

Универзитет у Београду – Електротехнички факултет

Катедра за сигнале и системе



ДИПЛОМСКИ РАД

Класификација покрета руке на основу кинематских параметара применом неуралних мрежа

Кандидат

Марија Новичић 2013/0076

Ментор

Др Милица Јанковић, доцент

Београд, Септембар 2017. године

Захвалница

Желим да се захвалим свом ментору, доц. др Милици Јанковић, на корисним саветима и сугестијама које ми је пружила током израде овог рада у Лабораторији за биомедицинско инжењерство Електротехничког факултета у Београду.

Хвала доц. др. Горану Кваичеву на указаној помоћи приликом израде овог рада.

Хвала свим колегама и колегиницама са Одсека за сигнале и системе на квалитетним саветима и лепом дружењу током претходних година.

Хвала и Борку Јовановићу на предлагању ове теме и на несебичној помоћи током израде.

Хвала свим испитаницима који су учествовали у реализацији овог дипломског рада.

Посебно се захваљујем породици и пријатељима на пруженој подршци и бескрајном стрпљењу.

Марија Новичић

У Београду, септембар 2017. године

Садржај

1. УВОД.....	1
2. ВЕШТАЧКЕ НЕУРАЛНЕ МРЕЖЕ.....	4
2.1. СТРУКТУРА НЕУРАЛНИХ МРЕЖА	4
2.2. АЛГОРИТАМ ПРОПАГИРАЊА УНАЗАД	6
2.2.1. <i>Levenberg–Marquardt–ово обучавање.....</i>	<i>7</i>
2.3. ГЕНЕРАЛИЗАЦИЈА НЕУРАЛНЕ МРЕЖЕ	8
3. ИНЕРЦИЈАЛНИ СЕНЗОРИ.....	9
3.1. ЖИРОСКОП	9
3.2. АКЦЕЛЕРОМЕТАР	10
3.3. МАГНЕТОМЕТАР	11
4. МЕТОДОЛОГИЈА РАДА	12
4.1. ИСПИТАНИЦИ	12
4.2. MUO ARMBAND	12
4.3. ПРОТОКОЛ МЕРЕЊА	13
4.4. АКВИЗИЦИЈА И АНАЛИЗА ПОДАКА	14
4.4.1. <i>Online програм</i>	<i>14</i>
4.4.2. <i>Offline програм</i>	<i>15</i>
5. КЛАСИФИКАЦИЈА ПОКРЕТА РУКЕ	16
5.1. ИЗДВАЈАЊЕ ОБЕЛЕЖЈА	16
5.2. ОБУЧАВАЊЕ ВЕШТАЧКЕ НЕУРАЛНЕ МРЕЖЕ	16
6. РЕЗУЛТАТИ	18
6.1. РЕЗУЛТАТИ ПРЕТПРОЦЕСИРАЊА.....	18
6.1.1. <i>Испитаник ID1</i>	<i>18</i>
6.1.2. <i>Испитаник ID2</i>	<i>19</i>
6.1.3. <i>Испитаник ID3</i>	<i>21</i>
6.2. РЕЗУЛТАТИ КЛАСИФИКАЦИЈЕ.....	22
6.2.1. <i>Класификација покрета руке.....</i>	<i>22</i>
6.2.2. <i>Класификација положаја руке.....</i>	<i>25</i>
7. ДИСКУСИЈА И ЗАКЉУЧАК.....	28
ЛИТЕРАТУРА.....	29
СПИСАК СЛИКА.....	31
СПИСАК ТАБЕЛА.....	33

1. Увод

Одевна технологија (енг. *Wearable technology*) подразумева „паметне уређаје“ који интегришу рачунарску јединицу и уграђени су у делове одеће или модне детаље (сатове, наочаре, прстење, нарукнице и др.) [1]. Основне примене оваквих уређаја су у домену мониторинга виталних сигнала, олакшаној интеракцији и/или управљању другим електронским уређајима. Интеракција са другим уређајима путем „паметне технологије“ се базира на детекцији покрета тела, њиховој класификацији и формирању управљачких сигнала. Из тог разлога је развој алгоритама који омогућавају класификацију покрета и активности делова људског тела у реалном времену од посебног значаја.

У литератури се могу наћи различити приступи у праћењу покрета шаке или прста без поставке сензора директно на шаку корисника. За праћење покрета се користе различите методе: мерење ЕМГ сигнала ([2]), коришћење инерцијалне мерне јединице ([3] и [4]), коришћење камере ([5]), и друге.


Myo Armband представља један пример носивог уређаја произведен од стране компаније Thalmic Labs, USA. Главна улога ове нарукнице јесте управљање електронским уређајима помоћу покрета руке и електричне активности мишића подлактице. Детаљнији опис Myo нарукнице је дат у поглављу 4.2. Осим за комерцијалну употребу, ова нарукница може да се искористи и као сензор за прикупљање ЕМГ сигнала и сигнала са инерцијалних сензора. Помоћу ових сигнала је могуће управљање вештачком шаком у циљу супституције ампутираних или генетски неразвијених шака. Група истраживача са универзитета Johns Hopkins (Балтимор, Мериленд, Сједињене Америчке државе) је развила систем за управљање вештачком руком помоћу сигнала добијених са две Myo нарукнице [6]. Предност овог система (Слика 1.1) лежи у релативно мањој цени у односу на остала протетска решења. Принцип рада се заснива на бежичном слању ЕМГ сигнала на рачунар који даље управља вештачком руком [7].



Слика 1.1 Систем за управљање вештачком руком помоћу сигнала добијених са две Myo нарукнице. Слика преузета са [7].

Да би се омогућило управљање вештачком руком или шаком потребно је извршити класификацију снимљених сигнала. Студија [8] се бави класификацијом покрета подлактице помоћу ЕМГ сигнала снимљених на површини коже. Применом адаптивног Neuro-Fuzzy закључивања у овом раду је постигнута успешност од 92% приликом класификације издвојених временско-фреквенцијских обележја ЕМГ сигнала. Рад [9] се базира на класификацији покрета подлактице у реалном времену у циљу управљања неуралном протезом. За класификацију ЕМГ сигнала у реалном времену је коришћена fuzzy C-mean кластеризација. Класификатор је улазне сигнале који карактеришу четири различита покрета класификовао са тачношћу од $92.7\% \pm 3.2\%$.

Постоје студије где ради постизања бољих резултата за класификацију покрета уз инерцијалне сензоре користили и електромиографске (ЕМГ) сензоре ([10]). У овом раду су неуралне мреже коришћене за предикцију флексије/екстензије лакта и пронације/супинације подлактице помоћу шест ЕМГ сензора и угаоне брзине и линеарног убрзања надлактице. Комбинацијом кинематике и мишићне активности током offline анализе је постигнута тачност од 96% за флексију/екстензију лакта и 92% за пронацију/супинацију подлактице. Међутим, online анализа је дала веће грешке предикције, и то 13.7° и 23.3° респективно. На слици 1.2 је приказана поставка сензора приликом реализације овог пројекта.



Слика 1.2 Пројектован систем током студије [10]. Приказана је поставка сензора током две фазе обучавања неуралне мреже

У студији [11] се врши класификација покрета током ходања постављањем сензора на кук испитаника применом неуралних мрежа. Коришћењем вишеслојне перцепторске мреже је постигнута успешност класификацију у опсегу од 89% до 92%.

У овом раду је описан систем за класификацију покрета и положаја руке на основу сигнала добијених са инерцијалних сензора. Класификација покрета се врши помоћу две неуралне мреже. Реализован систем представља део пројекта чији је циљ супституција функције шаке код људи којима те функције недостају. Како би се пројектовао low-cost уређај, изабрана је Муо наруквица у којој су смештени инерцијални сензори.

Након уводног поглавља је дата теоријска основа о вештачким неуралним мрежама, описане су основне структуре и правила обучавања неуралних мрежа. Описана је и оптимизација алгорита за обучавање неуралне мреже пропагацијом уназад. У наставку је описана инерцијална мерна јединица и сензори које она садржи, као и принцип рада

жироскопа и акцелерометра. У четвртом поглављу је описан систем за мерење сигнала, протокол мерења, као и практични део овог рада.

Практични део овог дипломског рада укључује:

- Online аквизицију сигнала са сензора
- Offline обраду и анализу снимљених сигнала
- Класификацију покрета руке на основу снимљених сигнала

Коначно, дискутовани су резултати имплементираног алгоритма класификације покрета руке. У закључку је описан значај пројектованог система и његова могућа побољшања.


2. Вештачке неуралне мреже

Вештачке неуралне мреже (енг. *Artificial Neural Networks*) представљају један облик вештачке интелигенције који је конструисан тако да користи неке од принципа рада људског мозга. Оне представљају системе за информационо процесирање и своју примену су пронашле у класификацији и препознавању облика, апроксимацији функција, оптимизацији, векторској квантизацији и груписању података [12].

У овом поглављу ће бити описана општа структура и функција вештачких неуралних мрежа, као и правила обучавања. Детаљно ће бити објашњен алгоритам обучавања који је примењен за класификацију покрета руке у овом раду.

2.1. Структура неуралних мрежа

Неуралне мреже се састоје од великог броја густо повезаних процесирајућих елемената (енг. *Processing elements*). Како неуралне мреже моделују понашање стварних неурона у људском мозгу, ови елементи се најчешће називају вештачким неуронима.



Слика 2.1.1 Математички модел биолошког неурона

Математички модел биолошког неурона је приказан на слици 2.1.1, и најчешће се назива М-Р неурон. Функција М-Р неурона се може проширити на модел процесирајућег елемента, односно вештачког неурона. Овај модел се састоји од два дела – улазних и излазних сигнала.

Интеграциона функција f (енг. *Net function*) служи за комбиновање информација са спољашних извора или других неурона. Најчешће је то линеарна комбинација улаза x_i и тежинских фактора w_{ij} :


$$f_i = net_i = \sum_{j=1}^m w_{ij} x_j - \theta_i \quad (2.1.1)$$

при чему θ_i представља праг активације и-тог неурона.

Излаз неурона је дефинисан као излаз функције активације $a(f)$ (енг. *Transfer function*). На улаз функције активације се доводи збирни репрезент улазних сигнала f_i .


$$y_i = a(\text{net}_i) = a\left(\sum_{j=1}^m w_{ij}x_j - \theta_i\right) \quad (2.1.2)$$

Уобичајени облици активационе функције су степ функција, „*Hard limiter*“, функција рампе и униполарна или биполарна сигмоидална функција (Слика 2.1.2).



Слика 2.1.2 Облици активационих функција: степ функција (а), „*Hard limiter*“ (б), функција рампе (в), униполарна сигмоидална функција (г) и биполарна сигмоидална функција (д). Слика је преузета и измењена са [12]

Неуралне мреже се састоје од великог броја елемената за процесирање који су међусобно повезани. Излаз сваког неурона је преко тежинских коефицијената повезан са наредним неуроном (*feedforward* НМ) или са самим собом (рекурентна НМ). Неурони су међусобно груписани у слојеве. На основу броја слојева неуралне мреже се деле на једнослојне и вишеслојне. Први слој се назива улазним слојем и његова улога је да прослеђује податке из околине, док последњи, излазни слој даје коначан резултат. Између улазног и излазног слоја се могу налазити скривени слојеви који прослеђују релевантне информације од улаза ка излазу. На слици 2.1.3 је приказан пример вишеслојне неуралне мреже.



Слика 2.1.3 Пример вишеслојне *feedforward* неуралне мреже. Слика је преузета и измењена са [13]

Неуралне мреже показују особине учења и генерализације на основу сета података за обучавање. Разликују се две категорије обучавања неуралних мрежа:

- 1) Параметарско обучавање које се заснива на ажурирању тежинских коефицијената
- 2) Структурно обучавање које се заснива на мењању структуре неуралне мреже

Циљ параметарског обучавања неуралне мреже јесте да се променом тежинских коефицијената омогући адекватно понашање неуралне мреже. Постоје три типа параметарског обучавања:

- 1) Супервизијско обучавање – ажурирање тежинских коефицијената се врши на основу поређења тренутних и жељених излаза, који су познати.
- 2) Учење са критиком је облик супервизијског учења код кога нису тачно познати жељени излази, већ је позната информација колико је тренутни излаз „добар“
- 3) Несупервизијско обучавање – не постоји повратна информација, па неурална мрежа сама мора да мења своје параметре

2.2. Алгоритам пропагирања уназад

Пропагирање уназад (енг. *Back propagation*) представља једану од метода за обучавање вештачке неуралне мреже. Овај алгоритам се може применити код вишеслојних неуралних мрежа са континуалним и диференцијабилним функцијама активације. Пропагирање уназад је један од облика супервизијског обучавања, те је познат обучавајући скуп парова улаза и жељених излаза $\{(x_k, d_k) | k = 1, 2, \dots, m\}$. За дате парове алгоритам мења тежинске коефицијенте у циљу исправне класификације улазних сигнала.

Алгоритам обучавања пропагирањем уназад се састоји из две фазе. На почетку се улазни сигнали пропагирају ка излазном слоју и добијају се тренутни излази y_i . Затим се рачуна сигнал грешке као одступање тренутног излаза од жељеног. Сигнал грешке се пропагира уназад до претходног слоја, при чему долази до ажурирања тежинских коефицијената. Формира се критеријумска функција $E(w)$ (енг. *cost function*) дефинисана једначином:

$$E(w) = \frac{1}{2} \sum_{i=1}^m e^2 = \frac{1}{2} \sum_{i=1}^m [d_i - y_i]^2 \quad (2.2.1)$$

Ажурирање тежинских коефицијената се заснива на примени методе негативног градијента критеријумске функције. Вредност коефицијента који спаја i -ти неурон у k -том слоју и j -ти неурон у $(k-1)$ слоју се мења помоћу следеће једначине:

$$\begin{aligned} \Delta^k w_{ij} &= \eta \cdot {}^k \delta_i \cdot {}^{k-1} y_j \\ {}^k w_{ij}^{new} &= {}^k w_{ij}^{old} + \Delta^k w_{ij} \end{aligned} \quad (2.2.2)$$

где је са ${}^k \delta_i$ означен сингал грешке између i -тог неурона у $k-1$ слоју и k -тог слоја. Параметар η представља константу обучавања и говори о брзини конвергенције.

2.2.1. Levenberg–Marquardt–ово обучавање

Алгоритам обучавања пропагацијом грешке уназад је представљао значајан напредак у области тренирања неуралних мрежа. Међутим, показало се да примена овог алгоритма може бити неефикасна. На ефикасност највећи утицај има константа обучавања η . Што је вредност ове константе већа то ће неурална мрежа брже конвергирати ка жељеним вредностима, али ће доћи и до прескока који може довести до појаве осцилација. Избором мале вредности константе обучавања смањује се могућност појаве прескока, али је конвергенција знатно спорија. Постоји више метода за оптимизацију овог алгоритма.

i) Увођење моментума у методу негативног градијента

Идеја је да се сваком ажурирању тежинских коефицијената додаје момент инерције и на тај изврши филтрирање промене. Ажурирање коефицијената је дефинисано следећом једначином:

$$w(t+1) = w(t) - \eta \cdot \nabla E(t) \quad (2.2.3)$$

ii) Gauss-Newton-ов алгоритам

За разлику од методе негативног градијента који користи само први извод критеријумске функције, овај алгоритам се заснива на примени и њених виших извода. Ажурирање тежинских коефицијената поред градијента критеријумске функције зависи и од њеног другог извода.

$$w(t+1) = w(t) - H^{-1}(w(t)) \cdot \nabla E(w(t)) \quad (2.2.4)$$

при чему H представља Хесијан матрицу, тј. матрицу других извода критеријумске функције. Матрица H се може апроксимирати помоћу Јакобијан матрице J ради једноставнијег рачунања.

$$H(w) = \nabla^2 E(w) \approx J^T J \quad (2.2.5)$$

iii) Levenberg–Marquardt–ов алгоритам

Levenberg–Marquardt–ов алгоритам представља мешавину претходно описаних алгоритама оптимизације. Комбинацијом ове две методе се постиже стабилност моментума и ефикасност Gauss-Newton-ог алгоритма. Принцип рада се заснива на примени моментума у околини комплексних закривљења, све док не може да се изврши квадратна апроксимација када метод постаје Gauss-Newton-ов алгоритам [14].

Levenberg–Marquardt–ов алгоритам уводи још једну апроксимацију Хесијан матрице која гарантује инвертибилност матрице $J^T J$:

$$H \approx J^T J + \mu I \quad (2.2.6)$$

где μ означава коефицијент комбинације и увек има позитивне вредности, а I представља јединичну матрицу. Правило ажурирања тежинских коефицијената применом Levenberg–Marquardt–овог алгоритма је дато са:

$$w(t+1) = w(t) - H^{-1}(t) \cdot J(t) \cdot e(t). \quad (2.2.7)$$

Мана овог алгоритма јесте потреба за рачунањем инверзне Хесијан матрице при сваком ажурирању тежинских коефицијената. Из тог разлога, овај алгоритам је ефикасан само код неуралних мрежа са малим бројем скривених слојева. Такође, проблем представља и потреба за великом количином меморије за чување Јакобијан матрице.

2.3. Генерализација неуралне мреже

Приликом обучавања неуралне мреже треба обратити пажњу на обучавајући скуп података. Обучавајући скуп треба изабрати тако да буде довољан и одговарајући. Алгоритам обучавања пропагирањем уназад даје неуралне мреже које добро генерализују. За неуралну мрежу кажемо да добро генерализује ако за нове улазе даје разумне резултате на излазу. Уколико за мале промене улазних параметара дође до катастрофалних промена на излазу, онда је дошло до преобучавања неуралне мреже. Мреже са великим бројем параметара за обучавање, у односу на обучавајући скуп, могу добро да се обуче, али не и да генерализују добро.

Једна од метода за заштиту од преобучавања неуралне мреже је рано заустављање. Мрежа се не обучава на целом обучавајућем скупу, већ на једном делу. Остатак података из обучавајућег скупа се користи за валидацију и тестирање неуралне мреже. Након сваке епохе се проверавају перформансе неуралне мреже.

3. Инерцијални сензори


Инерцијална мерна јединица (енг. *Inertial Measurement Unit*) представља електронски уређај који омогућава процену оријентације тела помоћу инерцијалних сила које делују на тело. Оријентација се процењује применом различитих претварача који мере силе убрзања, угаоне брзине, а у неким случајевима и магнетног поља које окружује тело. Принцип рада сензора се заснива на првом и другом Њутновом закону. Познајући интензитет и правац силе која делује на тело се може добити његово убрзање, а интеграцијом те вредности можемо добити брзину и позицију [15].

Инерцијални сензори се највише користе за навигацију покретних објеката као што су авиони, вођене ракете или бродови, али су своју примену нашли и у биомедицинском инжењерству.

Конвенционални инерцијални сензори се састоје од 3-осног акцелерометра и 3-осног жироскопа за естимацију позиције у тродимензионалном простору. Неки сензори у себи могу имати и 3-осни магнетометар који омогућава мерење магнетног поља које делује на тело.


3.1. Жироскоп

Жироскопи су уређаји за мерење угаоне брзине ротације тела у односу на референтни координатни систем. Први жирокопи су се заснивали на закону о одржавању угаоног момента и називају се ротациони жирокопи (Слика 3.1.1). Ови жирокопи се састоје од инерцијалног диска који ротира великом брзином. Број ових дискова одређује број степена слободе жироскопа. При ротирању делује спољашњи моменат у правцу нормалном на осу ротације и зависи од угаоне брзине и момента инерције у односу на осу ротације [16].



Слика 3.1.1 Ротациони жирокоп, слика преузета и измењена са [17]

Жироскопи могу да мере угаону брзину у једном, два или три правца. У комбинацији са 3-осним акцелерометром, 3-осни жироскоп обезбеђује праћење кретања објекта са шест степени слободе. 3-осни жироскоп детектује промену ротације сензора, и ову информацију представља преко три компоненте: угла пропињања (енг. *Pitch*), угла ваљања (енг. *Roll*) и угла скретања (енг. *Yaw*). На слици 3.1.2. су приказана три ротирајућа диска са дефинисаним угловима.



Слика 3.1.2 Ротирајући дискови са дефинисаним угловима пропињања, ваљања и скретања, слика преузета и измењена са [18]


Комерцијални жироскопи се израђују у MEMS (енг. *Microelectromechanical systems*) технологији. Применом MEMS технологије је омогућена брза израда жироскопа малих димензија. Принцип рада ових жироскопа се заснива на Кориолисовом ефекту. Кориолисов ефекат је добио име по научнику Гаспару-Густаву Кориолису који је дефинисао Кориолисове силе. Кориолисове силе се јављају при транслаторном кретању тела по другом обртном телу. Кориолисова сила је пропорционална угаоној брзини обртног тела и брзини тела које се креће праволинијски у односу на осу ротације. MEMS жироскопи прате промене угаоне брзине мерењем ове силе [19].

3.2. Акцелерометар

Акцелерометри су сензори који служе за мерење убрзања. Акцелерометри детектују укупно убрзање у односу на фиксан координатан систем који представља збир убрзања земљине теже и убрзања које делују на тело. Унутар акцелерометра се налазе микроструктуре које се савијају услед момента или гравитације. При убрзавању објекта на који је постављен акцелерометар долази до савијања које је пропорционално том убрзању. Ово савијање се може детектовати електронским путем [20].

Највећи број комерцијалних акцелерометара мери убрзање у два или три правца. За реконструкцију положаја тела у тродимензионалном простору користе се 3-осни акцелерометри који детектована убрзања представљају кроз три компоненте локалног координатног система.

Највећа примена акцелерометра је у навигационим системима. Могу се наћи и у паметним телефонима нове генерације, као и у конзолама за игре (нпр. Wii конзола). Због својих карактеристика могу се користити и у биомедицинском инжењерству за праћење људских покрета. Акцелерометри омогућавају праћење позиције тела, физичке активности, као и класификацију покрета.



Слика 3.2.1 Пример 2-осног (лево) и 3-осног (десно) акцелерометра за мерење нагиба, слика је преузета и измењена са [21]

3.3. Магнетометар

Магнетометри су уређаји за мерење магнетског поља. Они дају информацију о оријентацији тела у зависности од магнетног поља планете Земље. Најчешћа примена магнетоматра је у компасима.

У комбинацији са жироскопом и акцелерометром, магнетометри дају прецизнију информацију о позицији и оријентацији тела. Међутим, информације које даје магнетометар нису коришћене у овом раду.

4. Методологија рада

4.1. Испитаници

У овој студији је учествовало три испитаника, од којих је два здраво, а трећи нема развијену шаку. Испитаници су обавештени о неинвазивној процедури мерења и дали пристанак да учествују у мерењу. Основне информације о испитаницима су приказане у табели 4.2.1.

ID испитаника	Старост (године)	Пол (М – мушки, Ж – женски)	Доминантна рука
ID1	23	Ж	Десна
ID2	34	М	Десна
ID3	49	Ж	Десна

Табела 4.2.1 Основне информације о испитаницима који су учествовали у студији

4.2. Myo Armband

Myo Armband је комерцијални уређај произведен од стране Thalmic Labs компаније (Слика 4.1.1) и служи за управљање апликацијама које се могу наћи на рачунарима и мобилним телефонима. Карактеристична поставка наруквице је на подлактици, одмах испод лакта. Постоји и програмско окружење за прикупљање и обраду сигнала у циљу препознавања покрета или положаја руке у тродимензионалном простору.



Слика 4.1.1 Myoarmband постављена на подлактицу десне руке (слика преузета са [22])

Састоји се од осам електромиографских (ЕМГ) сензора за мерење електричне активности мишића. Анализом сигнала који долазе са ових сензора Муо наруквица може да класификује покрете шаке. Осим ЕМГ сензора, овај уређај поседује и инерцијалну мерну јединицу (ИМЈ) са девет степени слободе. ИМЈ је опремљена са 3D акцелерометром, 3D жирокопом и 3D магнетометром и служи за детектовање померања руке.

Сигнали прикупљени са ових сензора се преносе бежично преносе до рачунара путем *Bluetooth* протокола. Фреквенција одабирања ЕМГ сигнала износи 200 Hz, а сигнала са инерцијалних сензора је 50 Hz.

У овом раду, за класификацију покрета руке су коришћени само сигнали са ИМЈ.

4.3. Протокол мерења

Муо наруквица се поставља на подлактицу испитаника, одмах испод лакта. Сваки испитаник је имао један задатак. Задатак се састојао од промене положаја руке по дефинисаној секвенци. Постојало је шест карактеристичних положаја (Слике 4.3.1 и 4.3.2) у секвенци. Промена положаја се вршила по одређеном редоследу на сваких пет секунди. Једно мерење почиње и завршава се са 5 секунди паузе. Извршавање задатка је поновљено три пута код сваког испитаника.



Слика 4.3.1 Положаји руке током извршавања задатка. Приказан је референтни положај (лево), као и кретање у сагиталној равни (у средини и десно)



Слика 4.3.2 Положаји руке током извршавања задатка. Приказано је кретање у трансверзалној равни (лево и у средини), као и ротација длана (десно)

4.4. Аквизиција и анализа података

Званични програм за прикупљање и анализу сигнала са сензора који се налазе на Муо наруквици се може преузети са званичног сајта компаније Thalmic Labs ([23]). Међутим, овај програм не омогућава приступ сировим сигнаlima са сензора, па није коришћен у овом раду.

За потребе овог рада су реализована два софтвера. За online прикупљање података је реализован софтвер у програмском окружењу Python (Python Software Foundation, <https://www.python.org>). Други софтвер је реализован у програмском окружењу Matlab (Mathworks Inc., Natick, USA) и служи за offline анализу и обраду снимљених сигнала.


4.4.1. Online програм

Софтвер за online аквизицију података је реализован у програмском окружењу Python из више разлога. Пре свега, постоји библиотека написана у програмском језику Python која омогућава комуникацију између Муо наруквице и рачунара. Ова библиотека даје приступ сировим сигнаlima које дају акцелерометар и жирокоп. Такође, постоји једноставан начин за real-time обраду података, а касније и реализацију управљања у програмском језику Python.

Софтвер за прикупљање сигнала је у целости преузет са [24]. Оригиналом коду је додата могућност снимања сигнала у текстуалну датотеку. Снимање је извршено са фреквенцијом одабирања од 50 Hz, а подаци се у текстуалну датотеку уписују на сваких 0.05 секунди.


4.4.2. Offline програм

У програмском пакету Matlab је написан програм за offline анализу и обраду сигнала који су претходно снимљени. Offline анализа почиње учитавањем свих снимљених сигнала из текстуалних датотека. Након учитавања сигнала у свакој секвенци је уклоњена пауза са почетка снимања. Сигнали измерени акцелерометром су филтрирани применом медијан филтра са ширином прозора од 10 одбирака. На слици 4.4.1 је приказан пример сигнала измереног акцелерометром пре и након филтрирања.



Слика 4.4.1 Временски облик сигнала измереног 3-осним акцелерометром (горе) и исти сигнал након филтрирања (доле)

Сигнали измерени жирокопом су такође филтрирани медијан филтром са ширином прозора од 10 одбирака. Након тога је извршена нормализација сигнала како добијени резултати не би варирали у зависности од испитаника. Нормализовани сигнали су затим квадрирани да би се смањио утицај флукуације сигнала док рука мирује. На слици 4.4.2 пример сигнала измереног акцелерометром пре и након обраде.



Слика 4.4.2 Временски облик сигнала измереног 3-осним жирокопом (горе) и исти сигнал након филтрирања, нормализације и квадрирања (доле)

5. Класификација покрета руке

Последњи сегмент offline програма јесте обучавање вештачке неуралне мреже у циљу класификације покрета руке. Припрема за обучавање мреже, као и само обучавање је описано у овом поглављу.

5.1. Издвајање обележја

Успех система за класификацију облика у потпуности зависи од избора обележја који представљају дате облике. Стога, успех класификације сигнала измерених инерцијалним сензорима лежи у адекватном избору обележја. За класификацију овако сложених сигнала је потребно изабрати вишеструке параметре који представљају дате сигнале.


За издвајање обележја су употребљене прозорске функције које издвајају кратак временски период снимљених сигнала. Дужина трајања прозора је изабрана визуелном инспекцијом сигнала, обрађајући пажњу на брзе промене сигнала измереног жирокопом. Ширина прозорске функције износи 0.5 секунди.

Проучавањем постојеће литературе могу се пронаћи различити параметри који добро описују дате сигнале [25]. Изабрана су два обележја која пружају најбоље резултате приликом класификације сигнала са жирокопа. За сваки прозор је рачуната варијанса сигнала и средња вредност сваког снимљеног сигнала. Обележја су издвојена за све снимљене сигнале и доведена на улаз неуралне мреже.

5.2. Обучавање вештачке неуралне мреже


Трениране су две неуралне мреже, једна за добијање правца и смера кретања руке у релативном координатном систему, а друга за добијање информације о положају руке у односу на тело. За тренирање обе неуралне мреже је примењен алгоритам пропагирања уназад са Levenberg–Marquardt–овом методом оптимизације алгоритма.

Правец и смер кретања руке је детектован класификацијом сигнала измереног помоћу жирокопа. Прва неурална мрежа има шест улаза који представљају по два обележја за сваки канал жирокопа. Неурална мрежа се састоји од четири слоја: улазног слоја, два скривена слоја са биполарним сигмоидалним функцијама активације и излазног слоја са линеарном функцијом активације. Покрети су класификовани у шест класа – кретање руке горе/доле, кретање руке лево/десно, ротација длана и мировање руке. Класе су представљене са јединицом у једном од шест редова и нулом у осталим. Блок шема прве неуралне мреже је дата на слици 5.2.1.



Слика 5.2.1 Шема вештачке неуралне мреже за класификацију правца и смера кретања руке, у првом скривеном слоју има шест, а у другом девет неурона

Релативан положај руке у односу на тело је добијен класификацијом сигнала измерених помоћу акцелерометра. Неурална мрежа се састоји од четири слоја: улазног слоја, два скривена слоја са биполарним сигмоидалним функцијама активације и излазног слоја са линеарном функцијом активације. Вектор улаза има шест елемената који представљају издвојена обележја за сваки од канала акцелеромета. Положај руке је класификован у седам класа које су представљене са јединицом у једном од шест редова и нулом у осталим. Блок шема прве неуралне мреже је дата на слици 5.2.2.



Слика 5.2.2 Шема вештачке неуралне мреже за класификацију правца и смера кретања руке, у првом скривеном слоју има шест, а у другом десет неурона


Класификација сигнала је имплементирана у програмском окружењу Matlab у приложеној датотеци *MarijaNovicicDiplomskiRad.m*. Укупан сет података је подељен на три дела: 70% за тренирање, 15% за валидацију и 15% за тестирање неуралне мреже. Укључена је заштита од преобучавања неуралне мреже. Постоји више услова за заустављање тренирања неуралне мреже: достизање максималног броја епоха тренирања (1000), вредност грешке у средњем квадратном смислу постане мања од жељене вредности (0.001) или ако се укључи заштита од преобучавања. Након сваког обучавања вредности матрице тежинских коефицијената и прагови се чувају у циљу добијања оптималне класификације.

6. Резултати


У овом поглављу су приказани временски облици измерених сигнала након обраде, као и резултати класификације покрета руке на основу ових сигнала помоћу неуралних мрежа. Резултати процесирања обухватају измерене сигнале за сваког од испитаника током сваког покушаја.

6.1. Резултати претпроцесирања


6.1.1. Испитаник ID1



Слика 6.1.1 Временски облици сигнала измерених на испитанику ID1 током првог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде.




Слика 6.1.2 Временски облици сигнала измерених на испитанику ID1 током другог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде.




Слика 6.1.3 Временски облици сигнала измерених на испитанику ID1 током трећег покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде.

6.1.2. Испитаник ID2




Слика 6.1.4 Временски облици сигнала измерених на испитанику ID2 током првог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде.

Класификација покрета руке на основу кинематских параметара
применом неуралних мрежа
Марија Новичић




Слика 6.1.5 Временски облици сигнала измерених на испитанику ID2 током другог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде.




Слика 6.1.6 Временски облици сигнала измерених на испитанику ID2 током трећег покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде.


6.1.3. Испитаник ID3



Слика 6.1.7 Временски облици сигнала измерених на испитанику ID3 током првог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде.



Слика 6.1.8 Временски облици сигнала измерених на испитанику ID3 током другог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде.



Слика 6.1.9 Временски облици сигнала измерених на испитанику ID3 током трећег покушаја. На графицима су приказане све три осе акцелерометра (горе) и жироскопа (доле) након обраде.

6.2. Резултати класификације

За визуализацију успешности класификације је коришћена матрица конфузије. Матрица конфузије је квадратна матрица чији редови представљају предиктоване класе, а колоне представљају стварне класе. На дијагонали се налази број успешно класификованих одбирака, односно колики се проценат добијених излаза поклапа са стварним излазима. Ван главне дијагонале су приказане грешке класификације. У пољу $C(i, j)$ је приказан број одбирака за које се зна да припадају класи i , а класификовани су као одбирци класе j .

6.2.1. Класификација покрета руке

Успешност класификације неуралне мреже зависи и од случајне расподеле одбирака по скуповима. Да би се приказао утицај ове расподеле цео поступак тренирања и симулирања неуралне мреже је поновљен 10 пута. У табели 6.2.1 су приказане перформансе неуралне мреже приликом тренирања, валидације и тестирања у облику:


$$mse = \text{средња_вредност} + \text{стандардна_девијација} \quad (6.2.1)$$

	<i>Mean Squared Error (mse)</i>
Тренирање	0.0235 ± 0.016
Валидација	0.0271 ± 0.041
Тестирање	0.0259 ± 0.050

Табела 6.2.1 Перформансе неуралне мреже приликом понављања поступка тренирања, валидације и тестирања 10 пута

Приликом понављања обучавања неуралне мреже успешност класификације се кретала у опсегу од 88% до 94%. У наставку су приказани резултати за тежинске коефицијенте и прагове који дају једне од најбољих резултата приликом класификације покрета руке.

График перформансе прве неуралне мреже је приказан на слици 6.2.1. График приказује зависност грешке класификације у средње квадратном смислу у зависности од епохе тренирања.



Слика 6.2.1 График перформансе неуралне мреже за класификацију покрета руке

Са плавом линијом је означена грешка приликом тренирања неуралне мреже, црвена линија приказује грешку приликом валидације, а жута приликом тестирања неуралне мреже. На графику је приказан и тренутак пред преобучавање неуралне мреже, у овом тренутку неурална мрежа даје најбоље перформансе. Најбоље перформансе су постигнуте у 23. епохи и са грешком од 0.0196.

На сликама 6.2.2 – 6.2.4 су приказане конфузионе матрице добијене након тренирања неуралне мреже над обучавајућем скупом, као и симулације неуралне мреже над валидационим и тренирајућем скупом, респективно.

Матрица конфузије за обучавајући скуп

	Пауза	Горе	Доле	Лево	Десно	Ротација	
Добијени излази	722 72.8%	49 4.9%	5 0.5%	6 0.6%	4 0.4%	6 0.6%	91.2% 8.8%
	3 0.3%	32 3.2%	1 0.1%	0 0.0%	0 0.0%	0 0.0%	88.9% 11.1%
	1 0.1%	0 0.0%	39 3.9%	0 0.0%	0 0.0%	0 0.0%	97.5% 2.5%
	1 0.1%	0 0.0%	1 0.1%	39 3.9%	0 0.0%	0 0.0%	95.1% 4.9%
	1 0.1%	0 0.0%	0 0.0%	0 0.0%	42 4.2%	1 0.1%	95.5% 4.5%
	3 0.3%	1 0.1%	0 0.0%	0 0.0%	0 0.0%	35 3.5%	89.7% 10.3%
Жељени излази	98.8% 1.2%	39.0% 61.0%	84.8% 15.2%	86.7% 13.3%	91.3% 8.7%	83.3% 16.7%	91.6% 8.4%

Слика 6.2.2 Матрица конфузије након тренирања мреже за класификацију покрета руке на скуп за обучавање

Класификација покрета руке на основу кинематских параметара
применом неуралних мрежа
Марија Новичић

Матрица конфузије за валидациони скуп

Добијени излази	Пауза	162 76.1%	10 4.7%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	93.6% 6.4%
	Горе	0 0.0%	9 4.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Доле	0 0.0%	0 0.0%	5 2.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Лево	1 0.5%	0 0.0%	0 0.0%	8 3.8%	0 0.0%	0 0.0%	88.9% 11.1%
	Десно	2 0.9%	0 0.0%	0 0.0%	0 0.0%	11 5.2%	0 0.0%	84.6% 15.4%
	Ротација	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 1.9%	100% 0.0%
		98.2% 1.8%	47.4% 52.6%	83.3% 16.7%	100% 0.0%	100% 0.0%	100% 0.0%	93.4% 6.6%
		Пауза	Горе	Доле	Лево	Десно	Ротација	Жељени излази

Слика 6.2.3 Матрица конфузије након симулације мреже за класификацију покрета руке на скупу за валидацију

Матрица конфузије за тестирајући скуп

Добијени излази	Пауза	162 76.1%	6 2.8%	1 0.5%	2 0.9%	2 0.9%	3 1.4%	92.0% 8.0%
	Горе	0 0.0%	9 4.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Доле	0 0.0%	0 0.0%	8 3.8%	0 0.0%	0 0.0%	1 0.5%	88.9% 11.1%
	Лево	0 0.0%	0 0.0%	0 0.0%	8 3.8%	0 0.0%	0 0.0%	100% 0.0%
	Десно	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.8%	1 0.5%	88.9% 11.1%
	Ротација	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.9%	100% 0.0%
		100% 0.0%	60.0% 40.0%	88.9% 11.1%	80.0% 20.0%	80.0% 20.0%	28.6% 71.4%	92.5% 7.5%
		Пауза	Горе	Доле	Лево	Десно	Ротација	Жељени излази

Слика 6.2.4 Матрица конфузије након симулације мреже за класификацију покрета руке на скупу за тренирање

Укупна грешка класификације приликом тренирања износи 91.6%. Најуспешнија класификација је класификација покрета из класе „Доле“, који је исправно класификован у 97.5% случајева. Најмање успешно је класификован покрет из класе „Горе“, са процентом успешне класификације од 88.9%. Из матрице конфузије се може уочити и да су покрети из класе „Горе“ највише класификовани као покрети из класе „Пауза“ која означава мировање руке у неком од положаја, чак у 8.3% случајева. Неисправно класификовани покрети су највише класификовани као покрети класе „Горе“.

Приликом валидације неуралне мреже је постигнута успешност класификације од 93.4%. Најуспешније су класификовани покрети из класа „Горе“, „Доле“ и „Ротација“ са процентом успешности од 100%. Најмањи проценат успешности имају одбирци из класе „Десно“ и он износи 84.6%. Током тестирања неуралне мреже је 92.5% одбирака исправно класификовано.

Из приложених резултата се може закључити да није дошло до преобучавања неуралне мреже, односно да мрежа добро генерализује. Класификација нових података, скуп за тестирање, и даље даје задовољавајуће резултате, тј. грешку класификације у средње квадратном смислу од 0.019.

6.2.2. Класификација положаја руке

Поступак обучавања неуралне мреже за класификацију положаја руке је идентичан као и код мреже за класификацију положаја руке. Како би се уочиле промене у успешности класификације у односу на случајну расподелу одбирака, поступак тренирања и симулације неуралне мреже је поновљен 10 пута. У табели 6.2.2 су дате вредности грешке класификације у средњем квадратном смислу у облику:


$$mse = \text{средња_вредност} + \text{стандардна_девијација} \quad (6.2.2)$$

	Mean Squared Error (mse)
Тренирање	0.0342 ± 0.054
Валидација	0.0384 ± 0.072
Тестирање	0.0446 ± 0.0171

Табела 6.2.2 Перформансе неуралне мреже приликом понављања поступка тренирања, валидације и тестирања 10 пута

Приликом понављања обучавања неуралне мреже успешност класификације се кретала у опсегу од 77% до 86%.

На слици 6.2.5 је приказан график перформансе неуралне мреже приликом класификације положаја руке. Најбоље перформансе су постигнуте у 51. епохи и тада грешка класификације у средње квадратном смислу износи 0.0343.



Слика 6.2.5 График перформансе неуралне мреже за класификацију положаја руке

На сликама 6.2.6 – 6.2.8 су приказане конфузионе матрице приликом тренирања, валидације и тестирања, респективно.

Матрица конфузије за обучавајући скуп

Добијени излази	Пауза	167 16.8%	10 1.0%	0 0.0%	1 0.1%	6 0.6%	0 0.0%	0 0.0%	90.8% 9.2%
	Средина	31 3.1%	358 36.1%	0 0.0%	17 1.7%	33 3.3%	0 0.0%	0 0.0%	81.5% 18.5%
	Горе	2 0.2%	0 0.0%	90 9.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	97.8% 2.2%
	Доле	8 0.8%	2 0.2%	0 0.0%	80 8.1%	0 0.0%	0 0.0%	0 0.0%	88.9% 11.1%
	Лево	3 0.3%	5 0.5%	0 0.0%	0 0.0%	42 4.2%	0 0.0%	0 0.0%	84.0% 16.0%
	Десно	4 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	49 4.9%	0 0.0%	92.5% 7.5%
	Ротација	6 0.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	78 7.9%	92.9% 7.1%
		75.6% 24.4%	95.5% 4.5%	100% 0.0%	81.6% 18.4%	51.9% 48.1%	100% 0.0%	100% 0.0%	87.1% 12.9%
		Жељени излази							
		Пауза	Средина	Горе	Доле	Лево	Десно	Ротација	

Слика 6.2.6 Матрица конфузије након тренирања мреже за класификацију положаја руке на скупу за обучавање

Укупна грешка класификације приликом тренирања друге неуралне мреже износи 87.1%. Најуспешније су класификовани одбирци из класе „Горе“ са процентом успешности 97.8%. Најмању успешност, од 81.5% имају одбирци из класе „Средина“, и они су најчешће класификовани као припадници класе „Лево“ (7.5%).

Матрица конфузије за валидациони скуп

Добијени излази	Пауза	29 13.6%	3 1.4%	1 0.5%	0 0.0%	2 0.9%	1 0.5%	0 0.0%	80.6% 19.4%
	Средина	6 2.8%	83 39.0%	0 0.0%	3 1.4%	6 2.8%	0 0.0%	0 0.0%	84.7% 15.3%
	Горе	0 0.0%	0 0.0%	23 10.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Доле	1 0.5%	0 0.0%	0 0.0%	8 3.8%	0 0.0%	0 0.0%	0 0.0%	88.9% 11.1%
	Лево	3 1.4%	1 0.5%	0 0.0%	0 0.0%	17 8.0%	0 0.0%	0 0.0%	81.0% 19.0%
	Десно	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.8%	0 0.0%	88.9% 11.1%
	Ротација	3 1.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 6.6%	82.4% 17.6%
		67.4% 32.6%	95.4% 4.6%	95.8% 4.2%	72.7% 27.3%	68.0% 32.0%	88.9% 11.1%	100% 0.0%	85.4% 14.6%
		Жељени излази							
		Пауза	Средина	Горе	Доле	Лево	Десно	Ротација	

Слика 6.2.7 Матрица конфузије након симулације мреже за класификацију положаја руке на скупу за валидацију

Класификација покрета руке на основу кинематских параметара
применом неуралних мрежа
Марија Новичић

Матрица конфузије за тестирајући скуп

Добијени излази	Пауза	28 13.1%	8 3.8%	1 0.5%	0 0.0%	4 1.9%	0 0.0%	0 0.0%	68.3% 31.7%
	Средина	4 1.9%	76 35.7%	0 0.0%	6 2.8%	5 2.3%	0 0.0%	0 0.0%	83.5% 16.5%
	Горе	1 0.5%	0 0.0%	18 8.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	94.7% 5.3%
	Доле	3 1.4%	2 0.9%	0 0.0%	15 7.0%	0 0.0%	0 0.0%	0 0.0%	75.0% 25.0%
	Лево	2 0.9%	0 0.0%	0 0.0%	0 0.0%	14 6.6%	0 0.0%	0 0.0%	87.5% 12.5%
	Десно	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 4.2%	0 0.0%	90.0% 10.0%
	Ротација	3 1.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	13 6.1%	81.3% 18.8%
		66.7% 33.3%	88.4% 11.6%	94.7% 5.3%	71.4% 28.6%	60.9% 39.1%	100% 0.0%	100% 0.0%	81.2% 18.8%
		Жељени излази							
		Пауза	Средина	Горе	Доле	Лево	Десно	Ротација	

Слика 6.2.8 Матрица конфузије након симулације мреже за класификацију положаја руке на скупу за тестирање

Успешност класификације приликом валидације неуралне мреже износи 85.4%, при чему су најуспешније класификовани одбирци из класе „Горе“. Током тестирања одбирци класе „Горе“ су такође најуспешније класификовани са процентом од 94.7%. Укупна успешност класификације током тестирања износи 81.2%. Одбирци класе „Пауза“ приликом валидације и тестирања имају најмањи проценат успешности (80.6% и 98.3%, респективно).

7. Дискусија и закључак

У претходном поглављу су приказани резултати мерења и класификације сигнала. Визуелним поређењем резултата претпроцесирања за све испитанике може се уочити поновљивост облика сигнала код свих испитаника приликом извршавања задатка. Најчешћи узрок одступања представља ротација длана, односно појава промене угаоне брзине по x оси када то није очекивано. Овај артефакт се може уочити на сигнаlima са жироскопа, док ова појава нема великог утицаја на сигнале са акцелерометра. Такође, на сигнаlima са жироскопа се може уочити разлика у амплитуди сигнала и у дужини трајања импулса. Ова појава не зависи само од испитаника, већ варира и код снимања различитих покушаја на једном испитанику. Узрок ових разноликости јесте брзина којом испитаник мења положај руке. Посматрајући сигнале са акцелерометра се може уочити недоследност у вредности сигнала током мировања руке.

Укупна успешност класификације покрета руке износи 92.5%, а тачност класификације положаја руке износи 84.57%. Издвајањем успешности одређених класа података, добијени резултати се могу поредити са резултатима добијеним у [7]. У овом раду је постигнута тачност од 92% за пронацију/супинацију подлактице и 96% за флексију/екстензију лакта. Пронацију/супинацију подлактице одговара класа „Ротација“ чији су одбирци успешно класификовани у 96.5% случајева. Флексију/екстензију лакта се могу придружити класе „Горе“ и „Доле“, са тачношћу класификације од 96.3% и 91.76 %, респективно. Резултат класификације пројектоване неуралне мреже се поклапа са резултатима добијеним у [7], при чему треба узети у обзир да су у овом раду за класификацију коришћена и мишићна активност подлактице. Класификација положаја руке је била успешна у 84.57% случајева. Разлог лошије класификације ове неуралне мреже може бити постојање покрета који припадају класи „Пауза“. Ова класа садржи делове сигнала који одговарају промени положаја руке, а не стању када рука мирује. У даљем унапређивању овог рада треба елиминисати ове делове сигнала током класификације положаја руке.

Боља класификације пројектованог система би се постигла стварањем веће базе података, односно укључивањем већег броја испитаника. Највише доприноса у даљој анализи има укључивање већег броја испитаника са ампутираном руком или шаком. Осим већег броја испитаника, за развијање бољег система је потребно у протокол укључити већи број положаја и покрета руке које испитаник треба да изврши.

Сам уређај за мерење поред инерцијалне мерне јединице садржи и ЕМГ сензоре за мерење електричне активности мишића. Једна од ставки за унапређење овог система је комбинација већ измерених сигнала са ЕМГ сигнаlima. Неурална мрежа употребљена у овом раду троши мало процесорског времена и није рачунски захтевна. Пројектован алгоритам је могуће имплементирати на микроконтролер који би могао бити уграђен у вештачку шаку. Такође, треба напоменути и да су испитаници мировали током извршавања задатка у овом протоколу. Уколико би ово био део система за управљање вештачком шаком потребно је одредити утицај ходања на сигнале са инерцијалних сензора.

Даљи рад на овој теми би био посвећен имплементацији неуралне мреже на микроконтролер и стварању аутономног система за управљање вештачком шаком.

Литература

- [1] Tehrani K. & Michael A. (2014) Wearable Technology and Wearable Devices: Everything You Need to Know. *Wearable Devices Magazine*, WearableDevices.com – последњи приступ септембар 2017.
- [2] Samadani, A. A., & Kulic, D. (2014). Hand gesture recognition based on surface electromyography. In: *Engineering in Medicine and Biology Society (EMBC), 2014 36th Annual International Conference of the IEEE* (pp. 4196-4199). Chicago, USA: IEEE.
- [3] Amma, C., Georgi, M., & Schultz, T. (2014). Airwriting: a wearable handwriting recognition system. *Personal and ubiquitous computing*, 18(1), 191-203.
- [4] Hartmann, B., & Link, N. (2010). Gesture recognition with inertial sensors and optimized DTW prototypes. In *Systems Man and Cybernetics (SMC), 2010 IEEE International Conference on* (pp. 2102-2109). Istanbul, Turkey: IEEE.
- [5] Kim, D., Hilliges, O., Izadi, S., Butler, A. D., Chen, J., Oikonomidis, I., & Olivier, P. (2012). Digits: freehand 3D interactions anywhere using a wrist-worn gloveless sensor. In *Proceedings of the 25th annual ACM symposium on User interface software and technology* (pp. 167-176). Cambridge, USA: ACM.
- [6] <https://www.youtube.com/watch?v=LSuzMxQDmzg>, последњи приступ септембар 2017.
- [7] <https://www.cnet.com/news/myo-armbands-used-to-control-prosthetic-arm/>, последњи приступ септембар 2017.
- [8] Guvenc, S. A., Demir, M., & Ulutas, M. (2014). Detection of forearm movements using wavelets and Adaptive Neuro-Fuzzy Inference System (ANFIS). In *Innovations in Intelligent Systems and Applications (INISTA) Proceedings, 2014 IEEE International Symposium on* (pp. 192-196). Alberobello, Italy: IEEE.
- [9] Momen, K., Krishnan, S., & Chau, T. (2007). Real-time classification of forearm electromyographic signals corresponding to user-selected intentional movements for multifunction prosthesis control. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 15(4), 535-542.
- [10] Blana, D., Kyriacou, T., Lambrecht, J. M., & Chadwick, E. K. (2016). Feasibility of using combined EMG and kinematic signals for prosthesis control: a simulation study using a virtual reality environment. *Journal of Electromyography and Kinesiology*, 29, 21-27.
- [11] Wang, N., Ambikairajah, E., Lovell, N. H., & Celler, B. G. (2007). Accelerometry based classification of walking patterns using time-frequency analysis. In *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE* (pp. 4899-4902). Lyon, France: IEEE.
- [12] Lin, C. T & Lee, C. S. G. (1996). *Neural fuzzy systems: A neuro-fuzzy synergism to intelligent systems*. Prentice Hall PTR.

- [13] <http://jamjacobs.blogspot.rs/2011/02/ai-in-designing-intelligent-ship.html>, последњи приступ септембар 2017.
- [14] Hao, Y. & Wilamowski M. B. (2001). *Levenberg–Marquardt training*. Industrial Electronics Handbook 5.12.
- [15] https://en.wikipedia.org/wiki/Inertial_measurement_unit, последњи приступ септембар 2017.
- [16] Ђурић-Јовичић, М. (2012). *Методe анализе сигнала са инерцијалних сензора за анализу хода пацијента са оштећеним обрасцем хода*. Докторски рад. Београд: Електротехнички факултет
- [17] <http://majalah1000guru.net/2015/07/laser-menuntunku-ke-bulan/>, последњи приступ септембар 2017.
- [18] <http://blog.denivip.ru/index.php/2013/07/the-art-of-core-motion-in-ios/?lang=en>, последњи приступ септембар 2017.
- [19] Ауторизоване белешке са предавање доц. др Надице Миљковић на предмету Клиничко инжењерство (13E042КЛИ) Универзитет у Београду – Електротехнички факултет, 2016/2017 године.
- [20] <https://www.automatika.rs/baza-znanja/senzori/akcelerometri.html>, последњи приступ септембар 2017.
- [21] <http://insights.globalspec.com/article/1263/specifying-an-accelerometer-function-and-applications>, последњи приступ септембар 2017.
- [22] <http://time.com/4173507/myo-armband-review/>, последњи приступ септембар 2017.
- [23] <https://www.myo.com/start>, последњи приступ септембар 2017.
- [24] <https://github.com/NiklasRosenstein/myo-python>, последњи приступ септембар 2017.
- [25] Preece, S. J., Goulermas, J. Y., Kenney, L. P., & Howard, D. (2009). A comparison of feature extraction methods for the classification of dynamic activities from accelerometer data. *IEEE Transactions on Biomedical Engineering*, 56(3), 871-879.

Списак слика

Слика 1.1 Систем за управљање вештачком руком помоћу сигнала добијених са две Муо наруквице. Слика преузета са [7].	1
Слика 1.2 Пројектован систем током студије [10]. Приказана је поставка сензора током две фазе обучавања неуралне мреже	2
Слика 2.1.1 Математички модел биолошког неурона	4
Слика 2.1.2 Облици активационих функција: степ функција (а), „ <i>Hard limiter</i> “ (б), функција рампе (в), униполарна сигмоидална функција (г) и биполарна сигмоидална функција (д). Слика је преузета и измењена са [12]	5
Слика 2.1.3 Пример вишеслојне feedforward неуралне мреже. Слика је преузета и измењена са [13]	5
Слика 3.1.1 Ротациони жирокоп, слика преузета и измењена са [17]	9
Слика 3.1.2 Ротирајући дискови са дефинисаним угловима пропињања, ваљања и скретања, слика преузета и измењена са [18]	10
Слика 3.2.1 Пример 2-осног (лево) и 3-осног (десно) акцелерометра за мерење нагиба, слика је преузета и измењена са [21]	11
Слика 4.1.1 Муоarmband постављена на подлактицу десне руке (слика преузета са [22])	12
Слика 4.3.1 Положаји руке током извршавања задатка. Приказан је референтни положај (лево), као и кретање у сагиталној равни (у средини и десно)	13
Слика 4.3.2 Положаји руке током извршавања задатка. Приказано је кретање у трансверзалној равни (лево и у средини), као и ротација длана (десно)	14
Слика 4.4.1 Временски облик сигнала измереног 3-осним акцелерометром (горе) и исти сигнал након филтрирања (доле)	15
Слика 4.4.2 Временски облик сигнала измереног 3-осним жирокопом (горе) и исти сигнал након филтрирања, нормализације и квадрирања (доле)	15
Слика 5.2.1 Шема вештачке неуралне мреже за класификацију правца и смера кретања руке, у првом скривеном слоју има шест, а у другом девет неурона	16
Слика 5.2.2 Шема вештачке неуралне мреже за класификацију правца и смера кретања руке, у првом скривеном слоју има шест, а у другом десет неурона	17
Слика 6.1.1 Временски облици сигнала измерених на испитанику ID1 током првог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде	18
Слика 6.1.2 Временски облици сигнала измерених на испитанику ID1 током другог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде	18
Слика 6.1.3 Временски облици сигнала измерених на испитанику ID1 током трећег покушаја. На графицима су приказане све три осе акцелерометра (горе) и жирокопа (доле) након обраде	19

Слика 6.1.4 Временски облици сигнала измерених на испитанику ID2 током првог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жirosкопа (доле) након обраде.	19
Слика 6.1.5 Временски облици сигнала измерених на испитанику ID2 током другог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жirosкопа (доле) након обраде.	20
Слика 6.1.6 Временски облици сигнала измерених на испитанику ID2 током трећег покушаја. На графицима су приказане све три осе акцелерометра (горе) и жirosкопа (доле) након обраде.	20
Слика 6.1.7 Временски облици сигнала измерених на испитанику ID3 током првог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жirosкопа (доле) након обраде.	21
Слика 6.1.8 Временски облици сигнала измерених на испитанику ID3 током другог покушаја. На графицима су приказане све три осе акцелерометра (горе) и жirosкопа (доле) након обраде.	21
Слика 6.1.9 Временски облици сигнала измерених на испитанику ID3 током трећег покушаја. На графицима су приказане све три осе акцелерометра (горе) и жirosкопа (доле) након обраде.	22
Слика 6.2.1 График перформансе неуралне мреже за класификацију покрета руке.	23
Слика 6.2.2 Матрица конфузије након тренирања мреже за класификацију покрета руке на скупу за обучавање.	23
Слика 6.2.3 Матрица конфузије након симулације мреже за класификацију покрета руке на скупу за валидацију.	24
Слика 6.2.4 Матрица конфузије након симулације мреже за класификацију покрета руке на скупу за тренирање.	24
Слика 6.2.5 График перформансе неуралне мреже за класификацију положаја руке.	25
Слика 6.2.6 Матрица конфузије након тренирања мреже за класификацију положаја руке на скупу за обучавање.	26
Слика 6.2.7 Матрица конфузије након симулације мреже за класификацију положаја руке на скупу за валидацију.	26
Слика 6.2.8 Матрица конфузије након симулације мреже за класификацију положаја руке на скупу за тестирање.	27

Списак табела

Табела 4.2.1 Основне информације о испитаницима који су учествовали у студији	12
Табела 6.2.1 Перформасне неуралне мреже приликом понављања поступка тренирања, валидације и тестирања 10 пута	22
Табела 6.2.2 Перформасне неуралне мреже приликом понављања поступка тренирања, валидације и тестирања 10 пута	25