodnocení. Signál musí být nejprve zesílen pomocí předzesilovače a přístrojového zesilovače, který také zajišťuje galvanické oddělení pacienta od elektrické sítě. Dále musí být se signálu vyfiltrováno požadované frekvenční pásmo a eliminovány pohybové artefakty. Každý elektromyograf by měl umožňovat snímání jak pomocí intramuskulárních elektrod, tak pomocí povrchových elektrod a také volbu mezi bipolárními a unipolárními svody. Většina elektromyografů bývá vybavena také stimulátorem pro měření somatosenzorických a motorických evokovaných potenciálů.

[1][11]

Signál generovaný svaly a periferními nervy má velice nízkou amplitudu, přibližně v rozmezí 20 μV až 90 mV, proto je důležité tento signál patřičně zesílit. Takto nízký signál potřebujeme zesílit až 100 000x. Při snímání pomocí intramuskulárních elektrod může být naměřená amplituda vyšší. Jedním důležitých požadavků pro předzesilovač je vysoký vstupní odpor (alespoň 100 M Ω), z důvodu malé plochy u intramuskulárních elektrod. Z tohoto důvodu jsou voleny, pro přepínání mezi unipolárním a bipolárním měřením, klasické relé namísto polovodičových.

[11][15]

Dalším důležitým faktorem je správná filtrace signálu, které lze dosáhnout jak analogově tak digitálně. Elektromyografický signál může dosahovat frekvencí až 10 kHz, což ho výrazně odlišuje od jiných biologických signálů. Většinou je pro každý měřicí kanál zařazena pásmová propust, které má dolní mezní kmitočet 5 Hz a horní mezní kmitočet 500 Hz pro povrchové elektrody. U intramuskulárních elektrod bývá horní mezní kmitočet 10 kHz. Dále musí být odfiltrována frekvence síťového rušení 50 Hz.

[2][14]

3.3 Hodnocení elektromyografického signálu

K analýze a následnému hodnocení elektromyografického signálu se nejvíce využívá detekce změn frekvenčního spektra a amplitudy v čase. Samotný nezpracovaný signál EMG nese také důležité informace. Lze z něj vyhodnotit, zda je měřený sval aktivní či nikoliv nebo vyhodnotit aktivitu svalu při určité činnosti. Pro přesnější hodnocení a další práci je však nezbytné signál dále zpracovat. Nejčastějšími měřeními modalitami jsou sumární akční potenciály svalu (CMAP), akční potenciál motorické jednotky (MUAP) a EMG jednoho svalového vlákna (SFEMG).

3.3.1 Analýza amplitudy


Aktivace svalu je spojena s akčním potenciálem motorické jednotky jej inervující. V ideálním případě by měl sval v klidovém režimu vykazovat aktivitu 0 V a při překročení aktivačního prahu by měl dojít k jeho kontrakci. Jelikož se signál skládá z mnoha hrotových amplitud o vysoké frekvenci a je nutno signál upravit zpracovatelné podoby. Nejčastějším způsobem bývá rektifikace a následné vyhlazení signálu.

[16]

Rektifikace

Hodnoty amplitudy EMG se pohybují kolem nuly, čili jak v záporných, tak v kladných hodnotách. Při zprůměrování těchto hodnot by byl výsledek teoreticky roven nule, proto se využívá rektifikace. Pomocí rektifikace buďto odstraníme záporné hodnoty ze signálu (half wave rectification) nebo záporné hodnoty přepoklopíme do kladných (full wave rectification).

[17]

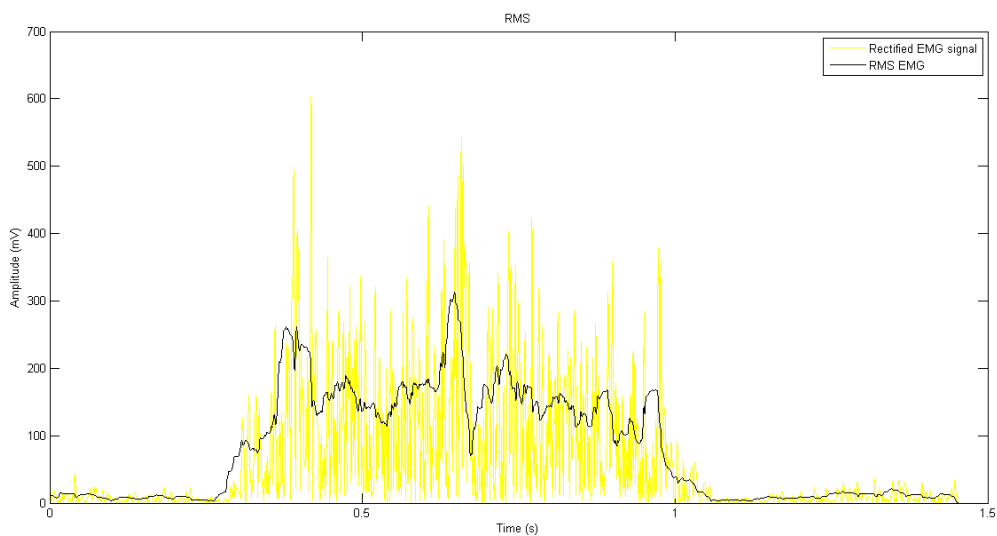


Obr. 3-4 Příklad rektifikace (full wave rectification).

Vyhlazení

Rektifikovaný signál stále obsahuje ostré hrotové amplitudy, proto se přechází k vyhlazení signálu. Vnikne nám jakási obálka signálu, kterou lze pak daleko jednodušeji zpracovávat. K vyhlazení signálu se nejčastěji využívá průměrování rektifikovaných hodnot (AVR z angl. average rectified value) nebo výpočtem středních kvadratických hodnot (RMS z angl. root mean square).


[17]



Obr. 3-5 Rektifikovaný signál (žlutě), RMS (černě). [18]

3.3.2 Frekvenční analýza

Pro frekvenční analýzu bývá využíván převod z časové oblasti do frekvenční, pomocí rychlé Fourierovy transformace (FFT). Výpočet FFT probíhá ze surových, předem neupravených dat. Cílem frekvenční analýzy je získání frekvenčního a výkonového spektra EMG signálu. Nejčastěji hodnocené parametry jsou průměrná frekvence, střední hodnota frekvence a vlnový rozsah spektra.



Obr. 3-6 Využití FFT pro frekvenční analýzu EMG získané z biceps brachii. [19]

Jedním z problémů využití FFT je aliasing. Tento jev vzniká, pokud není dodržen Nyquistův teorém, který nám říká, že vzorkovací frekvence musí být minimálně 2x větší než nejvyšší frekvence v signálu. Pro FFT analýzu EMG signálu se však doporučuje až 4x větší frekvence aby se zamezilo aliasingu.

[19]

4 Rešerše

4.1 Úvod

Rešerše se zabývá sumací aktuálních poznatků na poli snímání EMG a jeho využití v nositelných elektronických zařízeních. Hlavním cílem je zjištění postupů a metod ke správnému snímání EMG a také metody tvorby algoritmů pro správné rozpoznávání gest při pohybech ruky.

4.2 Články

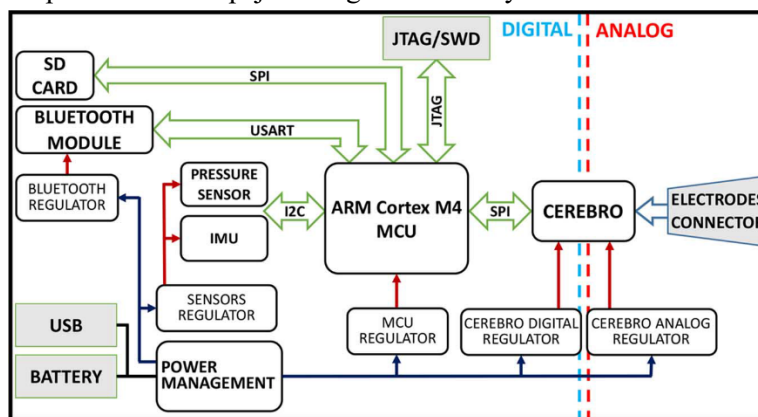
Název: A Versatile Embedded Platform for EMG Acquisition and Gesture Recognition

Autor: S. Benatti; F. Casamassima; B. Milosevic; E. Farella; P. Schonle; S. Fateh T. Burger; Qiuting Huang; L. Benini

Publikováno: 2015 IEEE Transactions on Biomedical Circuits and Systems, Vol. 9, No. 5, October

Autoři článku vytvořili elektronické zařízení pro rozeznání gest ruky ze snímaného EMG signálu. Jedním z cílů práce bylo veškeré zpracování signálu a rozeznání gest provést přímo na DPS a ne pomocí koncového software. Výsledky jsou v průběhu srovnávány se dvěma dalšími zařízeními.

Bylo zjištěno, že nejlepšími výsledky bylo dosaženo pomocí 7 párů elektrod, kde se měří diferenční potenciál mezi protějšími elektrodami. Elektrody jsou připojeny k Cerebro ASIC (Application Specific Integrated Circuit), kde probíhá předzpracování biologického signálu. Samotné zpracování signálu probíhá v ARM Cortex M4 MCU, který je vybaven FPU, RAM o velikosti 192 kB a FLASH od velikosti 1 MB. Pro přenos signálu do koncové aplikace bylo zvoleno Bluetooth specifikace 2.1 z důvodu přenosu dat při vysokých rychlostech. Elektronika je osazena na šestivrstvé DPS, kde jedna z vrstev je pouze zem pro oddělení napájecí a signálové vrstvy.



Obr. 4-1 Blokové schéma zařízení

Pro rozpoznání gest autoři zvolili metodu strojového učení SVM. Ale bylo zdůrazněno, že se jednotlivé známé metody pro naučení a určení gest ve výsledku moc neliší.

[20]


Autoři článku zvolili čistě hardwarově řešení segmentace gest bez použití koncového zpracování signálu v počítači. Z tohoto projektu mohou být čerpány cenné informace týkající se hardwarového zpracování signálu a možná kombinace se zpracováním softwarovým.

Název: Electrode Layout of Wristband EMG Measuring Device for Hand Gesture Recognition

Autor: H. Motoyama; T. Inoue; Y. O. Kato; J. Ozawa

Publikováno: 2015 IEEE International Conference on Consumer Electronics

Tento článek se zabývá ideálním rozložením elektrod na zápěstí pro detekci gest. Cílem bylo redukovat množství elektrod po správnou detekci gest. Při této studii bylo testováno klasické rozmístění elektrod, kde jsou 2 aktivní elektrody umístěny na jednom svalu a je měřen jejich diferenční potenciál a tzv. crossover layout, kde nejsou elektrody umístěny na stejném svalu vedle sebe, nýbrž na svalech jiných (např. vedlejších). Tudiž se měří diferenční potenciál dvou různých svalů a ne oblast na jednom svalu. Pro přesnější měření byl zakomponován také 3-D akcelerometr.



Obr. 4-2 Prototyp náramku pro snímání EMG

Při testování na 5 subjektech bylo zjištěno, že crossover layout dokáže rozpoznat stejná gesta jako standartní rozložení elektrod, při použití polovičního množství elektrod. Pokles přesnosti při použití crossover layout byl pouze 3 %. Ovšem je zdůrazněno, že je tuto metodu ověřit na rozšířenějších testech a potvrdit tak její efektivitu.

[21]

Výsledkem této práce je důkaz, že může být dosažené skoro stejné přesnosti segmentace jednotlivých gest zápěstí při použití menšího počtu elektrod a tzv. crossover layoutu rozmístění elektrod. Toto rozložení může vést ke snížení počtu elektrod použitých pro snímání, avšak s pravděpodobně nutným přidáním akcelerometrů.

Název: Gesture Segmentation and Recognition with an EMG-based Intimate Approach

Autor: F. Carrino; A. Ridi; E. Mugellini; O. A. Khaled; R. Ingold

Publikováno: 2012 Sixth International Conference on Complex, Intelligent, and Software Intensive Systems

V tomto článku je popsán vývoj systému pro rozeznání gest na základně snímání EMG signálu. Byly použity 4 elektrody, kde 2 elektrody jsou umístěny na triceps a další 2 na předloktí. Pro snímání EMG bylo použito zařízení MQ-16 od Marq-Medical z důvodu nízké hmotnosti a bezdrátového přenosu pomocí Bluetooth. Data byly přeneseny do počítače a pomocí OpenViBE platformy proběhla analýza signálu pro potřebu segmentace gest.

Naměřený EMG signál je zesílen a převeden na digitální hodnoty pomocí 16 bitového A/D převodníku. Poté je přiveden Butterworthův filtr 4. řádu s dolní mezní frekvencí 20 Hz a horní mezní

frekvenci 450 Hz. Dále je signál segmentován do posuvných oken (sliding window strategy) o délce 256 ms s překryvem 128 ms. Z těchto oken je pak měřena Efektivní hodnota (Root Mean Square), Logaritmičtý výkon pásma (Logarithmic Band Power) a střední absolutní hodnota (Mean Absolute Value). Na základě těchto hodnot je provedena klasifikace gest nebo klidového stavu pomocí Lineární diskriminační analýzy (Linear Discriminant Analysis).

V závěru byly testovány 2 gesta a to pro flexi či extenzi zápěstí. Bylo zjištěno, že systém rozpozná gesta s přesností 95,88 %.

[22]

V článku se autoři zabývají segmentací dvou gest při snímání EMG z tricepsu a předloktí. Dle mého názoru je umístění elektrod na triceps, při rozpoznání gest flexe a extenze zápěstí, zbytečná. Elektrody mohly být umístěny jinde na předloktí pacienta, což by vedlo k větší mobilitě, nebo se pokusit gesto rozpoznat pouze ze dvou elektrod umístěných na předloktí. Zajímavé a přínosné je ovšem použití Butterworthova filtru a následné zpracování signálu pomocí oken. Výsledné počítané parametry mohou být důležité pro správné rozpoznání gest.

Název: Hand Sign Classification Techniques Based on Forearm Electromyogram Signals

Autor: Takeshi Tsujimura; Kosuke Urata; Kiyotaka Izumi

Publikováno: 2015 International Conference on Informatics, Electronics & Vision (ICIEV)

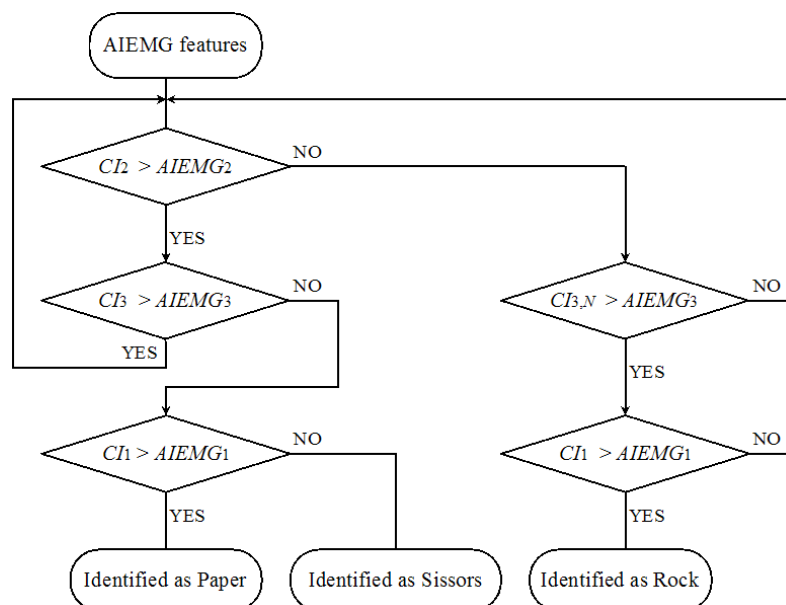
Tato práce se zabývá rozeznání gest kámen, nůžky, papír na základně dvou různých přístupů. Na základě anatomických předpokladů a měření bylo zjištěno, že při různých gestech se aktivuje jeden či více z předem zmíněných svalů, jak můžeme vidět v tabulce Tab. 4-1.

Tab. 4-1 Tabulka aktivity svalů při jednotlivých gestech. ○:sval je aktivní, ×:sval není aktivní

Sval		Kámen	Nůžky	Papír
Ch. 1	Extensor pollicis brevis	×	×	○
Ch. 2	Extensor digitorum	×	○	○
Ch. 3	Flexor digitorum profundus	○	×	×

Pro měření byly použity 3 elektrody. Jedna na svalu *extensor pollicis brevis*, druhá na svalu *extensor digitorum* a třetí na svalu *flexor digitorum profundus*. Jako zařízení pro měření EMG byl zvolen elektromyograf s vzorkovací frekvencí 10 kHz a 16 bit A/D převodníkem. Zároveň byl signál integrován a převeden tak na IEMG (Integrated EMG). Oba tyto signály jsou pak přivedeny do PC a zde vyhodnoceno tzv. AIEMG (Average Integrated EMG), které představuje průměr EMG signálu za určený čas.

Prvním přístupem pro měření byla empirická prahová metoda (Empirical Thresholding Method). Nejprve je v tomto algoritmu rozhodnuto, zda je měřený sval aktivní či nikoliv. Poté je na základě AIEMG a nastavených prahových hodnot vybráno odpovídající gesto. Prahové hodnoty byly určeny z experimentálního měření. Pro kanál Ch. 1 byla prahová hodnota 0,6 V, pro Ch. 2 0,78 V a pro Ch. 3 0,62 V. Na základně rozhodovacího algoritmu zobrazeného na obrázku Obr. 4-3 je rozhodnuto o které gesto se jedná.



Obr. 4-3 Algoritmus pro prahové rozhodování

Empirická prahová metoda správně určila gesto v 93 % případů.

Druhou testovanou metodou byla meta heuristická metoda založena na genetickém algoritmu. Bylo vytvořeno 50 instancí pro každé gesto, které sloužily pro naučení genetického algoritmu. Velikost populace byla zvolena 3000 a maximální počet generací zvolen 300. První naučení genetického algoritmu bylo provedeno na populaci o 3000 s maximální hloubkou 20, křížením 1.0 a výskytem mutací 0.9. Výsledný algoritmus byl určen reprodukcí generací s nejlepší fitness funkcí. Tato metoda byla úspěšná v 99 % případů.

[23]

Tento výzkum dobře porovnává rozlišení tří gest se stejným elektromyografem, ale jiným softwarovým zpracováním. Použití genetického algoritmu se ukázalo velmi přesné (přesnost až 99 %), proto stojí určitě za zvážení použití tohoto algoritmu v cílové aplikaci.

Název: Hand Posture and Gesture Recognition using MYO Armband and Spectral Collaborative Representation based Classification

Autor: Ali Boyali; Naohisa Hashimoto; Osamu Matsumoto

Publikováno: 2015 IEEE 4th Global Conference on Consumer Electronics (GCCE)

Tento článek se zabývá analýzou EMG signálu, rozpoznání gest a kvalitou rozpoznávání gest. Pro snímání EMG je využit MYO armband od Thalmic Labs, který je zaměřen na rozpoznávání gest ruky dle snímání EMG a následnou komercializaci této technologie. Pro rozpoznání šesti různých gest jsou v této práci použity metody zvané *Subspace Clustering (SC)* a *Collaborative Representation based Classification (CRC)*. Nejprve byla nasnímána data pro každé gesto a to vždy v pozici relaxace a poté udělení gesta. Z takto nasnímaných dat byl vytvořen datový slovník, pro rozpoznání jednotlivých gest v reálném čase. Pomocí metody SC je pro každé gesto vytvořen cluster dat. Tyto jsou poté využity k výpočtu a správné klasifikaci gesta pomocí metody CRC. Ta je založena na systému lineárních rovnic a převodu do spektrální domény. Výsledná přesnost pro jednotlivá gesta se pohybovala mezi 97-100 %.

[24]

V této práci je zajímavé, že se autoři snaží použít již hotový komerční výrobek pro rozpoznání gest a nasnímaný signál rozpoznat podle jiných metod, než které jsou použity v originále. S vysokou úspěšností se podařilo gesta rozpoznat pomocí obou použitých metod.

Název: Using Forearm Electromyograms to Classify Hand Gestures

Autor: Gene Shuman

Publikováno: 2009 IEEE International Conference on Bioinformatics and Biomedicine

V této práci byla provedena studie pro výběr nejlepšího klasifikačního a rozhodovacího algoritmu pro rozpoznání gest ruky. Pro dosažení nejlepšího výsledku při klasifikaci šesti gest byly elektrody umístěny dle tabulky Tab. 4-2.

Tab. 4-2 Umístění elektrod

Kanál	Sval	Umístění
1	ED (<i>Extensor Digitorum</i>)	2,5 palce nad zápěstím
2	FDS (<i>Flexor Digitorum Superficialis</i>)	2,5 palce nad zápěstím
3	FCU (<i>Flexor Carpi Ulnaris</i>)	4 palce nad zápěstím
4	ED (<i>Extensor Digitorum</i>)	2,5 palce pod loktem
5	PL (<i>Palmaris Longus</i>)	3 palce pod loktem

Pro snímání EMG byl použit elektromyograf DelSys Myomonitor. EMG signál byl digitalizován a poté spočítán kvadratický průměr (RMS) pro dvou sekundové okno, které koresponduje s délkou trvání gesta. Hodnoty z každého senzoru byly snímány po dobu 5 sekund při vzorkovací frekvenci 1 kHz. Hodnoty RMS byly potom spočítány pro 2000 digitalizovaných hodnot měřených mezi první a třetí sekundou. Vypočtené RMS hodnoty byly převedeny na klasifikační prvky pomocí Weka Machine Learning/Data Mining Tool.

Klasifikační trénink byl proveden pro 90 instancí: 15 pokusů, 6 různých gest za pokus. Každá instance obsahuje data z pěti měřících kanálů, což nám dá celkově 450 hodnot. Bylo testováno celkově 6 klasifikačních algoritmů: Artificial Neural Network (ANN), Random Forest (RF), One Nearest-Neighbor (1NN), Decision Tree with Boosting (DT/B), Support Vector Machine (SVM), a Decision Tree (DT). Po prvním měření byla, pro zvýšení přesnosti, vždy použita analýza rozptylu (ANOVA) pro odstranění odlehklých, čili špatně naměřených, hodnot. Bylo zjištěno, že z výše uvedených klasifikačních algoritmů byl nejpřesnější Artificial Neural Network (93,3 %), poté Random Forest (90 %) a třetí nejpřesnější byl One Nearest-Neighbor (86,7 %).

[25]

Velmi povedený článek, ve kterém autoři zkoumají 6 různých rozhodovacích algoritmů. Porovnáním úspěšnosti byl nejpřesnější algoritmus umělé neuronové sítě. Na druhou stranu se zdají úspěšnosti jednotlivých algoritmů celkem nízké, protože jiní autoři dosahují při použití například neuronových sítí až 99% úspěšnosti.

Název: EMG-Based Signal Processing System for Interpreting Arm Gestures

Autor: Osamah A. Alsayegh

Publikováno: 2000 10th European Signal Processing Conference

V této práci je popsána funkčnost systému a klasifikačního algoritmu pro rozeznání dvanácti gest ruky. EMG je snímáno ze tří svalů: *anterior deltoid* (AD), *medial deltoid* (MD) a *biceps brachii*

(BB). Pro získání EMG dat bylo provedeno celkem 50 pokusů pro každé gesto (celkově 600 pokusů pro 12 gest). Pro zaznamenání aktivity loketního a ramenního kloubu byly použity bipolární elektrody. Pro snímání samotného EMG signálu byl použit přístroj Biopac MP30. Pro snímání byla použita vzorkovací frekvence 500 Hz, poté byl použit hornopropustný filtr $f_c = 30 \text{ Hz}$, dále dolnopropustný filtr $f_c = 250 \text{ Hz}$ a nakonec pásmová propust $f_0 = 60 \text{ Hz}$. Celkové zesílení bylo 2500.

Zpracování signálů probíhalo ve třech krocích. V prvním fázi bylo cílem dostat co nejhladší EMG signál. Signál byl tedy nejprve rektifikován, nato normalizován (odstraněny odlehlé hodnoty) a naposled filtrován dolnopropustným filtrem. V druhé fázi byly z obálky signálu detekovány a uloženy význačné body společně s časem jejich výskytu. Ve třetí fázi jsou z vyhlazeného signálu spočítány parametry θ_1, θ_2 a θ_3 dle níže uvedených vzorců.

$$\begin{aligned}\theta_1 &= \int_{t_i}^{t_j} |EMG_{MD}| dt, \\ \theta_2 &= \int_{t_i}^{t_j} |EMG_{AD}| dt, \\ \theta_3 &= \int_{t_i}^{t_j} |EMG_{BB}| dt, j = i + 1.\end{aligned}$$

Z těchto parametrů je pak vytvořen charakteristický vektor pro jednotlivá gesta. Typ této klasifikace je tzv. *context-dependent classification*, za využití Bayesovy věty. Celková úspěšnost detekce dvanácti gest celé ruky byla 96 %.

[26]

Autoři úspěšně klasifikovali 12 gest celé ruky snímáním třech velkých svalů v okolí ramenního pletence. Nejedná se sice o snímání stejných gest jako je cíl této práce, ale ukazují zde efektivní využití Bayesovy věty pro rozlišení jednotlivých gest.

Název: Gesture Recognition Using Real Time EMG

Autor: Rachel Martina Edith; A. Bhargavi Haripriya

Publikováno: 2015 IEEE Sponsored 2nd International Conference on Innovations in Information, Embedded and Communication systems

V této diplomové práci je řešeno zařízení pro povrchové snímání EMG, následná detekce gest pro posouvání snímků v prezentaci. EMG je snímáno ze dvou elektrod, které jsou umístěny na zápěstí a předloktí, pomocí zařízení Grove EMG Detector od Seedstudio. Signál je přiveden na A/D převodník a následně do mikroprocesoru. Z mikroprocesoru jsou data pomocí ZIGBEE bezdrátově přeneseny do počítače pro další zpracování. Prahové hodnoty pro rozeznání různých typu gest byly po zesílení signálu nastaveny na 100 mV pro otevření a zavření dlaně, 90 mV rychlé zvednutí předloktí a 84-89 mV pro pomalé zvednutí předloktí. Na závěr práce je provedena diskuze ohledně prací zabývajících se podobným tématem.

[27]


Téma toho článku je velice podobné cíli této práce. Využití ZIGBEE oproti Bluetooth nebo WiFi je zajímavá alternativa, která stojí za zvážení. Závěrečná diskuze ohledně prací zabývajících se podobným tématem byla přínosem, pro čerpání dalších informací od jiných autorů.

Název: Hand Gesture-Based Interface with Multichannel sEMG Band Enabling Unknown Gesture Discrimination

Autor: Jakub Tomczyński; Piotr Kaczmarek; Tomasz Mańkowski

Publikováno: 2015 Proceedings of the 10th International Workshop on Robot Motion and Control, Poznan University of Technology

Hlavním záměrem této práce je sestavení zařízení pro detekci dvanácti chtěných gest a pro odmítání gest nechtěných. Pro snímání EMG signálu bylo zvoleno celkem 14 elektrod v diferenčním zapojení, čili celkově 7 kanálů. Umístění elektrod je znázorněno na obrázku Obr. 4-4.



Obr. 4-4 Umístění elektrod

Každý kanál má vlastní zesilovač, který je navržen přesně pro tuto aplikaci. Zesilovače se sestávají z přístrojového zesilovače od Texas Instruments INA326. Dále je použita pásmová propust pro frekvence 10-330 Hz. Zesilovače mají analogový výstup, který je dále vzorkován frekvencí 2 kHz v mikroprocesoru pomocí 12-bit A/D převodníku.

Pro rozpoznání kdy gesto začíná a kdy končí, bylo použito výpočtu kvadratického průměru (RMS) a posuvného okna o velikosti 256 ms. Pro klasifikaci gest byla zvolena neuronová síť s jednou skrytou vrstvou. Celková úspěšnost pro rozpoznání chtěných gest byla 97 % a úspěšnost odmítání gest nechtěných byla 96 %.

[28]


Tato práce byla zajímavá a odlišná od jiných tím, že se autoři snažili jak rozpoznat chtěné gesta, tak gesta nechtěná. Tudiž zde neprobíhalo žádné odemykací gesta, ale rovnou rozpoznávání, zda je gesto chtěné či nechtěné. Úspěšnost je ovšem vykoupena velkým počtem použitých elektrod.

Název: Multiple Hand Gesture Recognition Based on Surface EMG Signal

Autor: Xiang Chen; Xu Zhang; Zhang-Yan Zhao; Ji-Hai Yang; Vuokko Lantz; Kong-Qiao Wang

Publikováno: 2007 The 1st International Conference on Bioinformatics and Biomedical Engineering

Cílem této práce je vytvoření systému pro co nejvíce gest ruky za použití co nejméně snímacích elektrod. Experiment byl proveden pro celkově 24 gest za použití dvou aktivních elektrod. Pro snímání EMG byl použit přístroj DELSYS BAGNOLI-2 se zabudovaným filtrem pásmová propust (20-1000 Hz) a zesilovačem (60 dB). Vzorkovací frekvence byla 2 kHz. Digitalizace proběhla pomocí PCMCIA karty (NI DAQ PCI-6010). Umístění elektrod je znázorněno na níže uvedeném obrázku Obr. 4-5. Testování proběhlo na 4 subjektech. Každé gesto bylo provedeno více než 100x a trvalo přibližně 1 sekundu.



Obr. 4-5 Umístění elektrod

V první části zpracování snímaného signálu bylo důležité rozlišit, kdy gesto začíná a kdy končí. Toto bylo provedeno výpočtem kvadratického průměru (RMS) amplitud a následným posuvem okna o 60 vzorků. Při detekci hodnoty nižší než je nastavená prahová hodnota, bylo vyhodnoceno, že gesto skončilo. Jako parametry pro extrakci charakteristických prvků jednotlivých gest byly zvoleny střední absolutní hodnota (MAV) a poměr středních absolutních hodnot. Pro klasifikaci gest byl zvolen Lineární Bayesův klasifikátor, z důvodu krátkého výpočetního času výsledku. Celková úspěšnost detekce jednotlivých gest byla průměrně pro všechny subjekty 95%.

[29]

Autoři vytvořili rozlišení celkem 24 gest s průměrnou úspěšností 95 % za použití pouze tří elektrod. Což považuji za velmi úspěšné. Úprava probíhala využitím oken po 60ti vzorcích a následným výpočtem RMS. Segmentaci zajistila Bayeova věta s MAV jako parametrem.

4.3 Závěr rešerše

Z rešerše vyplývá, že valná většina systémů zabývajících se rozpoznáním gest, zpracovává a vyhodnocuje data až v počítači. Ke snímání EMG je ve většině případů použit již hotový elektromyograf. Dále z rešerše plyne, že nejčastější a nejspolehlivější metody pro klasifikaci gest jsou neuronové sítě, Random Forest (a jeho obměny) a pomocí Bayesovy věty. Bylo nabyto velké množství znalostí o správném umístění elektrod pro co nejlepší snímání signálu, avšak toto musí být testováno až pro konkrétní aplikaci s konkrétními gesty.

5 Návrh a realizace měřicího řetězce

Praktická část této práce má dvě hlavní části. První část se zabývá návrhem a konstrukcí zařízení pro měření myopotenciálů. Dále pak přenosem naměřených dat do počítače kde se odehrává druhá část této práce a to softwarové zpracování.

5.1 Návrh měřicího kanálu pro snímání myopotenciálů


V této podkapitole bude popsán návrh měřicího kanálu pro snímání myopotenciálů z předloktí. Bude zde popsáno řešení napájení a jednotlivé součástky, které jsou použity v zapojení.

5.1.1 Napájení

Pro napájení zapojení bylo zvoleno napájecí napětí +5 V, které je dodáváno z USB nebo z desky Arduino Nano, ke kterému je zapojení připojeno.

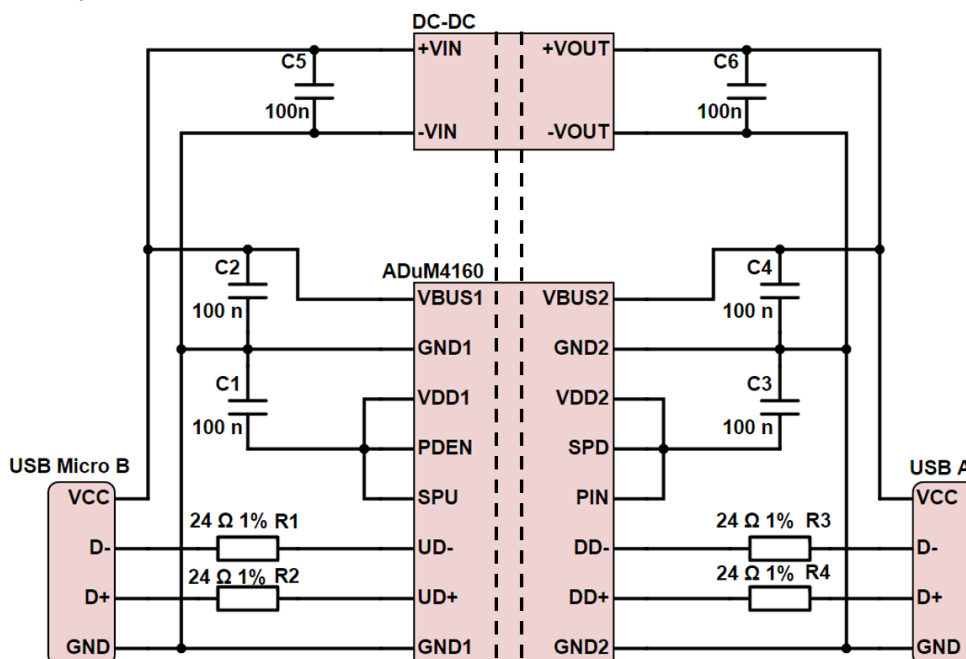
5.1.1.1 Galvanické oddělení

Z důvodu bezpečnosti a splnění normy IEC 60601-1 musí být zdroj napájení galvanicky oddělen od člověka. Nejvýhodnějším řešením je již galvanicky oddělit USB kabel, který vede z počítače do desky Arduino Nano (viz. Obr. 5-1). Takto je již člověk a celé zapojení chráněno.



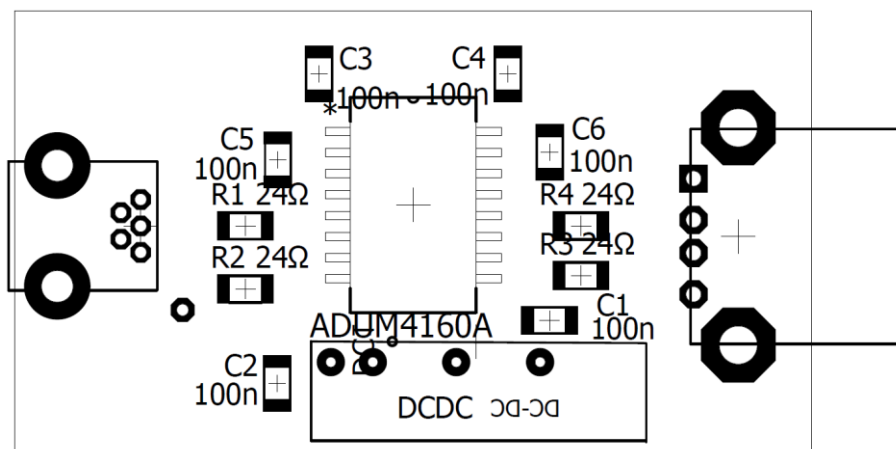
Obr. 5-1 Blokový diagram galvanického oddělení

Pro galvanické oddělení datových linek USB (D+, D-) bylo využito integrovaného obvodu ADuM4160. Tento digitální izolátor je navržen přímo pro galvanické oddělení USB jak v režimu low speed, režimu full speed. Volby jednotlivých režimů se nastavují vhodným vyzkratováním pinů v zapojení. Pro galvanické oddělení napájení bylo využito DC/DC měniče se vstupním i výstupním napětím 5 V a výkonem 1 W.



Obr. 5-2 Schéma zapojení galvanického oddělení

Na výše uvedeném obrázku (viz Obr. 5-2) je zobrazeno schéma zapojení integrovaného obvodu ADuM4160 v režimu full speed a zapojení DC-DC měniče do obvodu.




Obr. 5-3 Osazovací předpis DPS pro galvanické oddělení

Výsledná DPS byla osazena součástkami dle osazovacího předpisu (viz Obr. 5-3) a slouží jako univerzální galvanické oddělení USB. Fotky reálného zpracování osazené desky pro galvanické oddělení jsou uvedeny v příloze IV.

5.1.1.2 Symetrizátor

Z důvodu vytvoření virtuální země a napájecího napětí $\pm 2,5$ V byl navrhnut symetrizátor (viz Obr. 5-4).



Obr. 5-4 Symetrizátor napětí

Z výstupu V+ a V- jsou dále symetricky napájeny operační zesilovače. Výstup N tvoří virtuální zem, referenci a je k němu připojena referenční elektroda z pacienta.


5.1.2 Přístrojový zesilovač

První část obvodu začíná snímáním myopotenciálů elektrody a přivedením tohoto signálu do přístrojového zesilovače. Jako přístrojový zesilovač byla zvolena INA126 od Texas Instruments. Tento zesilovač má dva vstupy pro signál a na výstupu je jejich diference. Zapojením rezistoru se dá jednoduše

nastavit zesílení napětí. Zesilovač má fixní napětí 5 a může být zvýšeno až na 10 000. Vhodný rezistor je jednoduše vypočítám dle následujícího vzorce.

$$G = 5 + \frac{80 \text{ k}\Omega}{R_g} \quad (5.1)$$

$$G = 5 + \frac{80 \cdot 10^3}{20 \cdot 10^3} = 9$$



Obr. 5-5 Zapojení přístrojového zesilovače INA126

Z výše uvedené rovnice a experimentálního měření bylo pomocí 20 k Ω rezistoru nastaveno zesílení 9. Vyšší zesílení způsobovalo přechod zesilovače do saturace z důvodu polarizace elektrod. Přístrojový zesilovač je napájen symetrickým napájením $\pm 2,5$ V a referenční vstup je připojen k virtuální zemi N. Z přístrojového zesilovače pokračuje signál do hornopropustného filtru.

5.1.3 Filtrace


Elektrické potenciály svalů se pohybují ve frekvenčním spektru od 20 Hz do 500 Hz. Proto byl navržen hornopropustný a dolnopropustný filtr, které spolu propouští pouze toto frekvenční pásmo. Za tyto filtry je zařazena pásmová zadrž pro odfiltrování síťového brumu 50 Hz.

5.1.3.1 Hornopropustný filtr (HPF)

Byl navrhnout filtr 2. řádu typu horní propust s teoretickou mezní frekvencí 20 Hz. Při reálném řešení a výběru součástek z dostupných řad bylo dosaženo reálné mezní frekvence 20,434 Hz. Signál jde z přístrojového zesilovače přes hornopropustný filtr do dolnopropustného filtru (viz Obr. 5-6).


$$f_c = \frac{1}{2\pi\sqrt{C1C2R3R6}} \quad (5.2)$$

$$f_c = \frac{1}{2\pi\sqrt{6,8 \cdot 10^{-9} \cdot 6,8 \cdot 10^{-9} \cdot 820 \cdot 10^3 \cdot 1,6 \cdot 10^6}} = 20,434 \text{ Hz}$$



Obr. 5-6 Návrh hornopropustného filtru 20 Hz

Navržený filtr má následující frekvenční a fázovou charakteristiku (viz Obr. 5-7). Pod mezní frekvencí je frekvenční disperse -2 (-40 dB/dek).




Obr. 5-7 Frekvenční a fázová charakteristika hornopropustného filtru

5.1.3.2 Dolnopropustný filtr (LPF)

Byl navrhnut filtr 2. řádu typu dolní propust s teoretickou mezní frekvencí 500 Hz. Při reálném řešení a výběru součástek z dostupných řad bylo dosaženo reálné mezní frekvence 494,948 Hz. Signál jde z hornopropustného filtru přes dolnopropustný filtr do úzkého notch filtru (viz. Obr. 5-8).


$$f_c = \frac{1}{2\pi\sqrt{R1R2C3C5}} \quad (5.3)$$

$$f_c = \frac{1}{2\pi\sqrt{10 \cdot 10^3 \cdot 10 \cdot 10^3 \cdot 47 \cdot 10^{-9} \cdot 22 \cdot 10^{-9}}} = 494,948 \text{ Hz}$$



Obr. 5-8 Návrh dolnoproustného filtru 500 Hz

Navržený filtr má následující frekvenční a fázovou charakteristiku (viz. Obr. 5-9). Nad mezní frekvencí je frekvenční disperse -2 (-40 dB/dek).



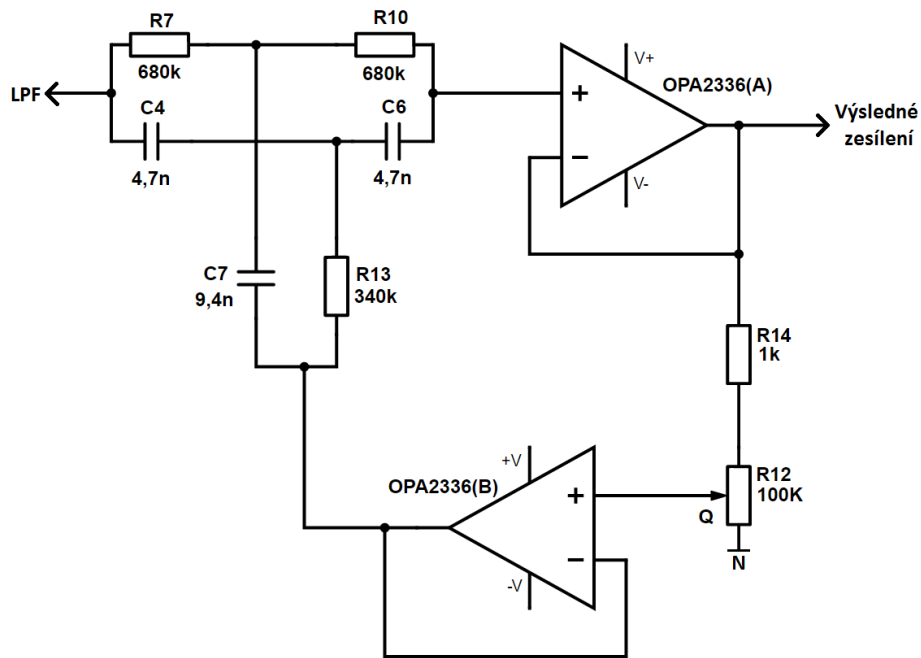
Obr. 5-9 Frekvenční a fázová charakteristika dolnoproustného filtru

5.1.3.3 Pásmová zádrž (Notch filtr)

Měřicí kanál dále obsahuje úzkou pásmovou zádrž pro potlačení rušení 50 Hz, který jde ze sítě a je jím přehlčený prostor. Při použití tohoto zapojení je dosaženo filtrace 50 Hz ve velmi úzkém spektru, čímž jsou zachovány cenné biologické signály. Při reálném řešení a výběru součástek z dostupných řad bylo dosaženo reálné zádrže na frekvenci 49,798 Hz.

$$f_c = \frac{1}{2\pi \cdot R7 \cdot C4} \quad (5.4)$$

$$f_c = \frac{1}{2\pi \cdot 680 \cdot 10^3 \cdot 4,7 \cdot 10^{-9}} = 49,798 \text{ Hz}$$



Obr. 5-10 Pásmová zádrž 50 Hz


Trimerem R12 je regulována jakost filtru a rezistor R14 zabraňuje přechodu obvodu do oscilace při nastavení trimru na minimální hodnotu. Z notch filtru signál dále pokračuje na výsledné zesílení.

5.1.4 Výsledné zesílení

Výsledné zesílení je dáno poměrem rezistorů ve zpětné vazbě dle vzorce:

$$A_u = 1 + \frac{R_{14}}{R_{15}} \quad (5.5)$$

$$A_u = 1 + \frac{680 \cdot 10^3}{2 \cdot 10^3} = 341$$




Obr. 5-11 Výsledné zesílení $A_U = 341$

Výsledné zesílení bylo experimentálně nastaveno tak, aby maximální hodnota napětí špička-špička byla 5 V respektive $\pm 2,5$ V. To z důvodu, že následující A/D převodník má rozsah 0-5 V, tak aby byl využit jeho maximální rozsah.

5.2 Přenos naměřených dat do PC

Výstupem DPS pro měření myopotenciálů jsou 4 konektory, kde jeden konektor odpovídá vždy jednomu měřicímu kanálu. Tyto výstupy jsou přivedeny na analogové vstupy mikrokontroléru Arduino Nano.

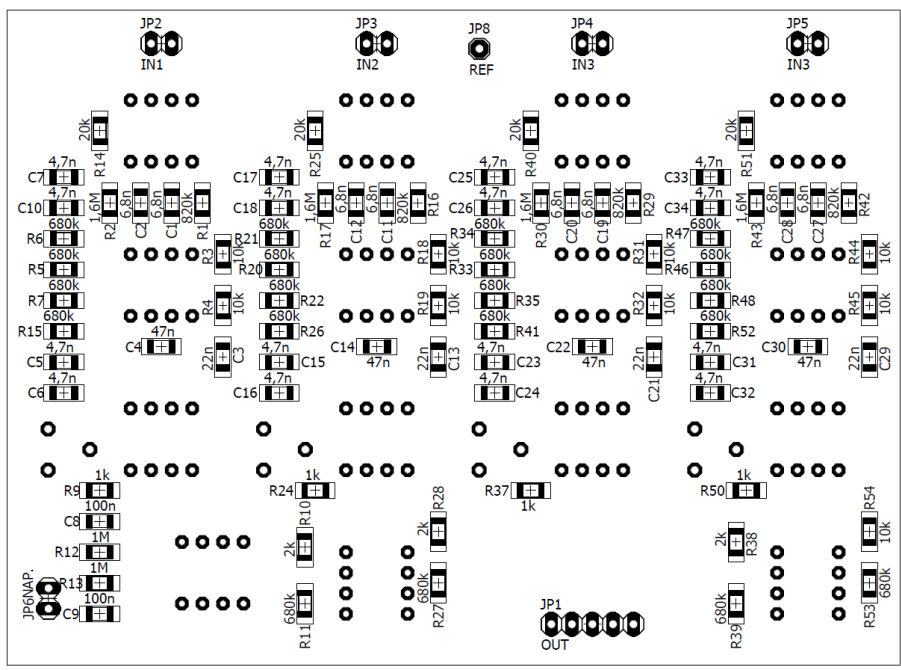


Obr. 5-12 Arduino Nano [30]

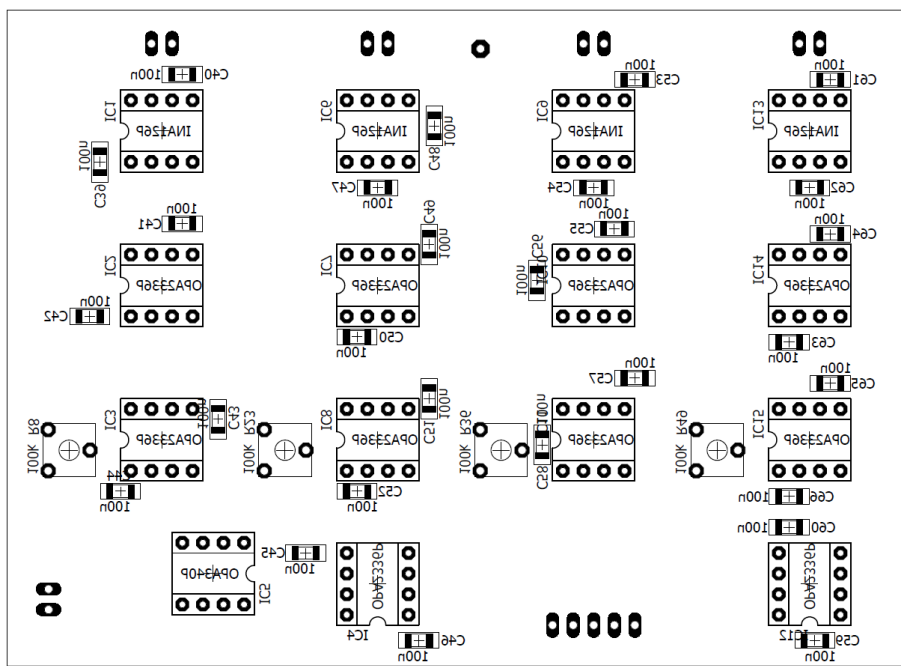
Zde je pomocí 10-bitového A/D převodníku signál digitalizován. Následuje složení paketu dle komunikačního protokolu (viz kapitola 6.1) a odeslání paketu přes USB do PC.

5.3 Návrh DPS

Pro výše uvedená zapojení byla navržena deska plošných spojů. Na tuto desku byly umístěny čtyři měřicí kanály a symetrizátor napětí. Osazovací předpis horní strany DPS je znázorněn na obrázku Obr. 5-13 a dolní strany DPS na obrázku Obr. 5-14. Ke všem operačním zesilovačům byly připojeny blokovací kondenzátory o velikosti 100 nF, aby se snížila pravděpodobnost nedeterministického kolapsu na minimum.



Obr. 5-13 Osazovací předpis horní strany desky



Obr. 5-14 Osazovací předpis spodní strany desky

6 Softwarové zpracování dat

6.1 Komunikační protokol

V této podkapitole bude popsán komunikační protokol mezi Arduinem a počítačem. Mezi zařízeními je zasílán jednoduchý paket, který obsahuje nezaměnitelnou počáteční a koncovou hodnu. Mezi těmito nezaměnitelnými hodnotami jsou data naměřená z elektrod a převedená pomocí 10-bit A/D převodníku na digitální čísla v rozmezí od 0 do 1023.

6.1.1 Skladba paketu

Nezaměnitelná hodnota, která označuje začátek paketu je 0xFC (252) a nezaměnitelná hodnota, která označuje konec paketu je 0xFD (253). Bylo nutné vytvořit tyto dvě specifické hodnoty proto, aby bylo vždy možné přesně určit, kdy paket začal a kdy paket skončil.

Tab. 6-1 Skladba paketu

Počáteční znak	Data	Koncový znak
0xFC (252)	x Bytu	0xFD (253)

Třetí a poslední nezaměnitelnou hodnotou je 0xFE (254). Pokud nastane situace, kdy naměřená hodnota je rovna jedné z nezaměnitelných hodnot, je využit tzv. octet stuffing. Ten zajistí unikové sekvence pro zapsání nezaměnitelných znaků. Tyto sekvence jsou pak dále dekódovány v počítači na základně tohoto komunikačního protokolu (viz Tab. 6-2).

Tab. 6-2 Octet stuffing

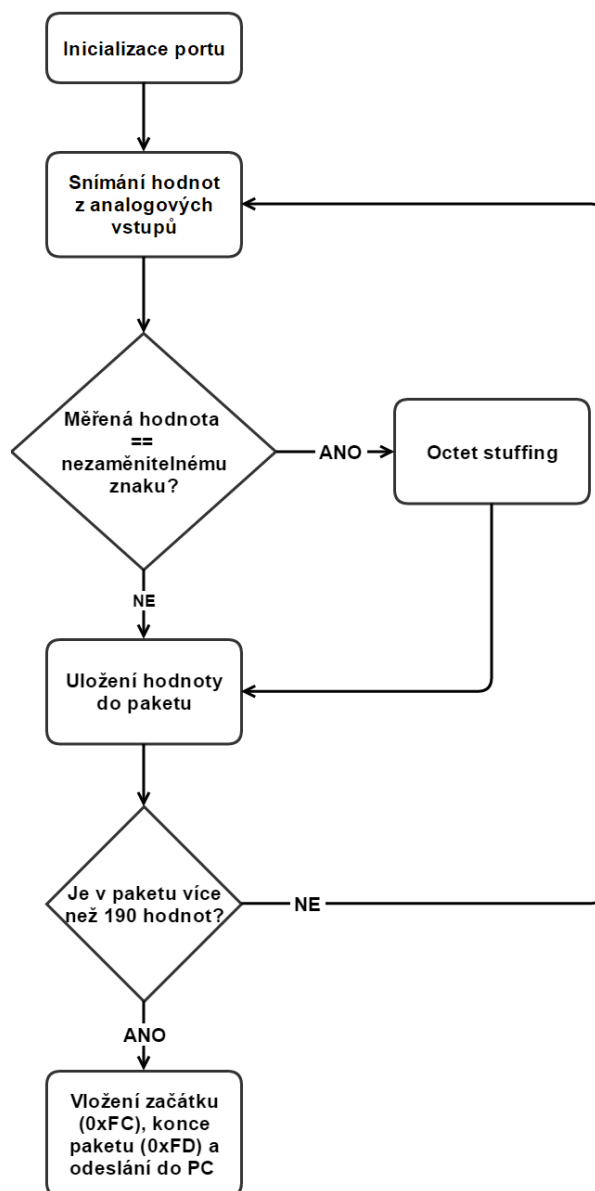
Nezaměnitelné znaky	Octet stuffing nezaměnitelných znaků
0xFC (252)	0xFE 0xDC
0xFD (253)	0xFE 0xDD
0xFE (254)	0xFE 0xDE

Čili znak 0xFE a hodnota nesledující po něm nám rozlišuje, zda jde o zakódovanou hodnotu nebo reálnou. Pomocí tohoto jednoduchého algoritmu lze tedy vždy přesně určit kde je začátek a konec paketu.

6.1.2 Zpracování dat v Arduino Nano

Pro snímání analogového signálu a jeho následnou digitalizaci byl zvolen mikrokontrolér Arduino Nano. Jeho rozměry (1,8 cm x 4,2 cm), cena a jednoduché programovací prostředí jej dělají ideální volbou pro tuto práci.


Výstupy čtyř měřících kanálů, pro snímání myopotenciálů, jsou připojeny na čtyři analogové vstupy Arduina. Zde jsou vzorkovány pomocí 10-bit A/D převodníku a složeny do paketu. Data jsou vzorkována frekvencí 1 kHz. Z předchozí kapitoly vyplývá, že paket začíná hodnotou 0xFC a končí hodnotou 0xFD. Mezi těmito hodnotami se nachází 190 hodnot naměřených dat, které jsou již po Octet stuffing. Tento paket je odeslán do PC přes USB rychlostí 115200 baudů. Na Obr. 6-1 je zobrazen diagram zpracování dat do paketu v Arduinu.



Obr. 6-1 Diagram zpracování dat do paketu v Arduino

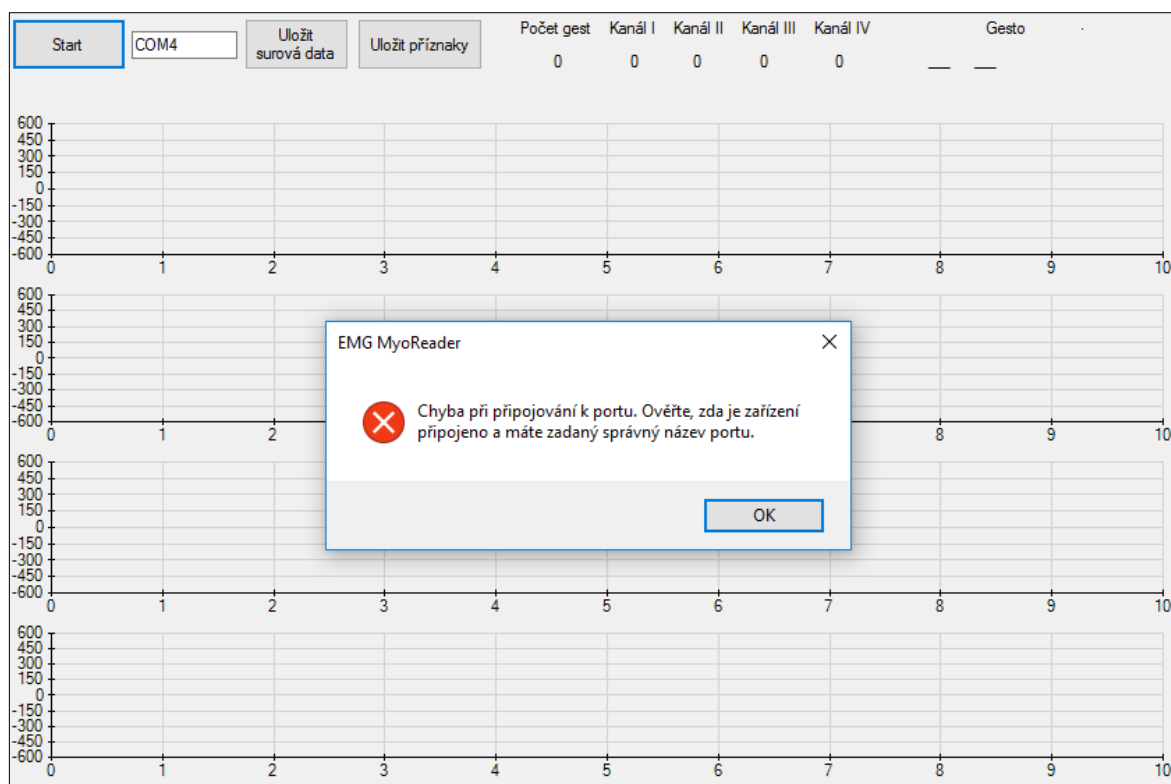
6.1.3 Přijetí a zpracování paketu v PC

Paket je přenášen z Arduina do PC pomocí standardní USB linky. Při spuštění programu uživatel navolí číslo COM portu, ke kterému je Arduino připojeno a stiskem tlačítka *Start* otevře port a spustí měření. Uživatelské rozhraní při zapnutí programu je zobrazeno na obrázku Obr. 6-2.



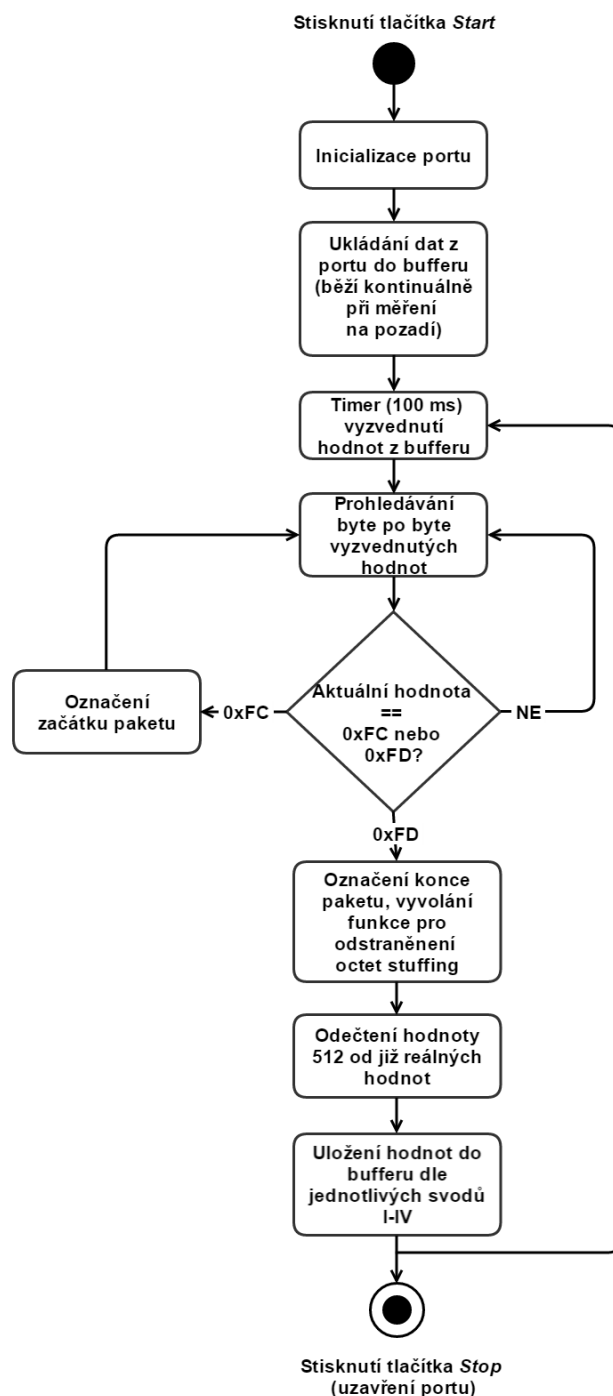
Obr. 6-2 Uživatelské rozhraní při spuštění programu

Při zadání správného čísla portu a stisku tlačítka *Start* se otevře port na modulační rychlosti 115200 baudů a začnou do něj proudit pakety. Pokud na zvoleném portu není připojeno zařízení, objeví se chybová hláška (viz Obr. 6-3).



Obr. 6-3 Chybová hláška při nezdaření se připojení k portu

Program detekuje, že jsou dostupná data na portu a uloží je do bufferu, odkud jsou poté brána k dekódování. Každých 100 ms se vyvolá funkce timeru, ve které probíhá dekódování paketu. Díky nezaměnitelné hodnotě 0xFC detekujeme nejprve začátek paketu a od této hodnoty začneme ukládat data do pomocné proměnné. Jakmile detekujeme hodnotu 0xFD, je paket ukončen a vyvolána funkce pro odstranění octet stuffing. Nahrazování reálnými hodnotami probíhá dle klíče v tabulce Tab. 6-2. Na konci zpracování paketu je od každé již reálné hodnoty odečtena hodnota 512, čímž je dosaženo posunutí signálu zpět do nuly, protože použitý A/D převodník kóduje hodnoty v rozmezí 0 až 1023. Tyto výsledné hodnoty jsou uloženy zpět do bufferu, ale již rozděleny do čtyř proměnných dle svodů I-IV.

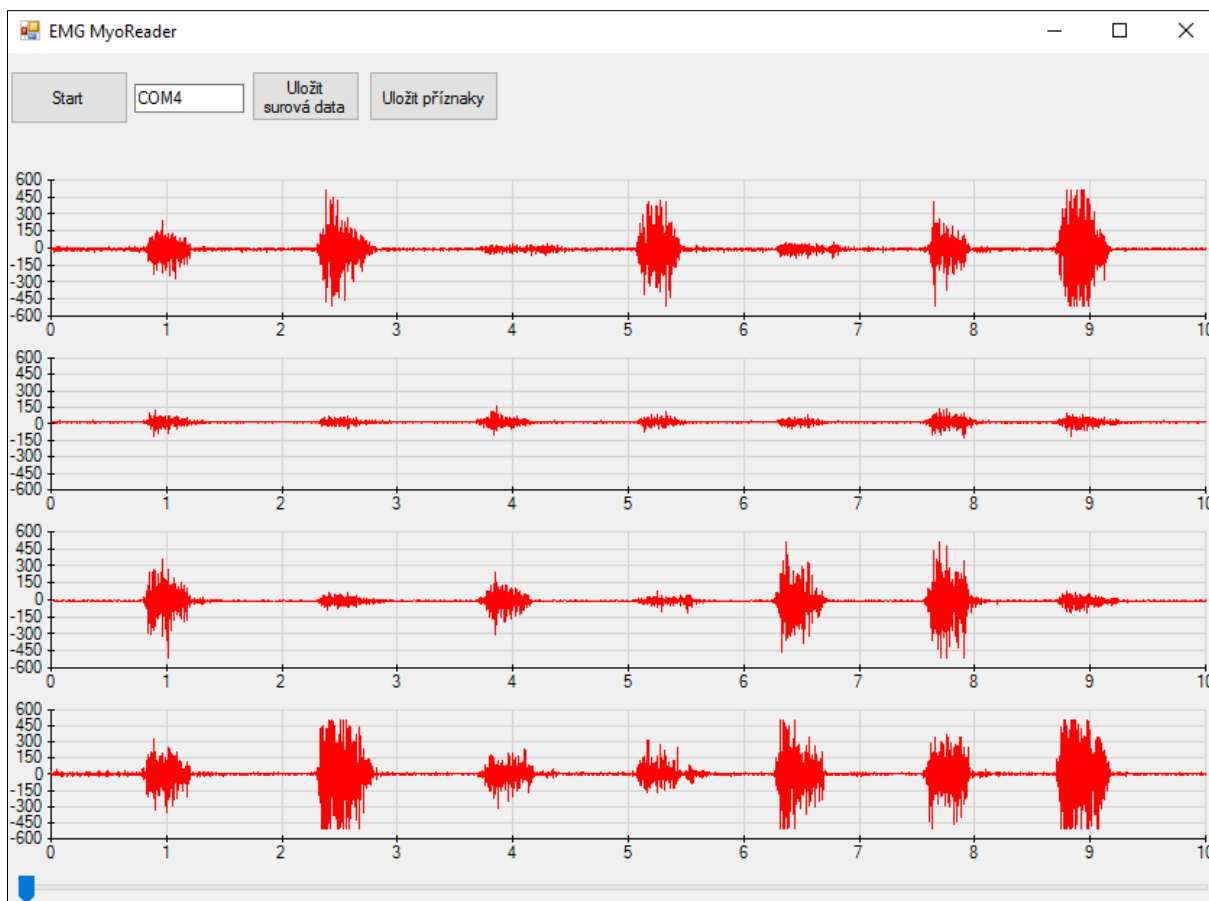


Obr. 6-4 Stavový diagram příjmu dat do PC

6.2 Vykreslování měřených dat

V okně uživatelského rozhraní jsou pod sebou ve čtyřech samostatných grafech vykreslována měřená data z jednotlivých svodů. Pro tyto grafy a jejich vykreslování byla navržena samostatná komponenta s názvem *FastGraph*. Komponenta byla navržena z důvodu nedostačující výkonosti vykreslování velkého množství dat zabudované C# komponenty pro vykreslování grafů.

Vykreslování dat je zajištěno timerem s opakovací frekvencí 100 ms. Při každém spuštění timeru jsou z bufferu vyzvednuta data, která jsou již rozdělena do jednotlivých kanálů. Toto rozdělení a dekódování bylo již popsáno v předešle kapitole (viz 6.1.3).



Obr. 6-5 Vykreslování měřeného signálu v reálném čase

6.3 Adaptivní segmentace

Adaptivní segmentace slouží k rozpoznání nestacionarit v signálu. Při správně zvolených parametrech, lze pomocí adaptivní segmentace rozdělit signál na úseky, které se od sebe nějak hraničně liší. Jedním z cílů této práce bylo, aby snímání a vyhodnocování signálu probíhalo simultánně a v reálném čase. Musel být proto použit takový algoritmus pro adaptivní segmentaci, který by byl výpočetně nenáročný a dostatečně rychlý.


6.3.1 Realizace

Z výše uvedených důvodů byla jednoznačně zvolena pro tuto práci adaptivní segmentace na základě dvou spojených oken. Tento algoritmus jednoduchý, čili nevyužívá moc výpočetní kapacity, a

tím pádem také rychlý, což jej činí ideálním pro využití v reálném čase. Navíc probíhá adaptivní segmentace v každém kanále nezávisle na sobě, proto je vhodná pro online multikanálové měření.

Metoda vychází z poznatku, že průměrná diference vzorků signálu je přímo úměrná střední frekvenci signálu v daném okně. Míra diference je pak vytvořena kombinací obou částí, po vynásobení váhovými koeficienty získanými experimentálně.

[31]



Obr. 6-6 Princip adaptivní segmentace na základě dvou spojených oken [31]

Nejprve je nutné spočítat odhad střední amplitudy:

$$ADIF = \sum_{i=1}^{WL} |x_i| \quad (6.1)$$

Poté spočítat odhad střední frekvence:

$$FDIF = \sum_{i=1}^{WL} |x_i - x_{i-1}| \quad (6.2)$$

Z toho vypočteme výslednou diferenci:

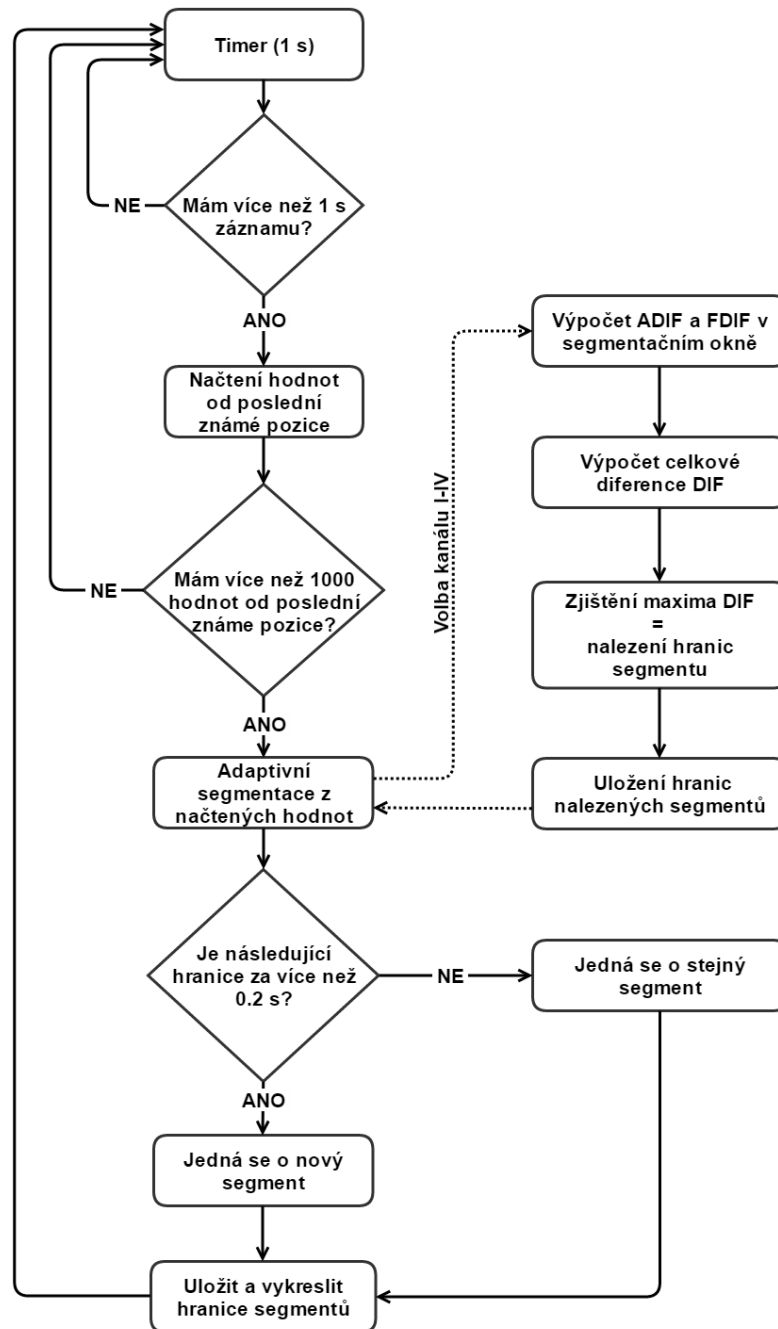
$$DIF = 1 \cdot |ADIF_1 - ADIF_2| + 7 \cdot |FDIF_1 - FDIF_2| \quad (6.3)$$

kde $ADIF_1$, $ADIF_2$ a $FDIF_1$, $FDIF_2$ jsou amplitudy a frekvence dvou spojených oken které se posouvají po měřeném signálu.

Následně se vypočte prahová hodnota diference,

$$THR = \frac{1}{BL} (1 \cdot |ADIF_1 - ADIF_2| + 7 \cdot |FDIF_1 - FDIF_2|) \quad (6.4)$$

kteou když vypočtená diference překročí, tak ji označí jako hranici segmentu. Ve výše uvedených vzorcích zkratka WL zastává window length, což je velikost okna a v našem případě byla zvolena 400. Zkratka BL zastává velikost příchozích dat, čili počet dat v daném zkoumaném vzorku.



Obr. 6-7 Blokový diagram nalezení segmentů v signálu

6.4 Výpočet příznaků segmentu

Pro každý nalezený segment pomocí adaptivní segmentace jsou spočítány příznaky, na základě kterých bude probíhat klasifikace jednotlivých gest. Klasifikace je dobrá jen tak, jak dobře jsou zvoleny příznaky, dle kterých se rozhoduje. Záměrem bylo najít rovnováhu mezi počtem, čili dostatečnou kvalitou, a výpočetní náročností příznaku. Proto byly zvoleny tyto tři příznaky, které reprezentují důležité vlastnosti měřeného signálu:

- střední kvadratická hodnota (RMS)
- logaritmický výkon pásma (LBP)
- první derivace (DIFF)

Příznak RMS je typickým statistickým komponentem a je považován za jeden z nejvýznamnějších, protože nám udává výkon signálu. V kontextu této práce potom určuje jak moc je daný sval aktivní v daném čase.

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (6.5)$$

Druhým zvoleným příznakem bylo LBP, protože udává logaritmický výkon pásma v daném okamžiku. Tento příznak byl zvolen na základně nabytých znalostí z rešerše.

$$x_{LBP} = \log \left(1 + \frac{1}{N} \sum_{i=1}^N x_i^2 \right) \quad (6.6)$$

Třetím zvoleným příznakem byla derivace. Tento příznak byl zvolen z experimentálního pozorování a podává cennou informaci o provedeném gestu.

$$x_{DIFF} = \frac{1}{N} \sum_{i=1}^N |x_{i-1} - x_i| \quad (6.7)$$

Původním plánem bylo použití střední absolutní hodnoty jako třetí příznak.

$$x_{MAV} = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (6.8)$$

Skrze experimentální měření bylo zjištěno, že střední absolutní hodnota má skoro vždy stejnou výpovědní hodnotu jako střední kvadratická hodnota. Proto byla nahrazena výše zmíněnou derivací.

6.5 Návrh fuzzy množin

Jedním z dílčích cílů této práce bylo využití fuzzy logiky při klasifikaci jednotlivých gest. Fuzzy množiny jsou vytvořeny pro jednotlivé příznaky v daných kanálech. Pro vytvoření fuzzy množin bylo naměřeno 102 instancí každého gesta ve všech kanálech. Což nám dává pro čtyři kanály celkově 408 hodnot pro jedno gesto a pro jeden příznak. Z těchto hodnot byla vždy vypočítána střední hodnota a směrodatná odchylka (viz Tab. 6-3 a Tab. 6-4). Pomocí těchto hodnot byly poté vytvořeny prototypy fuzzy množin a následně upraveny do výsledné podoby.

Tab. 6-3 Tabulka středních hodnot příznaků pro jednotlivá gesta v jednotlivých kanálech

		Pěst	Vpravo	Vlevo	Nahoru	Dolů
Kanál I.	RMS	64.130	100.259	15.750	97.220	22.551
	LBP	3.596	3.972	2.387	3.947	2.700
	DIFF	50.411	82.847	12.062	69.844	19.476
Kanál II.	RMS	37.711	24.300	26.959	23.246	26.497
	LBP	3.150	2.771	2.852	2.729	2.838
	DIFF	27.193	15.967	19.056	12.863	17.289
Kanál III.	RMS	138.249	22.610	44.945	22.550	96.087
	LBP	4.277	2.706	3.289	2.692	3.955
	DIFF	106.959	19.702	42.877	18.632	91.465
Kanál IV.	RMS	93.451	169.194	56.182	40.663	133.251
	LBP	3.935	4.454	3.483	3.188	4.235
	DIFF	82.313	169.870	49.863	34.941	132.736

Tab. 6-4 Tabulka směrodatných odchylek příznaků pro jednotlivá gesta v jednotlivých kanálech

		Pěst	Vpravo	Vlevo	Nahoru	Dolů
Kanál I.	RMS	13.276	27.013	2.462	25.365	3.015
	LBP	0.180	0.231	0.125	0.226	0.114
	DIFF	11.347	20.470	2.095	19.643	3.201
Kanál II.	RMS	3.100	1.202	4.391	2.496	3.932
	LBP	0.071	0.043	0.133	0.088	0.125
	DIFF	3.303	1.813	4.471	2.113	3.979
Kanál III.	RMS	14.238	2.136	8.966	4.416	14.826
	LBP	0.089	0.080	0.172	0.164	0.140
	DIFF	13.824	2.362	9.483	3.932	16.650
Kanál IV.	RMS	10.734	14.671	11.134	10.851	24.289
	LBP	0.101	0.075	0.166	0.237	0.163
	DIFF	11.725	19.041	9.657	9.291	28.226

Návrhy fuzzy množin byly pro dobrou vizualizaci provedeny ve Fuzzy Logic Toolboxu prostřední Matlab R2016a. Bylo navrženo celkem 12 fuzzy množin a to pro zvlášť pro každý příznak v daném kanále. Každá množina obsahuje celkem 7 funkcí příslušnosti a to pět pro jednotlivá gesta a dvě pro neklasifikovaná gesta.

6.5.1 Příklad návrhu fuzzy množiny


V této kapitole bude uveden příklad návrhu jedné fuzzy množiny, konkrétně příznaku DIFF pro čtvrtý kanál. Jak již bylo výše zmíněno, nejdříve byla vypočítána střední hodnota a směrodatná odchylka (viz Tab. 6-5) pro každé gesto příznaku DIFF ve čtvrtém kanále. Následně byl spočítán interval, ve kterém se jednotlivá gesta pohybují.

$$interval\ gesta = E(X) \pm \sigma \quad (6.9)$$

Tab. 6-5 Tabulka hodnot pro návrh fuzzy množiny příznaku DIFF ve IV. kanále

Gesto	Střední hodnota E(X)	Směrodatná odchylka σ	Interval
Pěst	82.313	11.725	(70.588; 94.038)
Vpravo	169.870	19.041	(150.829; 188.911)
Vlevo	49.863	9.657	(40.206; 59.52)
Nahoru	34.941	9.657	(25.65; 44.232)
Dolů	132.736	28.226	(160; 962)


Hodnoty v tabulce (viz Tab. 6-5) byly vyneseny do návrhu ve Fuzzy Logic Toolboxu. Hraniční body funkce příslušnosti odpovídají hodnotám intervalu a špička ve vrcholu odpovídá střední hodnotě pro dané gesto.



Obr. 6-8 Neupravený návrh fuzzy množiny; zleva: žádné gesto, nahoru, vlevo, pěst, dolů, vpravo, žádné gesto

Z takto zobrazených funkcí příslušnosti lze posoudit, jak budou jednotlivá gesta v daném kanálu rozlišitelná a jak to ovlivní výsledné váhování pro gesto v kanále. Jak lze vidět na obrázku Obr. 6-8, gesta v příznaku DIFF IV. kanálu jsou velice dobře rozlišitelná, protože se překrývají jen minimálně. Může být skoro s jistotou řečeno, že gesto pěst bude mít ve čtvrtém kanálu velkou váhu, protože je prakticky osamostatněno od ostatních gest.

Následně pro vynesení množin a jejich vizuálnímu posouzení přichází na řadu úprava, tak aby byly funkce příslušnosti gest co nejideálnější a hlavně aby vždy součet funkcí v daném bodě dával výsledek 1.



Obr. 6-9 Upravený návrh fuzzy množiny; žádné gesto, nahoru, vlevo, pěst, dolů, vpravo, žádné gesto

Body jednotlivých křivek slouží poté jako zdroj informací o jednotlivých funkcích příslušnosti v daných fuzzy množinách. V C# je potom tato množina (DIFF kanál IV) zapsána takto:

$$\{ 0, 20, 25.65f, 36.94f, 47.86f, 59.52f, 70.6f, 94, 104.5f, 144, 163, 175, 188.9f, 1000 \}$$

Dále je nadefinováno pořadí, v jakém jsou jednotlivá gesta v dané množině. Pro tuto množinu (DIFF kanál IV) jsou gesta zapsána takto:

$$\{ 4, 3, 1, 5, 2, 6 \}$$

6.6 Klasifikace gest

Po návrhu všech dvanácti fuzzy množin byly jejich hodnoty nadefinovány jako konstanty v programu. Na základně příslušnosti jednotlivých příznaků do daných fuzzy množin bude probíhat první část klasifikace gesta. Po první části klasifikaci gest, která probíhá v jednotlivých kanálech, se přistoupí dále k druhé části a to k váhování. Obě metody budou popsány v níže uvedených podkapitolách. V tabulce Tab. 6-6 je uvedeno přiřazení čísla jednotlivým gestům a jejich barevné označení.

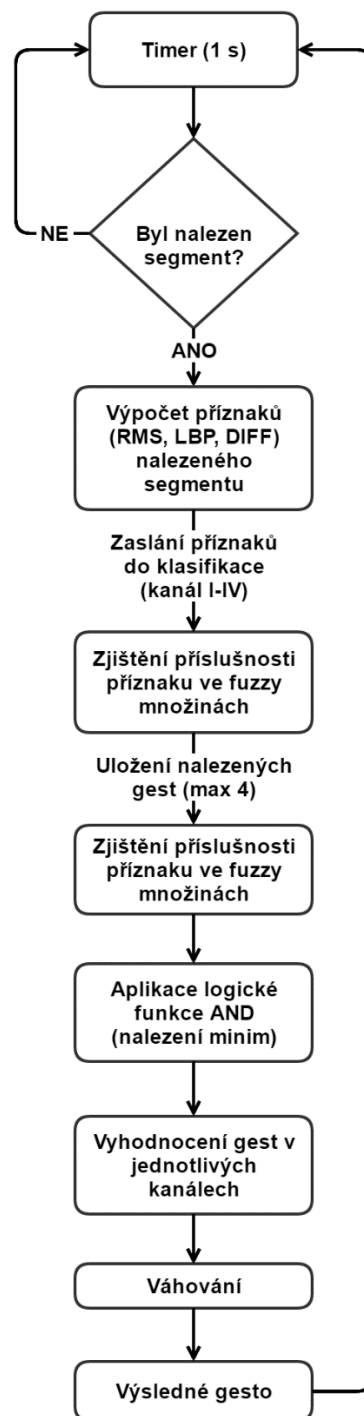
Tab. 6-6 Označení gest

Číslo gesta	Název gesta	Barevné označení
1	pěst	červená
2	vlevo	červená
3	vpravo	zelená
4	nahoru	žlutá
5	dolů	modrá
6	žádné gesto	černá

Číslo bylo gestům přidáno z důvodu programátorského, aby byla gesta v programu jasně odlišitelná. Barevné označení je čistě pro lepší vizualizaci toho, které gesto bylo vybráno. Na obrázku Obr. 7-2 je v pravém horním rohu zřejmé, že bylo vybráno gesto vlevo, které má číselné označení 3 a barevné označení zelená.

6.6.1 Klasifikace dle míry příslušnosti ve fuzzy množině

Klasifikace gest navazuje přímo na funkci adaptivní segmentace popsanou v kapitole 6.3. Jakmile jsou nalezeny hranice segmentu a jsou od sebe vzdáleny maximálně 0.9 s, je vyvolána funkce pro výpočet příznaků. Do této funkce je zaslán počáteční index a konečný index nalezeného segmentu. Jsou spočítány všechny příznaky (viz kapitola 6.4) pro všechny kanály. Takto spočítané příznaky jsou uloženy do proměnné a poslány do funkce kde dochází k výpočtu příslušnosti jednotlivých příznaku do daných fuzzy množin.



Obr. 6-10 Zjednodušený diagram klasifikace gest

Na výše uvedeném diagramu je uveden postup, jakým dochází k vypočítání příslušnosti jednotlivých gest (příznaků) do fuzzy množin. Výsledkem tohoto algoritmu jsou čtyři čísla, která reprezentují, jaké bylo gesto v daném kanálu klasifikováno. V uživatelském rozhraní jsou tyto dílčí výsledky zobrazeny pod kolonkami Kanál I – IV.

6.6.2 Dodatečné váhování gest v jednotlivých kanálech

V druhé části klasifikace jsou již dostupné příslušnosti z jednotlivých kanálů. Za předpokladu, že by všechny příznaky všech gest ve všech kanálech byly jasné a zřetelné rozlišitelné, nebylo by potřeba váhování, ale ani fuzzy množin. Cílem váhování je zpřesnění měření na základě zkušeností experta a experimentálním měření.

Základní idea spočívá v tom, že určitá gesta jsou v určitých kanálech rozeznávána více než jiná. Toto tvrzení lze potvrdit už pouhým pohledem na neupravené fuzzy množiny (viz Příloha 3). Například v kanálu III se překrývají gesta nahoru a vpravo, ale ostatní gesta jsou naprosto rozlišitelné. Už tento fakt vede k tomu, že tyto dvě překrývající se gesta budou buď špatně rozlišitelné anebo rozlišitelnost jednoho gestu bude lepší na úkor rozlišitelnosti gestu druhého. Tyto předpoklady, které byly získány vizuálním posouzením množin, musely být ověřeny experimentálně.

Na začátku experimentálního měření byly všechny váhy nastaveny na hodnotu 1, čímž bylo váhování vypnuto. Pro každé gesto bylo provedeno 20 měření a zaznamenáno, které kanály určily gesto správně a kolikrát. Na základě těchto dat byly nastaveny prozatímní hodnoty vah. Následovala další série experimentálního měření a hodnoty vah byly nastaveny již na finální verzi (viz Tab. 6-7).

Tab. 6-7 Tabulka vah jednotlivých gest

	Kanál I	Kanál II	Kanál III	Kanál IV
Pěst	7	1	1	5
Vlevo	3	2	1	7
Vpravo	4	3	4	1
Nahoru	3	4	1	5
Dolů	7	1	3	6
Žádné gesto	1	1	1	1

Výsledné gesto je potom to, které má největší součet vah v kanálech, ve kterých bylo nalezeno. Maximální počet gest, mezi kterými se v této části rozhoduje, je čtyři, protože jsou čtyři měřící kanály. Minimální počet je pak jedno a to v případě, kdy se všechny kanály shodnou na stejném gestu.




Obr. 6-11 Diagram vyhodnocení finálního gestu

7 Testovací měření

V závěru práce bylo provedeno finální testovací měření. Záměrem testovacího měření bylo otestovat celkovou funkci programu a především přesnost měření. Fuzzy množiny a váhování byly navrženy dle svalové aktivity autora práce, proto je testovací měření provedeno na něm.

7.1 Umístění elektrod a demonstrace gest



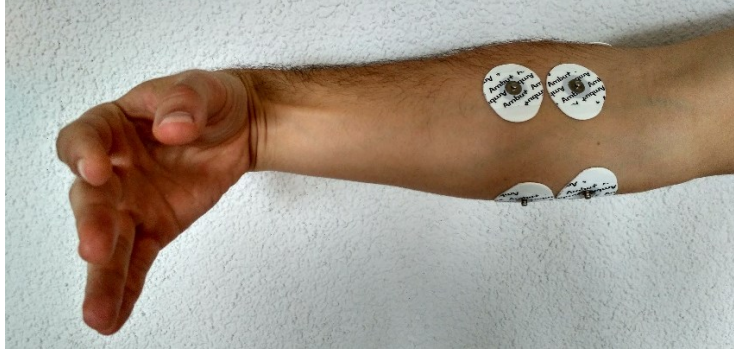

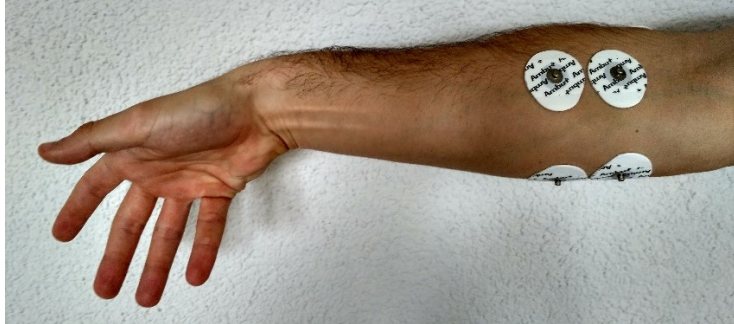
Elektrody byly umístěny na stejná místa jako při získávání dat pro tvorbu fuzzy množin.



Obr. 7-1 Umístění elektrod na předloktí

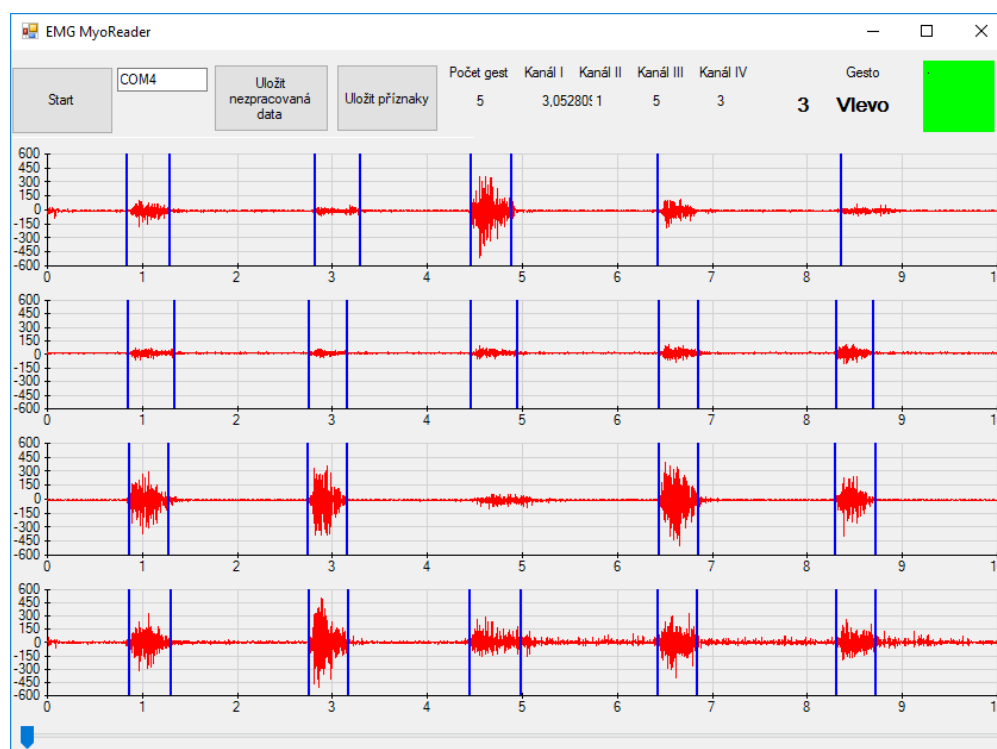
Referenční elektroda může být umístěna například na loketní kosti, čili na svalově neaktivním místě, anebo kdekoliv v dostatečné vzdálenosti od snímacích elektrod. V níže uvedené tabulce jsou zobrazena gesta, která se algoritmus snaží klasifikovat.

Tab. 7-1 Demontrace gest pro klasifikaci

Číslo a název gesta	Demontrace gesta
<p>1 Pěst</p>	 A photograph of a right arm in a fist gesture, with the hand clenched. The forearm is visible, showing four circular white markers with black text and a central dot. The background is a plain, light-colored wall.
<p>2 Vpravo</p>	 A photograph of a right arm pointing towards the right. The hand is open, with the index finger extended. The forearm is visible, showing four circular white markers with black text and a central dot. The background is a plain, light-colored wall.
<p>3 Vlevo</p>	 A photograph of a right arm pointing towards the left. The hand is open, with the index finger extended. The forearm is visible, showing four circular white markers with black text and a central dot. The background is a plain, light-colored wall.
<p>4 Nahoru</p>	 A photograph of a right arm pointing upwards. The hand is open, with the index finger extended. The forearm is visible, showing four circular white markers with black text and a central dot. The background is a plain, light-colored wall.
<p>5 Dolů</p>	 A photograph of a right arm pointing downwards. The hand is open, with the index finger extended. The forearm is visible, showing four circular white markers with black text and a central dot. The background is a plain, light-colored wall.

7.2 Testování obecné funkčnosti programu a tlačítek

Jako první byl testován program jako takový. Funkčnost tlačítek a funkcí, které může uživatel vyvolat. Při nastavení správného COM portu a stisku tlačítka start se započalo měření a vykreslování měřených dat. Vykreslování hranic adaptivní segmentaci je vždy přesně na hranicích, kde dochází ke změnám amplitudy a frekvence signálu. Čili funkce připojení k portu, příjem dat z Arduina, vykreslování signálu a následná adaptivní segmentace, můžeme označit jako funkční.



Obr. 7-2 Záznam testovacího měření

Při ukončení měření byla vyzkoušena tlačítka pro ukládání dat. Při stisku tlačítka *Uložit nezpracovaná data* se data, po specifikování názvu souboru a místa uložení, uložila ve formátu csv. Stejně funguje tlačítko *Uložit příznaky*, které nám uloží vypočtené příznaky z jednotlivých segmentů.

7.3 Testování přesnosti rozlišování gest

Posledním krokem testovacího měření bylo ověřit přesnost určování gest na základně nastavených fuzzy množin a váhování. Bylo provedeno 40 měření pro každé gesto a vyhodnocena celková přesnost.

Tab. 7-2 Tabulka přesnosti určování gest

Gesto	Počet správných určení	Počet správných určení [%]
Pěst	40	100
Vpravo	26	65
Vlevo	34	85
Nahoru	24	60
Dolů	22	55
Celkem	146	73

Z výše uvedené tabulky (viz Tab. 7-2) je zřejmé, že nejlépe rozpoznatelné gest je pět s úspěšností rozpoznání 100%. Následuje gesto vlevo s rozpoznatelností 85%. Další tři gesta mají lehce nadpoloviční úspěšnost rozpoznání. Při bližším pohledu na neupravené množiny v příloze č. 3, lze již předpokládat, že některé gesta budou lépe rozlišitelná než jiná. Dále je tento algoritmus velice náchylný na správné umístění elektrod. Pokud jsou elektrody umístěny jinak, nezapadají jednotlivá data do fuzzy množin, tak jak by měla. V neposlední řadě velice záleží na provedení gesta. Tyto nedostatky algoritmu byly minimalizovány počtem naměřených instancí pro jedno gesto a následným váhováním. Možná zlepšení tohoto algoritmu jsou popsány v následující kapitole.

7.4 Návrhy na zvýšení přesnosti měření

Pokud by bylo žádoucí zůstat u této metody klasifikace a zároveň zvýšit přesnost, tak zavedením jednoho nebo více níže uvedených návrhů, toho může být teoreticky dosaženo.

1. Použití většího množství elektrod

Použitím většího množství elektrod lze určitě dosáhnout lepších výsledků v rozpoznávání gest. Více elektrod znamená více informací o dané svalové aktivitě. Ovšem více elektrod znamená také, že zapotřebí mnohem vyšší výpočetní výkon a více měřících kanálů. Tím se zvedají požadavky na celkovou velikost zařízení, celkovou cenu zařízení, spotřebu a výpočetní výkon. Myslím, že zvolený počet čtyř párů elektrod je optimální. Za zvážení stojí použití například šesti párů elektrod s umístěním na jiné svalové skupiny.

2. Klasifikace menšího množství gest nebo jiných gest

Klasifikace menšího množství gest zaručeně povede ke zvýšení přesnosti, protože se budou méně překrývat funkce příslušnosti ve fuzzy množinách. Další možností je vybrat jiné gesta pro klasifikaci, ale toto by se zase odráželo množstvím a umístěním elektrod.

3. Větší základní báze dat

Další možnou, ale časově náročnou možností pro zlepšení algoritmu by bylo provést více měření pro jednotlivá gesta z různých lidí. Pokud by se například získalo 100 instancí pro jednotlivá gesta od různých lidí, různých věkových skupin a různých svalových proporcí, bylo by možné tento algoritmus udělat přesnější.

4. Použití jiného klasifikačního algoritmu

V poslední řadě by šlo ke klasifikaci přistupovat pomocí úplně jiného algoritmu. Z rešerše bylo vyčteno, že možné další algoritmy pro klasifikaci jsou umělé neuronové sítě, fuzzy k-NN klasifikátor nebo pomocí Bayesovy věty.

8 Závěr

Tato diplomová práce měla za účel návrh a tvorbu systému pro klasifikaci myopotenciálů gest ruky. Tvorba prototypové desky skýtala mnoho komplikací, od volby správných operačních zesilovačů, přes návrh přesných filtrů až po řešení jevu polarizace elektrod. Všechny tyto překážky byly však úspěšně vyřešeny a byla vytvořena prototypová deska čtyř měřících kanálů pro snímání myopotenciálů. Z důvodu ochrany uživatele bylo vytvořeno galvanické oddělení USB, takže při poruše na straně zdroje, nedojde na straně uživatele k úrazu elektrickým proudem. Výstupy desky jsou připojeny k analogovým vstupům mikrokontroléru Arduino Nano kde dochází k převodu analogového signálu na digitální se vzorkovací frekvencí 1 kHz, což je pro měření zcela dostačující. Data jsou dle jednoduchého komunikačního protokolu zaslána do PC ke zpracování.

Druhou velkou částí této práce bylo vytvoření algoritmu pro klasifikaci gest založenou na fuzzy logice. Zde se jednalo o zcela experimentální vytvoření nového algoritmu pro klasifikaci. Základem rozpoznání gesta je segmentace, tedy rozpoznání, že v signálu nastalo nějaké gesto. K tomu byla použita metoda adaptivní segmentace pomocí dvou spojených oken. Tato dvě spojená okna plují po signálu a hledají změny diference, která je vyšší než prahová hodnota. Tento algoritmus funguje dle mého názoru dostatečně a využívá jen velmi malé procento operačního výkonu. Uživatel může v uživatelském rozhraní přehledně v reálném čase pozorovat měřený signál a nalezené segmenty, neboť se hranice segmentů vykreslují přímo na měřený signál s minimálním zpožděním (max. 1 s).

Výpočtem příznaků (střední kvadratická hodnota, logaritmický výkon pásma a první derivace) nalezených segmentů se určuje, jaké gesto bylo provedeno. Naměřením 102 instancí každého gesta byla vytvořena základní báze dat, dle které byly navrženy fuzzy množiny pro každý příznak ve všech kanálech. Čili bylo navrženo celkem 12 fuzzy množin pro pět gest (pěst, vpravo, vlevo, nahoru a dolů). Gesto je potom určeno na základě míry příslušnosti v dané fuzzy množině a následném systému váhování.

Testovací měření vyhodnotilo celkovou přesnost tohoto algoritmu na 73 %. Snímaná data jsou velmi náchylná na umístění elektrod a správném provedení gesta. Pokud jsou elektrody umístěny trochu jinak anebo gesto provedeno nesprávně, dostáváme potom falešné hodnoty měření. V poslední kapitole jsou návrhy jak zvýšit přesnost a robustnost toho algoritmu například zvětšením základní báze dat, použitím většího množství elektrod, či úplnou změnou klasifikačního algoritmu. V této první experimentální fázi je přesnost měření 73 % dostatečná.

Literatura

- [1] DUFEK, Jaroslav. Elektromyografie. Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví, 1995. Učební texty (Institut pro další vzdělávání pracovníků ve zdravotnictví). ISBN 8070132086.
- [2] KELLER, Otakar. Obecná elektromyografie: fyziologické základy a elektrofyzilogická vyšetření se zvláštním zřetelem k rozboru potenciálů motorické jednotky. Praha: Triton, 1999. ISBN 80-725-4047-5.
- [3] NEURONS TRANSPORT MESSAGES IN THE BRAIN. *Genetic Science Learning Center: Learn.Genetics*[online]. 2014 [cit. 2016-07-15]. Dostupné z: <http://learn.genetics.utah.edu/content/addiction/neurons/>
- [4] TROJAN, Stanislav. Lékařská fyziologie. Vyd. 4., přeprac. a dopl. Praha: Grada, 2003. ISBN 80-247-0512-5.
- [5] ČIHÁK, Radomír. Anatomie. Třetí, upravené a doplněné vydání. Ilustrace Ivan Helekal, Jan Kacvinský, Stanislav Macháček. Praha: Grada, 2016. ISBN 978-80-247-3817-8.
- [6] MERLETTI, Roberto a Dario FARINA. *Surface Electromyography: Physiology, Engineering and Applications*. 1. Wiley-IEEE Press, 2016. ISBN 978-1-118-98702-5.
- [7] Training to Failure? | MuscleTech. *MuscleTech* [online]. [cit. 2016-07-22]. Dostupné z: <http://www.muscletech.com/training/training-to-failure/>
- [8] 6. Svalová kontrakce. *Funkce buněk a lidského těla* [online]. [cit. 2016-07-23]. Dostupné z: <http://fbtl.cz/skripta/iv-pohybova-soustava/6-svalova-kontrakce/>
- [9] The muscles of the arm and hand. *Human anatomy* [online]. [cit. 2016-08-09]. Dostupné z: <http://anatomy-medicine.com/musculoskeletal-system/87-the-muscles-of-the-arm-and-hand.html>
- [10] HORÁČEK, Jaroslav. Anatomie pro bakalářské studium se zdravotnickým zaměřením. Ostrava: VŠB - Technická univerzita Ostrava, 2006. ISBN 80-248-1203-7.
- [11] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje 1*. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013. ISBN 978-80-248-3107-7.
- [12] CRISWELL, Eleanor. a Jeffrey R. CRAM. *Cram's introduction to surface electromyography*. 2nd ed. Sudbury, MA: Jones and Bartlett, 2011. ISBN 07-637-3274-5.
- [13] LAPATKI, B. G. A thin, flexible multielectrode grid for high-density surface EMG. *Journal of Applied Physiology* [online]. 2003, **96**(1), 327-336 [cit. 2016-10-03]. DOI: 10.1152/jappphysiol.00521.2003. ISSN 8750-7587. Dostupné z: <http://jap.physiology.org/cgi/doi/10.1152/jappphysiol.00521.2003>
- [14] CHMELAŘ, Milan. *Lékařská přístrojová technika I*. Brno: Akademické nakladatelství CERM, 1995. Učební texty vysokých škol. ISBN 80-858-6763-X.
- [15] CHMELAŘ, Milan a Jiří ROZMAN. *Lékařská přístrojová technika*. 1. vyd. Praha: SNTL-Nakladatelství technické literatury, 1982, 182 s.
- [16] KADAŇKA, Zdeněk, Stanislav VOHÁŇKA a Josef BEDNAŘÍK. *Praktická elektromyografie: text určen pro postgraduální vzdělávání lékařů*. Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví, 1994. ISBN 80-701-3181-0.
- [17] KROBOT, Alois a Barbora KOLÁŘOVÁ. *Povrchová elektromyografie v klinické rehabilitaci*. Olomouc: Univerzita Palackého v Olomouci, 2011. ISBN 978-80-244-2762-1.

- [18] EMG Signal Processing - Smoothing - The Root Mean Square (RMS). *G-BIOMECH* [online]. 2014 [cit. 2016-11-05]. Dostupné z: <http://g-biomech.blogspot.cz/2014/07/emg-signal-processing-smoothing-root.html>
- [19] PHINYOMARK, Angkoon, Sirinee THONGPANJA, Huosheng HU, Pornchai PHUKPATTARANONT a Chusak LIMSAKUL. The Usefulness of Mean and Median Frequencies in Electromyography Analysis. *Computational Intelligence in Electromyography Analysis - A Perspective on Current Applications and Future Challenges* [online]. InTech, 2012 [cit. 2016-11-06]. DOI: 10.5772/50639. ISBN 978-953-51-0805-4. Dostupné z: <http://www.intechopen.com/books/computational-intelligence-in-electromyography-analysis-a-perspective-on-current-applications-and-future-challenges/the-usefulness-of-mean-and-median-frequencies-in-electromyography-analysis>
- [20] BENATTI, Simone, Filippo CASAMASSIMA, Bojan MILOSEVIC, et al. A Versatile Embedded Platform for EMG Acquisition and Gesture Recognition. *IEEE Transactions on Biomedical Circuits and Systems*. 2015, **9**(5), 620-630. DOI: 10.1109/TBCAS.2015.2476555. ISSN 1932-4545. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7303979>
- [21] MOTOYAMA, Hiroyuki, Tsuyoshi INOUE, Yumiko O. KATO a Jun OZAWA. Electrode layout of wristband EMG measuring device for hand gesture recognition. *2015 IEEE International Conference on Consumer Electronics (ICCE)*. IEEE, 2015, 148-149. DOI: 10.1109/ICCE.2015.7066357. ISBN 978-1-4799-7543-3. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7066357>
- [22] CARRINO, Francesco, Antonio RIDI, Elena MUGELLINI, Omar Abou KHALED a Rolf INGOLD. Gesture Segmentation and Recognition with an EMG-Based Intimate Approach - An Accuracy and Usability Study. *2012 Sixth International Conference on Complex, Intelligent, and Software Intensive Systems*. IEEE, 2012, 544-551. DOI: 10.1109/CISIS.2012.173. ISBN 978-1-4673-1233-2. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6245626>
- [23] TSUJIMURA, Takeshi, Kosuke URATA a Kiyotaka IZUMI. Hand sign classification techniques based on forearm electromyogram signals. *2015 International Conference on Informatics, Electronics*. IEEE, 2015, 1-6. DOI: 10.1109/ICIEV.2015.7334031. ISBN 978-1-4673-6902-2. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7334031>
- [24] BOYALI, Ali, Naohisa HASHIMOTO a Osamu MATSUMOTO. Hand posture and gesture recognition using MYO armband and spectral collaborative representation based classification. *2015 IEEE 4th Global Conference on Consumer Electronics (GCCE)*. IEEE, 2015, 200-201. DOI: 10.1109/GCCE.2015.7398619. ISBN 978-1-4799-8751-1. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7398619>
- [25] SHUMAN, Gene. Using Forearm Electromyograms to Classify Hand Gestures. *2009 IEEE International Conference on Bioinformatics and Biomedicine*. IEEE, 2009, 261-264. DOI: 10.1109/BIBM.2009.36. ISBN 978-0-7695-3885-3. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5341789>
- [26] ALSAYEGH, O. A. EMG-based signal processing system for interpreting arm gestures. *10th European Signal Processing Conference*. Tampere, 2000, 1-4. Dostupné také z: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7075215&isnumber=7065137>
- [27] EDITH, Rachel Martina a A. BHARGAVI HARIPRIYA. Gesture recognition using real time EMG. *2015 International Conference on Innovations in Information, Embedded and*

- Communication Systems (ICIECS)*. IEEE, 2015, 1-3. DOI: 10.1109/ICIECS.2015.7193196. ISBN 978-1-4799-6817-6. Dostupné také z:
<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7193196>
- [28] TOMCZYNSKI, Jakub, Piotr KACZMAREK a Tomasz MANKOWSKI. Hand gesture-based interface with multichannel sEMG band enabling unknown gesture discrimination. *2015 10th International Workshop on Robot Motion and Control (RoMoCo)*. IEEE, 2015, 52-57. DOI: 10.1109/RoMoCo.2015.7219713. ISBN 978-1-4799-7043-8. Dostupné také z:
<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7219713>
- [29] CHEN, Xiang, Xu ZHANG, Zhang-Yan ZHAO, Ji-Hai YANG, Vuokko LANTZ a Kong-Qiao WANG. Multiple Hand Gesture Recognition Based on Surface EMG Signal. *2007 1st International Conference on Bioinformatics and Biomedical Engineering*. IEEE, 2007, 506-509. DOI: 10.1109/ICBBE.2007.133. ISBN 1-4244-1120-3. Dostupné také z:
<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4272617>
- [30] http://www.nuttyengineer.com/wp-content/uploads/2016/11/ARDUINO_NANO.png
- [31] MOHYLOVA, Jitka, Vladimir KRAJCA, Hana SCHAABOVA, Vaclava SEDLMAJEROVA, Svojmil PETRANEK a Tomas NOVAK. *Fuzzy c-Means Algorithm in Automatic Classification of EEG* [online]. s. 147 [cit. 2017-04-06]. DOI: 10.1007/978-3-319-33609-1_13. Dostupné z:
http://link.springer.com/10.1007/978-3-319-33609-1_13

Seznam příloh

Příloha I	Seznam součástek pro prototypovou desku
Příloha II	Seznam součástek pro galvanické oddělení
Příloha III	Fotky reálné osazené desky pro galvanické oddělení
Příloha IV	Fotky reálné osazené prototypové desky pro měření myopotenciálů
Příloha V	Návrhy neupravených a upravených fuzzy množin (příloha na CD)
Příloha VI	Software EMG_MyoReader (příloha na CD)

Příloha I

Tab. 8-1 Seznam součástek pro prototypovou desku

	Označení	Hodnota	Pouzdro
Kondenzátory	C1	6,8 nF	C1206
	C2	6,8 nF	C1206
	C3	22 nF	C1206
	C4	47 nF	C1206
	C5	4,7 nF	C1206
	C6	4,7 nF	C1206
	C7	4,7 nF	C1206
	C8	100 nF	C1206
	C9	100 nF	C1206
	C10	4,7 nF	C1206
	C11	6,8 nF	C1206
	C12	6,8 nF	C1206
	C13	22 nF	C1206
	C14	47 nF	C1206
	C15	4,7 nF	C1206
	C16	4,7 nF	C1206
	C17	4,7 nF	C1206
	C18	4,7 nF	C1206
	C19	6,8 nF	C1206
	C20	6,8 nF	C1206
	C21	22 nF	C1206
	C22	47 nF	C1206
	C23	4,7 nF	C1206
	C24	4,7 nF	C1206
	C25	4,7 nF	C1206
	C26	4,7 nF	C1206
	C27	6,8 nF	C1206
	C28	6,8 nF	C1206
	C29	22 nF	C1206
	C30	47 nF	C1206
	C31	4,7 nF	C1206
	C32	4,7 nF	C1206
	C33	4,7 nF	C1206
	C34	4,7 nF	C1206
	C39	100 nF	C1206
	C40	100 nF	C1206
	C41	100 nF	C1206
	C42	100 nF	C1206
	C43	100 nF	C1206

Kondenzátor	C44	100 nF	C1206
	C45	100 nF	C1206
	C46	100 nF	C1206
	C47	100 nF	C1206
	C48	100 nF	C1206
	C49	100 nF	C1206
	C50	100 nF	C1206
	C51	100 nF	C1206
	C52	100 nF	C1206
	C53	100 nF	C1206
	C54	100 nF	C1206
	C55	100 nF	C1206
	C56	100 nF	C1206
	C57	100 nF	C1206
	C58	100 nF	C1206
	C59	100 nF	C1206
	C60	100 nF	C1206
	C61	100 nF	C1206
	C62	100 nF	C1206
	C63	100 nF	C1206
	C64	100 nF	C1206
	C65	100 nF	C1206
C66	100 nF	C1206	
Rezistory	R1	820 k Ω	R1206
	R2	1,6 M Ω	R1206
	R3	10 k Ω	R1206
	R4	10 k Ω	R1206
	R5	680 k Ω	R1206
	R6	680 k Ω	R1206
	R7	680 k Ω	R1206
	R8	100 k Ω	R1206
	R9	1 k Ω	R1206
	R10	2 k Ω	R1206
	R11	680 k Ω	R1206
	R12	1 M Ω	R1206
	R13	1 M Ω	R1206
	R14	20 k Ω	R1206
	R15	680 k Ω	R1206
	R16	820 k Ω	R1206
	R17	1,6 M Ω	R1206
	R18	10 k Ω	R1206
	R19	10 k Ω	R1206

Rezistory	R20	680 k Ω	R1206
	R21	680 k Ω	R1206
	R22	680 k Ω	R1206
	R23	100 k Ω	R1206
	R24	1 k Ω	R1206
	R25	20 k Ω	R1206
	R26	680 k Ω	R1206
	R27	680 k Ω	R1206
	R28	2 k Ω	R1206
	R29	820 k Ω	R1206
	R30	1,6 M Ω	R1206
	R31	10 k Ω	R1206
	R32	10 k Ω	R1206
	R33	680 k Ω	R1206
	R34	680 k Ω	R1206
	R35	680 k Ω	R1206
	R36	100 k Ω	R1206
	R37	1 k Ω	R1206
	R38	2 k Ω	R1206
	R39	680 k Ω	R1206
	R40	20 k Ω	R1206
	R41	680 k Ω	R1206
	R42	820 k Ω	R1206
	R43	1,6 M Ω	R1206
	R44	10 k Ω	R1206
	R45	10 k Ω	R1206
	R46	680 k Ω	R1206
	R47	680 k Ω	R1206
	R48	680 k Ω	R1206
	R49	100 k Ω	R1206
	R50	1 k Ω	R1206
R51	20 k Ω	R1206	
R52	680 k Ω	R1206	
R53	680 k Ω	R1206	
R54	2 k Ω	R1206	
Přístrojové zesilovače	IC1	INA126P	DIL08
	IC6	INA126P	DIL08
	IC9	INA126P	DIL08
	IC13	INA126P	DIL08
Operační zesilovače	IC2	OPA2336P	DIL08
	IC3	OPA2336P	DIL08
	IC4	OPA2336P	DIL08


Operační zesilovače	IC5	OPA350P	DIL08
	IC7	OPA2336P	DIL08
	IC8	OPA2336P	DIL08
	IC10	OPA2336P	DIL08
	IC11	OPA2336P	DIL08
	IC12	OPA2336P	DIL08
	IC14	OPA2336P	DIL08
	IC15	OPA2336P	DIL08
Konektory	JP1	OUT	1X05
	JP2	IN1	1X02
	JP3	IN2	1X02
	JP4	IN3	1X02
	JP5	IN4	1X02
	JP6	NAP.	1X02
	JP8	REF	1X01

Příloha II


Tab. 8-2 Seznam součástek pro galvanické oddělení

	Označení	Hodnota	Pouzdro
Kondenzátory	C1	100 nF	C1206
	C2	100 nF	C1206
	C3	100 nF	C1206
	C4	100 nF	C1206
	C5	100 nF	C1206
	C6	100 nF	C1206
Rezistory	R1	24 Ω 1%	R1206
	R2	24 Ω 1%	R1206
	R3	24 Ω 1%	R1206
	R4	24 Ω 1%	R1206
Integrovaný obvod	U1	ADUM4160BRIZ	SOIC16
DC-DC měnič	DC1	AM1D-0505SZ	DC-DC do DPS
Konektory	U2	USB1X90	USB A do DPS
	U3	USB PCB MBW	USB mini B do DPS

Příloha III




Obr. 9-1 Deska pro galvanické oddělení shora




Obr. 9-2 Deska pro galvanické oddělení zdola

Příloha IV



Obr. 9-3 Finální prototypová deska pohled zdola



Obr. 9-4 Finální prototypová deska pohled shora