

UNIVERZA V MARIBORU

FAKULTETA ZA ELEKTROTEHNIKO,
RAČUNALNIŠTVO IN INFORMATIKO

DOKTORSKA DISERTACIJA

**Uporaba vseprisotnega računalništva za
kvalitativno vrednotenje vzorcev rekreativne
fizične aktivnosti**

September 2013

Igor Pernek



Univerza v Mariboru

Fakulteta za elektrotehniko,
računalništvo in informatiko

DOKTORSKA DISERTACIJA

**Uporaba vseprisotnega računalništva za
kvalitativno vrednotenje vzorcev rekreativne
fizične aktivnosti**

September 2013

AVTOR Igor Pernek
MENTOR red. prof. dr. Peter Kokol

Avtor:	Igor Pernek, univ. dipl. inž. rač. in inf.
Mentor:	red. prof. dr. Peter Kokol
Lektor:	Nina Skube, prof. slov.
Naslov:	Uporaba vseprisotnega računalništva za kvalitativno vrednotenje vzorcev rekreativne fizične aktivnosti
UDK:	004.655.3:004.855(043.3)
Ključne besede:	vseprisotno računalništvo, prepoznavanje aktivnosti, strojno učenje, vrednotenje kvalitet
Število izvodov:	9

Maribor, 19. 6. 2013
Številka: DR 49/2013/428-DM

Na osnovi 287., 140., 142. in 144. člena Statuta Univerze v Mariboru (Statut UM-UPB10, Ur. l. RS, št. 46/2012) ter sklepa 22. redne seje Senata Univerze v Mariboru, ki je potekala 18. 6. 2013 v zvezi z vlogo doktorskega kandidata Igorja Perneka za sprejem odločitve o predlagani temi doktorske disertacije in mentorja

izdajam naslednji

SKLEP

Odobri se tema doktorske disertacije Igorja Perneka s Fakultete za elektrotehniko, računalništvo in informatiko z naslovom »Uporaba vseprisotnega računalništva za kvalitativno vrednotenje vzorcev rekreativne fizične aktivnosti«. Za mentorja se imenuje red. prof. dr. Peter Kokol. Kandidat mora članici predložiti izdelano doktorsko disertacijo v zadostnih izvodih najpozneje do 17. 6. 2017.

Obrazložitev:

Kandidat Igor Pernek je 23. 10. 2012 na Fakulteti za elektrotehniko, računalništvo in informatiko vložil vlogo za potrditev teme doktorske disertacije z naslovom »Uporaba vseprisotnega računalništva za kvalitativno vrednotenje vzorcev rekreativne fizične aktivnosti«. Za mentorja je bil predlagan red. prof. dr. Peter Kokol.

Senat Fakultete za elektrotehniko, računalništvo in informatiko je na osnovi pozitivnega mnenja komisije za oceno teme doktorske disertacije, ki je ugotovila, da kandidat izpolnjuje pogoje za pridobitev doktorata znanosti, in ocenila, da je predlagana tema ustrezna, sprejel pozitivno mnenje in poslal predlog teme doktorske disertacije s predlogom mentorja v odobritev Senatu univerze.

Senat Univerze v Mariboru je po proučitvi vloge in na osnovi določil Statuta Univerze v Mariboru sprejel svojo odločitev o predlagani temi doktorske disertacije in imenoval mentorja, kot izhaja iz izreka.

V skladu s 144. členom Statuta Univerze v Mariboru mora kandidat za pridobitev doktorata znanosti najpozneje v štirih letih od dneva izdaje tega sklepa, članici predložiti izdelano doktorsko disertacijo v zadostnih izvodih. Kandidatu je bil določen rok za oddajo izdelane doktorske disertacije glede na datum sprejetja teme na pristojnjem organu.

Pouk o pravnem sredstvu:

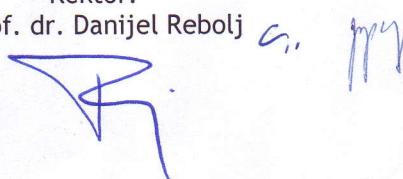
Zoper ta sklep je možna pritožba na Senat Univerze v Mariboru v roku 8 dni od prejema tega sklepa.

Obvestiti:

1. Kandidata.
2. Fakulteto.
3. Arhiv.



Rektor:
Prof. dr. Danijel Rebolj



Most important, ubiquitous computers will help overcome the problem of information overload. There is more information available at our fingertips during a walk in the woods than in any computer system, yet people find a walk among trees relaxing and computers frustrating. Machines that fit the human environment instead of forcing humans to enter theirs will make using a computer as refreshing as taking a walk in the woods.

— *Mark Weiser, The Computer for the 21st Century*

Zahvala

Staršema, ker sta me naučila, da je vredno vztrajati.

Sestri, prijateljem in prostovoljcem, ki so sodelovali v včasih fizično izredno napornih eksperimentih.

Mentorju prof. dr. Petru Kokolu za podporo med podiplomskim študijem. Dr. Karin Anni Hummel za nasvete med in po raziskovalnem obisku na Univerzi na Dunaju. Prof. dr. Ruzeni Bajcsy in dr. Gregoriju Kurillu za gostoljubje in plodne razprave v času raziskovanja na Univerzi v Kaliforniji - Berkeley.

Gregorju in Simonu za dobro delovno vzdušje v pisarni.

Javni agenciji za raziskave in razvoj Republike Slovenije za financiranje doktorskega študijsa.

Posebna zahvala Simoni, ker je vztrajno manjšala geografsko razdaljo, ki jo je med nazu vrivala moja odsotnost.

Naslov: Uporaba vseprisotnega računalništva za kvalitativno vrednotenje vzorcev rekreativne fizične aktivnosti

Ključne besede: vseprisotno računalništvo, prepoznavanje aktivnosti, strojno učenje, vrednotenje kvalitete

Povzetek

Vseprisotno računalništvo je v preteklosti postalo popularno tudi v zdravstvu, predvsem na področju podpore rekreativnih fizičnih aktivnosti. Pri tem se je večina preteklih raziskav osredotočala na uporabo vseprisotnih senzorjev in naprav za prepoznavanje tipa ter količine izvedenih aktivnostih, manj pozornosti pa je bilo posvečeno zaznavanju kvalitativnih parametrov vadbe, kot sta pravilnost in intenzivnost vadbe. V doktorskem delu izvedemo analize in predlagamo algoritme za vrednotenje intenzivnosti in pravilnosti različnih tipov rekreativne fizične aktivnosti v realnem času na zmogljivostno omejenih vseprisotnih napravah. Predlagamo algoritem, ki z 99 % natančnostjo prepozna število ponovitev treninga moči in zaznava njihove mejne točke z napako 215 ms oz. 11 % dolžine posamezne ponovitev. Izvedemo analizo uporabnosti različnih značilk pospeška in metod numeričnega napovedovanja za ocenjevanje intenzivnosti aerobnih aktivnosti. Ugotovimo, da enostavne metode, kot je linearna regresija, z majhnim število natančno izbranih značilk omogočajo napovedovanje srčnega utripa vadbe z napako približno 15 utripov na minuto. Na koncu predlagamo še hierarhični algoritem, ki s podatki, pridobljenimi iz petih nosljivih pospeškometrov, omogoča prepoznavanje intenzivnosti treninga moči. Prepoznavanje intenzivnosti poteka v dveh fazah, pri čemer je v prvi fazi prepoznan tip aktivnosti, v drugi pa je zaznana intenzivnost z ozirom na prepoznano aktivnost. Predlagani algoritem dosega 86 % natančnost prepoznavanja tipa aktivnosti in 6 % napako zaznavanja intenzivnosti. Dodatno analiza različnih konfiguracij senzorjev pokaže, da uporaba podmnožice senzorjev dosega rezultate primerljive natančnosti.

Title: Recognizing quality parameters of physical activities based on ubiquitous computing

Keywords: ubiquitous computing, activity recognition, machine learning, quality evaluation

Abstract

During the last years ubiquitous computing has become an interesting research topic in healthcare, particularly in the area of physical activity support. Most of the past research focused on recognizing different activites and their duration, not taking into account qualitative activity parameters, such as activity intensity and execution correctness. This thesis describes algorithms for real-time recognizion of correctness and intensity for different types of physical activities using ubiquitous sensors. An algorithm is proposed being able to correctly recognize 99 % of strength training repetitions with an average temporal recognition error of 215 ms or 11 % of individual repetition duration. Further, different types of statistical features and supervised machine learning methods are evaluated for predicting the intensity of common aerobic activities. The results show that simple methods, such as linear regression, with a small set of carefully selected features, can be used to predict the intensity of aerobic activities with an average error of 15 heart beats per second. Finally, a hierarchical algorithm is proposed to recognize the intensity of strength training activities using a set of wearable sensors. The algorithm recognizes the type of the activity performed and its intensity in two successive steps. The accuracy of the algorithm is 86 % for recognizing the exercise types with a 6 % error in intensity recognition. Additionally, an in-depth analysis of different sensor configurations is performed, showing that using only a subset of sensors achieves promising results.

Kazalo

Kazalo	xi
Kazalo slik	xiv
Kazalo tabel	xv
Simboli in kratice	xviii
1 Uvod	1
1.1 Vseprisotno računalništvo v preventivnem zdravstvu	1
1.2 Delitev fizičnih aktivnosti	3
1.3 Senzorji za merjenje fizične aktivnosti	4
1.4 Kvalitativni parametri športnih aktivnosti	6
1.5 Cilji naloge	9
1.6 Izvirni znanstveni prispevki naloge	10
1.7 Pregled poglavij	10
2 Povezane raziskave	12
2.1 Vseprisotno računalništvo za podporo športa	12
2.1.1 Rekreativni šport	13
2.1.2 Elitni šport	19
2.2 Prepoznavanje fizičnih aktivnosti	22
3 Uporabljene metode in algoritmi	30
3.1 Zaznavanje vrhov v časovnih signalih	30
3.2 Dinamično časovno poravnavanje	32

KAZALO

3.3	Metode strojnega učenja	34
3.3.1	Linearna regresija	36
3.3.2	Logistična regresija	37
3.3.3	Večnivojski perceptron	38
3.3.4	Regresijsko drevo	39
3.3.5	Metoda podpornih vektorjev	41
4	Zaznavanje treninga moči s standardnimi mobilnimi napravami	43
4.1	Motivacija	43
4.2	Mobilni asistent za podporo treninga moči	45
4.2.1	Platforma	45
4.2.2	Vadbena okolja	47
4.2.3	Vaje in mišične skupine	49
4.3	Algoritem za detekcijo ponovitev	51
4.3.1	Predobdelava	54
4.3.2	Izbira kandidatov	55
4.3.3	Vrednotenje podobnosti	56
4.3.4	Klasifikacija	59
4.4	Zbiranje podatkov	60
5	Strojno učenje za vrednotenje intenzivnosti aerobnih aktivnosti	62
5.1	Motivacija	62
5.2	Mobilni pomočnik za zajemanje podatkov	64
5.3	Analiza podatkov	64
5.3.1	Predobdelava	64
5.3.2	Računanje značilk	65
5.3.3	Izbira značilk	66
5.3.4	Modeli za numerično napovedovanje	67
5.4	Zbiranje podatkov	68
6	Prepoznavanje intenzivnosti anaerobnih aktivnosti z nosljivimi senzorji	70
6.1	Motivacija	70
6.2	Nosljiva platforma za podporo treninga moči	72

KAZALO

6.2.1	Senzorji	72
6.2.2	Nabor vaj	73
6.3	Algoritem vrednotenja intenzivnosti	76
6.3.1	Predobdelava	77
6.3.2	Priprava značilk	77
6.3.3	Prepoznavanje aktivnosti in intenzivnosti	78
6.4	Zbiranje podatkov	80
7	Rezultati	83
7.1	Metrike ocenjevanja algoritmov	83
7.2	Vzorec	86
7.3	Vrednotenje pravilnosti anaerobnih aktivnosti	87
7.3.1	Zaznavanje števila ponovitev	87
7.3.2	Natančnost zaznavanja ponovitev	89
7.4	Vrednotenje intenzivnosti aerobnih aktivnosti	91
7.4.1	Natančnost različnih konfiguracij značilk	91
7.4.2	Natančnost za različne napovedne modele	91
7.5	Vrednotenje intenzivnosti anaerobnih aktivnosti z nosljivimi senzorji	93
7.5.1	Izbira parametrov drsečega okna	94
7.5.2	Uspešnost algoritma	97
7.5.3	Izbira konfiguracije senzorjev	99
7.5.4	Vpliv količine učnih podatkov	101
8	Diskusija	103
9	Zaključek	107
A	Soglasje za sodelovanje v raziskavi	109
B	Življjenjepis	111
C	Osebna bibliografija	112
Viri		116

Kazalo slik

3.1	Primer EKG-signala	31
3.2	Vizualizacija strukture nevronske mreže	39
3.3	Struktura odločitvenega drevesa	40
3.4	Primer SVM z uporabo jedra	41
4.1	Zaslonske maske mobilne aplikacije	47
4.2	Lokacije namestitve pametnega telefona	48
4.3	Pregled korakov algoritma zaznavanja ponovitev	53
4.4	DTW-preslikava med predlogo C in tokom pospeška R	58
5.1	Položaj namestitve pametnega telefona med izvajanjem meritev.	69
6.1	Položaj namestitve nosljivih senzorjev pospeška med vadbo.	73
6.2	Vizualizacija izvedenih vaj.	75
6.3	Diagram poteka algoritma za vrednotenja intenzivnosti	79
6.4	Senzor za merjenje pospeška SHIMMER.	81
7.1	Napaka prepoznavanja začetka in konca ponovitev	90
7.2	Korelacijski koeficient za različne modele in števila značilk	92
7.3	RMSE za različne modele in števila značilk	93
7.4	Natančnost prepoznavanja posameznih vaj	98
7.5	Napaka zaznavanja intenzivnosti za posamezne vaje	99
7.6	Uporabljene konfiguracije senzorjev	100
7.7	Natančnost prepoznavanja vaj za različne količine učnih podatkov	101
7.8	Napaka zaznavanja intenzivnosti za različne količine učnih podatkov	102

Kazalo tabel

1.1	Stopnje Borgove lestvice intenzivnosti	8
1.2	Cone srčnega utripa	8
2.1	Najpogosteje uporabljeni senzorji za zaznavanje aktivnosti	13
2.2	Najpogosteje prepoznавani tipi fizičnih aktivnosti	23
2.3	Uporabljene dolžine drsečega okna	23
2.4	Uporabljene metode strojnega učenja	24
2.5	Uporabljene značilke	28
3.1	Metode strojnega učenja in uporabljeni vrsti napovednega modela.	36
4.1	Seznam vaj v omejenem in prostem okolju	50
4.2	Povzetek notacije algoritma detekcije ponovitev	51
4.3	Izvor različnosti vzorcev ponovitev	52
6.1	Seznam izbranih vaj za trening moči zgornjega dela telesa.	74
6.2	Opis pomembnih atributov udeležencev raziskave.	80
7.1	Notacija rezultatov napovedi binarnega klasifikacija problema . .	84
7.2	Rezultati prepoznavanja ponovitev	88
7.3	Rezultati napovedovanja intenzivnosti aerobnih aktivnosti	92
7.4	Natančnost prepoznavanja tipa vaj za različne konfiguracije oken .	96
7.5	Napaka zaznavanja intenzivnosti vaj za različne konfiguracije oken	96
7.6	Uspešnost algoritma za poln nabor senzorjev	97
7.7	Uspešnost algoritma za različne senzorje	100

Simboli in kratice

Simboli

a_k Vhodni atribut linearne regresije

C Matrika cen $c(X, Y)$ za vsa podzaporedja X in Y

$c_P(X, Y)$ Skupna cena prileganja med zaporedjema X in Y

$c(X, Y)$ Cena razlike zaporedij X in Y

D Zbiralna matrika cen

M Dolžina časovnega zaporedja Y

N Dolžina časovnega zaporedja X

P Zaporedje, ki določa pot poravnave med časovnima zaporedjema X in Y

w_k Uteži linearne regresije

X Vzorčno časovno zaporedje

x Izhodni atribut linearne regresije

Y Vzorčno časovno zaporedje

Kratice

BAN Lokalna telesna omrežja (ang: *Body Area Networks*)

BD Vaja bočni navpični dvig

KAZALO TABEL

BLI	Borgova lestvica intenzivnosti
CC	Korelacijski koeficient
CLOF	Faktor lokalnih razrednih osamelcev (ang.: <i>Class Local Outlier Factor</i>)
DD	Metoda direktne gostote (ang.: <i>Direct Density</i>)
DTW	Dinamično časovno poravnavanje (ang.: <i>Dynamic Time Warping</i>)
EKG	Elektrokardiogram
EM	Metoda optimizacije pričakovanja (ang.: <i>Expectation Maximization</i>)
EZ	Enosenzorske značilke
FFT	Hitra Fourierjeva transformacija (ang.: <i>Fast Fourier Transform</i>)
FN	Nepravilna manjkajoča napoved (ang.: <i>False Negative</i>)
FP	Nepravilna napoved (ang.: <i>False Positive</i>)
HMM	Skrit model Markova (ang.: <i>Hidden Markov Model</i>)
IR	Vaja izteg roke nad glavo
KM	K-means gručenje
kNN	Metoda k-najbližjih sosedov (ang.: <i>k-Nearest Neighbour</i>)
LCF	Lokalni klasifikacijski faktor (ang.: <i>Local Classification Factor</i>)
LDA	Linearna diskriminantna analiza (ang.: <i>Linear Discriminant Analysis</i>)
LR	Linearna regresija
MDC	Klasifikator najkrajših razdalj (ang.: <i>Mimimum-Distance Classifier</i>)
NBLI	Normalizirana Borgova lestvica intenzivnosti
NB	Naivni bayes (ang.: <i>Naïve bayes</i>)

KAZALO TABEL

NCCF	Normalizirana navzkrižna korelacija (ang.: <i>Normalized Cross Correlation Function</i>)
PCA	Metoda glavnih komponent (ang.: <i>Principal Component Analysis</i>)
PG	Vaja potisk nad glavo
RD	Regresijska drevesa
1RM	Mejna teža dviga (ang.: <i>One Repetition Maximum</i>)
RMSE	Koren povprečne vrednosti kvadrirane napake (ang.: <i>Root Mean Squared Error</i>)
RMS	Koren kvadriranega povprečja (ang.: <i>Root Mean Square</i>)
SD	Vaja sprednjji navpični dvig
SG	Savitzky-Golay filter
SVM	Metoda podpornih vektorjev (ang.: <i>Support Vector Machine</i>)
TN	Pravilna manjkajoča napoved (ang.: <i>True Negative</i>)
TP	Pravilna napoved (ang.: <i>True Positive</i>)
UR	Vaja ukrivljenje rok
UV	Vaja upognjeno veslanje
VP	Večnivojski perceptron
ZZ	Združene značilke

Poglavlje 1

Uvod

V tem poglavju predstavimo motivacijo za uporabo vseprisotnih naprav za vrednotenje kvalitativnih parametrov vzorcev fizične aktivnosti. Najprej opišemo vlogo vseprisotnega računalništva v zdravstvu. Pri tem se osredotočimo predvsem na področje preventivne rekreacije. Nato predstavimo parametre in tipe fizične aktivnosti ter opišemo senzorje, ki omogočajo njihovo zaznavanje. Na koncu poglavja orišemo izvirne znanstvene prispevke in na kratko povzamemo strukturo poglavij naloge.

1.1 Vseprisotno računalništvo v preventivnem zdravstvu

Pred več kot dvema desetletjema je Mark Weiser v znamenitem eseju "*The Computer for the 21st Century*" [1] predstavil svojo vizijo računalništva prihodnosti. Vseprisotno računalništvo, kot ga je poimenoval, je opisal kot paradigma popolne spojitve računalnikov z okoljem, obdobje, ko bodo računalniki neviden del vsakdana in bodo uporabnikom nevpadljivo v podporo pri najrazličnejših aktivnostih. Dandanes je aplikacije vseprisotnega računalništva mogoče opaziti na mnogih področjih. Pametne omare nam priporočajo oblačila, primerna trenutnemu vremenu [2], mobilni vodiči nam kažejo najkrajšo pot med krajevema [3], sistemi za podporo vzdrževalnih del pa znajo prepoznati opravilo, kot je privijanje vijaka, in v realnem času prikazati navodila za njegovo izvedbo [4].

Vseprisotno računalništvo pa postaja vse pomembnejše tudi v zdravstvu. Demografske spremembe dvajsetega stoletja, ki so posledica daljše življenjske dobe zaradi tehnološkega razvoja, so fokus zdravstva premaknile iz tradicionalnega jedra, temelječega zgolj na podajanju diagnoz in izvajanju intervencij znotraj bolnišničnih in kliničnih okolij, proti preprečevanju in zdravljenju najrazličnejši bolezni v vsakdanjih okoljih. Tako se vseprisotno računalništvo v zdravstvu uporablja za [5]:

1. *vzpodbujanje zdravega načina življenja skozi fizično aktivnost,*
2. *upravljanje in preprečevanje tveganj nastanka bolezni,*
3. *upravljanje kroničnih bolezni,*
4. *upravljanje in hitro zdravljenje akutnih bolezni ter*
5. *omogočanje samostojnega življenja.*

V doktorski disertaciji se osredotočimo na področje preventivnega zdravstva, konkretno na področje preventivne rekreacije, ki temelji na uporabi vseprisotnih naprav za *spodbujanje zdravega načina življenja skozi fizično aktivnosti* in *upravljanje ter preprečevanje tveganj nastanka bolezni*. Študije kažejo, da je redna fizična aktivnost eden izmed najpomembnejših faktorjev za zdravo in kvalitetno življenje. Znižuje namreč tveganje obolenja za kroničnimi boleznimi, kot so srčno-zilne bolezni, sladkorna bolezen, rak, povišan pritisk, debelost, depresija in osteoporoza [6, 7, 8, 9, 10], ter je lahko v določenih primerih celo učinkovitejša od klasičnega zdravljenja [11, 12].

Vseprisotne naprave za podporo preventivne rekreacije se najpogosteje uporabljajo za izboljšanje, nadzor, dokumentiranje in analizo fizičnih aktivnosti [5]. Slednje obsega zaznavanje trajanja, tipa in kvalitativnih parametrov vadbe. Zaznavanje trajanja fizičnih aktivnosti omogoča enostavno spremljanje količine vadbe, kar pomembno vpliva na motivacijo za vadbo [13, 14], prepoznavanje tipa fizičnih aktivnosti omogoča samodejno ustvarjanje uravnoveženega programa vadbe, spremljanje kvalitativnih parametrov vadbe pa nudi potencial za prepoznavanje pravilnosti vadbe, kar pomembno vpliva na učinkovitost vadbe in niža tveganje nastanka poškodb [15].

V doktorskem delu se osredotočimo na razvoj metod in algoritmov za zaznavanje in kvantitativno vrednotenje kvalitativnih parametrov rekreativne fizične aktivnosti. V nadaljevanju predstavimo podprte tipe fizične aktivnosti, uporabljene senzorje in natančneje definiramo kvalitativne parametre, ki jih naslavljamo.

1.2 Delitev fizičnih aktivnosti

Fizična aktivnost je definirana kot kakršnokoli telesno gibanje, ki izdatno poveča porabo energije in je rezultat krčenja mišic [15]. Fizično aktivnost je mogoče kategorizirati na različne načine. Tip fizične aktivnosti pogosto definira najpogostejša aktivnost, značilna za del dneva, v katerem se aktivnost dogaja. Tako je v grobem fizično aktivnost mogoče deliti na naslednje kategorije [16]:

- spalno,
- službeno in
- prostočasno.

Omenjene kategorije vplivajo na zdravje posameznika in se odražajo celo z vplivom na javno zdravstvo [16]. V doktorskem delu se osredotočamo na specifično kategorijo prostočasnih fizičnih aktivnosti, konkretno, na aktivnosti rekreativnega športa. Za njih je značilno, da se načrtovane, strukturirane in ponavljajoče ter se izvajajo s ciljem izboljšanja fizične zmogljivosti. Slednje je mogoče tako z izboljšanjem parametrov telesne spretnosti kot z izboljšanja parametrov telesnega zdravja. V doktorskem delu se osredotočamo zgolj na parametre telesnega zdravja, ki se dalje delijo na [15]:

- srčno-žilno vzdržljivost,
- skeletno-mišično vzdržljivost,
- skeletno-mišično moč,
- sestavo telesa in

-
- fleksibilnost.

Omejimo se z golj na aktivnosti, ki omogočajo izboljšanje srčno-žilnih in skeletno-mišičnih parametrov, saj ti najpomembnejše vplivajo na dejavnike javnega zdravja [16]. Primera takšnih aktivnosti predstavlja aerobna in anaerobna vadba, ki se med seboj razlikujeta glede na prevladujoči tip metabolizma, aktiviranega med aktivnostjo, in glede na različen vpliv na parametre telesnega zdravja [17]. Pogost tip aerobnih aktivnosti predstavlja ponavljajoče se ritmične aktivnosti, kot so hoja, kolesarjenje in plavanje, medtem ko so najpogosteji primerki anaerobne vadbe visokointenzivne intervalne aktivnosti in trening moči [17].

Aktivnosti, ki omogočajo izboljšanje parametrov telesnega zdravja, je mogoče vrednotiti na različne načine z meritvami različnih natančnosti. Najvišjo natančnost dosegajo laboratorijski testi, ki jih je mogoče izvajati le v okoljih s specializirano opremo, medtem ko je natančnost testov, ki so dostopni širši populaciji, bistveno nižja, saj ti navadno temeljijo na samooceni [16], za katero velja, da je nezanesljiva, časovno intenzivna in moteča [18].

V doktorskem delu želimo preveriti, ali je mogoče objektivno vrednotenje aktivnosti, ki vplivajo na izboljšanje srčno-žilnih in skeletno-mišičnih parametrov telesnega zdravja, in sicer na način, ki je dostopen širši populaciji. V ta namen se opremo na uporabo vseprisotnih senzorjev in naprav, ki jih natančneje predstavimo v naslednjem poglavju.

1.3 Senzorji za merjenje fizične aktivnosti

Zajemanje in merjenje podatkov o fizičnih aktivnostih je mogoče s pomočjo različnih vrst senzorjev. Ti se med seboj razlikujejo predvsem glede na položaj namestitve senzorja med fizično aktivnostjo in glede na način zajemanja aktivnosti ter se v grobem delijo na [19]:

- senzorje za zajemanje položaja,
- fiziološke senzorje,
- senzorje za nadzor opreme in

-
- senzorje za zajemanje gibanja.

Senzorji za zajemanje položaja se najpogosteje uporabljajo za zaznavanje razdalje aktivnosti, pretežno sestavljenih iz premikov po enostavnih trajektorijah. Primer takšnih aktivnosti predstavljajo tek, kolesarjenje, hoja, veslanje ipd. Na osnovi informacij o spremembni položaja v času omogočajo zaznavanje hitrosti, ki nudi pomembne informacije o intenzivnosti aktivnosti. Tako je npr. za aktivnosti, ki so bile izvedene na enaki razdalji z različnimi hitrostmi, mogoče reči, da so bile tiste, ki so bile izvedene z višjo hitrostjo, izvedene z višjo stopnjo intenzivnosti. Zaznavanje položaja se najpogosteje izvaja s pomočjo sistemov GPS ali diferenčnih GPS, pri čemer so drugi natančnejši. Slabost omenjenih sistemov je, da omogočajo zaznavanje položaja zgolj na prostem, medtem ko so neuporabni v zaprtih prostorih. Zaznavanje položaja v zaprtih prostorih je mogoče s pomočjo aktivnih in pasivnih radijskih oddajnikov. Slabost sistemov radijskih oddajnikov je, da navadno zahtevajo temeljiti poseg v opazovano okolje, saj zahtevajo namestitev oddajnikov v okolje. Senzorji za zajemanje položaja so tako bodisi nameščeni na opazovanem subjektu bodisi del opazovanega okolja. V doktorskem delu se ne osredotočamo na zaznavanje intenzivnosti s pomočjo senzorjev za zajemanje položaja, saj je bila njihova uporaba že dobro raziskana v preteklosti [20, 21].

Fiziološki senzorji omogočajo zaznavanje vitalnih znakov, kot so srčni utrip, potenje, dihanje in telesna temperatura [22, 23]. V nasprotju s senzorji za zajemanje položaja so fiziološki senzorji navadno nameščeni neposredno na telo uporabnika. Z uporabo energijsko varčnih protokolov kratkega dometa, kot so Bluetooth, WiMedia in Zigbee [22], se povezujejo v lokalna telesna omrežja (ang.: *Body Area Networks*, BAN) [24], ki ob zaznavanju podatkov velikokrat že podpirajo osnovne operacije obdelave in analize podatkov ter omogočajo njihov prenos na oddaljene lokacije. V doktorskem delu uporabljam fiziološke senzorje zgolj kot referenčne senzorje za preverjanje natančnosti predlaganih algoritmov.

Senzorji za nadzor opreme omogočajo neprestan in nemoteč nadzor nad parametri športnih pripomočkov. Njihova uporaba je zelo pogosta pri razvoju športnih pripomočkov, saj omogočajo tako testiranje športnih pripomočkov v realnih okoljih kot tudi nadzorovano in ponovljivo mehanično simulacijo uporabe športnih pripomočkov [19]. Navadno so nameščeni na uporabljanem pripomočku oz. predstavl-

jajo neločljiv del njega. V doktorskem delu nas zanimajo predvsem aktivnosti rekreativnega športa, zato se na senzorje za nadzor opreme ne osredotočamo.

Senzorji za zajemanje gibanja so primerni za zaznavanje aktivnosti, ki jih, zaradi omejenosti na okolja na prostem in visoke cene instrumentacije okolja, ni mogoče zaznati s senzorji za zajemanje položaja. Zaznavanje gibanja najpogosteje poteka s pomočjo inercijskih in tekstilnih senzorjev (glej pregled v Poglavlju 2.1). Ti so bodisi lahko del opazovanega okolja bodisi nosljivi na uporabniku. V doktorskem delu se osredotočimo zgolj na inercijske senzorje, saj ti zaradi kompaktnosti in nizke cene izdelave postajajo vse popularnejši. Prav tako so v preteklosti že bili uporabljeni za prepoznavanje različnih tipov fizičnih aktivnosti [25] in napovedovanje orientacije delov telesa [26]. Njihova poglavita slabost je, da posamezni senzorji ne omogočajo samostojnega zaznavanja orientacije in gibanja v prostoru. Slednje je mogoče zgolj z združevanjem podatkov različnih tipov senzorjev, najpogosteje pospeškometrov, žiroskopov, magnetometrov in temperaturnih senzorjev [27]. V okviru doktorskega dela se osredotočimo zgolj na pospeškometre, saj so za razliko od ostalih senzorjev ti resnično vseprisotni. Vgrajeni so namreč v večini standardnih pametnih telefonov, ki postajajo popularna platforma za podporo najrazličnejših aktivnosti [28]. Omejitev na senzorje pospeška zahteva razvoj specifičnih algoritmov, ki omogočajo napovedovanje kvalitativnih parametrov fizične aktivnosti (opisanih v naslednjem poglavju) na osnovi nepopolnih informacij.

Eksperimente, predstavljene v doktorskem delu, izvedemo s pomočjo dveh tipov pospeškometrov:

- pospeškometrov, vgrajenih v standardne pametne telefone, in
- samostojnih pospeškometrov, specializiranih za zaznavanje gibanja.

1.4 Kvalitativni parametri športnih aktivnosti

Za doseganje optimalnih učinkov rekreativne vadbe je ob zadostnem trajanju aktivnosti pomembno tudi, da so aktivnosti izvedene pravilno in s primerno stopnjo intenzivnosti.

Pravilnost izvedbe vaje je odvisna od tipa aktivnosti in od želenega učinka vadbe. Tako je v primeru treninga moči pravilnost definirana s pravilno držo telesa in pravilno dinamiko gibanja med izvedbo vaje. Študije namreč kažejo, da pravilna drža telesa pomembno vpliva na dosežen napredok [29]. Dodatno smernice za izvajanja treninga moči priporočajo, da so vaje, katerih cilj je pridobivanje hitrosti, izvedene v hitrem tempu, medtem ko je za vaje, katerih cilj je krepitev moči, priporočen počasen tempo izvajanja ponovitev [30].

Intenzivnost vadbe definira trud, ki je potreben za izvedbo posamezne fizične aktivnosti. Tega je mogoče izmeriti na različne načine, ki se med seboj razlikujejo glede na zahtevane pripomočke in stopnjo objektivnosti. Najosnovnejša načina merjenja intenzivnosti fizične aktivnosti sta:

- ocenjevanje počutja med aktivnostjo in
- merjenje srčnega utripa.

Ocenjevanje počutja med aktivnostjo je mogoče izvajati na načine z različnimi stopnjami subjektivnosti, pri čemer izrazito subjektivni načini omogočajo opis intenzivnosti v prostem slogu z uporabo ključnih besed, kot so *zelo naporno*, *ne-naporno* ipd., medtem ko manj subjektivni načini temeljijo na zaznavanju intenzivnosti s pomočjo standardiziranih vprašalnikov. Pogosto uporabljano metriko za ocenjevanje intenzivnosti fizične aktivnosti je definiral Borg [31]. Predlagana lestvica temelji na občutjih, kot jih dojema opazovani subjekt, in vključuje subjektivno zaznano povišanje srčnega utripa, hitrosti dihanja, povečano potenje in mišično utrujenost (Tabela 1.1). Čeprav je takšno zaznavanje intenzivnosti subjektivne narave, študije kažejo, da dobro napoveduje objektivnejše metrike intenzivnosti, kot je npr. srčni utrip [32].

Merjenje srčnega utripa, ki je navadno objektivnejše od samoocenjevanja počutja med aktivnostmi, se najpogosteje izvaja s pomočjo fizioloških senzorjev, nameščenih neposredno na telo merjenega subjekta. Omenjeni senzorji omogočajo zaznavanje parametrov, kot so število srčnih utripov na minuto in čas med zaporednimi srčnimi utripi (R-interval). Medtem ko v splošnem velja, da višje število srčnih utripov odraža intenzivnejšo fizično aktivnosti, je na osnovi srčnega utripa mogoče tudi natančnejše modeliranje stopnje fizične aktivnosti. Tabela 1.2

Tabela 1.1: Borgova lestvica ocen počutja med fizično aktivnostjo.

Vrednost	Opis aktivnosti
6	Brez napora
7	Ekstremno lahko
8	
9	Zelo lahko
10	
11	Lahko
12	
13	Zmerno težko
14	
15	Težko
16	
17	Zelo težko
18	
19	Ekstremno težko
20	Maksimalno težko

Tabela 1.2: Stopnje intenzivnosti fizične aktivnosti, predstavljene kot cone srčnega utripa [33].

Cona	Intenzivnost	% max srčnega utripa
I	Lahka	60%-75%
II	Srednja	75%-85%
III	Težka	85%-95%
IV	Zelo težka	95%-100%

prikazuje različne stopnje intenzivnosti fizične aktivnosti, izračunane glede na interval v razmerju z izmerjenim maksimalnim številom srčnih utripov v minutih.

V doktorskem delu ponudimo algoritme, ki omogočajo napovedovanje kvalitativnih parametrov aktivnosti rekreativnega športa, kot sta pravilnost in intenzivnost aktivnosti, zgolj s pomočjo vseprisotnih pospeškometrov. Pri tem se osredotočimo na to, da so algoritmi sposobni izvajanja v realnem času na zmogljivostno omejenih pametnih telefonih. V poglavju 5 preučimo modele za napovedovanje intenzivnosti aerobnih aktivnosti, medtem ko v poglavjih 4 in 6 ponudimo algoritme za vrednotenje pravilnosti in intenzivnosti treninga moči.

1.5 Cilji naloge

Cilj doktorske naloge je preučiti, kako je vseprisotne naprave mogoče uporabiti za kvantitativno vrednotenje parametrov pravilnosti rekreativnih fizičnih aktivnosti. Pri tem posebno pozornost posvetimo razvoju algoritmov, ki omogočajo izvajanje v realnem času na zmogljivostno omejenih vseprisotnih napravah. Razvite algoritme ovrednotimo za različne tipe fizičnih aktivnosti (anaerobne in aerobne aktivnosti). Cilje doktorske naloge povzemajo naslednja teza in raziskovalna vprašanja.

Teza

Vseprisotne naprave omogočajo zaznavanje in kvantitativno vrednotenje kvalitativnih parametrov rekreativne fizične aktivnosti.

Raziskovalno vprašanje 1:

Standardni pametni telefoni z vgrajenimi pospeškometri omogočajo zaznavanje in kvantitativno vrednotenje pravilnosti izvedbe anaerobnih aktivnosti.

Raziskovalno vprašanje 2:

Standardni pametni telefoni z vgrajenimi pospeškometri omogočajo zaznavanje in kvantitativno vrednotenje intenzivnosti aerobnih fizičnih aktivnosti.

Raziskovalno vprašanje 3:

Standardni pametni telefoni skupaj z mrežo senzorjev pospeška ob kvantitativnem vrednotenju pravilnosti omogočajo še vrednotenje intenzivnosti anaerobnih aktivnosti.

Preverjanje navedenih raziskovalnih vprašanj se odraža v izvirnih znanstvenih prispevkih, opisanih v naslednjem poglavju.

1.6 Izvirni znanstveni prispevki naloge

Izvirni prispevki doktorskega delo so:

1. Algoritem za zaznavanje pravilnost vzorcev anaerobnih aktivnosti, vsebovanih v neomejenem toku podatkov pospeška, na zmogljivostno omejenih vseprisotnih napravah v realnem času (Raziskovalno vprašanje 1).
2. Študija primernosti atributov pospeška in algoritmov nadzorovanega strojnega učenja za zaznavanje in vrednotenje intenzivnosti aerobne vadbe s pomočjo standardnega pametnega telefona (Raziskovalno vprašanje 2).
3. Algoritem za zaznavanje intenzivnosti izvajanja anaerobnih aktivnosti s pomočjo standardnih mobilnih naprav in senzorskih mrež pospeškometrov (Raziskovalno vprašanje 3).
4. Študija različnih konfiguracij senzorskih mrež na natančnost zaznavanja intenzivnosti anaerobnih aktivnosti s pomočjo standardnih mobilnih naprav in senzorskih mrež pospeškometrov (Raziskovalno vprašanje 3).

1.7 Pregled poglavij

V poglavju 2 predstavimo raziskave, povezane s temo naloge. Pregledamo in na kratko opišemo različne načine uporabe vseprisotnih naprav za podporo športa ter navedemo pretekle pristope k prepoznavanju fizičnih aktivnosti.

Poglavlje 3 na kratko oriše pomembne metode in algoritme, uporabljene v doktorskem delu. Predstavimo algoritme za zaznavanje vrhov v signalih, metodo dinamičnega časovnega poravnavanja in različne metode nadzorovanega strojnega učenja.

V poglavjih 4, 5 in 6 natančno opišemo metode in algoritme, iz katerih izhajajo izvirni znanstveni prispevki naloge. Pri tem poglavji 4 in 5 predstavljata rešitvi, ki temeljita zgolj na uporabi standardnih pametnih telefonov, medtem ko rešitev, predstavljena v poglavju 6, združuje uporabo pametnih telefonov in nosljivih senzorjev. Na začetku vsakega poglavja najprej predstavimo motivacijo za razvoj predlagane metode oz. algoritma, nato jo natančno opišemo. Poglavlje zaključimo

z opisom protokola zbiranja podatkov, uporabljenih za ovrednotenje predlaganih metod in algoritmov v Poglavlju 7.

V poglavju 8 sledi diskusija dobljenih rezultatov in interpretacija teze ter raziskovalnih vprašanj doktorskega dela.

Nalogo zaključimo s poglavjem 9, v katerem na kratko povzamemo pomembnejše ugotovitve in z odprtimi problemi predstavimo možnost nadgradnje v prihodnosti.

Poglavlje 2

Povezane raziskave

V tem poglavju opišemo pomembne raziskave, povezane z uporabo vseprisotnih senzorjev in naprav za vrednotenje kvalitativnih parametrov vzorcev rekreativne fizične aktivnosti. Najprej predstavimo uporabo vseprisotnega računalništva v športu. Na kratko opišemo področje in ponudimo iztočnico za raziskave, opisane v doktorskem delu. Nato predstavimo povezana dela, ki temeljijo na uporabi strojnega učenja za prepoznavanje fizičnih aktivnosti. Predstavljene raziskave upoštevamo kot priporočila za izbiro parametrov drsečega okna, značilk in obstoječih metod strojnega učenja ter predstavljajo pomembno osnovo za razvoj lastnih algoritmov.

2.1 Vseprisotno računalništvo za podporo športa

V preteklih letih se je pojavila množica raziskav na temo uporabe vseprisotnih senzorjev in naprav za podporo športnih aktivnosti. Osredotočale so se tako na profesionalni oz. elitni šport kot na rekreativne športne aktivnosti. Medtem ko poglaviti faktor sistemov za podporo rekreativnih aktivnosti predstavlja dostopnost sistema široki množici uporabnikov, sistemi za podporo elitnega športa zahtevajo predvsem visoko stopnjo natančnosti [34]. V naslednjih podpoglavljih navedemo primere uporabe vseprisotnega računalništva v rekreativnem in elitnem športu.

Tabela 2.1: Najpogosteje uporabljeni senzorji za zaznavanje aktivnosti.

Tip senzorjev	Vir
inercijski senzorji (pospeškometri, žiroskopi, magnetomati)	[34, 35, 38, 39, 40, 42, 43, 44, 45, 47, 48, 49, 50, 51, 52, 55, 56, 58, 59, 60, 61, 64, 65, 66, 67, 68, 69, 70, 71, 72]
GPS senzorji	[35, 36, 62, 63]
GSM senzorji	[46]
senzorji v oblekah	[41, 65]
senzorji za zaznavanje sile	[65]
senzorji srčnega utripa	[37, 40, 48, 49, 55, 57, 69]
tlačni senzor	[52]
mikrofoni	[35]

2.1.1 Rekreativni šport

V domeni rekreativnega športa so se vseprisotne naprave večinoma uporabljale v okviru sistemov za:

- zaznavanje podatkov o športnih aktivnostih [34, 35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45],
- motivacijo za športne aktivnosti [46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58, 59, 60] in
- virtualno trenerstvo [61, 62, 63, 64, 65, 66, 67, 68, 69, 70, 71, 72].

Pri tem so se najpogosteje uporabljali senzorji, navedeni v Tabeli 2.1, katerih primeri uporabe so natančneje opisani v nadaljevanju.

V [35] avtorji opišejo platformo, ki kolesarjem olajša iskanje primernih kolesarskih poti. Uporabnikom omogoča, da z mobilnimi napravami dokumentirajo opravljene poti in s skupnostjo delijo osnovne podatke o vožnji. Dodatno platforma omogoča izrabo vseprisotnih senzorjev, vgrajenih v mobilne naprave za

zaznavanje kompleksnejših informacij o kolesarskih aktivnostih, kot so npr. tip cestiča in predviden hrup na posamezni poti.

V [36] je opisana študija, v kateri so avtorji preučili pomen sistemov za spremeljanje fizičnih aktivnosti na prostem. V okviru študije je bila razvita aplikacija za zajemanje podatkov, kot so opravljena pot, hitrost in trajanje športnih aktivnosti. Aplikacija je omogočala zbiranje zajetih podatkov v skupnem spletnem sistemu in deljenje informacij o aktivnostih v izbranih socialnih krogih. Študija razkriva velik interes uporabnikov za spremeljanje športnih aktivnosti z uporabo mobilnih naprav.

ExerTrek [37] je mobilni sistem za spremeljanje športnih aktivnosti, ki uporabnikom nudi podporo pri doseganju zastavljenih ciljev. S pomočjo nosljivih senzorjev omogoča zaznavanje srčnega utripa in glede na izbrani cilj predlaga optimalni program vadbe v okviru predefinirane zmogljivosti vadečega. Dodatno sistem v realnem času zaznava intenzivnost vadbe in omogoča podajanje povratnih informacij za prilagoditev vadbene intenzivnosti.

Pansiot et al. v [34] predlagajo nosljiv senzorski sistem, ki omogoča samodejno zajemanje podatkov aktivnosti plavanja. Sistem s pomočjo pospeškometra, vgrajenega v plavalna očala, zaznava podatke o preplavanih dolžinah, zamahih in tehniki plavanja. Razširitev sistema z dodatnimi senzorji nudi potencial za analizo aktivnosti elitnih plavalcev. Podoben sistem z alternativnimi namestitvami senzorjev je predlagan tudi v [38]. Pri tem se avtorji osredotočijo predvsem na prepoznavanje stila plavanja, štetje števila zamahov in zaznavanje intenzivnosti plavanja. Na osnovi izvedene študije ugotovijo, da namestitev senzorja na hrbtu omogoča najvišjo natančnost zaznavanja stila plavanja, medtem ko sta natančnost štetja zamahov in zaznavanje intenzivnosti plavanja neodvisna od položaja senzorja. Podpora plavanja z dodatkom virtualnega trenerstva ponuja tudi sistem SwimMaster [64]. Podobno kot [34] in [38] s pomočjo pospeškometrov in vgrajenih vezij omogoča zaznavanje parametrov plavanja, kot so preplavana dolžina, število zamahov na dolžino, ravnotežje telesa in rotacija telesa med plavanjem. Avtorji izvedejo eksperimente, v okviru katerih ugotovijo, da je zaznane parametre mogoče uporabiti za podajanje povratnih informacij o pravilnosti plavanja v realnem času.

BALANCE [39] je mobilna platforma za spremjanje podatkov o energijski porabi med različnimi športnimi aktivnostmi, ki za samodejno zaznavanje informacij o energijski porabi izrablja pospeškometre, vgrajene v standardne mobilne naprave. Podobne zmogljivosti ponuja tudi sistem Jog Falls [40], le da za zaznavanje energijske porabe uporablja tako pospeškometre kot tudi senzorje srčnega utripa. Predlagani platformi je mogoče nadgraditi v kompleksnejši sistem, ki ob spremjanju energijske porabe uporabnikom omogoča tudi podajanje natančnih povratnih informacij o priporočljivih aktivnostih.

Moller et al. v [61] predstavijo GymSkill, mobilnega osebnega trenerja, ki s pomočjo pospeškometrov in žiroskopov, vgrajenih v standardne mobilne naprave, zaznava podatke vadbi. GymSkill izvaja kvantitativno analizo kvalitete gibov na ravnotežnih ploščah in omogoča podajanje predlogov za izboljšanje vadbe v realnem času.

MOPET [62, 63] je mobilni trener, ki s pomočjo GPS-senzorja spreminja položaj uporabnikov med fizičnimi aktivnostmi na prostem. Sistem omogoča podajanje vizualnih in zvočnih informacij v realnem času, kar pomembno vpliva na motivacijo uporabnika. Dodatno sistem ponuja še razširitev [73], ki uporabnikom omogoča učinkovito analizo zajetih podatkov in izboljšanje kvalitete treninga.

V [65] predstavijo nosljivo platformo za podporo učenja deskanja na snegu. Platforma je sestavljena iz kombinacije senzorskega in aktuatorškega vezja ter mobilne naprave. Mobilna naprava obdeluje podatke, zajete iz pospeškometrov, senzorjev sile in senzorjev, nameščenih v oblekah, prepoznavata vrsto in pravilnost aktivnosti ter posreduje povratne informacije aktuatorškemu vezju, ki v realnem času in na nevpadljiv način nudi popravke uporabniku.

Strohrmann et al. v izvedenih študijah [66, 67, 68] preučijo potencial uporabe nosljivih senzorjev za zaznavanje kinematičnih aktivnosti in razvijejo platformo za podporo rekreativnega teka. Razvita platforma omogoča zaznavanje stopnje izkušenosti tekača, prepoznavanje kvalitativnih parametrov teka (kot je npr. utrujenost tekača) in omogoča podajanje realno-časovnih povratnih informacij o pravilnosti tekaške aktivnosti. Zmogljivosti platforme temeljijo na metodah statističnega strojnega učenja in so naučene iz podatkov množice tekačev različnih izkušenosti. Avtorji v okviru študije ugotovijo, da množica dveh senzorjev, pritrjenih na nogo in bok uporabnika, zadostuje za natančno vrednotenje kvalitativnih

parametrov rekreativnega teka.

Personal Wellness Coach [69] podpira različne fizične aktivnosti in omogoča zajemanje podatkov, njihovo intrepretacijo, podajanje povratnih informacij in dolgoročno spremjanje vadbe. Sestavljen je iz množice nosljivih senzorjev za zaznavanje vadbe in programske opreme, ki uporabnika motivira pri doseganju zastavljenih ciljev in mu v realnem času posreduje povratne informacije o vadbi. Uporabniške študije kažejo, da razvit sistem predstavlja učinkovit in nemoteč način podpore vadbe, ki lahko v določenih aspektih celo nadomesti osebnega trenerja in dvigne učinkovitost vadbe.

Mattman et al. [41] predstavijo prototip oblačila, ki s pomočjo vgrajenih senzorjev omogoča prepoznavanje položaja zgornjega dela telesa. Sistem ovrednotijo za množico vaj treninga moči in pokažejo, da je uporaben za njihovo podporo. Omogoča namreč zaznavanje frekvence in števila ponovitev ter hitrosti gibanja. V [72] za nadzor aktivnosti treninga moči predlagajo brezščitno nosljivo platformo, sestavljeno iz množice pospeškometrov. Predlagana platforma omogoča zajemanje podatkov vadbe in jih posreduje v analizo osebnemu računalniku, ki izvaja podajanje povratnih informacij o pravilnosti vadbe. Sistem, predstavljen v [42], prav tako omogoča podporo treninga moči. Temelji na mobilnem telefonu, povezanem s pospeškometrom na roki in prsnem košu uporabnika. Omogoča prepoznavanje tipa vaj, izvedenih s prostimi utežmi, in štetje njihovih ponovitev. Predlagani algoritem štetja ponovitev vaj temelji na štetju lokalnih maksimumov signala pospeška, kar ga dela nerobustnega na različne hitrosti izvajanja ponovitev. Seeger et al. [43, 44] predlagano rešitev nadgradijo z dinamično prilagajajočim se algoritmom štetja ponovitev. Muehlbauer et al. [45] predlagajo rešitev za prepoznavanje aktivnosti treninga moči s pomočjo standardnega pametnega telefona. Pri tem se osredotočijo na zaznavanje aktivnosti vadbe in števila izvedenih ponovitev v neomejen toku podatkov.

V [70] opišejo sistem za podporo treninga golfa. Sistem je sestavljen iz množice nosljivih pospeškometrov in žiroskopov, nameščenih na uporabnika in palico za golf. Senzorji zajemajo podatke med izvajanjem giba in jih posredujejo modelu, ki s pomočjo tehnik obdelave signalov zaznava pravilnost izvedenih gibov in posreduje povratne informacije, s pomočjo katerih lahko uporabnik izboljša pravilnost izvedenih gibov.

Music et al. v [71] preučijo smiselnost uporabe pametnih telefonov za prepoznavanje kvalitete *hula hoop* gibov. Predlagajo algoritem, ki s pomočjo pospeškometrov, žiroskopov in magnetometrov omogoča zaznavanje različnih parametrov kvalitete ritmičnih gibov. V okviru raziskave ugotovijo, da magnetometri omogočajo najnatančnejšo zaznavanje parametrov aktivnosti *hula hoop* v realnem času.

Shakra [46] je mobilna platforma, ki uporabnikom omogoča zaznavanje podatkov o izvedenih fizičnih aktivnostih na osnovi GPS-signala in ponuja zmogljivosti komuniciranja, kot je npr. deljenje informacij o vadbi s prijatelji. Zaznavanje aktivnosti poteka s pomočjo nevronskih mrež. Avtorji študije ugotovijo, da zavedanje uporabnikov o izvedenih aktivnostih povečuje njihovo motivacijo za vadbo.

Exertainer [47] je platforma za podporo teka v urbanih okoljih, kjer tek na prostem ni praktičen in ni prijeten. Ponuja atraktivno alternativo teku na klasičnem tranžerju, saj na tekaški napravi ustvari virtualno okolje, ki ga je mogoče nadzorovati z nosljivim senzorjem. Avtorji predstavijo tudi igro, ki omogoča tekmovanje med različnimi uporabniki platforme in veča motivacijo za redno vadbo.

MPTrain [48] je mobilni sistem, ki s pomočjo glasbe pomaga pri doseganju vadbenih ciljev za aktivnosti, kot sta hoja in tek. Uporabnikom omogoča, da na osnovi srčnega utripa definirajo vadbene vzorce. Sistem s pomočjo nosljivih senzorjev zazna informacije o vadbi in prilagodi tempo predvajanja glasbe tempu definiranega vzorca. Avtorji v nadaljevanju predstavijo nadgradnjo sistema [49], ki uporabi povratnih informacij v obliki glasbe doda še dve pomembni motivacijski komponenti:

- uporabniški vmesnik, ki povečuje zavedanje uporabnikov, in
- virtualno tekmovanje.

Izvedena študija priča, da sistem izboljša izkušnjo teka in nudi pomoč pri doseganju bolj aktivnega življenja. Podobno idejo zasledujejo tudi Biehl et al. [50] in Wijnalda et al. [55]. Razvijejo sistema DJogger in IM4Sports, ki s pomočjo senzorjev zaznata tempo uporabnika in glede na zaznani tempo prilagodita hitrost vadbe. Rezultati študije kažejo, da prilagajanje glasbe pozitivno vpliva na dosežene hitrosti med tekom.

V [51] predstavijo sistem za prepoznavanje aktivnosti na osnovi podatkov, zajetih iz nosljivega pospeškometra. Ugotovijo, da je za natančno zaznavanje različnih fizičnih aktivnosti potrebnih več senzorjev in da povratne informacije o zaznanih aktivnostih uporabnike stimulirajo pri vadbi. Do podobnih ugotovitev pridejo tudi v [52]. Izvedejo študijo, v kateri ugotovijo, da so mobilne naprave uporabne za spremeljanje fizične aktivnosti in predstavljajo pomemben motivacijski faktor za redno vadbo. Rezultati študije namreč kažejo, da so uporabniki, ki so za spremeljanje uporabljali mobilne naprave z enostavnim uporabniškim vmesnikom, bistveno pogosteje vadili od tistih, ki za motivacijo niso uporabljali mobilnih naprav.

Mueller et al. [53] raziščejo, kako je računalniške naprave mogoče uporabiti kot motivacijo za izvajanja športnih aktivnosti s pomočjo povezovanja uporabnikov na daljavo. Razvijejo prototipe, ki:

- geografsko oddaljenim uporabnikom omogočajo sodelovanje pri igri z žogo,
- ponujajo virtualno, telesno nadzorovano izkušnjo letenja z zmajem in
- omogočajo tekmovanje v spletni igri z uporabo izometričnih vadbenih naprav.

Dodatno predstavijo sistem [54], ki geografsko ločenim uporabnikom s pomočjo mobilnih naprav in zvočne komunikacije omogoči izkušnjo skupnega teka.

V [56] predstavijo sistem za prepoznavanje gibov borilnih veščin, ki temelji na uporabi nizkocenovnih nosljivih pospeškometrov in žiroskopov. Sistem s pomočjo metod obdelave signalov in strojnega učenja prepozna izvedene gibe, njihovo kvaliteto in izkušenost izvajalcev. Cilj avtorjev je integracija sistema v igre borilnih veščin, kjer uporabnikom lahko nudijo podporo pri treningu in jim omogočajo izborov nasprotnikov, primernih njihovi stopnji izkušenosti.

V [57] predlagajo športno igro, ki na osnovi izmerjenega srčnega utripa med vadbo omogoča prilaganje vsebine igre. Predlagani pristop uporabnikom ponuja optimalno količino fizične aktivnosti in jih posledično ohranja motivirane za redno vadbo. Podobno idejo zasledujejo v [58], le da aktivnost uporabnika zaznavajo s pomočjo senzorjev pospeška, z razvito igro pa se osredotočajo predvsem na motivacijo starostnikov.

Idejo motivacije skozi igro zasledujejo tudi v [60]. Razvijejo igro, v kateri uporabniki na osnovi s pospeškometri izmerjene fizične aktivnosti pridobivajo virtualne točke, ki jih lahko uporabijo za nakup namigov pri reševanju miselnih iger. Avtorji izvedejo uporabniško študijo in ugotovijo, da takšna vrsta tekmovanja vpliva na spremembo vadbenih navad uporabnikov in predstavlja pomemben motivacijski faktor za ukvarjanje s fizično aktivnostjo.

Suh et al. [59] predlagajo sistem, ki s pomočjo pospeškometrov v standardnih pametnih telefonih in metod strojnega učenja pripravi optimalen intervalni trening za posameznika. Sistem s podajanjem povratnih informacij skozi glasbo omogoča motiviranje uporabnikov, pri čemer podatke o aktivnosti uporabnikov zajema iz uporabljenih senzorjev.

V [74] predlagajo idejo uporabe vseprisotnega računalništva za razvoj sistema, ki omogoča nadzor vadbenih navad uporabnikov, jih motivira za fizično aktivnost in jim omogoča prilagoditev vadbenih programov. Navedejo pet ključnih točk, ki jih morajo preučiti in nasloviti sistemi za nadzor in podajanje povratnih informacij o fizičnih aktivnostih, in sicer:

- katere aktivnosti zaznavati,
- katere senzorje uporabiti za zaznavanje aktivnosti,
- katere informacije je mogoče dobiti iz senzorjev,
- kako predstaviti podatke uporabniku in
- kako bodo predstavljeni podatki vplivali na uporabnika.

2.1.2 Elitni šport

V domeni elitnega športa so se vseprisotni senzorji in naprave uporabljali predvsem za podajanje povratnih informacij o vadbi [75, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87], redkeje za vrednotenje intenzivnosti aktivnosti [88]. Pri tem so povratne informacije lahko podane bodisi samodejno s strani sistema bodisi ročno s strani trenerjev. V nadaljevanju na kratko opisemo primere uporabe vseprisotnega računalništva za podporo elitnemu športu. Obširnejši pregled je na voljo v [19].

V [88] predstavijo sistem za vrednotenje intenzivnosti aktivnosti profesionalnih športnikov, ki na osnovi frekvence korakov, zaznane s pomočjo pospeškometrov, omogoča neinvazivno in nemoteče zaznavanje energijske porabe elitnih atletov. Sistem ovrednotijo za aktivnosti hoje in teka ter dosežejo zadovoljivo stopnjo natančnosti napovedovanja energijske porabe atletov.

V [75] Baca et al. predstavijo različne sisteme za podporo aktivnosti elitnega športa. Sistemi s pomočjo vgrajenih senzorjev zajemajo podatke o aktivnostih, kot so veslanje, namizni tenis in biatlon ter omogočajo podajanje relevantnih informacij o pravilnosti aktivnosti v realnem času.

Sturm et al. [76] razvijejo sistem za nemoteče merjenje kvalitativnih parametrov kajakašev. Sistem je sestavljen iz brezžično povezanih senzorjev, ki zajemajo sile med aktivnostjo veslanja in omogočajo posredovanje povratnih informacij o vadbi v realnem času.

V [77] je predstavljen sistem za spremljanje profesionalnih smučarjev. Sistem s pomočjo nosljivih senzorjev in videa zajema informacije o gibanju smučarjev, jih posreduje trenerjem in jim tako omogoča, da natančno identificirajo pomankljivosti tehnikе smučanja.

V [78] je predstavljen sistem za nadzor, prenos in obdelavo športnih podatkov, ki trenerjem omogoča boljši nadzor nad vadečimi. Sistem sestoji iz mobilne naprave in množice nosljivih senzorjev, ki zajemajo biomehanične, fiziološke in druge podatke o športni aktivnosti. Zajeti podatki so brezžično posredovani strokovnjakom, ki lahko na njihovi osnovi analizirajo aktivnosti atletov in jim z oddaljenih lokacij podajo posebljene povratne informacije.

Beetz et al. [79] predlagajo platformo za analizo nogometnih tekem v realnem času. Razvijejo sistem, ki omogoča zaznavanje položaja igralcev med igro in na osnovi zaznanega položaja predlaga različne modele igre. Dodatno sistem omogoča samodejno identifikacijo pomankljivosti v tehniki posameznih igralcev in ekip.

V [80] razvijejo senzorsko platformo za nadzor vadbenih in tekmovalnih aktivnosti elitnih atletov. Platformo testirajo za aktivnosti veslanja in plavanja ter ugotovijo, da so senzorsko pridobljeni podatki natančnejši od ročno označenih podatkov ter primerljivi s tehnološko in delovno intenzivnejšimi tehnikami, kot je videoanaliza.

Chi et al. [81] razvijejo platformo za podporo sojenja na tekmovanjih borilnih veščin. Cilj razvite platforme je s pomočjo senzorjev sile, nameščenih na tekmovalcih, sodnikom omogočiti večjo natančnost pri sojenju in izločiti kontroverznosti točkovanja. Avtorji v okviru raziskave izpostavijo pomembna vprašanja na temo vpliva tehnologije na šport in razpravljajo o tem, kdaj začenja tehnologija prekomerno posegati v šport.

V [82] predstavijo sistem za analizo aktivnosti golfa. Razviti sistem sestoji iz pospeškometra, vgrajenega v žogico za golf, in žiroskopov, nameščenih na palico za golf. Pri tem so pospeškometri namenjeni zajemanju podatkov o hitrosti žogice, žiroskopi pa zaznavanju kota udarca s palico. Avtorji izvedejo študijo sistema in ugotovijo, da so predlagani senzorji sicer dovolj natančni za podajanje kvalitativnih informacij o pravilnosti udarca, vendar stopnja natančnosti ni zadostna za natančno določanje hitrosti žogice in odmika palice. Posledično predlagajo, da se povratne informacije posredujejo v prilagojeni obliki, ki ne trpi nizke stopnje natančnosti.

V [83] predlagajo platformo, ki omogoča uporabo nosljivih senzorjev za analizo udarcev baseballa. Platforma uporabnikom v realnem času posreduje oceno pravilnosti udarca in poda povratne informacije, ki omogočajo učenje pravilnih gibov. Predlagana platforma temelji na metodi delno nadzorovanega gručenja, ki na osnovi prepisov gibanja preverja koordinacijo sklepov in okončin uporabnika.

Kusserow et. al [84] razvijejo sistem za zaznavanje mentalnega stanja elitnih smučarskih skakalcev. Sistem omogoča zajemanje srčnega utripa in pospeška na treningih, kvalifikacijah in tekmovanjih smučarskih skokov. Razvijejo tudi algoritem, temelječ na metodi DTW, ki omogoča primerjavo časovnih vzorcev srčnega utripa za skoke različnih tekmovalnih nivojev. Ugotovijo, da so vzorci srčnega utripa primerljivi med posameznimi skoki in odvisni od nivoja tekmovanja ter da razvita tehnologija nudi potencial za spremljanje in nadzor stresa elitnih tekmovalcev.

V [85] predlagajo orodje za trenerje plavanja, ki omogoča natančno analizo kvalitativnih parametrov plavanja, kot so razlike v zamahu med posameznimi plavalnimi cikli. Izvedejo študijo, v okviru katere preučijo, kako so karakteristike plavalnih gibov različnih stilov plavanja predstavljene v signalu pospeška. Rezultati študije pokažejo, da so pospeškometri uporabni za zaznavanje karakteristik

plavanja, kot sta hitrost in trajanje zamahov, in da omogočajo prepoznavanje različnih stilov plavanja.

Taherian et al. [86] razvijejo sistem za profiliranje šprintov s pomočjo nosljivih senzorjev. Opišejo metodo, ki s pomočjo nizkocenovnih senzorjev za zaznavanje sile omogoča zaznavanja kontakta atleta s tekaško površino, in predstavijo algoritmom, ki zajete podatke senzorjev pretvori v obliko, razumljivo atletom in trenerjem. Sistem primerjajo s stacionarnimi ploščami za zaznavanje sile in pokažejo, da cenejši in mobilnejši nosljivi senzorji omogočajo zaznavanje podatkov s primerljivo natančnostjo.

V [87] preverijo, ali informacije o kinematični usklajenosti med aktivnostjo veslanja vplivajo na izboljšanje veslaške tehnike. S pospeškometri zajamejo podatke o gibanju zgornjega in spodnjega dela telesa ter uporabnikom v realnem času podajo vizualne nasvete za izboljšanje tehnike veslanja. Ugotovijo, da veslači, ki so deležni povratnih informacij o tehniki veslanja, bistveno izboljšajo kinematično usklajenost gibanja.

Raziskave, navedene v poglavju 2.1.1, nakazujejo, da tipični scenariji uporabe vseprisotnih naprav za podporo rekreativnega športa pomanjkljivo naslavljajo področje vrednotenja kvalitativnih parametrov določenih fizičnih aktivnosti. Medtem ko sistemi za podporo elitnega športa (poglavje 2.1.2) temu področju posvečajo več pozornosti, ti navadno ne uporabljajo senzorjev in naprav, ki so dostopne široki množici uporabnikov, temveč temeljijo na specializirani strojni opremi. V doktorskem delu se osredotočimo na razvoj metod in algoritmov, ki s pomočjo vseprisotnih in široko dostopnih senzorjev ter naprav (kot so npr. standardni pametni telefoni in nizkocenovni pospeškometri) omogočajo vrednotenje intenzivnost vzorcev anaerobne in aerobne rekreativne fizične aktivnosti. Pri tem se opremo na različne metode strojnega učenja in statistične obdelave signalov, zato naslednje poglavje posvetimo opisu raziskav na tem področju.

2.2 Prepoznavanje fizičnih aktivnosti

V tem poglavju opišemo različne pristope k prepoznavanju fizičnih aktivnosti. Pri tem se omejimo zgolj na raziskave, katerih pristop temelji na uporabi vseprisotnih

pospeškometrov. V nadaljevanju na kratko povzamemo pomembnejše raziskave in v strnjeni obliku predstavimo bistvene parametre izvedenih raziskav, kot so:

- tipi prepoznanih aktivnosti (Tabela 2.2),
- velikosti drsečega okna v sekundah (Tabela 2.3),
- uporabljeni metodi (Tabela 2.4) in
- uporabljeni značilki (Tabela 2.5).

Tabela 2.2: Najpogosteje prepoznavani tipi fizičnih aktivnosti.

Tip aktivnosti	Vir
hoja	[89, 90, 91, 92, 93, 94, 95, 96, 97, 98, 99]
tek	[89, 90, 91, 92, 93, 95, 96, 97, 98, 99]
stoječ položaj	[89, 90, 93, 95]
kolesarjenje	[90, 92, 93, 98]
nordijska hoja	[90, 92, 93]
sedeč položaj	[90, 93, 94]
skakanje	[89, 91]
ležeč položaj	[90, 93]
hoja po stopnicah	[91, 94]
vožnja v dvigalu	[95, 96]

Tabela 2.3: Uporabljeni dolžini drsečega okna.

Dolžina okna v sekundah	Vir
0.25	[89]
0.5	[89]
1	[45, 89, 93, 94, 96]
2	[89, 91, 94, 96, 98]
3	[42]
4	[89]
5	[94, 100]
≈ 6	[95, 97]
10	[94, 99]
5 do 100	[90]

Tabela 2.4: Uporabljene metode strojnega učenja.

Ime metode	Vir
K-means gručenje (KM)	[89]
MDC	[90]
Metoda k-najbližjih sosedov (ang.: <i>k-Nearest Neighbour</i> , kNN)	[45, 90, 91, 94, 95, 96, 100]
Metoda optimizacije pričakovanja (ang.: <i>Expectation Maximization</i> , EM) + odločitvena drevesa	[92]
Odločitvene tabele	[95, 100]
Odločitvena drevesa	[45, 93, 94, 95, 99, 100]
Metoda podpornih vektorjev (ang.: <i>Support Vector Machine</i> , SVM)	[45, 100]
Maivni bayes (ang.: <i>Naïve bayes</i> , NB)	[42, 94, 95, 100]
Boosting	[100]
Bagging	[100]
Večinsko glasovanje	[100]
Skladanje (ang.: <i>Stacking</i>)	[100]
Nevronske mreže	[93, 94, 98, 99]
Logistična regresija	[94, 99]
Metoda direktne gostote (ang.: <i>Direct Density</i>)	[96]
Faktor lokalnih razrednih osamelcev (Faktor lokalnih razrednih osamelcev (ang.: <i>Class Local Outlier Factor</i>))	[96]
Lokalni klasifikacijski faktor (Lokalni klasifikacijski faktor (ang.: <i>Local Classification Factor</i>))	[96]
HMM	[42]

V [89] ugotovijo, da večina algoritmov za prepoznavanje fizičnih aktivnosti uporablja fiksno množico značilk. S sistematično analizo pokažejo, da je natančnost algoritmov mogoče izboljšati z uporabo značilk, specializiranih za posamezne fizične aktivnosti, in predstavijo priporočila izbiro značilk za različne aktivnosti. Dodatno ovrednotijo vpliv izbiro drsečega okna na natančnost prepoznavanja aktivnosti.

Kononen et al. [90] primerjajo različne algoritme za izbiro značilk in prepoznavanje aktivnosti. Primerjajo klasifikacijsko natančnost uporabe kompleksnih klasifikacijskih metod in enostavnih algoritmov, ki jih je mogoče enostavno in učinkovito implementirati na mobilnih napravah. Ugotovijo, da enostavni linearni

klasifikator, v primeru primerne izbire značilk, dosega dobre rezultate. Dodatno ponudijo različico klasifikatorja na osnovi najkrajših razdalj (ang.: *Minimum-Distance Classifier*, MDC), ki omogoča obdelavo podatkov v realnem času.

V [91] primerjajo 14 metod za ustvarjanje značilk iz surovega signala pospeška. Primerjane metode temeljijo na valjčni transformacij, časovni analizi in frekvenčni transformaciji signala s pomočjo hitre Fourierjeve transformacije (ang.: *Fast Fourier Transform*, FFT). Dodatno ovrednotijo natančnost klasifikacije za 3 različne postavitve senzorja pospeška, in sicer za postavitev na pasu, stegnu in gležnju. Rezultati kažejo, da so za prepoznavanje dinamičnih fizičnih aktivnosti najpomembnejše značilke iz frekvenčne domene signala.

Ghasemzadeh et al. [70] predlagajo kvantitativni model za ocenjevanje kvalitete golf udarcev. Poiščejo skupino značilk, katere linearna projekcija se spreminja glede na kvaliteto izvedenega udarca, pri čemer kvaliteto udarca definirajo na osnovi rotacije zapestja. Izvedejo serijo mehansko nadzorovanih udarcev različnih kvalitet, s pomočjo katerih zgradijo napovedni model za kvantitativno ocenjevanje. Pri tem si pomagajo z različnimi tehnikami manjšanja števila dimenzij, kot sta metoda glavnih komponent (ang.: *Principal Component Analysis*, PCA) in linearna diskriminantna analiza (ang.: *Linear Discriminant Analysis*, LDA). Kvaliteto udarcev ocenjujejo s pomočjo enačbe, naučene z metodo linearne regresije.

V [92] predstavijo metodo za prepoznavanje različnih aktivnosti z uporabo dvodimenzionalnih pospeškometrov, nameščenih na zapestju uporabnika. Predlagana metoda temelji na gručenju podatkov v homogene skupke in ustvarjanju pravil, ki posamezne primerke povežejo s pripadajočimi skupki. Pri tem dobljeni skupki ne združujejo nujno primerkov enake aktivnosti, prav tako pa lahko posamezna aktivnost pripada različnim skupkom. Posledično avtorji znotraj skupkov izvedejo natančnejo klasifikacijo aktivnosti na osnovi odločitvenih dreves. Pri tem za klasifikacijo uporabijo zgolj značilke, pridobljene iz zgoščenega signala, torej zgolj na mestih, kjer je odvod surovega signala enak nič. Predlagani pristop dosega višjo natančnost (85 %) od samostojne uporabe odločitvenih dreves (80 %).

V [101] predstavijo metodo za prepoznavanje akcij v neomejenem toku podatkov, ki temelji na skritem modelu Markova (ang.: *Hidden Markov Model*, HMM). Predlagana metoda je prilagojena za hitro izvajanje na zmogljivostno

omejenih vseprisotnih napravah in omogoča robustno prepoznavanje deloma različnih podvojenih aktivnosti. Ideja avtorjev je, da vsako aktivnost predstavijo kot ločen HMM, katerega izhod je vrednost, ki označuje pripadnost vhodnega toka podatkov posamezni aktivnosti. Prepoznan aktivnost je tako tista, katere HMM vrne najvišjo vrednost pripadnosti. Avtorji hitro izvajanje dosežejo s postopkom zgoščevanja podatkov, ki temelji na pretvorbi vektorjev značilk v abecedo z omejenim naborom vrednosti. Vhod v HMM tako niso značilke, izpeljane iz surovih podatkov, temveč nizi definirane abecede z odstranjenimi podvojenimi znaki. Predlagana metoda omogoča porazdeljeno delovanje na senzorjih in ne zahteva masovnega pošiljanja surovih podatkov med senzorji.

Ermes et al. [93] izvedejo študijo, v kateri preverijo, kako natančno je mogoče prepoznavati aktivnosti v nenadzorovanih okoljih. Ugotovijo, da je za učenju algoritmov strojnega učenja treba uporabiti tudi podatke, zajete zunaj laboratorijskih okolij, saj se natančnost prepoznavanja aktivnosti bistveno zmanjša, če so klasifikatorji naučeni zgolj na osnovi laboratorijskih podatkov. Avtorji študije dodatno naredijo primerjavo med samodejno naučenimi klasifikatorji, klasifikatorjem, osnovanem na domenskem znanju, in kombinacijo obojih. Rezultati kažejo, da klasifikator, ki je posledica kombinacije domenskega znanja in samodejno ustvarjenih pravil, dosega najvišjo natančnost.

V [96] se osredotočijo zgolj na uporabo algoritmov, ki temeljijo na učenju na osnovi primerov (ang.: *Instance-based learning*). Predlagajo dve prilagoditvi, ki izboljšata natančnost obstoječih algoritmov pri prepoznavanju podatkov časovnih vrst, in sicer:

- kodiranje časovnih informacij v primerke in
- večinsko glasovanje znotraj agregatnega okna.

Kodiranje časovnih informacij v primerke omogoča obogatitev vektorja značilk s časovnimi informacijami, izračunanimi v definiranem časovnem intervalu. Avtorji tako v vektor značilk ob surovih vrednostih dodajo tudi povprečje in varianco pospeška za pretekli eno in dve sekundi. Večinsko glasovanje znotraj agregatnega okna temelji na dejstvu, da ima vsaka aktivnost določeno minimalno dolžino trajanja, ki je daljša od dolžine klasifikacijskega drsečega okna. Avtorji tako uvedejo dodatno agregatno drseče okno (dolžine od 1 do 120 sekund), znotraj katerega

izvedejo večinsko glasovanje nad rezultati klasifikacijskih oken, in kot prepoznanu aktivnosti označijo tisto, ki je prejela največ glasov. Rezultati kažejo, da predlagani pristop omogoča uporabo zmogljivostno omejenih mobilnih naprav za učinkovito prepoznavanje aktivnosti s pomočjo algoritmov na osnovi primerkov.

V [97] predlagajo procesno učinkovit algoritem, implementiran neposredno na vgrajenih vezjih, ki za prepoznavanje aktivnosti ne potrebuje učenja, temveč temelji na predefiniranih pragovnih vrednostih. Ideja predlaganega pristopa je prepoznavanje aktivnosti na osnovi zaznavanja korakov in njihove frekvence, pri čemer so koraki v signalu zaznani kot ponavljanje vzorec, katerega amplituda je višja od določene pragovne vrednosti. Za detekcijo ponavljanja v signalu izračunajo korelacijo prvih 50 milisekund pospeška z ostalimi segmenti pospeška znotraj okna, dolžine 5.7 sekund, in kot mesta ponovitve izberejo točke, katerih vrednost funkcije normalizirane navzkrižne korelacije (ang.: *Normalized Cross Correlation Function*, NCCF) je višja od 0.6. Predlagani pristop omogoča visoko stopnjo natančnosti prepoznavanja hoje z občutljivostjo algoritma 1 in specifičnostjo 0.99.

Gyorbiro et al. [98] predstavijo sistem, ki prepoznavava gibe s pomočjo množice nosljivih pospeškometrov. Predlagajo pristop, ki temelji na dejstvu, da je kompleksne aktivnosti mogoče opisati z množico enostavnih komponent, ki odražajo intenzivnost gibanja posameznih delov telesa, pri čemer intenzivnost gibanja definirajo na osnovi spremembe zaznanega pospeška. Za klasifikacijo uporabijo množico nevronskih mrež, od katerih je vsaka specializirana za prepoznavanje določene vrste aktivnosti. Zaznana aktivnost je tista, katere mreža ima najvišjo stopnjo zaupanja v svojo odločitev. Preizkusijo različna števila skritih nevronov in ugotovijo, da mreže s tremi skritimi nevroni nudijo najboljši kompromis med natančnostjo in procesno zahtevnostjo algoritma.

Henpraserttae et al. [102] izpostavijo dva glavna problema uporabe pospeškometrov za zaznavanje aktivnosti, in sicer problema različnih orientacij in lokacij nošenja naprave med aktivnostmi. Navedejo tipične pristope naslavljanja omenjenih problemov, kot so

- uporaba robustnih značilk, neodvisnih od lokacije in orientacije naprave,
- uporaba množice modelov, specifičnih za lokacijo in orientacijo naprave,

-
- uporaba transformacijske matrike, ki omogoča pretvorbo signala pred klasifikacijo, in

predlagajo prilagojeno rešitev, ki temelji na kombinaciji obstoječih pristopov in omogoča robustno klasifikacijo aktivnosti neodvisno od izbrane lokacije in orientacije naprave.

Tabela 2.5: Uporabljene značilke.

Opis značilke	Vir
povprečje	[45, 70, 89, 90, 91, 92, 93, 94, 95, 96, 99, 100]
varianca	[70, 89, 90, 92, 93, 95, 96]
energija	[42, 89, 91, 100]
spektralna entropija (ang.: <i>Spectral entropy</i>)	[89, 93, 95]
diskretni FFT koeficienti	[89, 91, 94]
maksimum	[70, 90]
minimum	[70, 90]
razpon	[90]
fluktuacija	[45]
spektralna fluktuacija	[45]
pasovna širina	[45]
težišče frekvence (ang.: <i>Frequency centroid</i>)	[45]
lomna frekvenca spektra	[45]
koeficienti kepstruma	[45]
entropija spektra moči (ang.: <i>Power spectrum entropy</i>)	[90, 91]
frekvenca vrha (ang.: <i>Peak frequency</i>)	[90, 93]
moč vrha (ang.: <i>Peak power</i>)	[90]
amplituda vrha (ang.: <i>Peak magnitude</i>)	[42]
valjčne transformacije	[91]
25. percentil	[91, 93]
75. percentil	[91, 93]
korelacije med osmi	[42, 91, 95, 100]

glavna frekvenca (ang.: <i>Principal frequency</i>)	[91]
razlika med maksimumom in povprečjem	[70]
mediana	[70, 91, 93]
amplituda med vrhovi (ang.: <i>Peak-to-Peak amplitude</i>)	[70]
standardni odklon	[45, 70, 91, 94, 99, 100]
koren kvadrirane povprečja (ang: <i>Root Mean Square, RMS</i>)	[70]
naklon	[70]
povprečna razlike med vrednostmi dveh zaporednih točk	[92]
koeficient asimetrije (ang.: <i>Skewness</i>)	[93]
koeficient sploščenosti (ang.: <i>Kurtosis</i>)	[93]
moč signala v različnih frekvenčnih pasovih	[93]
surov pospešek	[96]
NCCF	[97]
povprečna absolutna razlika med povprečjem in vrednostmi	[99]
razredna porazdelitev	[99]
povprečen RMS	[99]
prvi integral	[42]

V naslednjem poglavju natančneje predstavimo podmnožico metod strojnega učenja, ki so se v domeni prepoznavanja aktivnosti izkazale kot najuporabnejše. Dodatno opišemo metodo DTW in predstavimo algoritme za zaznavanje vrhov v časovnih signalih.

Poglavlje 3

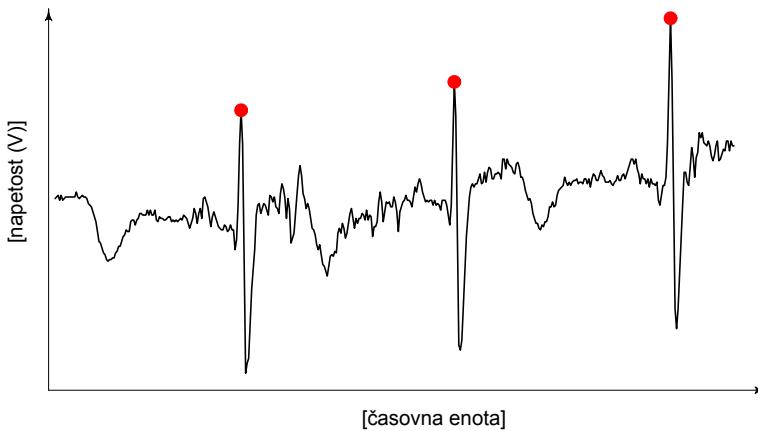
Uporabljene metode in algoritmi

V tem poglavju na kratko predstavimo obstoječe algoritme, uporabljene v doktorskem delu. Opisani algoritmi služijo kot podpora orodja razvoja metod vrednotenja kvalitativnih parametrov aktivnosti, v določenih primerih pa predstavljajo celo njihov sestavni del.

Najprej opišemo algoritme zaznavanja vrhov v časovnih signalih. Ti namreč predstavljajo pomembno hevristiko, ki omogoča učinkovito prepoznavanje časovnih vzorcev. Nato predstavimo metodo dinamičnega časovnega poravnavanja, ki omogoča primerjavo časovno nesinhroniziranih vzorcev. Poglavlje zaključimo z opisom uporabljenih metod strojnega učenja, pri čemer se osredotočimo na linearne in logistične regresije, večnivojski perceptron, odločitveno drevo in metodo podpornih vektorjev.

3.1 Zaznavanje vrhov v časovnih signalih

Zaznavanje vrhov v časovnih signalih predstavlja pomembno komponento različnejših algoritmov obdelave in analize signalov. Posebej pomembno vlogo predstavlja pri analizi signala elektrokardiogramov (EKG) [103]. EKG-signal je sestavljen iz množice ponavljajočih se vzorcev, ki jih sestavljajo vrhovi različnih amplitud (Slika 3.1). Nastali vrhovi so posledica električnih impulzov, ki jih sproža srce v različnih fazah delovanja [17]. Algoritmi zaznavanja vrhov omogočajo natančno prepoznavanje posameznih EKG-segmentov znotraj poten-



Slika 3.1: Primer EKG-signala. Pike označujejo ponavljajoče se vrhove različnih amplitud in oddaljenosti.

cialno neomejenega signala. Informacije o zaznanih vrhovih, kot sta amplituda in časovni interval med njimi, omogočajo neinvazivno diagnozo motenj in nepravilnosti srčnega delovanja.

Algoritme zaznavanje vrhov v domeni EKG je mogoče aplicirati tudi na problem obdelave signala gibanja, zaznanega s pospeškometrom [104]. Signal pospeška je namreč po svoji obliki zelo podoben oblikam EKG-signala, le da vrhovi signala niso posledica električne aktivnosti srca, temveč sprememb gibanja, zaznanih s senzorjem za merjenje pospeška.

V preteklih letih se je pojavila množica algoritmov za zaznavanje vrhov v časovnih signalih, od katerih najpomembnejši temeljijo na [105]:

- odvodu signala in digitalnih filtrih,
- valjčni transformaciji (ang.: *Wavelet transform*) in
- na nevronskih mrežah.

V doktorskem delu uporabimo pristop, temelječ na odvodu in digitalnem filtriranju signala. Signal pospeška najprej zgladimo in iz njega odstranimo visoke frekvence, nastale kot posledica šuma. V naslednjem koraku izračunamo odvod signala. Zaradi splošnosti in robustnosti za izračun odvoda uporabimo enostavno enačbo, ki temelji na izračunu povprečja naklonov linij med točko izračuna (x_i)

in njenim levi sosedom (x_{i-1}) ter levim in desnim sosedom (x_{i+1}) točke izračuna. Slednje natančneje opisuje enačba 3.1.

$$y_i = D'[x_i] = \frac{(x_i - x_{i-1}) + ((x_{i+1} - x_{i-1})/2)}{2} \quad (3.1)$$

V zadnjem koraku s pomočjo enačbe 3.2 ovrednotimo točke izračuna in prepoznamo vrhove signala.

$$Ovrednoti(y_i) = \begin{cases} \text{vrh}, & y_i < 0 \\ \text{ni vrh}, & y_i \geq 0 \end{cases} \quad (3.2)$$

3.2 Dinamično časovno poravnavanje

Dinamično časovno poravnavanje (ang.: *Dynamic Time Warping*, DTW) je tehnika iskanja optimalne poravnave časovnih zaporedij, ki izvira iz domene samodejnega prepoznavanja govora [106]. Prepoznavanje govora temelji na ideji primerjave vzorcev posameznih besed s tokom podatkov govora. Pri tem so vzorci zaradi različnih hitrosti izgovorjave lahko deloma različni od besed, vsebovanih v toku govora, kar onemogoča smiselno primerjavo na osnovi evklidske razdalje. DTW predstavlja učinkovito metriko za samodejno prepoznavanje govora, saj s pomočjo nelinearne transformacije časovnega zaporedja omogoča iskanje optimalnega prileganja med vzorci in tokom govora. V preteklih letih so različni raziskovalci idejo DTW preslikali onkraj meja samodejnega prepoznavanja govora, v domene, kot so podatkovno rudarjenje [107], prepoznavanje gibov [108] in aktivnosti [109].

Cilj DTW je najti preslikavo med zaporedjema $X = \{x_1, x_2, \dots, x_N\}$ dolžine N in $Y = \{y_1, y_2, \dots, y_M\}$ dolžine M , ki minimizira ceno razliko $c(X, Y)$ med zaporedjema. Pri tem sta zaporedji X in Y časovni zaporedji uniformno vzorčenih značilk. V splošnem velja, da je cena $c(X, Y)$ nizka, če sta si zaporedji X in Y podobni, in visoka, če sta različni. Ovrednotenje cene $c(X, Y)$ za vse kombinacije parov elementov zaporedij X in Y se odraža v matriki $C \in \mathbb{R}^{N \times M}$, pri čemer velja, da je $C(n, m) = c(x_n, y_m)$. Optimalna preslikava med zaporedjema X in Y je tista, katere skupna cena razlik je najnižja. Formalno je optimalna preslikava, ki jo v matriki cen C predstavlja (N, M) -pot poravnave, definirana kot zaporedje $P = (p_1, p_2, \dots, p_L)$, kjer velja $p_l = (n_l, m_l) \in [1 : N] \times [1 : M]$ in so izpolnjeni

naslednji pogoji [110]:

- i) Robni pogoji: $p_1 = (1, 1)$ in $p_L = (N, M)$.
- ii) Pogoj monotonosti: $n_1 \leq n_2 \leq \dots \leq n_L$ in $m_1 \leq m_2 \leq \dots \leq m_L$.
- iii) Pogoj velikosti koraka: $p_{l+1} - p_l \in \{(1, 0), (0, 1), (1, 1)\}$ za $l \in [1 : L - 1]$.

Preslikava $P = (p_1, p_2, \dots, p_L)$ definira optimalno poravnavo med zaporedjema $X = \{x_1, x_2, \dots, x_N\}$ in $Y = \{y_1, y_2, \dots, y_M\}$ tako, da v element x_{n_l} iz zaporedja X preslika element y_{m_l} iz zaporedja Y . Pri tem robni pogoj zahteva, da sta tako prvi kot zadnji element v X in Y poravnana drug z drugim, kar implicira zahtevo, da sta poravnani celotni zaporedji. Pogoj monotonosti zahteva, da če se element v X pojavi pred poljubnim drugim elementom, enako zaporedje velja za povezana elementa v Y . Pogoj velikosti koraka je mogoče razumeti kot pogoj zveznosti, saj zahteva, da noben od elementov v X ali Y ni izpuščen oz. podvojen v poravnavi [110].

Skupna cena $c_P(X, Y)$ prileganja P med zaporedjema X in Y je definirana kot

$$c_P(X, Y) = \sum_{l=1}^L c(x_{n_l}, y_{m_l}). \quad (3.3)$$

Nadalje velja, da je optimalna pot prileganja med zaporedjema X in Y pot prileganja P^* , za katero velja, da je njena cena najnižja od vseh možnih poti prileganja. Iz tega sledi, da je DTW-razdalja $DTW(X, Y)$ med X in Y definirana kot skupna cena poti prileganja P^* , kar formalno opisuje naslednji izraz [110]:

$$DTW(X, Y) = c_{P^*}(X, Y) = \min\{c_P(X, Y) \mid P \text{ je } (N, M)\text{-pot prileganja}\}. \quad (3.4)$$

Naiven način iskanja optimalne poti prileganja P^* temelji na neodvisnem izračunu vseh možnih poti prileganja med zaporedjema X in Y . To je neučinkovito, saj je kompleksnost takšnega algoritma eksponentna z ozirom na dolžini N in M . Učinkovitejši algoritem temelji na metodi dinamičnega programiranja. Za opis

DTW-algoritma, ki temelji na metodi dinamičnega programiranja, je treba definirati predponi zaporedij X (enačba 3.5), Y (enačba 3.6) in zbiralno matriko cen D (enačba 3.7).

$$X(1 : n) = (x_1, x_2, \dots, x_n) \text{ za } n \in [1 : N] \quad (3.5)$$

$$Y(1 : m) = (y_1, y_2, \dots, y_m) \text{ za } m \in [1 : M] \quad (3.6)$$

$$D(n, m) = DTW(X(1 : n)m, Y(1 : m)) \quad (3.7)$$

Izračun zbiralne matrike cen D , katere del predstavlja $DTW(X, Y)$, definiran kot $D(N, M)$, poteka po naslednjih korakih:

1. $D(1, 1) = c(1, 1).$

2. Prva vrstica:

$$D(1, m) = c(1, m) + c(1, m - 1), \forall m \in [1 : M].$$

3. Prvi stolpec:

$$D(n, 1) = c(n, 1) + c(n - 1, 1), \forall n \in [1 : N].$$

4. Vsi ostali elementi:

$$D(n, m) = c(n, m) + \min[D(n - 1, m - 1), D(n, m - 1), D(n - 1, m)]$$

Omenjeni algoritem omogoča izračun DTW v času $O(NM)$ in s potencialnimi izboljšavami omogoča izvajanje na zmogljivostno šibkejših mobilnih napravah v realnem času.

3.3 Metode strojnega učenja

Vsebovana podoglavlja predstavijo metode strojnega učenja, uporabljene v doktorskem delu. Strojno učenje je izrazito interdisciplinarna disciplina, ki gradi na področjih, kot so umetna inteligenca, statistika, verjetnost, teorija kompleksnosti, informacijska teorija ipd. [111]. V splošnem se strojno učenje ukvarja z razvojem algoritmov, ki na osnovi izkušenj optimizirajo vnaprej določen kriterij

uspešnosti [112]. To formalno opisuje naslednja definicija [111]:

Računalniški program se uči iz izkušenj E glede na razred problemov T in kriterij uspešnosti P , če se njegova uspešnost P za probleme razreda T izboljšuje z izkušnjami E .

V grobem je metode strojnega učenja mogoče razporediti v naslednje standardne kategorije:

- nadzorovano učenje,
- nenadzorovano učenje in
- spodbujevano učenje.

V primeru nadzorovanega učenja so algoritmu v fazi učenja posredovani primerki, ki vključujejo tako vhode kot izhode algoritma. Nadzorovana metoda strojnega učenja tako na primeru vhodov in izhodov definira model, ki omogoča napovedovanje izhoda primerka zgolj na podlagi posredovanih vhodov. V primeru nenadzorovanega učenja so algoritmu podani zgolj primerki z vhodnimi podatki, tа pa na njihovi osnovi zgradi model, ki se tem podatkom čim bolje prilega. Spodbujevano učenje temelji na principu nagrajevanja algoritma glede na pravilnost izvedene akcije s pozitivnimi in negativnimi nagradami. Takšno nagrajevanje omogoča učenje algoritmов strojnega učenja med samim izvajanjem.

V doktorskem delu se osredotočimo zgolj na uporabo metod nadzorovanega strojnega učenja, saj imamo v fazi učenja na voljo dovolj označenih učnih primerkov, ki nam omogočijo razvoj učinkovitih algoritmов. Metode nadzorovanega strojnega učenja je glede na tip napovednega modela mogoče razdeliti na:

- klasifikacijo (izhod je kategoričnega tipa) in
- regresijo (izhod je realno število).

Tabela 3.1 povzema v doktorskem delu uporabljene metode nadzorovanega strojnega učenja in navaja uporabljeni tip metod. Naslednja podpoglavlja na kratko orišejo delovanje uporabljenih metod.

Tabela 3.1: Metode strojnega učenja in uporabljeni vrsta napovednega modela.

Metoda	Napovedni tip
Linearna regresija	Klasifikacija
Logistična regresija	Regresija
Nevronske mreže	Regresija
Regresijska drevesa	Regresija
Metoda podpornih vektorjev	Klasifikacija, regresija

3.3.1 Linearna regresija

Linearna regresija je enostavna metoda numeričnega napovedovanja, ki temelji na predpostavki linearne odvisnosti podatkov. Zahteva, da so tako vhodni kot izhodni podatki numerične vrednosti. Ideja linearne regresije je, da izhodni atribut x izrazimo kot linearno kombinacijo vrednosti vhodnih atributov a_1, a_2, \dots, a_k in pripadajočih uteži w_0, w_1, \dots, w_k :

$$x = w_0a_0 + w_1a_1 + w_2a_2 + \dots + w_ka_k. \quad (3.8)$$

Enačba 3.8 definira splošno formulo za izračun izhodnega atributa x . Za izračun izhodne vrednosti posameznih učnih primerkov notaciji linearne enačbe dodamo nadpis $^{(i)}$ ($i \in [1 : n]$, kjer je n število učnih primerkov), ki identificira uporabljeni učni primerek. Izhodno vrednost za primerek i je tako mogoče izračunati na naslednji način:

$$w_0a_0^{(i)} + w_1a_1^{(i)} + w_2a_2^{(i)} + \dots + w_ka_k^{(i)} = \sum_{j=0}^k w_ja_j^{(i)}. \quad (3.9)$$

Cilj linearne regresije je izbira uteži w_0, w_1, \dots, w_k , ki minimizirajo vsoto kvadratov razlik med dejanskimi izhodnimi vrednostmi $x^{(i)}$ in napovedanimi izhodnimi vrednostmi za vhodne vrednosti $a_1^{(i)}, a_2^{(i)}, \dots, a_k^{(i)}$. Problem minimizacije vsote kvadratov razlik formalizira enačba 3.10, ki jo je mogoče rešiti z različnimi meto-

dami, kot sta metoda gradientnega spusta in metoda normalne enačbe [113].

$$\arg \min_{w_0, \dots, w_k} \sum_{i=1}^n \left(x^{(i)} - \sum_{j=0}^k w_j a_j^{(i)} \right)^2 \quad (3.10)$$

3.3.2 Logistična regresija

Idejo linearne regresije je z manjšimi prilagoditvami mogoče uporabiti za klasifikacijske probleme. Pri tem se regresija izvede za vsak posamezni razred izhodnega atributa, ki dobi vrednost 1, če primerek pripada dotednjemu razredu, in vrednost 0, če primerek ne spada v razred. Omenjena shema ima dve bistveni pomanjkljivosti [113]. Prvič, vrednosti, ki označujejo pripadnost, ne predstavljajo verjetnosti, saj se lahko nahajajo izven intervala $[0, 1]$. Drugič, kršena je predpostavka, ki pravi, da so regresijske napake statistično neodvisne in normalno porazdeljene, saj pričakovani napovedni atributi zajemajo zgolj vrednosti 0 in 1. Omenjene pomanjkljivosti odpravlja logistična regresija.

Ideja logistične regresije je, da vrednosti 0 in 1 ne napovedujemo neposredno, temveč zgradimo linearni model, ki temelji na transformaciji izhodne spremenljivke. To pomeni, da izhodno vrednost

$$P(1|a_1, a_2, \dots, a_k) \quad (3.11)$$

zamenjamo z vrednostjo, ki jo izračunamo kot

$$\log \left(\frac{P(1|a_1, a_2, \dots, a_k)}{1 - P(1|a_1, a_2, \dots, a_k)} \right). \quad (3.12)$$

Izhodne vrednosti tako niso več omejene na interval med 0 in 1, temveč lahko zavzemajo katerokoli vrednost med negativno in pozitivno neskončnostjo. S preoblikovanje enačbe 3.12 dobimo napovedni model, ki ga formaliziramo kot

$$P(1|a_1, a_2, \dots, a_k) = \frac{1}{1 + e^{-w_0 a_0 - w_1 a_1 - \dots - w_k a_k}}. \quad (3.13)$$

Podobno kot v primeru linearne regresije je tudi v primeru logistične regresije treba najti množico uteži w_0, w_1, \dots, w_k , ki minimizirajo določeno ceno modela. Ceno modela logistične regresije definira logaritem funkcije verjetja, ki ga formal-

izira enačba 3.14, pri čemer lahko $x^{(i)}$ zavzema vrednosti 0 in 1.

$$\sum_{i=1}^n (1 - x^{(i)}) \log \left(1 - P(1|a_1^{(1)}, a_2^{(2)}, \dots, a_k^{(k)}) \right) + x^{(i)} \log \left(P(1|a_1^{(1)}, a_2^{(2)}, \dots, a_k^{(k)}) \right) \quad (3.14)$$

Klasifikacija primerkov z logistično regresijo tako poteka s pomočjo odločitvene razmejitve, ki jo za binarne probleme določa:

$$P(1|a_1, a_2, \dots, a_k) = \frac{1}{1 + e^{-w_0 a_0 - w_1 a_1 - \dots - w_k a_k}} = 0.5. \quad (3.15)$$

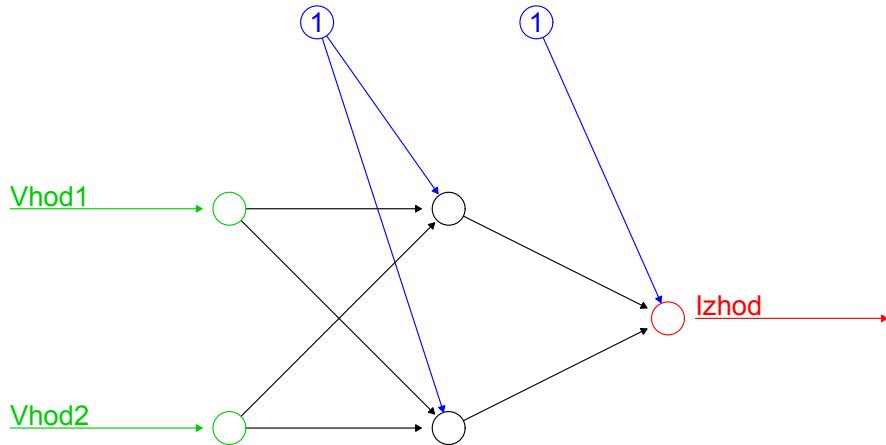
3.3.3 Večnivojski perceptron

Večnivojski perceptron predstavlja enega iz med najpogosteje uporabljenih tipov nevronske mreže. Uporaben je tako za regresijske kot klasifikacijske probleme [114] in za razliko od linearne ter logistične regresije omogoča napovedovanje podatkov, ki niso linearно ločljivi.

Večnivojski perceptron je zgrajen iz množice sigmoidnih aktivacijskih enot, ki so implementirane kot funkcije različnih oblik (logistična, signum, linearna ipd.). Te aktivacijske enote se imenujejo nevroni in se med seboj s pomočjo sinaps povezujejo v nivoje. Tako je večnivojski perceptron strukturiran kot povezan graf, v katerem nevroni predstavljajo vozlišča, sinapse pa enosmerne povezave med vozlišči. Za večnivojski perceptron velja, da lahko sinapse povezujejo zgolj nevrone sosednjih nivojev, ki jih v grobem ločimo na: vhodni nivo, izhodni nivo in skrite nivoje. Najenostavnnejši tip večnivojskega perceptrona ima zgolj en vhodni in en izhodni nivo ter je brez skritih nivojev. Dodajanje skritih nivojev omogoča modeliranje kompleksnejših relacij, ki so sposobne naslavljati probleme, ki niso linearno ločljivi.

Slika 3.2¹ prikazuje primer strukture nevronske mreže z dvema vhodnima (zeleni barva) in enim izhodnim nevronom (rdeča barva) ter s skritim nivojem z dvema nevronoma. Skriti nivo sestavljajo nevroni in sinapse, označeni z rdečo barvo. Dodatno sta na sliki prikazana še konstantna nevrona (modra barva),

¹Izdelana z orodjem [115].



Slika 3.2: Vizualizacija strukture nevronske mreže. Vhodne sinapse in nevroni so označeni z zeleno, skrite s črno, izhodne pa z rdečo barvo. Dodatno sta z modro barvo označena konstantna nevrona.

ki navadno predstavlja enega izmed vhodov izhodnega in skritih nivojev ter označuje utež, ki je neodvisna od prejšnjih nivojev modela (w_0).

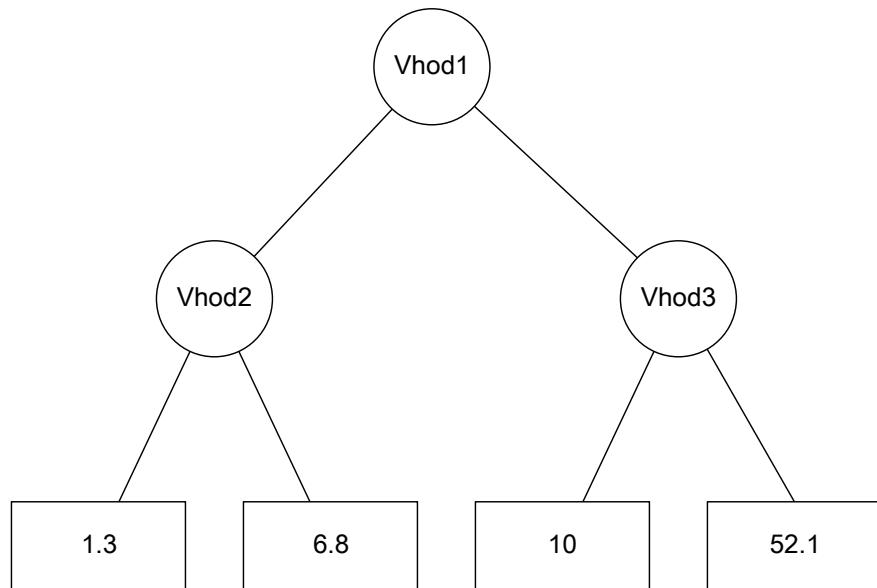
Učenje večnivojskega perceptronja tako zahteva:

- definicijo strukture nevronske mreže in
- določitev uteži posameznih sinaps.

Medtem ko je uteži sinaps ob fiksni strukturi večnivojskega perceptronja mogoče enostavno izračunati s pomočjo metode vzvratnega učenja [113], predstavlja optimalna določitev primerne strukture težji problem, ki ga navadno najuspešneje naslovimo z izkušnjami in preizkušanjem različnih konfiguracij nevronskeih mrež.

3.3.4 Regresijsko drevo

Regresijsko drevo je napovedni algoritem številčnih vrednosti, predstavljen v obliki drevesa. Sestavljen je iz v drevo povezanih vozlišč, pri čemer notranja



Slika 3.3: Struktura odločitvenega drevesa. Krožni simbol predstavlja notranja vozlišča, pravokotni pa zunanja vozlišča oz. liste.

vozlišča drevesa služijo odločjanju na podlagi vrednosti vhodnih podatkov, zunanja vozlišča (listi) drevesa pa predstavljajo odločitveno vrednost. To prikazuje Slika 3.3, kjer so notranja vozlišča predstavljena s krožnim, zunanja pa pravokotnim simbolom. Pri napovedovanju na osnovi dreves se glede na vrednosti notranjih vozlišč izvede usmeritev od vhoda do listov drevesa, ki predstavljajo napoved izhodne vrednosti. V primeru regresijskih dreves je izhodna vrednost število, naučeno kot povprečna vrednost izhodnega atributa vseh učnih primerkov, ki vodijo v dano vozlišče [113].

V odločitvenih vozliščih se navadno vrši primerjava posameznih vhodnih atributov z vrednostjo, določeno v fazi učenja algoritma. Če je primerjani vhodni podatek kategoričnega tipa, je število vejitev v dotičnem vozlišču navadno enako številu možnih vrednosti, ki jih lahko zavzame primerjani podatek. V nekaterih primerih so te vrednosti razporejene med različna vozlišča, kar pomeni, da je določeni vhodni podatek lahko testiran večkrat v drevesni hierarhiji. V primeru številčnih vhodnih podatkov se v notranjih vozliščih navadno vršijo odločitve, ki temeljijo na pravilih večje/manjše/enako.

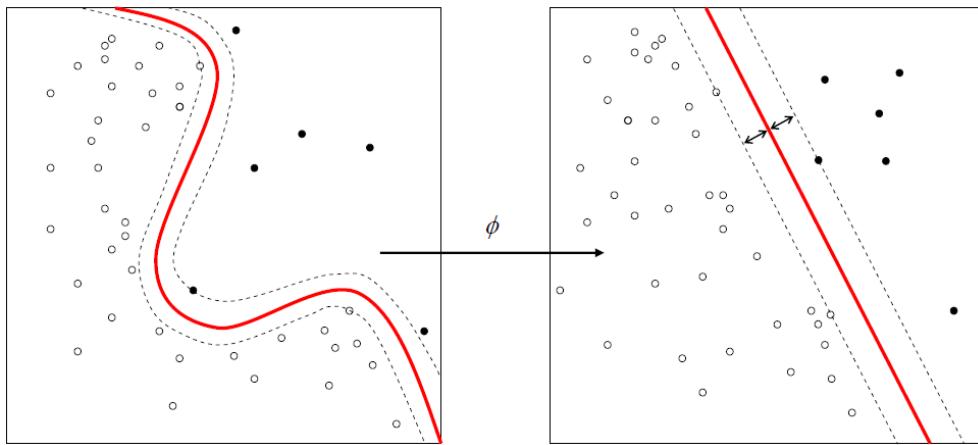
Gradnja regresijskega drevesa se začne z uporabo indukcijskega algoritma za

tvorbo izhodiščnega drevesa. Pri tem so odločitvena vozlišča izbrana na način, ki minimizira odstopanja izhodne vrednosti v posamezni veji. Nato so z drevesa oklešene nepotrebne veje, ki ne igrajo pomembne napovedne vloge, predstavljajo tveganje za prekomerno prileganje (ang.: *overfitting*) in večajo kompleksnost drevesa. Ena iz med glavnih prednosti drevesnih napovednih modelov je namreč ta, da omogočajo učinkovito vizualizacijo odločitvenega procesa, ki je posebej povedna, če drevo ni prekompleksno [116].

3.3.5 Metoda podpornih vektorjev

Metoda podpornih vektorjev (SVM) združuje lastnosti linearnih modelov učenja in modelov učenja na osnovi primerkov ter omogoča uporabo tako za klasifikacijske kot regresijske probleme.

SVM za odločanje uporablja hiper-ravnino v transformiranem prostoru vhodnih podatkov, katere parametri so izbrani tako, da ta maksimizira razdaljo med najbližjimi pravilno ločenimi primerki učne množice [117]. Konkretno, SVM v fazi učenja izbere majhno število kritičnih učnih primerkov vsakega razreda (imenovanih tudi podporni vektorji) in zgradi ločitveno funkcijo, ki maksimizira razdaljo med podpornimi vektorji.



Slika 3.4: Primer SVM z uporabo jedra. Polni in prazni krogci predstavljajo primerke različnih razredov. Z rdečo črto je prikazana meja med razredoma. Slika levo prikazuje primerke v linearno neločljivem prostoru, slika desno pa v linearno ločljivem prostoru po uporabi jedra ϕ .

Uporaba modela učenja na osnovi primerkov presega omejitve tipičnih linearnih ločitvenih modelov, saj z uporabo ločitvenih funkcij višjih redov (pogosto imenovanih tudi jedra) omogoča enostavno upoštevanje dodatnih nelinearnih pogojev [113]. S pomočjo nelinearnih jeder je namreč mogoče primerke, ki v prostoru vhodnih atributov niso ločljivi, preslikati v prostor, kjer so enostavno ločljivi (Slika 3.4). Pri tem je mogoče uporabiti različne tipe jeder, od katerih so najpogostejsa [118]:

- linearno: $\phi(x_i, x_j) = x_i^T x_j,$
- polinomsko: $\phi(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0,$
- Gaussovo RBF-jedro: $\phi(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0,$ in
- sigmoidno: $\phi(x_i, x_j) \tanh(\gamma x_i^T x_j + r).$

V notaciji jeder $x_i \in \mathbb{R}^n$ predstavlja množico vhodnih atributov, $y_i \in \{1, -1\}^l$ izhodni atribut, γ, r in d pa parametre jedra, ki jih je treba optimizirati za posamezni napovedni problem. Dodatno je treba optimizirati še parameter $C > 0$, ki predstavlja regularizacijsko kazen, uporabljeno v izogib prekomernemu prileganju modela.

V nadaljevanju predstavimo algoritme, ki s pomočjo metod, predstavljenih v tem poglavju, omogočajo kvantitativno vrednotenje kvalitativnih parametrov vadbe. V poglavjih 4, 5 in 6 opišemo metode za vrednotenje pravilnosti in intenzivnosti anaerobnih in aerobnih aktivnosti. Na začetku vsakega poglavju podamo motivacijo za metodo, predstavljeno v nadaljevanju. Dodatno opišemo tipe podprtih aktivnosti in predstavimo protokol zbiranja podatkov za ovrednotenje algoritma.

Poglavlje 4

Zaznavanje treninga moči s standardnimi mobilnimi napravami

V tem poglavju opišemo rešitev, ki omogoča natančno zaznavanje posameznih segmentov treninga moči in skozi analizo dinamike gibanja nudi platformo za kvantitativno vrednotenje pravilnosti izvedenih aktivnosti. Predlagamo algoritem, ki temelji zgolj na uporabi standardnih mobilnih naprav brez dodatnih zunanjih senzorjev in podpira širok nabor aktivnosti, izvedenih z različnimi pripomočki v različnih okoljih. Poglavlje povzema raziskavo, objavljeno v [119].

4.1 Motivacija

V preteklem desetletju se je na trgu pojavila množica pripomočkov, ki služijo podpori različnim fizičnim aktivnostim. Garmin [120], Polar [121] in Suunto [122] so razvili pametne ure, ki s pomočjo GPS-senzorja zaznavajo geografski položaj uporabnika in omogočajo prepoznavanje parametrov treninga, kot so razdalja, trajanje in hitrost premikanja. Uporabnikom ponujajo možnost arhiviranja zaznanih aktivnosti, bodisi na osebnem računalniku bodisi s pomočjo specializiranih oblačnih storitev. Slednje omogoča spremmljanje napredka skozi čas in deljenje podatkov o aktivnosti znotraj socialnih krogov.

Z vseprisotnostjo in tehnološkim razvojem pametnih telefonov pa vse več pozornosti pridobivajo mobilne aplikacije za podporo fizične aktivnosti. Pametni

telefoni omogočajo zaznavanje podatkov z različnih vgrajenih senzorjev, obdelavo zaznanih podatkov in podajanje povratnih informacij o vadbi v realnem času ter celo hranjenje podatkov za kasnejšo analizo [36, 63]. Popularnost mobilnih asistentov za vadbo dodatno stopnjujejo novi kanali za posredovanje aplikacij, kot sta Applov App Store [123] in Googlov Play [124]. Omogočajo namreč iskanje, prenos in namestitev mobilnih aplikacij na enostaven in uporabniku prijazen način.

Ključna pomanjkljivost mobilnih aplikacij za podporo fizične aktivnosti je, da so večinoma uporabne zgolj za spremljanje aerobnih aktivnosti, kot so kolesarjenje, tek in pohodništvo. Kljub temu, da študije kažejo, da so anaerobne aktivnosti, kot je trening moči, pomembna komponenta uravnoteženega programa vadbe [8, 125], je na področju samodejnega zaznavanja aktivnosti treninga moči še vedno praznina. Posledično so dnevni aktivnosti treninga moči še vedno vodení na papirju oz. temeljijo na ročnem vnosu s pomočjo aplikacij, kot je Jefit [126]. Zaradi okornosti ročnega vnosa podatkov je spremljanje treninga moči pogosto zanemarjeno, kar negativno vpliva na pogostost fizične aktivnosti in zmanjšuje motivacijo za redno vadbo [13, 14, 127]. Medtem ko obstajajo rešitve za samodejno spremljanje treninga moči (več v poglavju 2.1.1), te bodisi niso vseprisotne, so omejene na specifičen nabor vaj ali pa ne omogočajo natančnega spremljanja posameznih ponovitev. Slednje je zelo pomembno za podajanje povratnih informacij o pravilnosti vadbe.

Večina standardov in priporočil fizične aktivnosti vaje za krepitev moči predpisuje v okviru serij in ponovitev [8]. Posledično razvijemo algoritem, ki v realnem času na standardnih pametnih telefonih omogoča zaznavanje ponovitev brez dodatnih zunanjih senzorjev. Za temelj algoritma izberemo podatke, zaznane s senzorja pospeška, saj pospeškometri predstavljajo pomembno vseprisotno komponento standardnih pametnih telefonov [128], prav tako pa je bila njihova uporabnost v domeni treninga moči v preteklosti že uspešno pokazana [129]. Za demonstracijo smiselnosti pristopa razvijemo mobilnega asistenta za trening moči, ki teče na mobilnih napravah z vgrajenim senzorjem pospeška in operacijskim sistemom Android. Mobilni asistent uporabnika vodi skozi pripravljen program treninga moči in zajema podatke o pospešku za izvedene vaje. Predlagani algoritem s pomočjo metode DTW v realnem času obdeluje tok podatkov, zanjetih s pospeškometra, in zaznava informacije, kot sta število ponovitev in tra-

janje posameznih ponovitev. Slednje je pomembno, saj na osnovi analize dinamike izvedbe vaje omogoča kvantitativno vrednotenje pravilnosti vadbe. Dolgotrajne ponovitve so namreč učinkovitejše za pridobivanje moči, medtem ko so kratkotrajne ponovitve učinkovitejše za napredok hitrosti [30]. Posledično so pravilno zaznane ponovitve ključne za podajanje informacij o pravilnosti vadbe, saj omogočajo oceno trajanja ponovitev.

Izhajajoč iz opažanja, da je vaje treninga moči mogoče izvajati v različnih okoljih (npr. v telovadnici, doma, v naravi) in z uporabo različne opreme (npr. z utežnimi tranžerji, prostimi uteži, upornimi trakovi), zahtevamo, da je algoritem dovolj splošen in robusten za uporabo v različnih scenarijih. Algoritem preverimo za nabor tipičnih vaj treninga moči v dveh različnih okoljih z različnimi pripomočki:

- v *omejenem okolju* s pomočjo utežnih tranžerjev in
- v *neomejenem okolju* s pomočjo prostih uteži ter upornih trakov.

V naslednjih podoglavlјih definiramo uporabnost standardnih pametnih telefonov za podporo treninga moči, opišemo algoritem detekcije ponovitev in predstavimo protokol zbiranja podatkov eksperimentalne študije.

4.2 Mobilni asistent za podporo treninga moči

Vseprisoten pripomoček za podporo treninga moči mora izpolniti naslednje kriterije: uporabljeni platformi mora biti cenovno dostopna in ne sme zahtevati namestitve dodatnih senzorjev ter orodij; ponujati mora uporabniški vmesnik, ki je enostaven za uporabo in uporabnika vzpodbuja k vadbi, npr. s predlaganjem vaj in podajanjem povratnih informacij o vadbi; izkazati mora uporabnost v različnih okoljih (npr. telovadnica in narava) in nuditi podporo širokemu naboru vaj.

4.2.1 Platforma

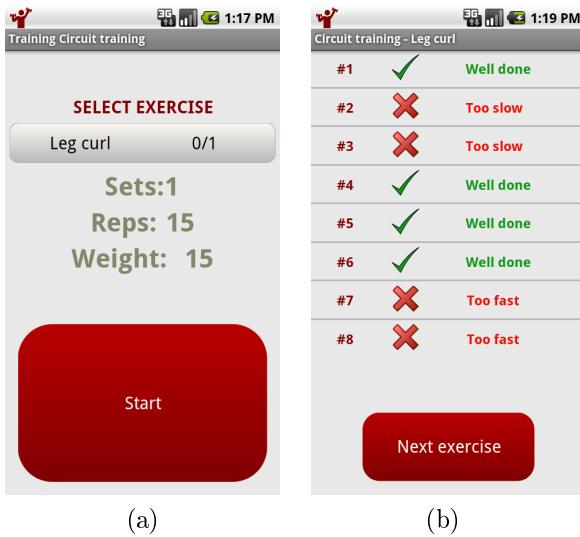
Predlagamo platformo za podporo treninga moči, ki temelji zgolj na uporabi standardnih pametnih telefonov s serijsko vgrajenimi pospeškometri. V okviru

eksperimentalne študije preverimo, ali pospeškometri, vgrajeni v standardne pametne telefone, nudijo zadostno stopnjo natančnosti za zanesljivo detekcijo vadbe. Posledično definiramo minimalno zahtevo za uporabljeno platformo, in sicer zahtevamo, da imajo uporabljeni pametni telefoni vgrajen pospeškometer, saj zaznani signal pospeška izrabljamo za samodejno detekcijo parametrov treninga moči. Raziskavo osredotočimo zgolj na pametne telefone, saj ti, kljub majhnosti in prenosljivosti, nudijo zmogljive procesne kapacitete,obilico pomnilnika, velik in intuitiven zaslon ter napredne komunikacijske zmogljivosti. Z vgrajenimi zvočniki in mikrofonom omogočajo predvajanje zvočnih povratnih informacij, sprejemanje glasovnih ukazov in predstavljajo idealno platformo za razvoj pripomočkov za podporo fizične aktivnosti, ki so poceni, prenosljivi, dostopni široki množici ljudi ter uporabni v različnih okoljih.

Posledično prototip pripomočka za detekcijo aktivnosti treninga moči razvijemo kot mobilno aplikacijo za pametne telefone s serijsko vgrajenim pospeškometrom, ki temeljijo na operacijskem sistemu Android z minimalno različico 2.1. Razviti prototip sestavljajo naslednje komponente:

- uporabniški vmesnik,
- komponenta za zaznavanje podatkov s senzorjev,
- komponenta za upravljanje nastavitev,
- algoritem za detekcijo ponovitev (glej poglavje 4.3) in
- komunikacijski modul.

Prototip aplikacije uporabnikom omogoča, da s spletnega podatkovnega vira prenesejo predefinirani trening. Po izbiri treninga aplikacija uporabnika vodi skozi različne vaje in predlaga parametre treninga, kot so priporočeno število serij, ponovitev in teža (Slika 4.1a). Aplikacija uporabnikom prav tako poseduje povratne informacije o kvaliteti vadbe, ki temeljijo na trajanju ponovitev (Slika 4.1b). Dodatno aplikacija permanentno hrani informacije o zaznanih ponovitvah in omogoča njihov izvoz v spletni profil uporabnika.

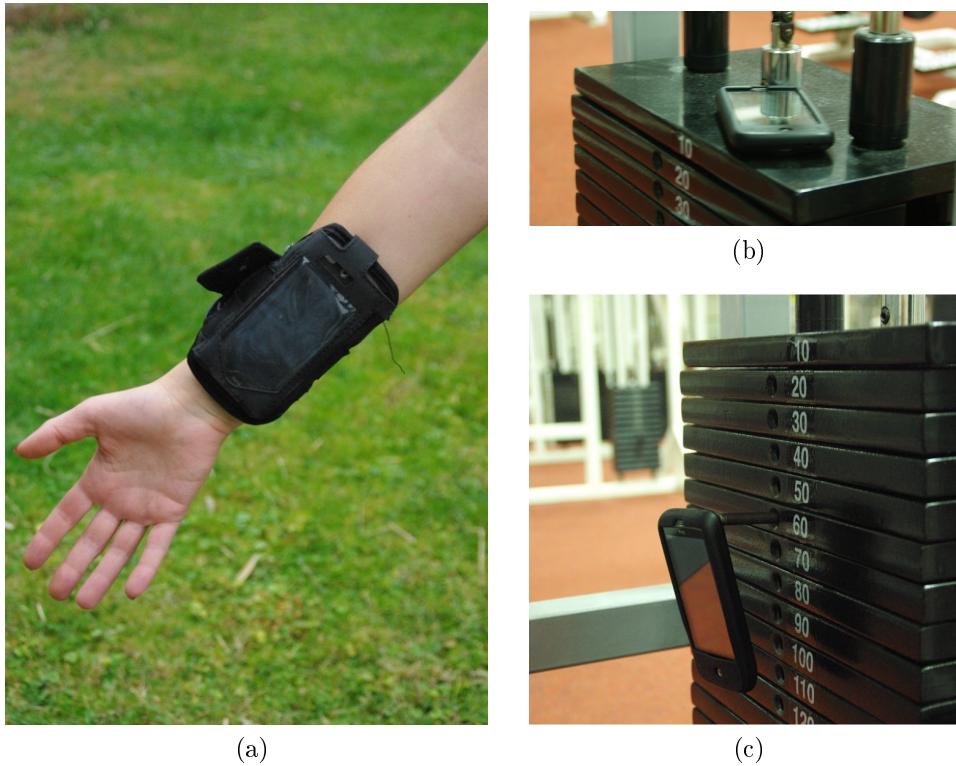


Slika 4.1: Zaslonske maske mobilne aplikacije prikazujejo: (a) informacije o treningu (priporočeno število serij, ponovitev in priporočeno breme vaje) in (b) povratne informacije o prepoznanih ponovitvah.

4.2.2 Vadbena okolja

Trening moči je mogoče izvajati v različnih okoljih in z uporabo različnih pripomočkov. S ciljem ponuditi rešitev, ki ni omejena zgolj na ozek nabor vaj v specifičnem okolju, se odločimo, da rešitev ovrednotimo v dveh različnih okoljih za množico vaj, ki obsegajo glavne mišične skupine: v namenskem vadbenem okolju (telovadnici) in v splošnem okolju (doma ali v naravi).

Izvajanje vaj za krepitev moči najpogosteje poteka s pomočjo utežnih tranžerjev, prostih uteži ali upornih trakov. Utežni tranžerji so navadno veliki, težki in nemobilni ter posledično večinoma omejeni na specializirana notranja okolja (npr. telovadnice). Na drugi strani so proste uteži in uporni trakovi lahki in mobilni ter posledično uporabni tudi v zunanjih okoljih. Podpora obeh okolij je nujna, saj vsako ponuja določene prednosti. Vadba v telovadnici ni odvisna od vremenskih razmer, zato so telovadnice primerno okolje za vadbo v obdobjih s slabim vremenom. Dodatno so telovadnice navadno opremljene z utežnimi tranžerji, ki so posebej primerni za začetnike, saj omejijo gibanje med vadbo in tako zmanjšajo možnosti poškodbe zaradi nepravilne izvedbe vaj. Na drugi strani predstavljajo proste uteži in uporni trakovi mobilno ter poceni alternativo vadbi z utežnimi



Slika 4.2: Lokacije namestitve pametnega telefona: (a) zapestna postavitev za vaje v neomejenem okolju, (b) in (c) predstavljata dve alternativni postavitvi za vaje v omejenem okolju (na utežnem tranžerju).

tranžerji, ki jo je mogoče izvajati v poljubnem okolju (npr. doma ali v naravi). V tem primeru so vadbeni gibi bolj svobodni in manj omejenih kot v primeru utežnih tranžerjev v telovadnici.

S ciljem robustne podpore obeh okolij zahtevamo, da predlagani algoritem omogoča zaznavanje vaj, izvedenih bodisi na utežnih tranžerjih bodisi s pomočjo prostih uteži ali upornih trakov. Ker je vaje s prostimi utežni mogoče izvesti tudi zgolj z bremenom telesne teže, zahtevamo, da je algoritem sposoben zaznati tudi takšne ponovitve.

Vaje, izvedene na utežnih tranžerjih, zaradi omejene poti, ki jo opravi pametni telefon med izvedbo vaje, poimenujemo *omejene vaje*. V primeru utežnih tranžerjev je pametni telefon postavljen na sklad uteži in posledično omejen zgolj na gibanje po vertikalni osi (Slika 4.2b). Slika 4.2c prikazuje alternativno postavitev

naprave za vaje na utežnih tranžerjih. Vaje, izvedene s prostimi utežmi, upornimi trakovi ali telesno težo, zaradi svobodnejšega gibanja pametnega telefona med izvedbo vaje imenujemo *proste vaje*. Pametni telefon se namreč v primeru prostih vaj giblje tridimenzionalno v prostoru. Zadnji stolpec Tabele 4.1 opisuje položaj pametnega telefona med posamezno prosto vajo, slika 4.2a pa prikazuje njegovo zapestno namestitev.

4.2.3 Vaje in mišične skupine

Ena izmed zahtev algoritma za zaznavanje ponovitev je robustnost in zmožnost zaznavanja omejenih ter prostih vaj različnih mišičnih. V [130] navajajo priporočilo, naj programi treninga moči za vsako glavno mišično skupino vsebujejo vsaj eno vajo. Za ovrednotenje algoritma v omejenem in prostem okolju, glede na priporočila literature treninga moči [131, 132, 133], izberemo množico vaj za krepitev mišic različnih mišičnih skupin. Razporeditev izbranih vaj je naslednja (za celoten seznam vaj glej Tabelo 4.1):

- štiri vaje za noge,
- dve vaji za roke,
- dve vaji za zgornji del trupa in
- ena vaja za spodnji del trupa.

Gibanje telesa med vadbo je močno odvisno od vadbenega pripomočka. V omejenem okolju so vse vaje izvedene s pomočjo utežnih tranžerjev, medtem ko so v prostem okolju vaje izvedene z različnimi pripomočki, kot so proste uteži, uporni trakovi in telesna teža. Med preliminarnimi študijami ugotovimo, da je odtis pospeška podoben za vaje, izvedene z različnimi pripomočki v prostem okolju. Posledično za izvedbo večine vaj v prostem okolju zaradi nizke cene in visoke stopnje mobilnosti uporabimo uporne trakove. V primeru trebušnjakov, počepov in stoječih dvigov na prste uporabimo bodisi proste uteži bodisi telesno težo vadbenega subjekta, saj omenjenih vaj ni mogoče udobno izvesti s pomočjo upornih trakov.

Tabela 4.1: Seznam vaj v omejenem in prostem okolju za različne mišice, mišične skupine in položaje namestitve pametnega telefona v prostem okolju (v omejenem okolju je telefon postavljen na vrh utežnega sklada).

Mišična skupina	Mišica	Omejena vaja	Prosta vaja	Namestitev (prosto)
Noge	Gluteus maximus	Nožni potisk	Počepi	Gleženj
Noge	Hamstrings	Ležeče ukrivljenje nog	Stoječe ukrivljenje nog	Gleženj
Noge	Quadriceps femori	Sedeč izteg noge	Sedež izteg noge	Gleženj
Noge	Soleus	Sedeč dvig na prste	Stoječ dvig na prste	Ankle
Roke	Triceps brachii	Sedeči potisk navzdol	Izteg roke	Zapestje
Roke	Biceps brachii	Sedeče ukrivljenje rok	Ukrivljenje rok	Zapestje
Zgornji trup	Pectoralis major	Ležeč potisk s prsi	Stoječ križni izteg	Zapestje
Zgornji trup	Latissimus dorsi	Sedeči poteg navzdol	Stoječ poteg navzdol	Zapestje
Spodnji trup	Rectus abdominis	Upogibi na napravi	Trebušnjaki	Zapestje

4.3 Algoritem za detekcijo ponovitev

Predlagamo algoritem za natančno detekcijo ponovitev treninga moči v signalu pospeška. Tabela 4.2 povzema notacijo, uporabljeno v opisu algoritma. Zaradi enostavnosti in želje po predstavitvi bistva algoritma sta čas začetka in konca ponovitve v algoritmu predstavljena kot indeks začetka in konca ponovitve v toku podatkov pospeška.

Tabela 4.2: Povzetek notacije algoritma detekcije ponovitev.

C	Časovno zaporedje predloge ponovitve $C = c_1, \dots, c_n$
n	Število vzorcev v predlogi C
R	Časovno zaporedje toka podatkov pospeška $R = r_1, \dots, r_m$
p	Indeks vrha v časovnem zaporedju predloge C , izračunan kot položaj $\max(C)$
I	Indici kandidatov ponovitev (vrhovi v toku pospeška R) $I = i_1, \dots, i_o$
ϵ	Raztezni količnik za spreminjanje velikosti okna okrog kandidatov ponovitev
α	Količnik podobnosti vrhov
s	Približen začetek ponovitve
e	Približen konec ponovitve
s'	Natančen začetek ponovitve
e'	Natančen konec ponovitve

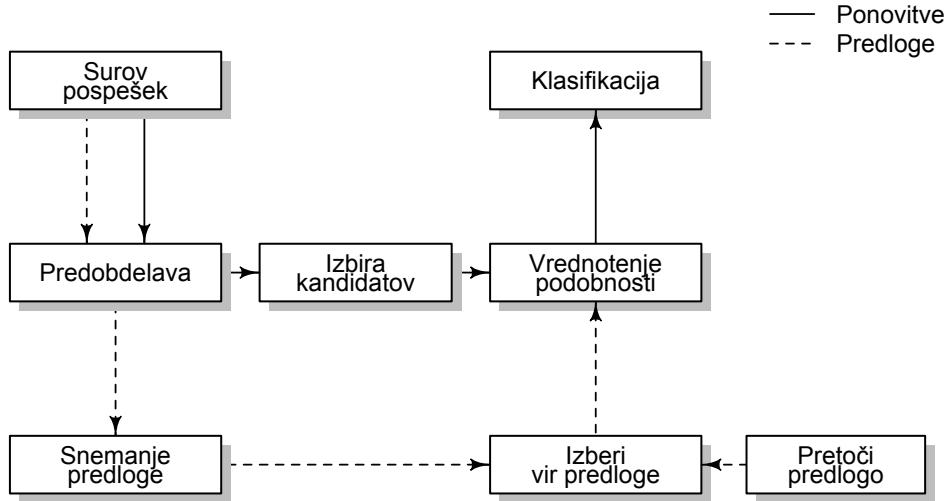
Ponovitev vaje treninga moči je definirana kot vzorec pospeška, pridobljen s pospeškometa pametnega telefona. Zaznana množica ponovitev vaje tvori *serijo ponovitev*. Vzorci ponovitev so del časovnega signala podatkov pospeška R . Cilj algoritma za zaznavanje ponovitev je natančna detekcija vzorcev ponovitev, ki predstavljajo gibanje med treningom moči, v realnem času na procesno omejenih mobilnih napravah. Za detekcijo uporabimo predloge vzorcev C , ki so lahko bodisi predefinirane s strani strokovnjaka treninga moči in prenesene s spleta ob namestitvi aplikacije bodisi zajete za vsakega posameznega uporabnika med postopkom kalibracije pod nadzorom osebnega trenerja. Uporaba predlog za detekcijo ponovitev je nujna, saj se vzorci posameznih vaj, izvedenih v različnih

Tabela 4.3: Izvor različnosti vzorcev ponovitev.

Razlike med vajami	Za različne vaje je značilna različna dinamika gibanja, kar se odraža kot razlike v signalu pospeška.
Razlike med pripomočki	Vaje, izvedene z različnimi pripomočki, aktivirajo različne osi pospeška z različnimi intenzivnostmi, kar se odraža kot razlike v signalu pospeška.
Razlike znotraj vaje	Enake vaje so lahko izvedene v različnem tempu, kar se odraža v razlikah signala pospeška.
Razlike znotraj vaje	Različne osebe lahko enako vaje izvajajo na različen način.

okoljih, med seboj močno razlikujejo, kar onemogoča zaznavanje na osnovi splošne definicije ponovitve treninga moči. Vrstici 1 in 2 v Tabeli 4.3 opisujeta izvor različnosti vzorcev ponovitev, ki jih odpravimo z uporabo predloge vzorca C .

Med treningom moči je potrebno predlogo C primerjati s podvzorcem toka pospeška R in ovrednotiti podobnost. Problem se pojavi, saj sta predloga C in dejanska ponovitev v toku pospeška R redko popolno poravnani. Razlogov za to je lahko več (vrstici 3 in 4 v Tabeli 4.3), najpogosteje pa je to posledica različnega tempa izvedbe ponovitev. Enostavne metrike za vrednotenje podobnosti, kot je npr. Evklidska razdalja, so tako, zaradi nesposobnosti upoštevanja razlik, nastalih kot posledica neporavnosti vzorcev, neuporabne za vrednotenje podobnosti med predlogom C in podvzorcem toka pospeška R . Zato predlagamo uporabo DTW (za natančnejši opis glej poglavje 3.2) za vrednotenje podobnosti med predlogom C in dejansko ponovitvijo v vzorcu R . DTW je tehnika dinamičnega programiranja, ki je že bila uporabljena za prepoznavanje gibov [108] in aktivnosti [109]. S pomočjo preslikave, ki minimizira razdaljo med vhodnimi zaporedji, omogoča DTW primerjavo zaporedij, ki niso časovno poravnana. Ustvarjeno preslikavo je mogoče uporabiti tudi za zaznavanje specifičnih dogodkov v toku podatkov R , ki so označeni v predlogi C . Primer takšnih dogodkov predstavlja začetek (s') in konec (e') ponovitve. V [134] je predstavljen DTW za vrednotenje podobnosti signalov v toku podatkov. Ker je računanje DTW procesno prezahtevno



Slika 4.3: Pregled korakov algoritma zaznavanja ponovitev. Koraki ustvarjanja predloge C so označeni s črtkano črto, polna črta pa označuje procesno pot vzorca pospeška R .

za neprestano izvajanje na zmogljivostno omejenem pametnem telefonu, predstavimo algoritem, ki omogoča učinkovito detekcijo vzorcev ponovitev v realnem času.

Slika 4.3 prikazuje glavne korake predlaganega algoritma. V koraku *predobdelave* (poglavlje 4.3.1) sta iz zajetega surovega signala pospeška ustvarjeni časovni zaporedji C in R . Predloga C je shranjena v skladišče predlog v fazi *snemanje predloge*. V primeru scenarija samostojnega osebnega trenerja brez kalibracije je predloga C pretočena s spleta (korak *pretoči predlogo*). Med vadbo je tok pospeška R v koraku *izbira kandidatov* (poglavlje 4.3.2) neprestano spremljan za potencialne kandidate ponovitev. Posledično je *vrednotenje podobnosti* (poglavlje 4.3.3) med predlogom C in podvzorcem R potrebno le za majhno podmnožico kandidatov iz R . Slednje močno pohitri algoritem zaznavanja vzorcev. V zadnjem koraku so zaznani vzorci ponovitev posredovani v *klasifikacijo* (poglavlje 4.3.4), ki kot izhod vrne zaznane ponovitve treninga moči. V naslednjih poglavjih natančno opišemo omenjene faze algoritma.

4.3.1 Predobdelava

Predobdelave sta deležna tako predloga C kot tudi tok signala pospeška R . Sestavljajo jo naslednje operacije:

- enakomerno ponovno vzorčenje,
- glajenje signala in
- zaznavanje glavne osi aktivnosti.

Pospeškometri so v standardne pametne telefone vgrajeni za potrebe prilaganja orientacije zaslona glede na položaj naprave in ne za neprestano vzorčenje podatkov. Posledično vgrajeni senzorji pogosto ne vzdržujejo konstantne frekvence vzorčenja in zajemajo podatke s spremenljivo gostoto v odvisnosti od razpoložljivosti procesnih kapacitet v danem trenutku. Za zagotavljanje optimalne natančnosti delovanja DTW-algoritma je treba zajeti surovi signal pospeška najprej ponovno vzorčiti z enakomerno frekvenco. To dosežemo z uporabo *linearne interpolacije*, ko je frekvanca vzorčenja prenizka, in s *povprečenjem zaporednih vzorcev*, ko je frekvanca vzorčenja previsoka. Za potrebe ovrednotenja algoritma frekvenco vzorčenja nastavimo na 10 Hz, kar pomeni, da so posamezni vzorci zajetega signala med seboj oddaljeni 100 ms. Frekvanca 10 Hz se je izkazala kot primerna za ovrednotenje algoritma, saj so ponovitve treninga moči navadno izvedene s frekvenco, ki je bistveno nižja od 10 Hz, kar zagotavlja, da pri vzorčenju ne prihaja do izgube informacij. S prilagajanjem frekvence vzorčenja je mogoče doseči kompromis med stisnjenoščjo in kvaliteto signala.

Signal z enakomerno frekvenco vzorčenja v naslednji fazi predobdelave zgradimo, s čimer odstranimo visokofrekvenčna nihanja, ki so posledica šuma pri vzorčenju surovega signala pospeška. Pospeškometri, vgrajeni v mobilne naprave, so navadno namreč nižje kakovosti in posledično zajemajo signal pospeška z opazno stopnjo šuma. Za glajenje signala uporabimo sedemtočkovni Savitzky-Golay [135] (SG) filter tretje stopnje. Vrednosti filtra izberemo na osnovi preliminarne analize vaj treninga moči. SG-filter aproksimira vrednosti znotraj določenega okna s polinomom zahtevane stopnje s ciljem minimizacije napake najmanjših kvadratov. Prednost uporabe SG-filtra je, da ta ne zakasni signala, hkrati pa ohrani značilke signala, kot so lokalni minimumi in maksimumi.

Dodatno zmanjšanje procesne zahtevnosti algoritma dosežemo z zaznavanjem glavne osi aktivnosti za posamezne vaje. Kljub temu, da so standardni pametni telefoni sposobni zajemati signal pospeška v treh različnih smereh, je za detekcijo ponovitev treninga moči zadostna obdelava signala zgolj v eni smeri. To je posledica dejstva, da večino vaj treninga moči sestavlja gibanje v eni smeri. To smer imenujemo *glavna os aktivnosti* in jo zaznamo v zadnji fazi predobdelave surovega toka podatkov pospeška. Zaradi zmanjšanja kompleksnosti algoritma to os za vsako vajo zaznamo med postopkom kalibracije. Posledično algoritem zahteva, da je med vadbo mobilna naprava orientirana v enaki smeri, kot je bila med kalibracijo. Omenjeno omejitev je mogoče enostavno odpraviti z vnovičnim zaznavanjem glavne osi aktivnosti med vsako vajo.

4.3.2 Izbira kandidatov

Neprestano računanje DTW znotraj toka podatkov je procesno prezahtevno za realno-časovno izvajanje na standardnih pametnih telefonih. Za zmanjšanje časovne kompleksnosti algoritma predlagamo korak, ki omogoča, da ne računamo DTW za zaporedja toka R , za katera je očitno, da ne vsebujejo ponovitev. Pri tem se opremo na opažanje, da ponovitve treninga moči sestavljajo vrhovi v signalu pospeška, ki imajo podobno amplitudo. Za detekcijo vrhov uporabimo pragovni algoritem zaznavanja vrhov (več v poglavju 3.1), ki nam omogoča, da iz množice vrhov toka vrednosti pospeška R izluščimo tiste, katerih amplituda je dovolj blizu vrednosti $\max(C)$. Indeks zaznanih vrhov posredujemo v fazo *vrednotenja podobnosti*, kjer izmed podzaporedij signala R v okolini zaznanega indeksa poiščemo vzorec z najnižjo normalizirano DTW-razdaljo.

Za izločitev vrhov z amplitudo, ki je bistveno nižja od najvišje vrednosti pospeška v predlogi C ($\max(C)$), uporabimo dinamično določen prag. Posledično so v fazo vrednotenja podobnosti posredovani le vrhovi z indeksom i , ki ustrezajo enačbi 4.1.

$$R_{[i:i]} \geq \max(C) \cdot \alpha^{-1} \quad (4.1)$$

Pri tem parameter α označuje zahtevano stopnjo podobnosti. Višja kot je vrednost α , več vrhov je posredovanih v fazo vrednotenja podobnosti in man-

jše je število napačno klasificiranih negativnih vzorcev (ang.: *False negatives*). Hkrati raste število kandidatov, za katere je treba računati DTW, kar veča procesno zahtevnost algoritma. Posledično je za optimalno delovanje algoritma treba izbrati smiselno vrednost parametra α . V naši implementaciji izberemo $\alpha = 3$, kar omogoča, da izločimo vrhove, katerih amplituda je manjša od tretjine najvišje vrednosti pospeška v predlogi C . Vrednost α je izbrana na osnovi opažanja, da ima večina vrhov, ki so bodisi posledica šuma bodisi posledica aktivnosti pred vadbo in po njej, v naši predštudiji amplitudo nižjo od ene tretjine $\max(C)$.

4.3.3 Vrednotenje podobnosti

Algoritem 1 opisuje uporabo DTW za vrednotenja podobnosti med predlogo C in podzaporedjem R . Slika 4.4 dodatno vizualno prikazuje predlagani koncept. Algoritem v zanki obhodi indice kandidatov ponovitev I , pridobljene iz prejšnje faze algoritma, in za vsakega izračuna približen čas začetka s in konca e ponovitve (Algoritem 1, vrstici 3-4). Približen čas začetka in konca sta izračunana kot indica v toku podatkov pospeška R . Izračunana indica sta kasneje uporabljeni za omejitve podzaporedja R , za katerega se izvede vrednotenje podobnosti z DTW. Za določitev s in e so uporabljene informacije, ki so implicitni del predlogi C , konkretno število vzorcev n in indeks vrha p .

Osnovni izračun vrh $p = \max(C)$ v predlogi C preslika v indeks i , ki predstavlja vrh v toku vrednosti pospeška R .

Na osnovi preslikave med i in p in z upoštevanjem števila vzorcev n v predlogi C je mogoče izračunati položaj približnega začetka (enačba 4.2) in konca (enačba 4.3) ponovitve v toku podatkov R .

$$s = i - p \quad (4.2)$$

$$e = i + (n - p) \quad (4.3)$$

To ilustriramo na konkretnem primeru. Predpostavljajmo, da ima predloga ponovitve C , ki vsebuje 30 vrednosti ($n = 30$), najvišjo vrednost oz. vrh na položaju $p = 10$. Izračun položaja približnega začetka s in konca e ponovitve v

Algoritem 1 PrimerjajDTW(C, R, p, I, ϵ)

```

1:  $\mathfrak{R} \leftarrow \emptyset$ 
2: for all  $i$  in  $I$  do
3:    $s \leftarrow i - \epsilon \cdot p$ 
4:    $e \leftarrow i + \epsilon \cdot (n - p)$ 
5:    $map \leftarrow izraunajDTW(C_{[1:n]}, R_{[s:e]})$ 
6:    $s' \leftarrow$  zadnji element v  $R$  povezan s  $C_{[1]}$  v  $map$ 
7:    $e' \leftarrow$  prvi element v  $R$  povezan s  $C_{[n]}$  v  $map$ 
8:    $dst \leftarrow normaliziranaDTWrazdalja(map, s', e')$ 
9:    $max \leftarrow maximum(R_{[s':e']})$ 
10:   $min \leftarrow minimum(R_{[s':e']})$ 
11:   $mean \leftarrow aritmetičnoPovprečje(R_{[s':e']})$ 
12:   $sd \leftarrow standardniOdklon(R_{[s':e']})$ 
13:   $rms \leftarrow RMS(R_{[s':e']})$ 
14:   $dur \leftarrow trajanje(s' : e')$ 
15:   $\mathfrak{R} \leftarrow dodaj(s', e', dst, max, min, mean, sd, rms, dur)$ 
16: end for

```

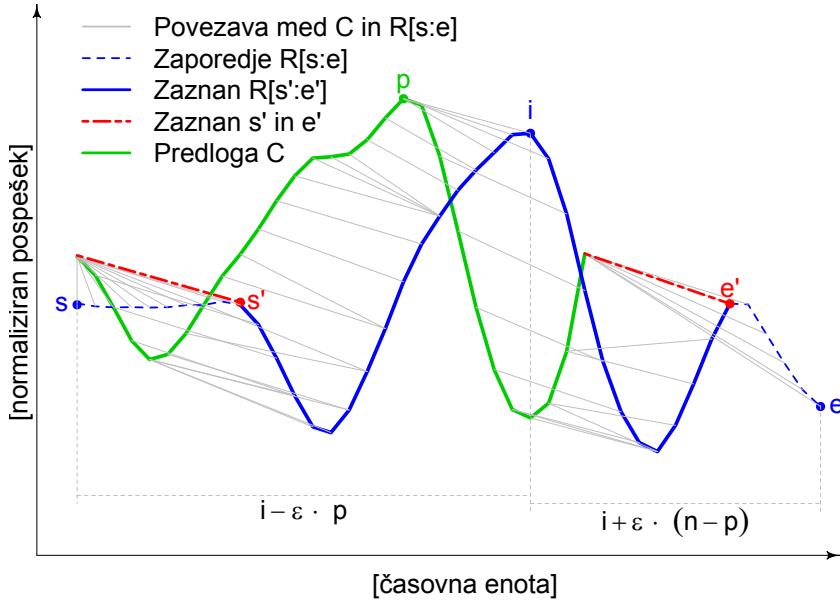
toku podatkov pospeška R z vrhom $i = 50$ prikazujeta izračuna 4.4 in 4.5.

$$s = i - p = 50 - 10 = 40 \quad (4.4)$$

$$e = i + (n - p) = 50 + (30 - 10) = 70 \quad (4.5)$$

Ker so lahko trajanja dejanskih ponovitev daljša od trajanja zajete predloge C , v algoritmu uvedemo nastavljen parameter ϵ , ki dodatno uravnava dolžino zajetega podzaporenda R . Vrednost parametra $\epsilon = 1$ določa, da je podzaporende $R_{[s:e]}$ enake dolžine kot predloga C . Za implementacijo algoritma uporabimo $\epsilon = 1.5$, kar pomeni, da na začetku in koncu podzaporenda R dodamo rob, ki obsega 50 % dolžine predloge C . Posledično je algoritem sposoben zaznati ponovitve, katerih trajanje je do 100 % daljše od trajanja predloge C . To se je izkazalo kot zgornja meja razlike med dolžino dejanske ponovitve in dolžino predloge v izvedeni eksperimentalni predštudiji.

Za iskanje podzaporenda $R_{[s:e]}$, ki je najbolj podobno predlogi C , uporabimo neomejen DTW-algoritem [134]. Ta kot izhod vrne preslikavo vrednosti predloge C v vrednosti podzaporenda $R_{[s:e]}$ (Algoritem 1, vrstica 5). Omenjena preslikava,



Slika 4.4: DTW-preslikava med predlogo C in tokom pospeška R . Za razlago označb glej Tabelo 4.2.

ki jo prikazuje tudi rdeča črtkana črta na Sliki 4.4, je uporabljen za določitev položaja natančnega začetka s' in konca e' ponovitve (Algoritem 1, vrstici 6-7). Uporaba neomejenega DTW-algoritma nam omogoča, da iz približnega podzaporedja $R_{[s:e]}$ določimo natančne meje kandidatov ponovitve $R_{[s':e']}$.

Za vsako podzaporedje $R_{[s':e']}$ izračunamo naslednje značilke (Algoritem 1, vrstice 8-14):

- normalizirano DTW-razdaljo (dst),
- najvišjo vrednost (max),
- najnižjo vrednost (min),
- aritmetično povprečje ($mean$),
- standardni odklon (sd),
- koren kvadrirane srednje vrednosti (rms) in

-
- trajanje (*dur*).

Omenjene značilke izberemo, saj je bodisi njihov izračun zelo enostaven bodisi so izračunane kot stranski produkt prejšnjih korakov algoritma (npr. normalizirana DTW-razdalja). Natančnejša navodila za izračun omenjenih značilk so na voljo v [136]. V zadnjem koraku so s' , e' in izračunane značilke posredovane v fazo klasifikacije.

4.3.4 Klasifikacija

V zadnjem koraku algoritma kandidate ponovitev, omejene s parom indeksov (s', e') , ovrednotimo s klasifikatorjem ter tako izločimo vzorce, ki najverjetneje ne predstavljajo dejanskih ponovitev. Za klasifikacijo izberemo klasifikator, temelječ na logistični regresiji (več v poglavju 3.3.2), saj je ta procesno nezahtevna, hkrati pa dovolj natančna za problem ločevanja vzorcev dejanskih (ang.: *True positives*) in lažnih (ang.: *False positives*) ponovitev, ki so linearno ločljive.

Logistična regresija je klasifikacijska metoda, kjer eno ali več neodvisnih spremenljivk uporabimo za napovedovanje binarne odvisne spremenljivke. Rezultat učenja klasifikatorja, temelječega na linearni regresiji, je linearna formula (enačba 4.6) s koeficienti w_i . Naučena formula nam omogoča, da izračunamo transformacijo podzaporedja pospeška, ki nam pove verjetnost, da določeno podzaporedje predstavlja dejansko ponovitev.

$$\begin{aligned} \text{logit}(p) = & w_0 + w_1 \cdot \text{dst} + w_2 \cdot \text{max} + w_3 \cdot \text{min} \\ & + w_4 \cdot \text{sd} + w_5 \cdot \text{rms} + w_6 \cdot \text{dur} \end{aligned} \tag{4.6}$$

Učenje koeficientov logistične regresije izvedemo v okolju Weka [137]. Za preprečevanje prekomernega prileganja (ang.: *Overfitting*) uporabimo desetdelno navzkrižno preverjanje (ang.: *ten-fold cross-validation*). Ker se različne vaje, izvedene v različnih okoljih, odražajo v različnih odtisih pospeška, zgradimo 18 različnih klasifikacijskih modelov za devet vaj v dveh različnih okoljih. To se ne odraža v visokih stroških režije, saj za shranjevanje posameznega modela zadostuje zgolj sedem numeričnih koeficientov.

V klasifikacijski fazi so glede na izvajano vajo in okolje izbrani parametri modela. Parametri so vstavljeni v enačbo 4.6, s pomočjo katere je izračunana vrednost $logit(p)$. V zadnjem koraku vrednost $logit(p)$ za posamezno podzaporedje pospeška pretvorimo v verjetnost in jo ovrednotimo s pomočjo pravila, ki ga definira enačba 4.7. To nam omogoča, da zavržemo kandidate, za katere je verjetnost, da predstavljajo dejanske ponovitve, nižja od 0.5.

$$Eval(s', e') = \begin{cases} \text{accept,} & \text{if } \frac{1}{1+e^{-logit(p)}} \geq 0.5 \\ \text{reject,} & \text{if } \frac{1}{1+e^{-logit(p)}} < 0.5 \end{cases} \quad (4.7)$$

4.4 Zbiranje podatkov

Uporabnost standardnih pametnih telefonov za zaznavanje treninga moči smo ovrednotili s pomočjo eksperimentov v različnih okolji in za različne tipe vaj ter pripomočkov. Vaje v omejenem okolju so bile izvedene s pomočjo utežnih tranžerjev, vaje v prostem okolju pa s pomočjo upornih trakov, prostih uteži in telesne teže.

Podatki pospeška so bili zajeti s pomočjo pametnega telefona HTC Desire z vgrajenim 3-osnim pospeškometrom (Bosch Sensortec BMA150). Dejanski začetek in konec vsake ponovitve sta bila označena s pomočjo glasovnih označb. Glasovne označbe so bile podane s strani osebe z izkušnjami s treningom moči, ki je med drugim nadzorovala tudi pravilnost izvedenih vaj. Glasovne označbe so služile kot temelj za ocenjevanje natančnosti prepoznavanja števila izvedenih ponovitev ter za merjenje napake zaznavanja začetka in konca ponovitev.

Pred vsako izvedeno serijo ponovitev so testni subjekti izvedli kalibracijski gib, ki smo ga shranili v skladišče predlog kot predlogo C . Zajemanje predloge C je bilo izvedeno s pomočjo zvočnih navodil, ki so uporabnike vodila skozi postopek kalibracije ter nam omogočila zajetje predlog z natančno definiranim začetkom in koncem.

Vse vaje v omejenem okolju so bile izvedene v telovadnici z uporabo utežnih tranžerjev. Proste vaje niso bile vezane na specifično okolje in so bile izvedene bodisi na prostem v parku bodisi na domu testnega subjekta bodisi v telovadnici, vendar brez uporabe utežnih tranžerjev. Vsak subjekt je izvedel dve seriji z

desetimi ponovitvami v obeh okoljih.

Ker je trening moči mogoče izvajati z različnimi bremeni vadbe, smo izbrali različni bremeni za izvedbo ponovitev prve in druge serije. Za izbiro bremena smo uporabili dva različna protokola. V omejenem okolju smo za vsak par uporabnika in vaje izračunali mejno težo dviga (ang.: *one repetition maximum*, 1RM). Mejna teža je maksimalna obremenitev, pri kateri subjekt še lahko izvede pravilno ponovitev vaje. Ker študije kažejo, da bremena, večja od 50 % 1RM, povečujejo mišično moč, smo za izvedbo prve serije izbrali breme 50 % 1RM, za izvedbo druge serije pa breme 70 % 1RM. Za vaje v prostem okolju razmerje med različnimi bremeni ni tako natančno določeno kot za vaje v omejenem okolju. Tako je mogoče reči, da je vadba z določenim tipom upornega traku, npr. črne barve, težja od vadbe z upornim trakom zelene barve, saj je črni trak debelejši od zelenega, ni pa mogoče natančno kvantificirati razlike v obremenitvi. Izbira bremena v neomejenem okolju je tako bistveno bolj subjektivna in temelji na naslednjem protokolu: uporabniki so preizkusili uporne trakove različnih debelin in za izvedbo prve serije izbrali tistega, s katerim so bili sposobni udobno izvesti 15 ponovitev, za izvedbo druge serije pa tistega, s katerim so bili sposobni udobno izvesti 10 ponovitev. Podoben protokol smo uporabili tudi za izbiro bremena vaj s prostimi utežmi in telesno težo.

Poglavlje 5

Strojno učenje za vrednotenje intenzivnosti aerobnih aktivnosti

V tem poglavju preučimo smiselnost uporabe standardnih pametnih telefonov brez dodatnih zunanjih senzorjev za kvantitativno vrednotenje kvalitete aerobnih aktivnosti. Ovrednotimo uspešnost različnih modelov za napovedovanje intenzivnosti aerobne fizične aktivnosti, naučenih z različnimi metodami nadzorovanega strojnega učenja in z različnim naborom značilk. Poglavlje povzema raziskavo, objavljeno v [138].

5.1 Motivacija

V zadnjem desetletju so bile predlagane različne rešitve, ki omogočajo uporabo standardnih pametnih telefonov za spremjanje fizične aktivnosti. Pri tem se večina obstoječih raziskav, osredotočenih na podporo rekreativne aerobne vadbe, posveča zgolj detekciji tipa in trajanja aktivnosti (glej poglavje 2.2). Bistveno manj pozornosti je bilo posvečeno uporabi pametnih telefonov za napovedovanje intenzivnosti fizične aktivnosti. Študije kažejo, da je slednje pomembno, saj je za izboljšanje zdravja in športne pripravljenosti treba izvajati aktivnosti nad določenim nivojem intenzivnosti [139]. Dodatno imajo različne stopnje intenzivnosti izvajanja aktivnosti različne učinke na zdravje. Tako je vadba srednje intenzivnosti koristna za razvoj vzdržljivosti in gradnjo aerobnih kapacitet,

medtem ko vadba visoke intenzivnosti izboljšuje srčno-žilni sistem [139, 140]. Zaznavanje informacij o intenzivnosti vadbe je tako ključnega pomena za optimizacijo treninga.

Merjenje intenzivnosti vadbe je mogoče z zaznavanjem števila srčnih utripov na minuto [141] (več v poglavju 1.4). To se navadno izvaja s specializiranimi senzorji, ki se s pomočjo standardov in protokolov, kot sta ANT+ in Bluetooth, povezujejo s pametnimi telefonimi in drugimi vseprisotnimi senzorji. Ključna pomanjkljivost senzorjev srčnega utripa je dejstvo, da navadno predstavljajo samostojno napravo, ki jo je treba povezati s pametnim telefonom. To močno zavira vseprisotnost merjenja srčnega utripa, saj od uporabnikov zahteva nakup dodatnega senzorja. Na drugi strani so pospeškometri že vgrajeni v večino standardnih pametnih telefonov in postajajo še pogostejši v novih generacijah naprav [142].

V nadaljevanju raziščemo, ali je standardne pametne telefone z vgrajenimi pospeškometri mogoče uporabiti za zaznavanje intenzivnosti fizične aktivnosti. Pri tem se osredotočimo na uporabo različnih značilk signala pospeška za napovedovanje števila srčnih udarcev na minuto. Smiselnost in učinkovitost pristopa preverimo s študijo, v okviru katere zajamemo podatke srčnega utripa in pospeška za primer aerobne aktivnosti. Zajete podatke obdelamo z različnimi modeli numeričnega napovedovanja. Zanimata nas predvsem:

- korelacija med dejansko in napovedano vrednostjo srčnega utripa ter
- povprečna absolutna napaka v številu utripov na minuto.

V naslednjih poglavjih predstavimo metodo zbiranja podatkov in opišemo način njihove analize. Rezultati analize podatkov se odražajo v dveh bistvenih doprinosih:

- študiji primernosti značilk signala pospeška za modeliranje intenzivnosti aktivnosti in
- študiji uporabnosti različnih numeričnih napovednih modelov.

5.2 Mobilni pomočnik za zajemanje podatkov

S ciljem pridobitve podatkov na terenu, izven laboratorijskega okolja, za zbiranje podatkov razvijemo mobilno aplikacijo, ki omogoča zajemanje podatkov z različnih senzorjev. Zaradi odprtosti platforme in zmožnosti hitrega razvoja prototipov se odločimo za uporabo platforme Android. Razvita aplikacija omogoča brezščeno povezavo s senzorjem srčnega utripa ANT+ in vzorčenje naslednjih podatkov s frekvenco 4 Hz:

- izračunani srčni utrip (U_v) in
- števec srčnih utripov (U_s) .

Medtem ko izračunani srčni utrip uporabimo kot metriko intenzivnosti aktivnosti, števec srčnih utripov uporabimo zgolj v kontrolne namene za zagotavljanje konsistentnosti vzorčnega signal. Ob zajetih podatkih srčne aktivnosti s senzorjev pametnega telefona zajamemo tudi podatke pospeška na x-, y- in z-osi (A_x , A_y , A_z). Vrednosti pospeška vzorčimo s frekvenco 80 Hz. Vse zajete vrednosti po končanih aktivnostih shranimo v datoteko za analizo na osebnem računalniku.

5.3 Analiza podatkov

V tem poglavju predstavimo postopek analize podatkov. Pred tem navedemo nekaj informacij o uporabljeni programski opremi. Predobdelavo in računanje značilk izvedemo v programskem jeziku R [143], izbiro značilk in ovrednotenje različnih modelov za numerično napovedovanje pa v programskem jeziku Java s pomočjo knjižnice za podporo strojnega učenja Weka [137].

5.3.1 Predobdelava

Pred računanjem značilk predobdelamo zajete podatke in jih pretvorimo v obliko, primerno za nadaljnjo obdelavo. V prvi fazi izločimo podatke z nekonsistentnimi vrednostmi srčnega utripa, ki ne izpolnjujejo pogoja, predpisanega z enačbo 5.1.

$$U_{s[i+1]} - U_{s[i]} = 1 \quad (5.1)$$

Nato podatke pospeška (A_x , A_y , A_z) in srčnega utripa (U_v) združimo v okvirje, dolge eno sekundo. Tako izničimo vpliv neenakomerne frekvence vzorčenja pospeška, ki predstavlja pogosto omejitev večine platform pametnih telefonov. Za vsako sekundo izračunamo aritmetično povprečje zajetih vrednosti, kar v primeru vrednosti pospeška služi tudi kot enostaven filter nizkega sita, s pomočjo katerega zgradimo morebitne vrednosti pospeška, nastale kot posledica šuma pri vzorčenju.

Na koncu izračunamo še skupno magnitudo pospeška A_t , kot jo opisuje enačba 5.2. Za slednje se odločimo, saj ugotovimo, da subjekti pametnega telefona med aktivnostjo najpogosteje ne nosijo enako orientiranega. Izračun skupne magnitude nam tako omogoči robustno zaznavanje pospeška neodvisno od orientacije naprave.

$$A_t = \sqrt{A_x^2 + A_y^2 + A_z^2} \quad (5.2)$$

5.3.2 Računanje značilk

Iz predobdelanga signala z uporabo tehnike drsečega okna izračunamo množico značilk. Ker na vrednost srčnega utripa ne vpliva zgolj stopnja trenutne aktivnosti, temveč tudi stopnja pretekle aktivnosti, izberemo različne velikosti drsečega okna, in sicer dolžine 60, 50, 40, 30, 20 in 10 elementov. Izbrane velikosti oken ustrezajo intervalom v sekundah enake dolžine. To je posledica predobdelave signala, kjer zajete podatke obdelamo na način, da vsak okvir predstavlja aktivnost ene sekunde. Kljub izbiri različnih velikosti drsečega okna, za vse velikosti uporabimo enoten korak premika, in sicer okna premikamo v intervalu ene sekunde. Posledično za srčni utrip vsake sekunde izračunamo značilke pospeška za zadnjih 60, 50, 40, 30, 20 in 10 sekund.

Za vsakega izmed uporabljenih oken izračunamo devet različnih značilk (skupno torej 54 značilk). Izberemo zgolj značilke, ki so se v preteklosti že izkazale kot uporabne za prepoznavanje aktivnosti in jih je mogoče enostavno izračunati na standardnih pametnih telefonih v realnem času (glej poglavje 2.2). Uporabljene značilke, skupaj z opisom in podatki o kompleksnosti izračuna, dobro povzema [136]. Zaradi višje stopnje procesne zahtevnosti izločimo značilke iz frekvenčne domene in ohranimo zgolj tiste, ki jih je mogoče izračunati v časovni

domeni signala. Izberemo naslednje značilke:

- aritmetično povprečje A_t ,
- standardni odklon A_t ,
- najvišja vrednost A_t ,
- najnižja vrednost A_t ,
- obseg A_t ,
- koren kvadrirane povprečja A_t ,
- korelacija med A_x in A_y ,
- korelacija med A_x in A_z in
- korelacija med A_y in A_z .

Neprestano računanje 54 različnih značilk na zmogljivostno omejenih pametnih napravah je lahko procesno preveč potratno. Zato pred uporabo napovednih modelov izberemo zgolj značilke, za katere se izkaže, da je njihova napovedna vrednost najvišja. V naslednjem poglavju opišemo postopek izbire značilk.

5.3.3 Izbira značilk

Izbiro značilk izvedemo s pomočjo metode RReliefF [144]. RReliefF je nagnadnja metoda Relief, ki deluje na numeričnih podatkih, izbira med več najbližjimi sosedji in je robustna na šum. Za izbiro metode RReliefF se odločimo, saj ne predpostavlja pogojne neodvisnosti značilk in je posledično primerna za probleme z veliko prepletanja med značilkami. Pričakujemo namreč, da bodo uporabljeni značilki močno pogojno odvisni, saj različne velikosti uporabljenih drsečih oken med seboj sovpadajo v veliki meri. Tako npr. velik del okna, dolžine 60 elementov, sestavlja okno, dolžine 50 elementov, velik del okna, dolžine 50 elementov, sestavlja okno, dolžine 40 elementov, itd.

Za izbiro značilk uporabimo naslednji protokol: v prvi fazi značilke razvrstimo padajoče glede na njihovo izračunano vrednost RReliefF; nato izberemo različne

podmnožice značilk, pri čemer najmanjša podmnožica vsebuje zgolj prvi dve značilki, vse naslednje podmnožice pa značilko več kot prejšnja. Posledično prva podmnožica vsebuje dve značilki z najvišjo vrednostjo RReliefF, druga podmnožica tri značilke z najvišjo vrednostjo RReliefF itd. Vsako podmnožico značilk uporabimo za učenje in ovrednotenje štirih različnih modelov za numerično napovedovanje.

5.3.4 Modeli za numerično napovedovanje

Za študijo primernosti značilk in vrednotenje natančnosti napovedovanja intenzivnosti aktivnosti uporabimo štiri različne algoritme nadzorovanega strojnega učenja. Ker za metriko intenzivnosti aktivnosti izberemo srčni utrip, katerega vrednost je podana numerično, se osredotočimo na algoritme, ki omogočajo regresijo oz. učenje na osnovi numeričnih učnih vrednosti. Izberemo naslednje regresijske algoritme:

- večnivojski perceptron,
- linearno regresijo,
- regresijska drevesa in
- metodo podpornih vektorjev.

Izbrani algoritmi so podrobneje opisani v poglavju 3.3, zaradi berljivosti tukaj povzemamo zgolj princip njihovega delovanja in navajamo uporabljenе parametre.

Večnivojski perceptron (VP, več v poglavju 3.3.3) je algoritem, temelječ na principu nevronskih mrež, ki za učenje uporablja metodo vzvratnega učenja. Sestavlja ga množica vozlišč, združenih v nivoje, pri čemer velja, da je vsak nivo polno povezan s sosednjimi nivoji. Za potrebe analize podatkov uporabimo VP z dvema skritima nivojem, od katerih ima vsak po tri vozlišča.

Linearna regresija (LR, več v poglavju 3.3.1) je eden izmed najenostavnejših algoritmov strojnega učenja. Deluje tako, da ločitveno premico prilagodi množici točk na način, ki minimizira vsoto kvadratov napak med napovedanimi in dejanskimi vrednostmi učne množice. Za vrednotenje značilk uporabimo algoritem

enostavne linearne regresije, ki izbere zgolj parameter, ki definira model z najmanjšo kvadrirano napako.

Regresijska drevesa (RD, več v poglavju 3.3.4) ovrednotimo s pomočjo algoritma Wekinega REPTree. REPTree je hiter algoritem, ki za gradnjo regresijskih dreves uporablja informacijski pribitek in rezanje. Za potrebe analize podatkov rezanje drevesa popolnoma izključimo, saj nas ne zanima interpretativnost dobljenega modela, temveč zgolj njegova natančnost.

Za ovrednotenje metode podpornih vektorjev (SVM, več v poglavju 3.3.5) uporabimo Wekino implementacijo SMOreg. SMOreg uporablja algoritem zaporedne minimalne optimizacije za učenje metode podpornih vektorjev s pomočjo polinomskih ali Gaussovih jeder. V našem primeru izberemo Gaussovo jedro z vrednostjo $\gamma = 0.01$, kar nam omogoči podporo nelinernih povezav med atributi.

Ovrednotenje omenjenih algoritmov izvedeno brez dodatne optimizacije parametrov modelov. Posledično navedeni rezultati predstavljajo konzervativno napoved natančnosti algoritmov, ki ponuja prostor za izboljšave z različnimi metodami optimizacije parametrov.

5.4 Zbiranje podatkov

Za ovrednotenje modelov zajamemo podatke o pospešku in srčnem utripu med aktivnostjo badmintona. Tega izberemo, saj predstavlja aktivnost, katere izvajanje vključuje širok spekter različnih intenzivnosti, hkrati pa je dovolj podobna ostalim popularnimi aerobnimi aktivnostim, ki ne omogočajo zaznavanja intenzivnosti vadbe s pomočjo ustaljenih metod, temelječih na geografskem lociranju (kot so npr. košarka, rokomet, tenis ipd.). V raziskavo rekrutiramo pet zdravih posameznikov (štirje moški, ena ženska; vsi stari 26 let), ki redno rekreativno igrajo badminton. Raziskavo izvedemo v okviru ozke starostne skupine, saj študije kažejo močno povezanost srčnega utripa in starosti [145], ki bi zaradi majhnega števila udeležencev lahko vnesla šum v napovedne modele. Podpora širšega starostnega spektra je tako mogoča v okviru nadaljnjih raziskav s pomočjo hierarhičnih modelov vrednotenja aktivnosti.

Med zbiranjem podatkov na testne subjekte namestimo senzor srčnega utripa Garmin ANT+ in pametni telefon Sony Ericsson Xperia Active, ki služi merjenju



Slika 5.1: Položaj namestitve pametnega telefona med izvajanjem meritev.

pospeška in zbiranju podatkov. Medtem ko je za senzor srčnega utripa predpisani naprsni položaj nošenja naprave, smo imeli pri izbiri položaja namestitve pametnega telefona na voljo več manevrskega prostora. Na osnovi preliminarnih testiran s subjekti ugotovimo, da je namestitev pametnega telefona pod kolenom nedominantne noge manj moteča od namestitve na roko ali bok. Namestitev pametnega telefona izvedemo s pomočjo športnega žepka, kot prikazuje Slika 5.1.

Skupno zberemo 377.28 minut aktivnosti igre badmintona, v povprečju 74.49 ± 5.01 minut za posamezni subjekt. Preliminarna analiza števca srčnih utripov U_s pokaže nekonsistentnost dela podatkov. Razlog za to je najverjetnejše predstavljal slab stik med senzorjem srčnega utripa in subjektom. Nekonsistentne dele odstranimo iz signala v postopku čiščenja. Po izvedenem postopku čiščenja za analizo ostane 304.19 minut aktivnosti, v povprečju 59.89 ± 10.78 minut na posameznika.

Poglavlje 6

Prepoznavanje intenzivnosti anaerobnih aktivnosti z nosljivimi senzorji

V tem poglavju opišemo rešitev, ki omogoča kvantitativno vrednotenje kvalitete treninga moči s pomočjo nosljivih senzorjev. Predlagamo algoritom, ki omogoča zaznavanje intenzivnosti treninga moči. Pri tem se opremo na metode nadzorovanega strojnega učenja. Algoritom ovrednotimo za različne konfiguracije senzorjev in različne parametre strojnega učenja (vpliv velikosti učne množice na natančnost) ter obdelave časovnih signalov (velikost in prekrivanje drsečega okna).

6.1 Motivacija

Medtem ko v Poglavjih 4 in 5 predstavimo metode za kvantitativno vrednotenje kvalitativnih parametrov fizične aktivnosti zgolj z uporabo standardnih pametnih telefonov, v tem poglavju razširimo nabor senzorjev in predstavimo algoritom, ki omogoča vrednotenje kvalitete anaerobnih aktivnosti na osnovi podatkov, zajetih s pomočjo množice nosljivih senzorjev. Pri tem se osredotočimo na vrednotenje intenzivnosti anaerobnih aktivnosti, konkretno, intenzivnosti treninga moči. Ta je pomembna, saj:

-
- je vadbeni efekt vaj, izvedenih s prenizko intenzivnostjo, nezadovoljiv,
 - previsoka intenzivnost vadbe vodi v pretreniranost (angl.: *overtraining*), ki se odraža v slabših rezultatih vadbe oz. lahko v skrajnem primeru vodi celo do poškodbe [146].

Zaznavanje intenzivnosti vadbe v realnem času tako nudi platformo za samodejno beleženje podatkov o kvaliteti vadbe in omogoča podajanje povratnih informacij o morebitni prilagoditvi vadbe med samim izvajanjem aktivnosti, torej takrat, ko so takšne informacije za uporabnika najbolj relevantne.

Predlagana metoda temelji na podatkih, zajetih s pomočjo nizkocenovnih in potencialno vseprisotnih senzorjev za zaznavanje pospeška. Ti omogočajo neinvazivno namestitev na uporabnika in zaradi svoje majhnosti ne motijo samega procesa vadbe. Cilj predlagane metode je za posamezno izvedeno aktivnost v realnem času prepoznati:

- tip aktivnosti in
- intenzivnost aktivnosti.

Za dosego slednjega se opremo na metode nadzorovanega strojnega učenja, s pomočjo katerih problem definiramo kot iskanje dveh napovednih modelov, prvega, klasifikacijskega, ki omogoča napovedovanje kategorije tipa posamezne aktivnosti, in drugega, regresijskega, ki omogoča napovedovanje zvezne numerične vrednosti, ki označuje intenzivnost aktivnosti. Pri tem različne tipe aktivnosti predstavljajo različne vaje treninga moči, različne intenzivnosti pa ocene, temelječe na Borgovi lestvici intenzivnosti (BLI, glej poglavje 1.4). Medtem ko se pri napovedovanju intenzivnosti aerobnih aktivnosti opremo na intenzivnost, definirano na osnovi srčnega utripa, se pri anaerobnih aktivnostih kljub višji stopnji subjektivnosti odločimo za BLI. Menimo namreč, da je ta primernejša za vrednotenje kratkotrajnih aktivnosti, saj so vrednosti srčnega utripa časovno zakasnjene, trajanja zakasnitrve pa ni mogoče enostavno enolično določiti, saj je to odvisno od fizične pripravljenosti posameznika. Dodatno BLI vključuje tudi parametre počutja posameznika, ki se ne izražajo v vrednostih srčnega utripa.

6.2 Nosljiva platforma za podporo treninga moči

V tem poglavju opišemo prototip nosljive platforme za podporo treninga moči. Pri tem se omejimo zgolj na uporabo standardnih pametnih telefonov in vseprisotnih senzorjev za zaznavanje pospeška. Opišemo tudi nabor vaj, uporabljen za ovrednotenje natančnosti predlaganega algoritma.

6.2.1 Senzorji

S ciljem zaznavanja kompleksnejših podatkov o izvedenih aktivnostih prototip sistema za vrednotenje intenzivnosti treninga moči definiramo z naslednjimi komponentami:

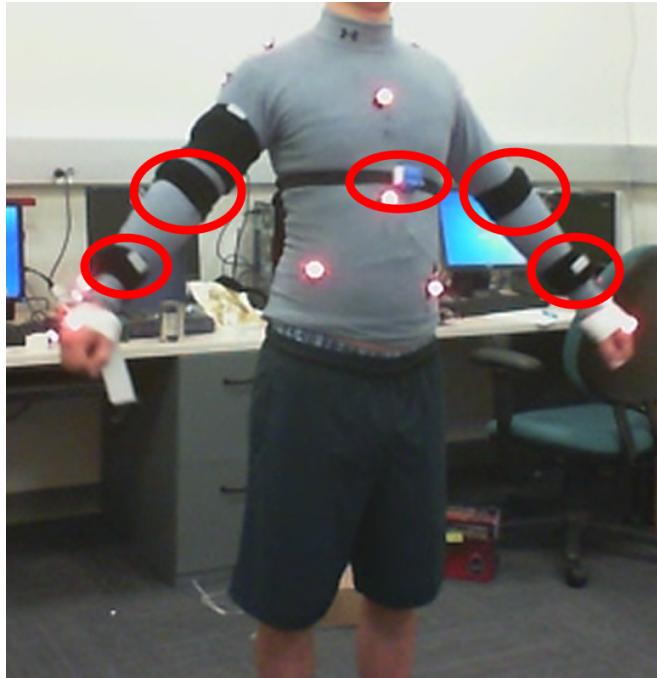
- standardni pametni telefon in
- pet nosljivih senzorjev za zaznavanje pospeška.

Osnovne komponente sistema so med seboj s pomočjo tehnologije Bluetooth povezane v brezžično lokalno piko omrežje (ang.: *piconet*). Medtem ko nosljivi senzorji skrbijo le za nemoteno zajemanje surovih podatkov pospeška in njihovo posredovanje centralni komponenti sistema, torej pametnemu telefonu, se na slednjem izvaja vsa obdelava zajetih podatkov (več v poglavju [6.3](#)). Dodatno pametni telefon z množico podprtih komunikacijskih protokolov in z različnimi vhodno/izhodnimi enotami nudi potencial za posredovanje podatkov na oddaljene lokacije in podajanje povratnih informacij v realnem času.

Nosljive senzorje namestimo na pet različnih telesnih lokacij, ki omogočajo zaznavanje gibanja za testni nabor vaj, predstavljenih v naslednjem poglavju. Izbrane lokacije namestitve, prikazane na Sliki [6.1](#), so:

- prsni koš,
- levo in desno zapestje ter
- leva in desna nadlaket.

Za pritrditev senzorjev uporabimo zgolj pripomočke, ki sodijo v standardni nabor rekreativne športne opreme. Tako senzorje na zapestje in nadlaket pritrdimo



Slika 6.1: Položaj namestitve nosljivih senzorjev pospeška med vadbo.

s pomočjo elastičnega bombažnega traku proti potenju, senzor, nameščen na prsnici koš, pa pritrdimo kar na naprsni senzor srčnega utrip. Takšna namestitev senzorjev je skladna s ciljem, da nameščeni senzorji ne motijo izvajane aktivnosti.

6.2.2 Nabor vaj

Sistem ovrednotimo za množico vaj treninga moči. Pri tem se omejimo zgolj na vaje za krepitev zgornjega dela telesa. Za te se odločimo, saj so raziskave, ki temeljijo na analizi kvalitete aktivnosti zgornjih okončin, veliko manj pogoste od raziskav, ki se osredotočajo na spodnje okončine (npr. vrednotenje vzorcev hoje [147], teka [66, 67, 68]).

Izberemo nabor šestih različnih vaj za trening moči zgornjega dela telesa (Tabela 6.1). Slika 6.2 natančneje prikazuje gibe ob izvedbi posameznih vaj. V prvi vrstici je prikazana vaja ukriviljenja rok (UR), druga vrstica prikazuje izvedbo vaje izteg roke nad glavo (IR), v tretji in četrtni vrstici pa sta prikazana sprednji (SD) in bočni navpični dvig (BD). Vrstica pet prikazuje izvedbo upognjenega veslanja (UV), vrstica šest pa potisk nad glavo (PG). Pri izvedbi vseh

Tabela 6.1: Seznam izbranih vaj za trening moči zgornjega dela telesa.

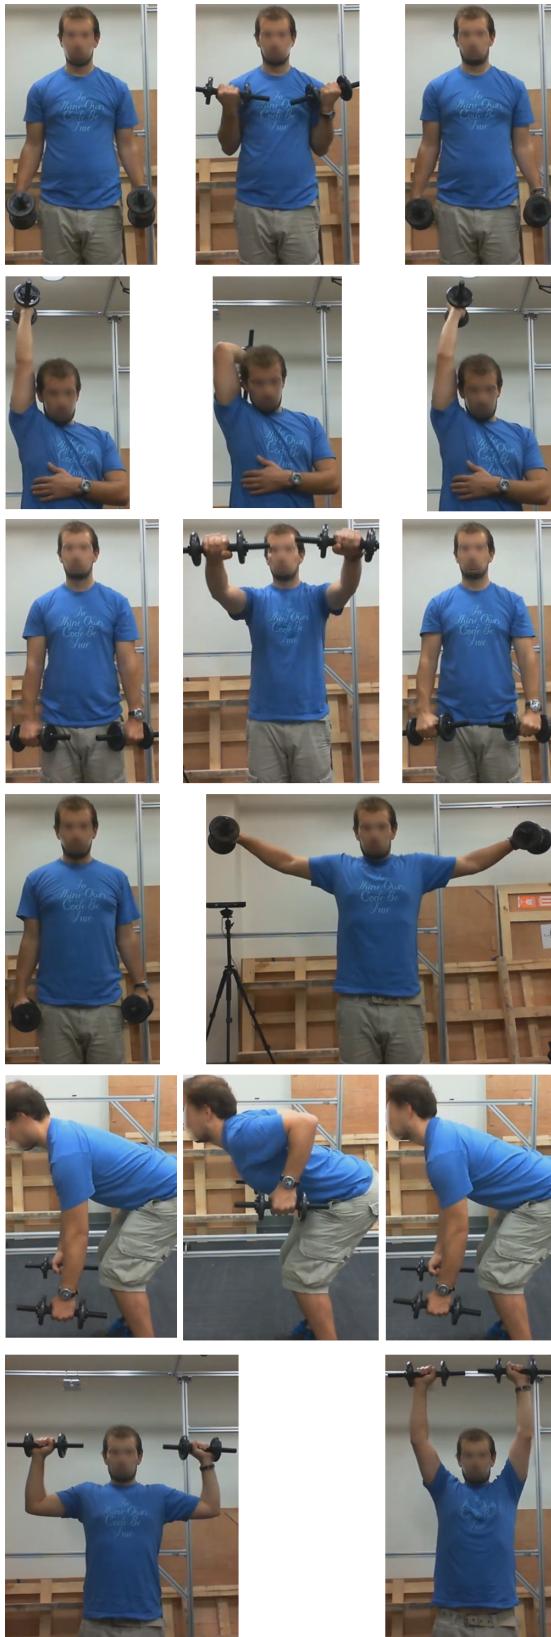
Mišična skupina	Vaja
roke	Ukrivljenje rok stoje (UR)
roke	izteg roke nad glavo stoje (IR)
hrbet	upognjeno veslanje stoje (UV)
rame	potisk nad glavo sede (PG)
rame	sprednji navpični dvig stoje (SD)
rame	bočni navpični dvig stoje (BD)

vaj, z izjemo iztega roke nad glavo, sodelujeta obe zgornji okončini. Kljub obstoju izvedenih iztega nad glavo, ki vključujejo obe zgornji okončini, se zaradi varnosti sodelujočih odločimo za izvedbo vaje zgolj z eno okončino. Izteg nad glavo namreč vključuje premik težkega bremena tesno ob glavi izvajalca, zato izvajalcem omogočimo, da si v primeru pretežkega bremena pomagajo s prosto roko. Namenoma v nabor vaj vključimo tudi vaje, katerih sestavnimi gibi so si zelo podobni. Primer takšnih vaj predstavlja navpični bočni in navpični sprednji dvig bremena. Obe vaji se odražata v podobnem navpičnem dvigu, le da je ta v primeru prve vzporeden boku izvajalca vaje, v primeru druge pa pravokoten nanj. Z ovrednotenjem algoritma za vaji navpičnega bočnega in prednjega dviga preverimo uspešnost predlaganega algoritma za vaje s podobnimi gibalnimi vzorci.

Izbrane vaje izvedemo z različnimi bremenimi, ki se odražajo v vadbi različnih stopenj intenzivnosti. Uporabljeni bremeni, izražena kot obremenitev posamezne zgornje okončine, so:

- brez bremena,
- 1.36 kilograma (3 lbs),
- 3.63 kilograma (8 lbs),
- 6.80 kilograma (15 lbs) in
- 9.07 kilograma (20 lbs).

Bremena za posamezno vajo, z izjemo iztega nad glavo, so izražena za posamezno zgornjo okončino in jih je, za informacijo o skupnem bremenu vadbe, treba podvojiti.



Slika 6.2: Vizualizacija izvedenih vaj.

6.3 Algoritem vrednotenja intenzivnosti

Vrednotenje intenzivnosti anaerobnih aktivnosti definiramo kot večnivojski problem, ki ga naslovimo s pomočjo hierarhičnega algoritma. Ideja hierarhičnih algoritmov je razbitje problema na več v nivoje povezanih enostavnnejših podproblemov, pri čemer rezultati nižjih nivojev omogočajo uspešnejše delovanje višjih nivojev [148]. Prepoznavanje intenzivnosti aktivnosti treninga moči predstavimo kot dvonivojski problem, pri čemer na prvem nivoju vršimo prepoznavanje tipa aktivnosti, na drugem pa končno vrednotenje intenzivnosti glede na prepoznani tip aktivnosti. Motivacija za uporabo omenjenega pristopa temelji na opažanjih, da:

1. se različni tipi aktivnosti treninga moči odražajo v podobnih odtisih signala pospeška, neodvisno od intenzivnosti izvedbe posameznih vaj,
2. se spremembu intenzivnosti aktivnosti treninga moči odraža v podobnem odtisu signala pospeška, ki je lokalen za tip izvedene vaje.

Slednje nam omogoča zaznavanje intenzivnosti različnih aktivnosti treninga moči s pomočjo dveh nivojev napovednih modelov z različno stopnjo specializacije. Prvi nivo izhaja iz opažanja 1 in je specializiran za prepoznavanje različnih aktivnosti, ki se odražajo v spremembah pospeška, nastalih kot posledica gibanja okončin v različne smeri. Drugi nivo izhaja iz opažanja 2 in se osredotoča zgolj na zaznavanje intenzivnosti že prepoznanih aktivnosti. Različne intenzivnosti se namreč odražajo v različnih odtisih pospeška, ki so si za enak tip vaje primerljive intenzivnosti med seboj podobni. Tako je npr. za vajo biceps visoke intenzivnosti značilno nestabilno nihanje trupa, za vajo navpičnega stranskega dviga visoke intenzivnosti nepopolni razpon gibanja itd.

Napovedne modele definiramo s pomočjo metod nadzorovanega strojnega učenja, konkretneje z metodo SVM (več v poglavju 3.3.5), saj se je ta v preteklosti že izkazala za zelo uporabno v domeni prepoznavanja fizičnih aktivnosti (glej poglavje 2.2). Pred posredovanjem podatkov v napovedni model SVM surove vrednosti pospeškometra najprej obdelamo v fazah predobdelave in izračuna značilk. To na kratko opišemo v naslednjih podpoglavljih.

6.3.1 Predobdelava

V postopku predobdelave surove podatke, zajete s senzorjev pospeška, preoblikujemo v obliko, primerno za uporabo z metodami nadzorovanega strojnega učenja. Predobdelavo sestavlja dva zaporedna koraka:

- časovna sinhronizacija podatkov in
- enakomerno ponovno vzorčenje.

V koraku časovne sinhronizacije podatke poravnamo glede na čas vzorčenja. Časovno sinhronizacijo izvedemo na osnovi časa prihoda paketa senzorskih podatkov na pametni telefon. To pomeni, da zavrzemo podatke o lokalnem času vzorčenja posameznega senzorja in upoštevamo zgolj čas, dodeljen s strani pametnega telefona kot osrednje naprave omrežja. Pri tem ne utrpimo izgube natančnosti, saj je latenca prenosa podatkov zanemarljiva v odnosu do dinamike izvedenih gibov.

Časovno poravnane podatke podobno kot v poglavju 4.3.1 enakomerno ponovno vzorčimo. To nam omogoča, da v naslednjih fazah upravljamo s podatki, ki so časovno enakomerno razporejeni. Enakomerno ponovno vzorčenje izvedemo neodvisno za posamezne senzorske kanale. To pomeni, da ga za pet senzorjev, od katerih vsak zajema podatke o spremembah pospeška v treh različnih smereh, izvedemo 15-krat. Enakomerno razporejene podatke na koncu razporedimo v intervalu z milisekundno natančnostjo.

6.3.2 Priprava značilk

Predobdelane podatke v naslednjem koraku pretvorimo v množico značilk. To storimo tako, da za podatke posameznega kanala senzorja, združene znotraj premikajočega se drsečega okna, izračunamo različne statistične vrednosti. Tako močno zmanjšamo tudi dimenzije problema in omogočimo hitrejše izvajanje algoritma. Za izračun izberemo značilke, ki jih lahko v grobem razdelimo v naslednji kategoriji:

- enosenzorske značilke (EZ) in
- združene značilke (ZZ).

Za EZ velja, da za njihov izračun zadostujejo podatki, pridobljeni z enega senzorja. Prednost uporabe takšnih značilk je, da jih je potencialno mogoče izračunati neodvisno od osrednje naprave omrežja, torej na samem nosljivem senzorju. To močno zmanjša količino podatkov, posredovanih med senzorji in osrednjo napravo omrežja, ter podaljša njuno avtonomijo. EZ zaradi nižje kompleksnosti izračuna izberemo zgolj iz časovne domene signala [136]. Uporabljene značilke so:

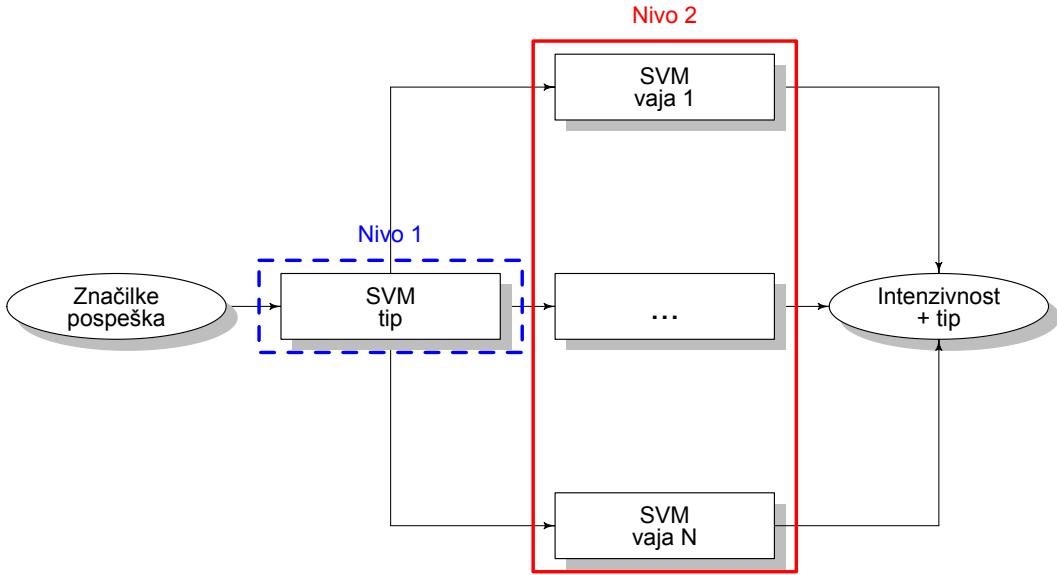
- aritmetično povprečje,
- standardni odklon,
- minimum,
- maksimum,
- razpon in
- RMS.

ZZ ob EZ vključujejo še večsenzorske značilke, ki omogočajo zajem kompleksnejših informacij gibanja, kot je npr. sinhronost premikanja različnih okončin. Njihova poglavita slabost je, da za izračun potrebujejo podatke vsaj dveh senzorjev, kar zahteva omrežni prenos celotnega toka podatkov. Od večsenzorskih značilk izberemo zgolj korelacijo, ki jo izračunamo za različne kombinacije senzorjev in osi. Kljub temu, da je kompleksnost izračuna korelacije nekoliko višja od kompleksnosti izračuna EZ [136], razliko v kompleksnosti sprejmemo kot dočustno, saj je izračun mogoče opraviti na osrednji procesni napravi. ZZ tako ob EZ združujejo še korelacije osi različnih senzorjev.

6.3.3 Prepoznavanje aktivnosti in intenzivnosti

Izračunane značilke predstavljajo vhod v napovedne modele SVM na obeh nivojih in služijo prepoznavanju tipa ter intenzivnosti aktivnosti. V skladu z dobro prakso uporabe metode SVM jih pred posredovanjem v posamezni nivo skaliramo in usrediščimo [118].

Predlagani algoritem združuje uporabo metode SVM za:



Slika 6.3: Diagram poteka algoritma za vrednotenja intenzivnosti. Črtkan moder kvadrat prikazuje klasifikator prvega nivoja, ki omogoča prepoznavanje tipa aktivnosti, poln rdeč kvadrat pa napovedne modelje drugega nivoja, ki služijo zaznavanju intenzivnosti aktivnosti. Vhod algoritma predstavlja izračunane značilke pospeška, izhod pa zazna intenzivnost in tip aktivnosti.

- kategorično klasifikacijo in
- zvezno regresijo.

SVM uporabimo v vlogi kategoričnega klasifikatorja na nivoju prepoznavanje tipa izvedenih aktivnosti, predstavljenih v poglavju 6.2.2. Dodatno naboru prepoznavanih aktivnosti dodamo še aktivnosti, ki označujejo nedefinirano nevadbeno aktivnosti. Nivo regresijskih napovednih modelov služi prepoznavanju intenzivnosti vadbe, izražene številčno v obliki BLI. Ta zajema cela števila na intervalu [6, 20]. V primeru napovednih modelov obeh nivojev se odločimo za Gaussovo RBF-jedro, saj praviloma nudi višjo stopnjo natančnosti za podatke, ki ne temeljijo na linearnih relacijah. Dodatno za vsakega izmed napovednih modelov s pomočjo mrežnega iskanja (ang.: *Grid search*) izvedemo optimizacijo parametrov C in σ , pri čemer σ izraža γ v skladu z enačbo $\gamma = \frac{1}{2\sigma}$ (glej poglavje 3.3.5).

Medtem ko nivo prepoznavanja aktivnosti sestavlja zgolj en napovedni model

SVM, nivo zaznavanja intenzivnosti sestavlja množica modelov SVM, od katerih je vsak specializiran za prepoznavanje intenzivnosti posameznega tipa aktivnosti. Takšna struktura omogoča enostavno podporo dodatnih aktivnosti brez bistvenega dviga procesne zahtevnosti metode. Dodatne tipe aktivnosti je namreč mogoče podpreti z uvajanjem novih napovednih modelov na nivoju zaznavanja intenzivnosti. Pri tem obstoječi modeli nivoja zaznavanja intenzivnosti ostanejo enaki, spremeni se zgolj napovedni model na nivoju prepoznavanja aktivnosti, saj ga je treba naučiti prepoznavanja dodanih aktivnosti.

Napovedni modeli obeh nivojev kot vhod prejmejo izračunane značilke, izhod algoritma pa predstavlja tip prepoznane aktivnosti in zaznana intenzivnost vadbe. Celotno delovanje algoritma natančneje prikazuje Slika 6.3.

6.4 Zbiranje podatkov

V okviru učenja in ovrednotenje predlaganega algoritma smo izvedli eksperiment, za katerega smo rekrutirali 11 zdravih posameznikov. Tabela 6.2 opisuje pomembne atributte udeležencev raziskave. Posamezniki so pred sodelovanjem v eksperimentu podpisali soglasje (Dodatek C), s katerim so se seznanili s potekom raziskave.

Tabela 6.2: Opis pomembnih atributov udeležencev raziskave.

Atribut	Vrednost
Spol	3 ženske, 8 moških
Starost	27 ± 4.5
Višina	172.2 ± 10.6
Teža	66.6 ± 9.4

Vsak posameznik je s štirimi različnimi bremenimi izvedel deset ponovitev vsake izmed vaj, predstavljenih v poglavju 6.2.2. Pri tem so bila bremena izbrana glede na spol udeleženca. Ženske so prvo ponovitev izvedle brez bremena, naslednje tri pa z bremenimi 1.36, 3.63 in 6.8 kilograma. Moški so vse ponovitve izvedli z bremenom, in sicer s težo 1.36, 3.63, 6.8 in 9.07 kg. Pred prvo ponovitvijo so tako moški kot ženske brez bremena izvedli testno serijo celotnega nabora vaj. Ob tem



Slika 6.4: Senzor za merjenje pospeška SHIMMER.

so sledili videonavodilom na zaslonu, ki so udeležence seznanila s posameznimi vajami in jim podala praktične nasvete za njihovo pravilno izvedbo. Podobnih videonavodil, a v krajši obliki, so bili uporabniki za osvežitev postopka izvedbe vaje deležni tudi pred izvajanjem vsake posamezne vaje.

Med izvajanjem vaj smo za vsakega izmed udeležencev v eksperimentu zajeli naslednje podatke:

- pospešek,
- 3D-koordinate gibanja v prostoru,
- EMG-signal mišic bicepsa in tricepsa desne roke,
- video.

V eksperimentu smo uporabili pet nosljivih tridimenzionalnih senzorjev za merjenje pospeška (Shimmer Research, Dublin, Ireland, Slika 6.4), nameščenih na lokacije, opisane v poglavju 6.2.1. Frekvenca vzorčenja senzorjev je znašala približno 30 Hz. Zajeti podatki so bili brezzično posredovani pametnemu telefonu, ki je s pomočjo razvite aplikacije podatke shranil v obliko, primerno za strojno obdelavo. Zajemanje 3D-koordinat v prostoru smo izvedli s pomočjo optičnega sistema za zajemanje gibanja Impulse (PhaseSpace Inc., San Leandro, CA). Sistem s frekvenco 480 Hz zajema 3D-položaj aktivnih LED-markerjev in omogoča zaznavanja gibanja z ločljivostjo 3600 X 3600 megatočk. Slednje nudi informacije o gibanju v prostoru z manj kot milimetrsko stopnjo napake in omogoča prepoznavanje do 48 različnih markerjev. Za zajemanje gibanja smo uporabili 10

kamer v krožni konfiguraciji, ki so pokrivale prostor v izmeri 2 X 2 metra. Sistem smo kalibrirali za vsakega posameznega udeleženca v eksperimentu. Zajete podatke o 3D-gibanju smo uporabili kot referenco za določitev časa začetka in konca posameznih ponovitev vaj. Podobno smo zajeit video uporabili za anotacijo posameznih segmentov aktivnosti z ustrezno vajo in bremenom.

Po vsaki izvedeni seriji je udeleženec eksperimenta podal:

- samooceno pravilnosti izvedbe vaje in
- oceno intenzivnosti vadbe na osnovi BLI.

Samoocena pravilnost izvedbe vaje je temeljila na oceni od 1 do 5, pri čemer je ocena 5 pomenila, da uporabnik meni, da je vajo izvedel popolnoma pravilno, 1 pa, da je vajo izvedel popolnoma nepravilno. Stopnje BLI so natančneje opisane v poglavju [1.4](#).

Poglavlje 7

Rezultati

V tem poglavju predstavimo rezultate ovrednotenja predlaganih algoritmov in metod. Najprej predstavimo uporabljene metrike ocenjevanja uspešnosti algoritmov. Nadaljujemo z rezultati algoritma zaznavanja treninga moči s standardnimi mobilnimi napravami (glej poglavje 4), nato predstavimo rezultate ovrednotenja različnih kombinacij značilk in metod strojnega učenja za prepoznavanje aerobnih aktivnosti (glej poglavje 5). Na koncu pa predstavimo še rezultate ovrednotenja algoritma za prepoznavanje intenzivnosti anaerobne vadbe s pomočjo nosljivih senzorjev (glej poglavje 6).

7.1 Metrike ocenjevanja algoritmov

Rezultate uspešnosti predlaganih algoritmov predstavimo s pomočjo različnih metrik ocenjevanja algoritmov. Izbrane metrike se razlikujejo glede na tip in strukturo vrednosti izhodnih podatkov napovednih modelov. Z ozirom na tip izhoda napovednih modelov ločimo metrike za ocenjevanje algoritmov s kategoričnim in numeričnim izhodom. Nadalje je struktura izhodnih vrednosti napovednih modelov s kategoričnim izhodom lahko uravnotežena ali neu-ravnotežena. Uravnotežena struktura izhoda napovednih modelov predstavlja izhodne vrednosti, za katere velja, da so njihove kategorije enakomerno zastopane. To v primeru napovednega modela z dvema različnima kategorijama pomeni, da je frekvenca pojavnosti posamezne kategorije v grobem podobna. Na drugi strani

neuravnotežena struktura izhodnih vrednosti predstavlja modele, za katere velja, da je pojavnost posamezne izhodne kategorije bistveno pogostejša od ostalih kategorij.

Uspešnost predlaganih algoritmov ovrednotimo s pomočjo naslednjih metrik:

- natančnost (ang.: *accuracy*),
- preciznost (ang.: *precision*),
- priklic (ang.: *recall*),
- F-vrednost (ang.: *F-score*),
- koren povprečne vrednosti kvadrirane napake (ang.: Root Mean Squared Error, RMSE).

Pred natančnejšim opisom uporabljenih metrik s pomočjo Tabele 7.1 predstavimo njihove ključne sestavne komponente. Pravilno napoved (TP) predstavlja primer, ko je izhod napovedi p enak dejanskemu izhodu, nepravilna napoved (FP) pa primer, ko je dejanski izhod n . Nasprotno, pravilna nenapoved (TN) predstavlja primer, ko je izhod napovedi n enak dejanskemu izhodu, manjkajoča napoved (FN) pa primer, ko je dejanski izhod enak p . V primeru prepoznavanja ponovitev treninga moči TP predstavlja primer prepoznane ponovitve v trenutku, ko se je ta dejansko zgodila, FP pa primer prepoznane ponovitve, ko te ni bilo. TN predstavlja primer, ko se ponovitev ni zgodila niti ni bila prepoznanata, FN pa primer, ko se je ponovitev zgodila, a ni bila prepoznanata.

Tabela 7.1: Notacija rezultatov napovedi binarnega klasifikacija problema.

		Dejanski izhod	
		p	n
Napovedan izhod	p'	Pravilna napoved (<i>True Positive</i> , TP)	Nepravilna napoved (<i>False Positive</i> , FP)
	n'	Nepravilna manjkajoča napoved (<i>False Negative</i> , FN)	Pravilna manjkajoča napoved (<i>True Negative</i> , TN)

Natančnost (enačba 7.1) predstavlja razmerje med pravilno zaznanimi dogodki in celotno populacijo dogodkov. Uporablja se za vrednotenja uspešnosti

algoritmov s kategoričnim in uravnoteženim izhodom. Slednjega v našem primeru predstavlja algoritmom prepoznavanja tipa različnih fizičnih aktivnosti.

$$natančnost = \frac{TP + TN}{TP + FL + FN + TN} \quad (7.1)$$

Preciznost (enačba 7.2), imenovana tudi pozitivna napovedna vrednost, povezuje število vseh pravilno prepoznanih dogodkov s številom vseh zaznanih dogodkov. V primeru prepoznavanja ponovitev treninga moči povezuje preciznost število pravilno prepoznanih ponovitev s številom vseh vzorcev, zaznanih kot ponovitve.

$$preciznost = \frac{TP}{TP + FP} \quad (7.2)$$

Priklic (enačba 7.3), imenovan tudi specifičnost, predstavlja razmerje med pravilno zaznanimi dogodki in vsemi dogodki, ki bi jih bilo treba zaznati. V primeru prepoznavanja ponovitev treninga moči predstavlja priklic razmerje med pravilno zaznanimi ponovitvami in vsemi ponovitvami, ki bi morale biti zaznane.

$$priklic = \frac{TP}{TP + FN} \quad (7.3)$$

Preciznost in priklic sta metriki vrednotenja uspešnosti algoritmov s kategorično napovedno vrednostjo, katerih vrednosti izhoda so močno neuravnovešene. To je značilno za prepoznavanje vzorcev v toku signala, saj je število pozitivnih primerkov, ki jih v našem primeru predstavljajo pravilno zaznane ponovitve treninga moči, bistveno nižje od števila negativnih primerkov, ki ne predstavljajo ponovitev in jih v našem primeru predstavlja množica vseh podzaporedij toka vrednosti pospeška.

F-vrednost (enačba 7.4) je metrika, ki predstavlja harmonično povprečje preciznosti in priklica ter omogoča opis deleža nepravilnih in manjkajočih napovedi v okviru ene vrednosti. To omogoča objektivno vrednotenje kategoričnih napovednih algoritmov z neuravnoteženimi vrednostmi izhoda.

$$F\text{-vrednost} = 2 \cdot \frac{preciznost \cdot priklic}{preciznost + priklic} \quad (7.4)$$

Za vrednotenje natančnosti številčnih napovednih modelov uporabimo metriko RMSE. RMSE omogoča kvantifikacijo razlike med napovedano in dejan-

sko številčno vrednostjo. Uporabimo ga za napovedovanje intenzivnosti aerobnih in anaerobnih aktivnosti, katerih vrednost izrazimo številčno. Enačba 7.5 formalizira RMSE-metriko, pri čemer \hat{Y} in Y predstavljata vektorja napovedanih in dejanski izhodnih vrednosti dolžine n .

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2} \quad (7.5)$$

7.2 Vzorec

Predlagane algoritme smo ovrednotili s pomočjo treh eksperimentov, v katerih je skupno sodelovalo 26 zdravih posameznikov. Pri rekrutiranju posameznikov smo se poslužili metode oportunističnega vzorčenja. To pomeni, da sodelujočih v eksperimentih nismo izbrali s ciljem zadostitve specifične porazdelitve vzorca, temveč smo v vzorec vključili vse, ki so se odzvali na povabilo za sodelovanje. Posledično so moški v našem vzorcu zastopani pogosteje kot ženske (18 moških, 8 žensk). To je najverjetnejše odraz dejstva, da se moški pogosteje ukvarjajo z izvedenimi fizičnimi aktivnosti (npr. treningom moči). Oportunistično vzorčenje nam je omogočilo hitrejšo izvedbo eksperimentov z večjo množico sodelujočih, pri čemer smo nekoliko žrtvovali zgolj možnost posplošenja rezultatov. Za slednjo menimo, da bistveno ne vpliva na uporabnost rezultatov doktorskega dela, saj predlagani algoritmi nakazujejo zgolj smiselnost uporabe za podporo predstavljenih športnih aktivnosti in ne implicirajo doseganja natančnosti rezultatov, primerljive z nadzorovanimi kliničnimi študijami.

Izgubo splošnosti zaradi oportunističnega vzorčenja omilimo z dosledno uporabo navzkrižnega preverjanja po protokolu izpusta testnega (ang.: *leave-one-subject-out cross validation*). Ta veleva, da pri uporabi metod nadzorovanega strojnega učenja v fazi učenja ne uporabimo podatkov subjekta, za katerega izvedemo testiranje uspešnosti algoritma. Posledično algoritem nujno vedno preverjamo s svežimi podatki, na katere še ni naletel v fazi učenja, kar zmanjšuje možnosti prekomernega prileganja.

Strukturo vzorcev sodelujočih v raziskavi natančneje povzemajo poglavja 4.4, 5.4 in 6.4, ki opisujejo način in postopek zbiranja podatkov

za posamezne predlagane algoritme.

7.3 Vrednotenje pravilnosti anaerobnih aktivnosti

V tem poglavju predstavimo rezultate algoritma, opisanega v poglavju 4.3. Pri tem smo se osredotočili na uspešnost zaznavanja števila ponovitev in natančnost zaznavanja začetne ter končne točke posamezne ponovitve.

7.3.1 Zaznavanje števila ponovitev

Zaznavanje števila ponovitev smo preverili za različne kombinacije uporabnikov, vaj in testnih okolij s pomočjo metrik preciznosti, priklica in F-vrednosti. Vse statistike so bile izračunane s pomočjo programskega jezika R [143] in pripadajočih paketov [149].

Ovrednotenje algoritma smo izvedli z uporabo dveh različnih metod za ustvarjanje predloge C . To sta:

- lastna predloga C in
- tuja predloga C .

V primeru lastne predloge C je uporabnik sam naučil algoritmom, kakšni so pravilni vzorci ponovitev. To pomeni, da se kalibracija algoritma izvede na osnovi uporabnikovih lastnih ponovitev. Ta metoda omogoča vrednotenje algoritma na osnovi lokalnih učnih podatkov in opisuje scenarij, ko uporabnik prvič izvede vaje ob nadzoru osebnega trenerja ter tako algoritmom nauči prepoznavanja ponovitev.

V primeru tuge predloge C algoritmom razpoznavajo vzorce na osnovi učnih podatkov tujega izvora. Omenjena metoda testira natančnost algoritma, naučenega na podatkih tujih subjektov, in opisuje scenarij, ko kalibracija algoritma s strani uporabnika ni potrebna, saj so predloge C ustvarjene s strani športnih strokovnjakov, kot so npr. osebni trenerji.

Zaradi visoke stopnje podobnosti med rezultati obeh načinov ustvarjanja predloge natančneje interpretiramo zgolj rezultate delovanja algoritma, naučenega s pomočjo tuge predloge C .

Tabela 7.2: Rezultati prepoznavanja ponovitev (aritmetična povprečja in standardni odkloni) za metodo tuje predloge.

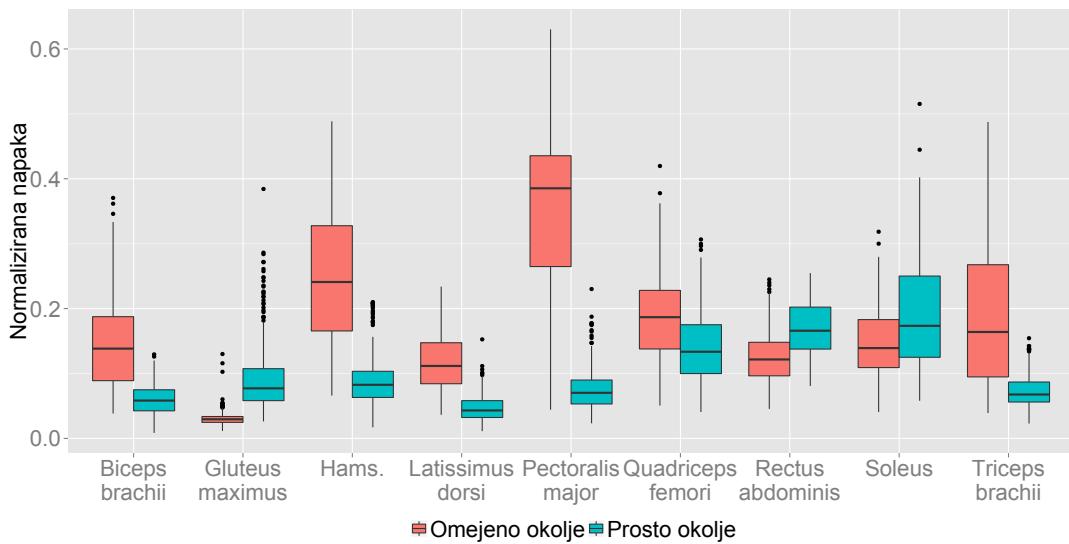
Mišica	Omejeno okolje			Prosto okolje		
	F-vrednost	Preciznost	Priklic	F-vrednost	Preciznost	Priklic
Biceps brachii	1 ± 0	1 ± 0	1 ± 0	1 ± 0	1 ± 0	1 ± 0
Gluteus maximus	0.995 ± 0.016	1 ± 0	0.99 ± 0.031	0.963 ± 0.08	1 ± 0	0.938 ± 0.121
Hamstrings	1 ± 0	1 ± 0	1 ± 0	0.999 ± 0.008	1 ± 0	0.998 ± 0.016
Latissimus dorsi	1 ± 0	1 ± 0	1 ± 0	0.997 ± 0.012	1 ± 0	0.995 ± 0.023
Pectoralis major	0.954 ± 0.067	1 ± 0	0.920 ± 0.114	0.970 ± 0.075	1 ± 0	0.949 ± 0.111
Quadriceps	1 ± 0	1 ± 0	1 ± 0	1 ± 0	1 ± 0	1 ± 0
Rectus abdominis	1 ± 0	1 ± 0	1 ± 0	0.995 ± 0.016	1 ± 0	0.99 ± 0.03
Soleus	0.999 ± 0.008	1 ± 0	0.998 ± 0.016	0.999 ± 0.008	1 ± 0	0.998 ± 0.016
Triceps brachii	1 ± 0	1 ± 0	1 ± 0	1 ± 0	1 ± 0	1 ± 0
Povprečje vaj	0.994 ± 0.027	1 ± 0	0.99 ± 0.046	0.991 ± 0.039	1 ± 0	0.985 ± 0.061

Analiza rezultatov zaznavanja števila ponovitev je pokazala, da algoritem dosega visoko preciznost, priklic in F-vrednost za različne vaje v različnih okoljih. Povprečna F-vrednost je znašala 0.993 ± 0.034 , kar predstavlja napako, manjšo od 1 %. To pomeni, da je algoritem izmed 100 različnih ponovitev napačno zaznal manj kot eno ponovitev. Tabela 7.2 natančneje povzema rezultate za posamezne vaje in okolja. Rezultati kažejo, da je število pravilno prepoznanih ponovitev višje v omejenem okolju. To gre pripisati predvsem nižjim vrednostim priklica za vajo *Gluteus maximus* v neomejenem okolju, saj so posamezni uporabniki vajo izvedeli na različen, a še vedno pravilen način, zaradi česar je algoritem gibe, ki niso predstavljeni dejanskih ponovitev, večkrat zmotno prepozna kot ponovitev. Kljub temu je razlika F-vrednosti omejenega in neomejenega okolja zanemarljiva, saj znaša zgolj 0.003 %.

7.3.2 Natančnost zaznavanja ponovitev

Zgolj zaznavanje števila ponovitev ne omogoča podajanja povratnih informacij o pravilnosti vadbe. Eden izmed načinov kvantitativnega ocenjevanja kvalitete izvedenih vaj temelji na času trajanja posameznih ponovitev. Različna trajanja ponovitev namreč vplivajo na napredok različnih fizičnih atributov, kot sta moč in eksplozivnost. Tako so npr. ponovitve, izvedene v krajšem času, primernejše za izboljšanje eksplozivnosti, daljše ponovitve za gradnjo moči itd. [30]. Medtem ko definicijo optimalnega trajanja ponovitev prepuščamo domenskim strokovnjakom, se v analizi osredotočimo na vrednotenje natančnosti zaznavanja ponovitev, ki omogoča izpeljavo trajanja ponovitev.

Konkretno, analiziramo, kako natančno je s pomočjo predlaganega algoritma mogoče zaznati čas začetka s' in konca e' pravilno prepoznane ponovitve. Za oceno napake zaznavanja s' in e' najprej izračunamo časovno razliko med parom (s', e') in dejanskimi mejami ponovitev, pridobljenimi med postopkom zvočnega označevanja. Za vsako ponovitev izračunamo povprečen čas odstopanja z različnimi predlogami C , ki ga normaliziramo glede na trajanje ponovitve. Napako časovnega zaznavanja mej ponovitve tako označimo kot vrednost znotraj intervala $[0, 1]$, pri čemer 0 označuje, da ni bilo napake pri zaznavanju para (s', e') , 1 pa, da je pri zaznavanju para (s', e') prišlo do napake reda dolžine ponovitve.



Slika 7.1: Napaka prepoznavanja začetka in konca ponovitev za metode tuje predloge, normalizirana glede na trajanje ponovitev (mediana, kvartili, ekstremne vrednosti).

Ponovitve z napako, višjo od dolžine ponovitve, smo označili kot nepravilne in jih izključili iz analize natančnosti zaznavanja.

Slika 7.1 prikazuje normalizirano napako zaznavanja začetnih in končnih točk ponovitev za različne vaje v različnih okoljih. Skupna mediana napake zaznavanja za različna okolja in vaje znaša 215 milisekund ter predstavlja 11 % trajanja posamezne ponovitve. V nasprotju z inuticijo in pričakovanji je bila napaka zaznavanja mej ponovitev višja za večino vaj v omejenem okolju in skorajda zanemarljiva za določene vaje v neomejenem okljusu. Eden izmed razlogov za to predstavlja dejstvo, da je bil senzor za vaje v neomejenem okolju nameščen neposredno na telo uporabnika in tako deležen bolj direktnega delovanja sil kot v primeru vaj omejenega okolja. Posledično so bile oblike vzorcev pospeška v neomejenem okolju intenzivnejše z bolj očitnimi začetki in konci ponovitev.

7.4 Vrednotenje intenzivnosti aerobnih aktivnosti

V tem poglavju predstavimo rezultate analize podatkov, opisane v poglavju 5.3. Uspešnost napovedovanja intenzivnosti športne aktivnosti smo preverili na osnovi metrike RMSE. Dodatno prikažemo še korelacijski koeficient (CC) ujemanja med dejanskimi in napovedanimi vrednostmi intenzivnosti aerobnih aktivnosti.

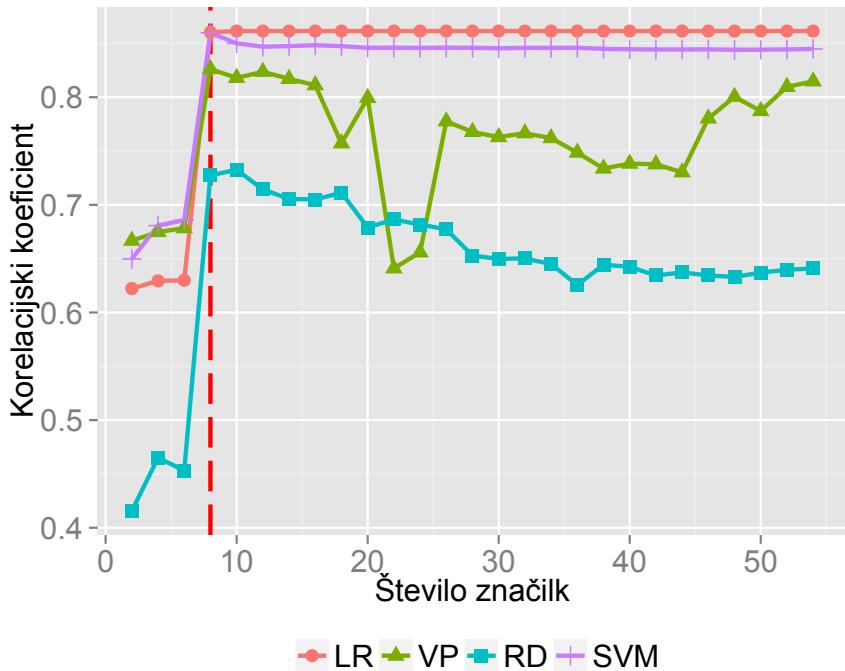
CC meri statistično korelacijo med dejansko in napovedano vrednostjo srčnega utripa in zajema vrednosti na intervalu $[-1, 1]$, pri čemer 1 označuje popolno pozitivno korelacijo, -1 popolno negativno korelacijo, 0 pa označuje, da med dejanskimi in napovedanimi vrednostmi ni korelacije. Vrednosti CC uporabimo zgolj kot dopolnilno metriko, s pomočjo katere preverjamo ujemanje z rezultati RMSE. Konkretno nas zanima, ali se za različna števila značilk in različne napovedne modele vrednosti RMSE in CC ujemata v spremenjanju natančnosti. Posledično ne računamo statistične signifikantnosti CC in ga ne uporabljammo kot metriko za merjenje absolutne natančnosti.

7.4.1 Natančnost različnih konfiguracij značilk

Sliki 7.2 in 7.3 prikazujeta CC- in RMSE-metriki za različne nabore značilk in različne napovedne modele. Na slikah je jasno vidno, da se vrednost obeh metrik občutno izboljša ob dodani osmi značilki (RMS za preteklih 60 sekund). Dodatno sliki prikazujeta, da uvajanje značilk po dodani osmi značilki bistveno ne izboljša natančnosti modelov oz. jo v določenih primerih celo poslabša (npr. negativni vrh v Sliki 7.2 pri številu značilk 22). Posledično smo se odločili, da rezultate interpretiramo le z uporabo prvih osem rangiranih značilk po metodi RReliefF. Ker enostavna linearna regresija temelji zgolj na uporabi enega parametra, smo v primeri LR zaradi visoke informacijske vrednosti uporabili zgolj RMS za preteklih 60 sekund. To je konsistentno z našim ciljem, poiskati algoritem in konfiguracijo značilk, za uporabo na zmogljivostno omejenih pametnih telefonih.

7.4.2 Natančnost za različne napovedne modele

Tabela 7.3 kaže na enakovrednost LR in SVM pri uporabi CC. Medtem ko CC za VP ni bistveno nižji, je natančnost RD bistveno nižja tako v smislu CC kot v



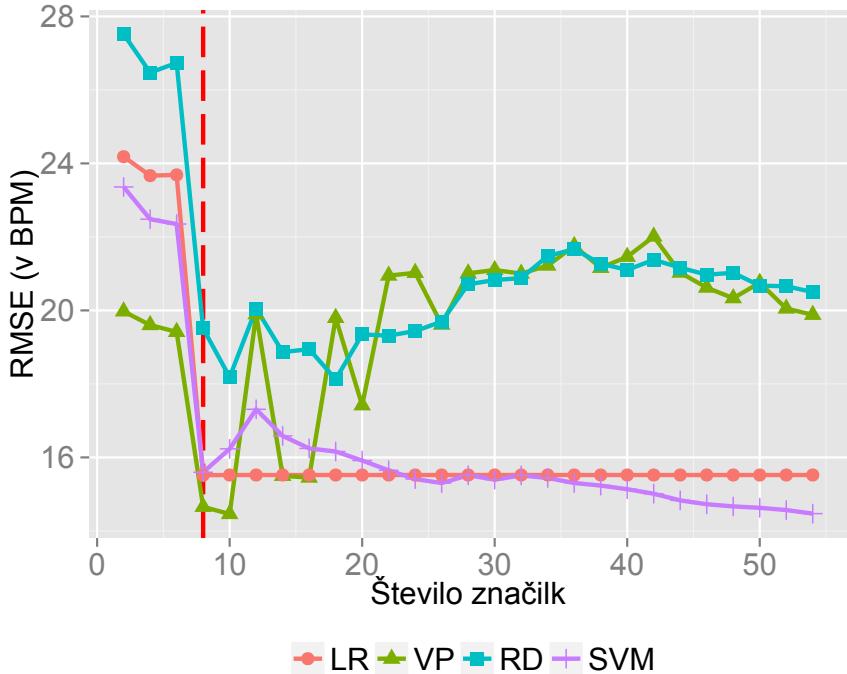
Slika 7.2: Korelacijski koeficient za različne modele in števila značilk.

smislu RMSE. Dodatno drevo, zgrajeno z RD-algoritmom, vsebuje visoko število vozlišč (okrog 1600) in je zato procesno zahtevno za obdelavo na zmogljivostno omejenih pametnih telefonih ter vseprisotnih napravah. V primeru RMSE VP dosega najboljšo vrednost, medtem ko sta LR in SMOreg tesno skupaj.

Tabela 7.3: Rezultati napovedovanja intenzivnosti aerobnih aktivnosti za 8 najboljših značilk.

	CC	RMSE
LR	0.86 ± 0.1	15.52 ± 3.76
VP	0.83 ± 0.1	14.66 ± 3.77
RD	0.73 ± 0.06	19.51 ± 1.76
SVM	0.86 ± 0.1	15.6 ± 3.73

Rezultati jasno kažejo, da LR, VP in SVM dosegajo visoko stopnjo natančnosti pri napovedovanju srčnega utripa ter posledično intenzitete fizične aktivnosti. CC-vrednost 0.85 nakazuje visoko stopnjo korelacije med dejanskim srčnim



Slika 7.3: RMSE za različne modele in števila značilk.

utripom in napovedjo na osnovi podatkov pospeškometra. Dodatno, RMSE reda 15 udarcev na minuto predstavlja napako manj kot 8 % najvišje vrednosti srčnega utripa, značilne za starostno skupino udeležencev eksperimenta. Ta nudi potencial za napovedovanje cone fizične aktivnosti (npr. aerobna cone, anaerobna cone itd.).

7.5 Vrednotenje intenzivnosti anaerobnih aktivnosti z nosljivimi senzorji

V tem poglavju predstavimo rezultate ovrednotenja algoritma, predlaganega v poglavju 6.3. Ob uspešnosti prepoznavanja tipa aktivnosti in napovedovanja intenzivnosti vadbe (poglavlje 7.5.2) algoritem ovrednotimo še za:

- različne velikosti in prekrivanja drsečega okna (poglavlje 7.5.1),
- različne konfiguracije nosljivih senzorjev (poglavlje 7.5.3) in

-
- različne količine učnih podatkov (poglavje 7.5.4).

Uspešnost prepoznavanja tipa aktivnosti predstavlja klasifikacijski problem, zato jo ovrednotimo na osnovi metrike natančnosti, ki definira razmerje med številom pravilno prepoznanih objektov aktivnosti in vseh objektov aktivnosti (enačba 7.1). Pri tem posamezni objekt aktivnosti predstavlja okvir drsečega okna. Intenzivnost aktivnosti definiramo na osnovi BLI. Preliminarne analize in pogovor z udeleženci raziskave pokažejo, da udeleženci, zaradi različnega praga bolečine in neizkušenosti z uporabo BLI, različno dojemajo posamezne stopnje lestvice. Posledično BLI-ocena 15 za enega posameznika ni nujno ustrezala stopnji intenzivnosti, ki so jo s 15 označili ostali posamezniki. Problem smo odpravili z izračunom normalizirane Borgove lestvice intenzivnosti (NBLI, enačba 7.6) za posameznika i , pri čemer NBLI zajema vrednosti na intervalu $[0, 1]$, kjer 0 označuje najnižjo zaznano stopnjo intenzivnosti posameznika, 1 pa najvišjo zaznano intenzivnost. Uspešnost zaznavanja intenzivnosti ovrednotimo z metriko RMSE (enačba 7.5), ki predstavlja vrednost napake številčne napovedi.

$$NBLI_i = \frac{BLI_i - \min(BLI_i)}{\max(BLI_i) - \min(BLI_i)} \quad (7.6)$$

Pred vrednotenjem algoritma za vsakega izmed napovednih modelov s pomočjo mrežnega iskanja izvedemo optimizacijo parametrov C in σ . Izkaže se, da parametra $C = 2$ in $\sigma = 0.01$ prinašata optimalne rezultate za večino napovednih modelov. Posledično vse nadaljnje preizkuse izvedemo z omenjenimi parametri modela.

V naslednjem podpoglavlju prikažemo rezultate analize različnih konfiguracij velikosti in prikrivanj drsečih oken. Vse preostale analize in vrednotenja algoritma izvedemo za konfiguracijo velikosti in prekrivanje okna, ki se odražata v najvišji natančnosti prepoznavanja aktivnosti ter najmanjši napaki zaznavanja intenzivnosti.

7.5.1 Izbira parametrov drsečega okna

Izbira ustreznih parametrov drsečega okna, kot sta velikost okna in stopnja prekrivanja med zaporednimi okni, pomembno vpliva na uspešnost algoritmov vred-

notenja aktivnosti. Pred izbiro parametrov drsečega okna, optimalnih za problem prepoznavanja intenzivnosti aktivnosti, smo preučili dolžine drsečih oken, uporabljene v sorodnih raziskavah (Tabela 2.3). Na osnovi dinamike gibanja in sorodnih raziskav smo izbrali štiri kandidate za izbire optimalne dolžine drsečega okna, in sicer dolžine 1 s, 2 s, 4 s in 6 s, ter dva kandidata za izbiro optimalne stopnje prekrivanja, in sicer prekrivanje 25 % dolžine drsečega okna in prekrivanje 50 % dolžine drsečega okna.

Za izbrane parametre drsečega okna smo izračunali enosenzorske značilke (EZ) in združene značilke (ZZ), opisane v poglavju 6.3.2. Iz zajetega toka podatkov smo zaradi različnih dolžin drsečega okna in različnih stopenj prikrivanja pridobili množice značilk različnih velikosti. Število izračunanih značilk je bilo bistveno manjše za konfiguracije z daljšo dolžino drsečega okna in nižjo stopnjo prekrivanja kot za konfiguracije s krajšo dolžino drsečega okna in z večjim prekrivanjem. Konkretno smo za dolžino okna 6 s in prekrivanje 50 % izračunali 3045 okvirjev značilk, medtem ko smo za dolžino okna 1 s in prekrivanje 25 % izračunali 36689 okvirjev značilk. Razlike v številu okvirjev značilk neposredno vplivajo na natančnost uporabljenih napovednih modelov, saj imajo konfiguracije parametrov drsečega okna z večjim številom okvirjev na voljo več učnih primerkov, kar omogoča učinkovitejšo učenje napovednih modelov. Prednost konfiguracij parametrov z večjim številom značilk izničimo z naključno izbiro podmnožice 2000 značilk za posamezne kombinacije dolžine in prekrivanja drsečega okna.

Ovrednotenje uspešnosti modelov za kandidate parametrov drsečega okna izvedemo z metodo navzkrižnega preverjanja tipa izpusti testnega. V nadaljevanju so prikazani rezultati ovrednotenja parametrov drsečega okna za prepoznavanje:

- tipa aktivnosti (Tabela 7.4) in
- intenzivnosti aktivnosti (Tabela 7.5).

Pri tem se ne osredotočimo na dejansko natančnost posamezne kombinacije parametrov drsečega okna, ampak izpostavimo zgolj razlike v natančnosti. Kombinacijo z najvišjo uspešnostjo označimo z vrednostjo 0, medtem ko ostale izrazimo kot razliko do najvišje uspešnosti v odstotkih. V primeru prepoznavanja tipa

aktivnosti je ta negativna, saj težimo k temu, da je natančnost prepoznavanja posameznih tipov čim višja, medtem ko v primeru zaznavanja intenzivnosti ta vrednost negativna, saj želimo minimizirati napako napovedi intenzivnosti.

Tabela 7.4: Razlike natančnosti prepoznavanja tipa vaj (v %) za različne velikosti in prekrivanja drsečih oken ter za različne tipe značilk. Višja vrednost predstavlja višjo stopnjo natančnosti.

		1 s	2 s	4 s	6 s
EZ	25 %	-3.2	-4.5	-1.7	-8.1
	50 %	-4.6	0	-3.9	-6.3
ZZ	25 %	-3	-0.3	-2.6	-3.5
	50 %	-3.9	0	-1.9	-3.9

Tabela 7.5: Razlike napake zaznavanja intenzivnosti (v %) za različne velikosti in prekrivanja drsečih oken ter za različne tipe značilk. Nižja vrednost predstavlja manjšo napako zaznavanja intenzivnosti.

		1 s	2 s	4 s	6 s
EZ	25 %	0.2	1.2	3.1	2.3
	50 %	0	0.9	2.6	2.1
ZZ	25 %	0.3	0.3	1.8	1.4
	50 %	0.6	0	2.1	1.3

Rezultati kažejo, da najvišjo natančnost prepoznavanja tipa aktivnosti dosežemo pri uporabi drsečega okna, dolžine 2 sekundi, in s prekrivanjem 50 % dolžine okna (Tabela 7.4). To velja tako za EZ kot ZZ. Natančnost ostalih kombinacij parametrov drsečega okna je od 0.3 % do 8.1 % nižja. Optimalni parametri drsečega okna so pri problemu zaznavanju intenzivnosti aktivnosti različni za EZ in ZZ (Tabela 7.5). Medtem ko je za EZ napaka najnižja pri uporabi drsečega okna, dolžine 1 sekunde s 50 % prekrivanjem, je za ZZ napaka, kot v primeru prepoznavanja tipa aktivnosti, najnižja za dolžino okna 2 sekundi in prekrivanje 50 % dolžine okna. Ker je optimalna napaka napovedovanja intenzivnosti aktivnosti v primeru uporabe zgolj EZ le slab odstotek nižja od napake pri uporabi drsečega okna, dolžine 2 sekund s 50 % prekrivanjem, smo tudi v primeru napovedovanja

intenzivnosti aktivnosti z uporabo EZ to kombinacijo izbrali kot optimalno. To nam omogoča, da algoritem značilk ne računa dvakrat za različni konfiguraciji drsečega okna, kar zmanjša njegovo procesno zahtevnost. Vse nadaljnje analize tako izvedemo za drseče okno, dolžine 2 sekund s 50 % prekrivanjem, oz. korak dolžine 1 sekunde. Uporabljeni konfiguracijski skladni so z izsledki sorodnih studij [94].

7.5.2 Uspešnost algoritma

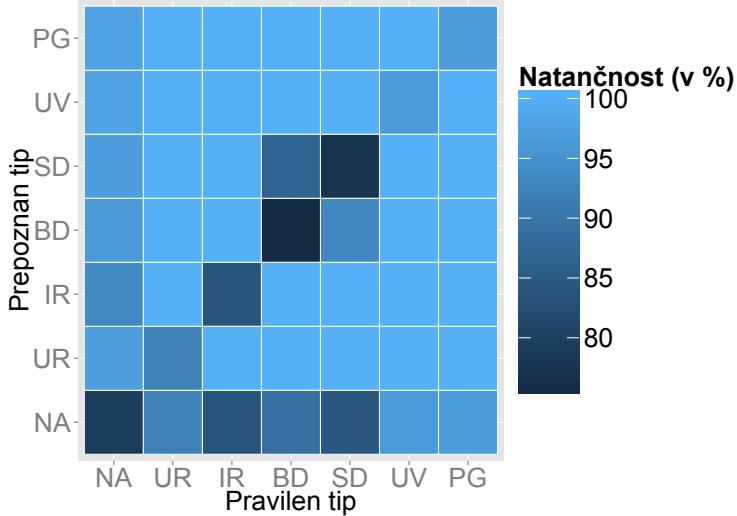
V tem poglavju ovrednotimo uspešnost predlaganega algoritma za poln nabor senzorjev. Pri tem nas zanimata natančnost prepoznavanja posameznih aktivnosti in napaka zaznavanja intenzivnosti za EZ ter ZZ.

Tabela 7.6: Uspešnost algoritma za poln nabor senzorjev (aritmetično povprečje in standardni odklon).

	Natančnost tipa	Napaka intenzivnosti
EZ	$84.2 \pm 11.3\%$	$6.6 \pm 2.2\%$
ZZ	$86.1 \pm 8\%$	$5.6 \pm 0.6\%$

Tako natančnost prepoznavanja tipa aktivnosti kot napaka zaznavanja intenzivnosti sta ugodnejši v primeru uporabe ZZ (Tabela 7.6), pri čemer znaša prva 86 %, druga pa približno 6 %. To pomeni, da je med 100 okvirji aktivnosti napacno klasificiranih manj kot 14 okvirjev in da napaka zaznavanja intenzivnosti v enotah BLI predstavlja odstopanje približno ene stopnje. Uspešnost uporabe zgolj EZ ni bistveno nižja (84 % natančnost prepoznavanja tipa aktivnosti, napaka zaznavanja intenzivnosti, manjša od 7 %) in nudi potencial za razvoj nosljivih senzorjev z nizko porabo energije.

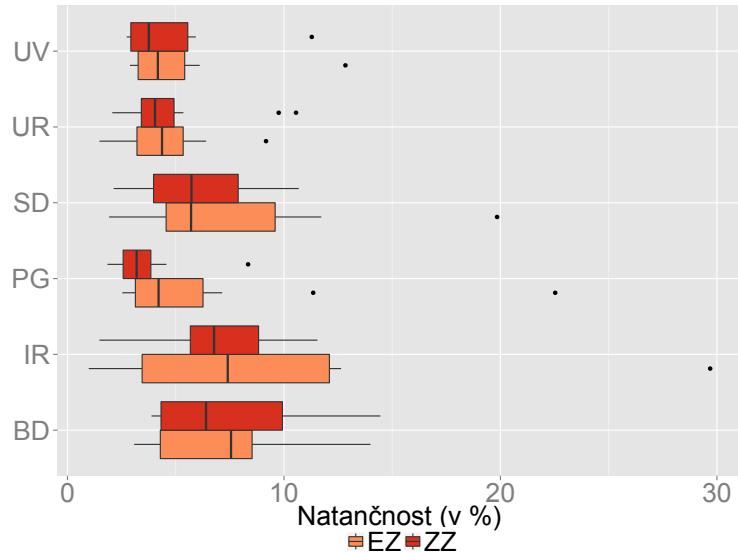
Slika 7.4 natančneje prikazuje natančnost prepoznavanja posameznih tipov vaj in najpogosteje napake klasifikacije aktivnosti z uporabo ZZ. Ker se struktura napak prepoznavanja tipa aktivnosti ne razlikuje med EZ in ZZ, rezultate predstavimo le za ZZ. Rezultati kažejo, da najvišjo natančnost prepoznavanja dosegajo vaje potisk nad glavo (PG), upognjeno veslanje (UV) in ukrivljenje rok (UR), medtem ko se najpogosteje napake pojavljajo pri vajah bočni (BD) in sprednji dvig (SD) ter pri prepoznavanju vaje izteg roke nad glavo (IR). Omen-



Slika 7.4: Natančnost prepoznavanja posameznih vaj. Kratice predstavljajo imena vaj, in sicer: NA - nevadbena aktivnost, UR - ukrivljenje rok, IR - izteg roke nad glavo, UV - upognjeno veslanje, PG - potisk nad glavo, SD - sprednji navpični dvig, BD - bočni navpični dvig.

jeno velja predvsem za vaje višjih intenzivnosti, ki so jih udeleženci zaradi težjega bremena izvedli v počasnejšem tempu in z več počitka med ponovitvami. To je algoritem pogosto nepravilno prepoznal kot nevadbeno aktivnosti (NA). Slika 7.4 prav tako kaže, da je napaka za vaji BD in SD nekoliko višja zaradi medsebojne zamenjave aktivnosti, kar je posledica izrazite podobnosti gibov omenjenih aktivnosti.

Dodatno analiziramo napako zaznavanja intenzivnosti za posamezne vaje. Slika 7.5 prikazuje diagrame kvartilov za različne vaje. Podobno kot v fazi prepoznavanja aktivnosti je tudi v primeru zaznavanja intenzivnosti napaka najvišja za vaje SD, BD in IR. Poglavitni razlog za to je najverjetneje dejstvo, da je izvedba omenjenih vaj z visoko intenzivnostjo napornejša kot izvedba ostalih vaj, zato so udeleženci ponovitve poskusili izvesti na različne načine, ki jih je zaradi raznolikosti in nizkega števila pojavnosti predlagani algoritemni uspel učinkovito modelirati. Slika 7.5 prav tako prikazuje, da sta mediana in razpon med kvartili napake pri uporabi ZZ za določene vaje (npr. IR) bistveno nižji kot pri uporabi zgolj EZ, kar nakazuje, da uporaba ZZ omogoča stabilnejšo napovedovanje intenzivnosti vadbe.



Slika 7.5: Napaka zaznavanja intenzivnosti za posamezne vaje (mediana, kvartili in ekstremne vrednosti).

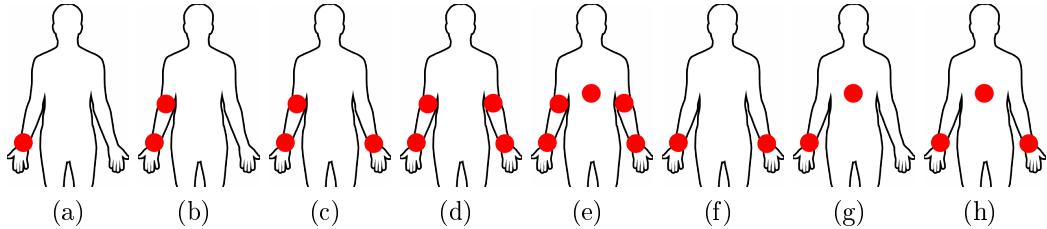
Omenjene analize so izvedene za polno konfiguracijo senzorjev. V naslednjem poglavju analiziramo natančnost prepoznavanja tipov aktivnosti in napako zaznavanja intenzivnosti za različne delne konfiguracije senzorjev.

7.5.3 Izbira konfiguracije senzorjev

V tem poglavju preučimo uspešnost algoritma za različne konfiguracije senzorjev. Analiza omogoča definicijo minimalnega nabora senzorjev, potrebnega za učinkovito detekcijo intenzivnosti vadbe.

Slika 7.6 prikazuje uporabljene konfiguracije senzorjev, Tabela 7.7 pa natančnost prepoznavanja tipa aktivnosti in napako zaznavanja intenzivnosti za različne senzorske konfiguracije. Rezultate izrazimo kot povprečno razliko natančnosti v primerjavi z referenčno konfiguracijo senzorjev, ki temelji na vseh petih uporabljenih senzorjih (konfiguracija na Sliki 7.6e).

Rezultati kažejo, da uporaba vseh petih senzorjev dosega optimalno natančnost prepoznavanja tipa aktivnosti zgolj ob uporabi EZ, medtem ko v primeru uporabe ZZ optimalno natančnost prepoznavanja aktivnosti s skoraj 1 % višjo natančnos-



Slika 7.6: Uporabljene konfiguracije senzorjev. Rdeči krogi prikazujejo lokacije namestitve senzorjev na frontalno orientirano telo (obraz spredaj).

tjo dosega konfiguracija senzorjev, prikazana na Sliki 7.6c. V primeru zaznavanja intenzivnosti polna konfiguracija petih senzorjev dosega najnižjo napako zaznavanja intenzivnosti tako v primeru EZ kot ZZ. Medtem ko senzorske kombinacije, prikazane na Slikah 7.6a, 7.6f, 7.6g in 7.6h, dosegajo bistveno višje stopnje napake, je napaka za senzorske kombinacije s Slik 7.6b, 7.6c in 7.6d višja zgolj za približno 1 %.

Tabela 7.7: Uspešnost algoritma za razlicne senzorje

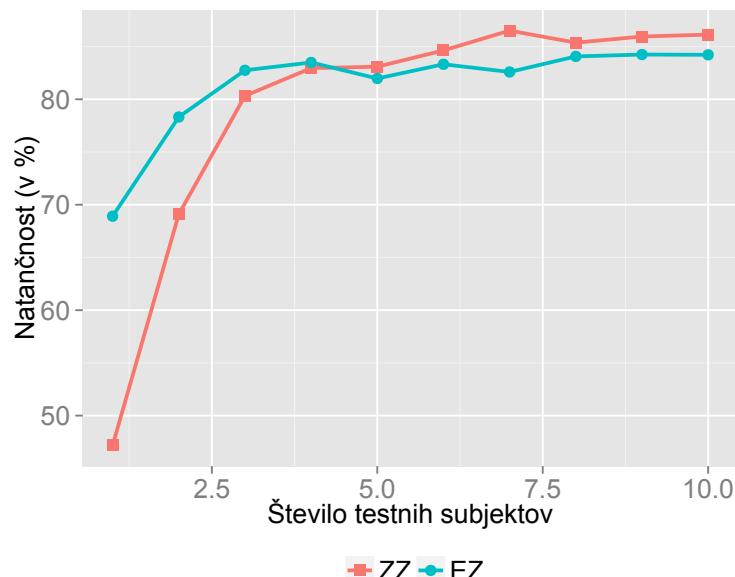
	Natančnost tipa (v %)		Napaka intenzivnosti (v %)	
	EZ	ZZ	EZ	ZZ
S1 (Slika 7.6a)	-9.4	-11.3	3	4
S2 (Slika 7.6b)	-2.6	-1.8	0.5	2.2
S3 (Slika 7.6c)	-0.9	0.8	0.5	1.3
S4 (Slika 7.6d)	-1.2	0.3	0.8	0.9
S5 (Slika 7.6e)	0	0	0	0
S6 (Slika 7.6f)	-1.5	-1.3	7.8	7.1
S7 (Slika 7.6g)	-3.1	-5.1	6.3	5.6
S8 (Slika 7.6h)	-1.7	-0.5	6.7	5.8

To nakazuje, da senzor, nameščen na prsnici koš uporabnika, ne prinaša bistvene informacijske vrednosti tako za prepoznavanje tipa aktivnosti niti i za zaznavanje intenzivnosti vadbe. Konfiguracije senzorjev, ki dosegajo optimalne rezultate, temeljijo zgolj na uporabi senzorjev, nameščenih na okončinah uporabnika. Rezultati ponujajo zanimiv uvid, saj kažejo, da kombinacija treh senzorjev, prikazana na Sliki 7.6c, ob uporabi ZZ omogoča slab 1 % natančnejše prepoznavanje tipa aktivnosti ob za dober 1 % višji napaki zaznavanja intenzivnosti vadbe. Slednje nudi potencial za razvoj sistema za avtomatsko vrednotenje vadbe zgolj

z naborom treh senzorjev.

7.5.4 Vpliv količine učnih podatkov

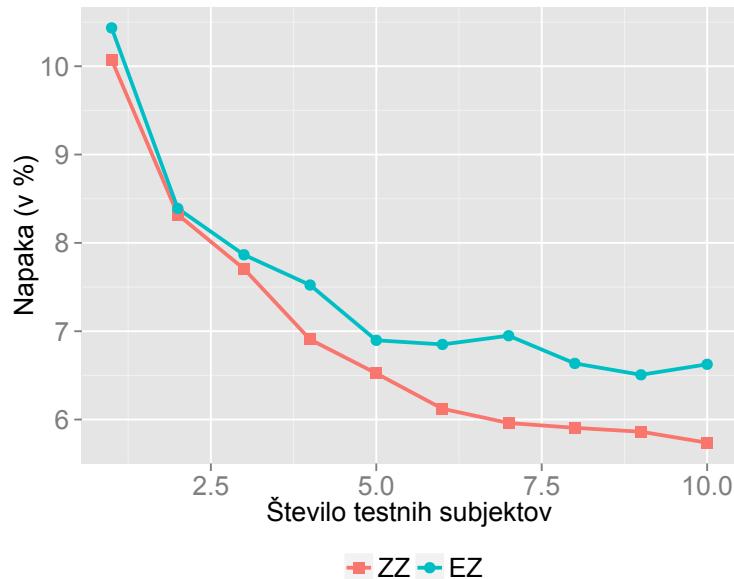
Ker predlagani algoritem za prepoznavanje tipa aktivnosti in zaznavanje intenzivnosti vadbe temelji na uporabi metod nadzorovanega strojnega učenja, preverimo, kako se uspešnost algoritma razlikuje glede na količino in pestrost uporabljenih učnih podatkov. Konkretno preverimo, kako se natančnost prepoznavanja tipa aktivnosti in napake zaznavanja intenzivnosti spreminja s podatki, ki temeljijo na različnem številu učnih subjektov.



Slika 7.7: Natančnost (v %) prepoznavanja vaj za različne količine učnih podatkov.

Vpliv količine učnih podatkov preučimo tako, da metodi prepoznavanja aktivnosti in zaznavanja intenzivnosti vadbe najprej ovrednotimo za napovedni model, naučen zgolj iz podatkov enega subjekta. Pri tem tega naključno izberemo iz razlike množice vseh subjektov in subjekta, na katerem preverjamo napovedni model. V nadalnjih korakih iterativno dodajamo po en naključno izbrani subjekt, dokler učna množica na obsega množice vseh subjektov z izjemo tistega,

na katerem preverjamo model. Rezultate zabeležimo za vsako kombinacijo učnih subjektov in jih predstavimo na Slikah 7.7 in 7.8.



Slika 7.8: Napaka (v %) zaznavanja intenzivnosti za različne količine učnih podatkov.

Rezultati kažejo, da se natančnost prepoznavanja tipa aktivnosti ne spreminja bistveno po dodanem tretjem učnem subjektu. To je posebej očitno v primeru uporabe zgolj enosenzorskih značilk, medtem ko ob uporabi večsenzorskih značilk natančnost prepoznavanja aktivnosti še rahlo niha (Slika 7.7). Slika 7.8 kaže, da se napaka zaznavanja intenzivnosti ne ustali tako očitno kot v primeru prepoznavanja aktivnosti, kar nakazuje, da je problem vrednotenje kvalitativnih parametrov bistveno težji od problema prepoznavanja vadbe. Kljub vsemu dosežena nizka stopnja napake zaznavanja intenzivnosti nudi potencial za razvoj učinkovitih algoritmov za vrednotenje kvalitativnih parametrov vadbe, ki jih je z večanjem količine učnih podatkov mogoče še izboljšati.

Poglavlje 8

Diskusija

V tem poglavju analiziramo rezultate, predstavljene v poglavju 7, in podamo njihovo interpretacijo v odnosu do teze ter raziskovalnih vprašanj, predstavljenih v poglavju 1.5. Dodatno v kontekstu pridobljenih rezultatov predstavimo izvirne znanstvene prispevke naloge, predstavljene v poglavju 1.6.

Raziskovalno vprašanje 1:

Standardni pametni telefoni z vgrajenimi pospeškometri omogočajo zaznavanje in kvantitativno vrednotenje pravilnosti izvedbe anaerobnih aktivnosti.

Raziskovalno vprašanje 1 zadevajo rezultati, predstavljeni v poglavju 7.3. V omenjenem poglavju smo analizirali natančnost algoritma zaznavanja ponovitev anaerobne aktivnosti, predstavljenega v poglavju 4. Preučili smo, kako natančno je zgolj s pomočjo pametnih telefonov mogoče zaznavati število ponovitev treninga moči ter kakšna je napaka zaznavanja meja ponovitev v omejenem in prostem okolju. Slednje omogoča ocenjevanje pravilnosti izvedenih vaj na osnovi trajanja ponovitev [30].

V primeru zaznavanja ponovitev smo analizirali preciznost, priklic in F-vrednost napovedovanja števila ponovitev. Rezultati kažejo, da tako v omejenem kot v prostem okolju algoritem dosega visoko F-vrednost zaznavanja ponovitev. V omejenem okolju pravilno zazna 99.4 % ponovitev, v prostem okolju pa 99.1 % ponovitev.

Mediana napake zaznavanja meja prepoznavanih ponovitev znaša 215 milisekund in predstavlja približno 11 % trajanje posameznih ponovitev. Medtem ko napaka zaznavanja trajanja večine vaj iz testnega nabora ne presega 20 % trajanja posameznih ponovitev, je za določene vaje, predvsem v omejenem okolju, nekoliko višja (30-40 % trajanja ponovitev za *Pectoralis major*). Slednje je najverjetneje posledica manj neposrednega delovanja sil na senzor pospeška v omejenem okolju, ki se odraža v vzorcih pospeška z manj izrazitimi in težje prepoznavnimi mejami ponovitev.

V splošnem navedeni rezultati kažejo, da standardni pametni telefoni s pomočjo vgrajenih pospeškometrov omogočajo natančno zaznavanje večine izvedenih vaj treninga moči in nudijo potencial za vseprisotno ocenjevanje pravilnosti anaerobnih aktivnosti. Prvi izvirni znanstveni prispevek doktorskega dela tako predstavlja algoritem, ki na zmogljivostno omejenih pametnih telefonih omogoča zaznavanje pravilnosti vzorcev anaerobnih aktivnosti, vsebovanih v neomejenem toku podatkov pospeška, v realnem času.

Raziskovalno vprašanje 2:

Standardni pametni telefoni z vgrajenimi pospeškometri omogočajo zaznavanje in kvantitativno vrednotenje intenzivnosti aerobnih fizičnih aktivnosti.

Raziskovalno vprašanje 2 zadevajo rezultati, predstavljeni v poglavju 7.4. Omenjeno poglavje predstavlja rezultate analize množice značilk in metod numeričnega napovedovanja (predstavljenih v poglavju 5) za vrednotenje intenzivnosti aerobnih fizičnih aktivnosti.

Primerjava metod numeričnega napovedovanja kaže, da večnivojski perceptron (VP) dosega najnižjo vrednost RMSE ob napovedovanju intenzivnosti aerobnih aktivnosti. Napaka VP, izražena v številu srčnih utripov na minuto, znaša 14.66 utripov. Tesno mu sledita linearna regresija (LR) s 15.52 utrpi in metoda podpornih vektorjev (SVM) s 15.6 utripi, medtem ko regresijska drevesa (RD) dosegajo najvišjo stopnjo napake (19.51 utripov).

Rezultati analize uspešnosti značilk, izračunanih iz signala pospeška, kažejo, da se vrednost RMSE za vse preverjane metode občutno izboljša po dodani osmi

značilki, ki predstavlja vrednost RMS za preteklih 60 sekund pospeška. Uvajanje dodatnih značilk ne prinaša bistvene izboljšave rezultatov in v nekaterih primerih celo izdatno poslabša natančnost napovednih modelov. Slednje je izrazito vidno v primeru uporabe VP s prvimi 22 značilkami, rangiranimi s pomočjo metode RReliefF ($\text{RMSE} > 20$ utripov).

Nižja vrednost RMSE za manjše število značilk in uspešnost procesno enostavnnejših metod, kot sta LR in VP s tremi skritimi nivoji treh vozlišč, v primerjavi z RD s približno 1600 vozlišči, kažejo, da standardni pametni telefoni omogočajo relativno natančno napovedovanje intenzivnosti aerobnih aktivnosti v realnem času. Napaka 15 srčnih utripov na minuto predstavlja napako, manjšo od 8 % najvišje vrednosti srčnega utripa, značilne za starostno skupino udeležencev študije. Slednje nudi potencial za natančno napovedovanje cone fizične aktivnosti. Drugi izvirni znanstveni prispevek doktorskega dela tako predstavlja študija primernosti atributov iz prostora pospeška in algoritmov nadzorovanega strojnega učenja ter ugotovitev, da je vrednotenje intenzivnosti aerobne vadbe v realnem času mogoče zgolj s pomočjo standardnih pametnih telefonov.

Raziskovalno vprašanje 3:

Standardni pametni telefoni skupaj z mrežo senzorjev pospeška ob kvantitativnem vrednotenju pravilnosti omogočajo še vrednotenje intenzivnosti anaerobnih aktivnosti.

Raziskovalno vprašanje 3 zadevajo rezultati, predstavljeni v poglavju 7.5. V omenjenem poglavju smo analizirali natančnost hierarhičnega algoritma, opisanega v poglavju 6, ki omogoča zaznavanja intenzivnosti vaj treninga moči z množico nosljivih senzorjev. Predlagani algoritem za ocenjevanje napake napovedovanja intenzivnosti vadbe potrebuje informacije o tipu izvajane vaje, zato uspešnost algoritma predstavimo skozi analizo natančnosti prepoznavanja vaj in napake napovedovanja intenzivnosti, izražene s pomočjo Borgove lestvice intenzivnosti (BLI). Rezultate predstavimo za enosenzorske (EZ) in združene značilke (ZZ), pri čemer je izračun prvih enostavnnejši ter podaljšuje avtonomijo nosljivih senzorjev.

Rezultati kažejo, da natančnost prepoznavanja tipa aktivnosti z naborom petih senzorjev in uporabo EZ dosega 84.2 %. Uporaba ZZ natančnost dodatno izboljša za slaba 2 %, tako da ta znaša 86.1 %. Slednje pomeni, da algoritem v primeru sedmih različnih kategorij aktivnosti, izvedenih z različno stopnjo intenzivnosti, napačno prepozna le slabih 14 % aktivnosti, pri čemer večino napake prispeva podmnožica vaj z višjo stopnjo intenzivnosti izvedbe. RMSE-zaznavanja intenzivnosti v primeru EZ znaša dobrih 6 %, v primeru ZZ pa odstotek manj, torej dobrih 5 %. Pretvorjeno v BLI slednje pomeni, je povprečna napaka napovedovanja intenzivnosti anaerobne vadbe reda ene stopnje BLI.

Dodatno analiza različnih konfiguracij nosljivih senzorjev pokaže, da predlagani algoritem ob uporabi ZZ nudi primerljive rezultate za konfiguracijo zgolj treh senzorjev, od katerih sta dva nameščena na zapestjih, eden pa nad komolčnim sklepom zgornje okončine. Konkretno se natančnost napovedovanja tipa aktivnosti s takšno konfiguracijo zviša za 1 %, medtem ko se natančnost zaznavanja intenzivnosti zniža za 1 %.

Predstavljeni rezultati razkrivajo potencial uporabe majhne množice nosljivih senzorjev za napovedovanje intenzivnosti anaerobnih aktivnosti, konkretneje aktivnosti treninga moči. Tretji in četrti izvirni znanstveni prispevek tako predstavlja algoritem za zaznavanje intenzivnosti izvajanja anaerobnih aktivnosti s pomočjo standardnih mobilnih naprav in senzorskih mrež pospeškometrov ter študija različnih konfiguracij senzorskih mrež na natančnost zaznavanje intenzivnosti anaerobnih aktivnosti.

Teza

Vseprisotne naprave omogočajo zaznavanje in kvantitativno vrednotenje kvalitativnih parametrov rekreativne fizične aktivnosti.

Zgoraj navedeni rezultati z ozirom na posamezna raziskovalna vprašanja nam omogočajo trdno argumentacijo teze doktorskega dela. Interpretacija rezultatov namreč kaže, da vseprisotne naprave, kot so standardni pametni telefoni in nosljivi senzorji pospeška, omogočajo učinkovito prepoznavanje kvalitativnih parametrov, kot sta pravilnost in intenzivnost anaerobnih ter aerobnih fizičnih aktivnosti.

Poglavlje 9

Zaključek

Vseprisotno računalništvo je v zadnjem desetletju prejelo izdatno mero pozornosti v preventivnem zdravstvu. Različni akademski in industrijski projekti so raziskali, kako je vseprisotne naprave mogoče uporabljati za podporo in vzpodbujanje redne fizične aktivnosti. Pri tem so se osredotočali predvsem na prepoznavanje različnih tipov fizičnih aktivnosti, medtem ko je bilo manj pozornosti posvečene prepoznavanju in kvantitativnem vrednotenju kvalitativnih parametrov fizičnih aktivnosti, kot sta npr. pravilnost in intenzivnost vadbe.

V doktorskem delu smo preučili možnosti uporabe vseprisotnih naprav za vrednotenje kvalitativnih parametrov fizične aktivnosti. Pri tem smo se osredotočili na prepoznavanje intenzivnosti aerobnih in pravilnosti ter intenzivnosti anaerobnih aktivnosti. Razvili smo algoritem, ki omogoča natančno zaznavanje ponovitev treninga moči in njihovih meja v neomejenem toku pospeška. Rezultati kažejo, da je ponovitve treninga moči mogoče zaznavati v realnem času na zmogljivostno omejenih pametnih telefonih s približno 99 % natančnostjo štetja ponovitev in 215-milisekundno napako zaznavanja meja ponovitev, kar znaša približno 11 % dolžine posameznih ponovitev.

Nato smo izvedeli študijo, s katero smo preverili natančnost uporabe različnih metod numeričnega napovedovanja in kombinacij značilk pospeška, pridobljenega s standardnih pametnih telefonov, za napovedovanje intenzivnosti aerobnih aktivnosti. Ugotovili smo, da izračun RMS za preteklih 60 sekund aktivnosti nudi najpomembnejše informacije za napovedovanje intenzivnosti in da enostavnejše metode, kot je linearna regresija, v napovedovanju intenzivnosti vadbe

konkurirajo natančnosti kompleksnejših metod, kot sta večnivojski perceptron in metoda podpornih vektorjev (RMSE približno 15 utripov na minuto), oz. jih celo prekašajo (regresijska drevesa z RMSE približno 20 utripov). Slednje nudi potencial za uporabo metod numeričnega napovedovanja za zaznavanje intenzivnosti aerobna vadbe na zmogljivostno omejenih pametnih telefonih v realnem času.

Na koncu predstavimo še hierarhični algoritem, ki s pomočjo pospeška, pridobljenega iz množice nosljivih senzorjev, omogoča zaznavanje intenzivnosti anaerobnih aktivnosti. Algoritem deluje v dveh korakih. V prvem prepozna tip izvajane aktivnosti, v drugem pa glede na prepoznani tip aktivnosti napove oceno intenzivnosti aktivnosti, izraženo na osnovi Borgove lestvice intenzivnosti (BLI). Rezultati kažejo, da nabor petih senzorjev omogoča prepoznavanja tipa aktivnosti s 84 % natančnostjo ob uporabi enostavnih enosenzorskih značilk (EZ). Natančnost se dvigne na 86 % ob uporabi kompleksnejših združenih značilk (ZZ), ki vključujejo podatke večih senzorjev. Napaka zaznavanja intenzivnosti za EZ znaša dobrih 6 %, za ZZ pa dobrih 5 %, kar v enotah BLI predstavlja približno eno stopnjo lestvice. Dodatno izvedemo študijo, s pomočjo katere ugotovimo, da konfiguracija, temelječa na treh senzorjih, za 1 % izboljša natančnost prepoznavanja aktivnosti, za 1 % pa zmanjša natančnost ocenjevanja intenzivnosti. Slednje nudi potencial za razvoj vseprisotnih namenskih sistemov za ocenjevanje intenzivnosti anaerobnih aktivnosti.

Rezultati kažejo, da signal pospeška, pridobljen iz vseprisotnih naprav in senzorjev, nudi zadostno količino informacij za kvantitativno vrednotenje kvalitativnih parametrov aerobnih in anaerobnih fizičnih aktivnosti. Razviti algoritmi in izvedene analize tako nudijo osnovo za razvoj specializiranih pripomočkov za vrednotenje rekreativne fizične aktivnosti.

Priloga A

Soglasje za sodelovanje v raziskavi

UNIVERSITY OF CALIFORNIA, BERKELEY

BERKELEY • DAVIS • IRVINE • LOS ANGELES • RIVERSIDE • SAN DIEGO • SAN FRANCISCO



SANTA BARBARA • SANTA CRUZ

PROFESSOR RUZENA BAJCSY
DEPARTMENT OF ELECTRICAL ENGINEERING AND COMPUTER SCIENCE
COLLEGE OF ENGINEERING
BERKELEY, CA 94720-1774

PHONE: (510) 642-9423
FAX: (510) 642-6163
EMAIL: BAJCSY@EECS.BERKELEY.EDU

CONSENT TO PARTICIPATE IN A RESEARCH STUDY: QUANTIFYING CORRECTNESS OF UPPER BODY EXERCISES USING WEARABLE SENSORS

My name is Igor Pernek. I am a Visiting Student Researcher under supervision of Prof. Ruzena Bajcsy at the Department of Electrical Engineering and Computer Science at the University of California at Berkeley. I would like to invite you to take part in my research study. This experiment aims at using wearable accelerometers to quantify correctness of upper body exercises performed with different free weights.

If you agree to participate in my research study, you will be asked to take part in the experiment that will last about 60 to 90 minutes. I will ask you for some personal information such as your age, gender, height, weight and physical activity habits. Then, I will ask you to perform 6 upper body exercises using dumbbells of different weight. During exercising, you will be asked to wear a suit with a number of LED sensors on it, 5 wearable accelerometer sensors (1 on each wrist, 1 on each elbow, and 1 on chest), 2 ECG sensors on one of your upper arms and a heart rate monitor on your chest.

There are minimal risks to you from taking part in this research, and no foreseeable direct benefit to you, either. However, it is hoped that the research will benefit to others. The project aims at developing new technologies for quantifying correctness of upper body exercises.

Participation in this research may involve a loss of privacy, but all the information that we obtain from you will be kept as confidential as possible. Your name and other identifying information about you will not be used in any reports of the research without your permission. After this research is completed, I may have the recordings and my notes available for use in future research by others or myself. Although I will keep your name confidential, you may still be identifiable to others on the videotape.

Your participation in this research is VOLUNTARY. You are free to refuse to take part. You may refuse to answer any questions and may stop taking part in the study at any time.

If you agree to take part in this research, please sign the form below.

If you have any questions regarding your treatment or rights as a participant in this research project, please contact the University of California at Berkeley's Committee for Protection of Human Subjects at 510-642-7461, subjects@berkeley.edu.

I have read this consent form and I agree to take part in this research.

Name & Signature

Date

Priloga B

Življenjepis

Igor Pernek se je rodil 15. 10. 1985 v Mariboru. Po končani osnovni šoli je prejel Zoisovo štipendijo za nadarjene dijake in šolanje nadaljeval na Prvi gimnaziji Maribor. Leta 2004 se je vpisal na študij računalništva na Fakulteti za elektrotehniko, računalništvo in informatiko v Mariboru. Med študijem je opravljal delo demonstratorja pri predmetih Algoritmi 1 in Programiranje 1. Prav tako je sodeloval pri študentskih projektih in se leta 2007 uvrstil v svetovni finale tekmovanja Imagine Cup v Južni Koreji, kjer je z ekipo zastopal barve Slovenije. Za to je prejel priznanje Univerze v Mariboru za odmevno promocijo univerze v svetu in priznanje za izjemne dosežke Ministrstva za visoko šolstvo, znanost in tehnologijo. Leta 2009 je po štirimesečnem študijskem obisku na Univerzi na Dunaju diplomiral pod mentorstvom dr. Petra Kokola in somentorstvom dr. Karin Anne Hummel (Univerza na Dunaju) ter se zaposlil kot mladi raziskovalec na Fakulteti za zdravstvene vede Univerze v Mariboru. Med doktorskim raziskovanjem je opravil dva štirimesečna raziskovalna obiska, leta 2010 na Univerzi na Dunaju (pod mentorstvom dr. Karin Anne Hummel) in leta 2012 na University of California – Berkeley (pod mentorstvom dr. Ruzene Bajcsy).

Priloga C

Osebna bibliografija

ČLANKI IN DRUGI SESTAVNI DELI

1.01 Izvirni znanstveni članek

1. PERNEK, Igor, HUMMEL, Karin Anna, KOKOL, Peter. Exercise repetition detection for resistance training based on smartphones. *Personal and ubiquitous computing*, Article first published online 06 DEC 2012, [12] str., ilustr. <http://link.springer.com/article/10.1007/s00779-012-0626-y/fulltext.html>, doi: [10.1007/s00779-012-0626-y](https://doi.org/10.1007/s00779-012-0626-y). [COBISS.SI-ID [1867684](#)]
2. ŠTIGLIC, Gregor, KOCBEK, Simon, PERNEK, Igor, KOKOL, Peter. Comprehensive decision tree models in bioinformatics. *PloS one*, 2012, vol. 7, iss. 3, str. [1-14], e33812. <http://www.plosone.org/article/info%3Adoi%2F10.1371%2Fjournal.pone.0033812>, doi: [10.1371/journal.pone.0033812](https://doi.org/10.1371/journal.pone.0033812). [COBISS.SI-ID [1788068](#)]
3. KOCBEK, Simon, SAETRE, Rune, ŠTIGLIC, Gregor, KIM, Jin-Dong, PERNEK, Igor, TSURUOKA, Yoshimasa, KOKOL, Peter, ANANIADOU, Sophia, TSUJII, Jun-ichi. AGRA: analysis of gene ranking algorithms. *Bioinformatics (Oxf., Print)*, 2011, vol. 27, no. 8, str. 1185-1186, ilustr. <http://bioinformatics.oxfordjournals.org/content/27/8/1185.full.pdf>, doi: [10.1093/bioinformatics/btr097](https://doi.org/10.1093/bioinformatics/btr097). [COBISS.SI-ID [1676708](#)]

1.04 Strokovni članek

4. PERNEK, Igor, UDDIN, Mostafa Abdulla, BRAVO-TORES, Jack Fernando. HotMobile 2012. *IEEE pervasive computing*. [Print ed.], 2012, vol. 11, no. 4, str. 84-87. [COBISS.SI-ID [1868452](#)]

1.08 Objavljeni znanstveni prispevek na konferenci

5. PERNEK, Igor, ŠTIGLIC, Gregor, KOKOL, Peter. How hard am i training? Using smart phones to estimate sport activity intensity. V: 32nd International Conference on Distributed Computing Systems, 18-21 June 2012, Macau, China. *ICDCSW 2012*, (Proceedings, CFP1228C-CDR). [s.l.]: IEEE Computer Society, cop. 2012, str. 65-68, graf. prikazi. [COBISS.SI-ID [1836196](#)]
6. ŠTIGLIC, Gregor, PERNEK, Igor, KOKOL, Peter, OBRADOVIĆ, Zoran. Disease prediction based on prior knowledge. V: *KDD 2012*. New York: ACM, cop. 2012, 7 str., graf. prikazi. [COBISS.SI-ID [1839012](#)]
7. ŠTIGLIC, Gregor, KOCBEK, Simon, PERNEK, Igor, KOKOL, Peter. Tuning decision tree models by imposing visual constraints. V: PERNER, Petra (ur.). *Machine learning and data mining in pattern recognition : 7th International Conference, MLDM 2011, New York, USA, August/September 2011 : poster proceedings*. Fockendorf: ibai-publishing, 2011, str. 38-48, ilustr. [COBISS.SI-ID [1744292](#)]

- 8.** KOCBEK, Simon, ŠTIGLIC, Gregor, PERNEK, Igor, KOKOL, Peter. Stability of different feature selection methods for selecting protein sequence descriptors in protein solubility classification problem. V: DILLON, Tharam (ur.). *Proceedings of the 23rd IEEE International Symposium on Computer-Based Medical Systems CBMS 2010, October 12-15, 2010 Perth, Australia*. Piscataway: IEEE, cop. 2010, str. 50-55. [COBISS.SI-ID [1648036](#)]
- 9.** PERNEK, Igor, HUMMEL, Karin Anna. SocioNet: A context-aware approach for lowering the communication barrier. V: MEERSMAN, Robert (ur.), HERRERO, Pilar (ur.), DILLON, Tharam (ur.). *On the Move to Meaningful Internet Systems: OTM 2009 Workshops : Confederated International Workshops and Posters, ADI, CAMS, EI2N, ISDE, IWSSA, MONET, OnToContent, ODIS, ORM, OTM Academy, SWWS, SEMELS, Beyond SAWSDL, and COMBEK 2009, Vilamoura, Portugal, November 1-6, 2009 : proceedings*, (Lecture Notes in Computer Science, LNCS 5872). Berlin; Heidelberg: Springer, cop. 2009, str. [444]-453. [COBISS.SI-ID [1543588](#)]

1.12 Objavljeni povzetek znanstvenega prispevka na konferenci

- 10.** KOCBEK, Simon, SAETRE, Rune, ŠTIGLIC, Gregor, KIM, Jin-Dong, PERNEK, Igor, TSURUOKA, Yoshimasa, KOKOL, Peter, ANANIADOU, Sophia, TSUJII, Jun-ichi. Analysis of gene ranking algorithms with extraction of relevant biomedical concepts from Pubmed publications. V: MĂNDOIU, Ion (ur.). *ICCABS 2011*. [s.l.]: IEEE, 2011, str. 249. <http://www.iccabs.org> [COBISS.SI-ID [1680548](#)]
-

MONOGRAFIJE IN DRUGA ZAKLJUČENA DELA

2.11 Diplomsko delo

- 11.** PERNEK, Igor. *Lowering the communication barrier with the help of mobile social networks : diploma thesis*. Maribor: [I. Pernek], 2009. XIII, 54 str., ilustr. <http://dkum.uni-mb.si/Dokument.php?id=10084>. [COBISS.SI-ID [13502998](#)]
-

IZVEDENA DELA (DOGODKI)

3.15 Prispevek na konferenci brez natisa

- 12.** PERNEK, Igor. *Exploiting mobile computing to support healthy living through strength training : lecture on 13th International Workshop on Mobile Computing Systems and Applications February 2012, San Diego, California, 28th February 2012*. San Diego, 2012. [COBISS.SI-ID [1814692](#)]

- 13.** PERNEK, Igor, ŠTIGLIC, Gregor, KOCBEK, Simon, KOKOL, Peter. *MobiFit: Towards effective*

mobile assistants for strength training : poster na 12th Workshop on Mobile Computing Systems and Applications, March 1-2, 2011, Phoenix, Arizona. Phoenix, Arizona, 2011. [COBISS.SI-ID [1732516](#)]

3.25 Druga izvedena dela

14. PERNEK, Igor. *Introduction to R : predstavitev programskega jezika R študentom doktorskega študija v programu Aplikativna kineziologija, UP, FAMNIT, 23.5.2012.* Koper, 2012. 46 pros. [COBISS.SI-ID [1814436](#)]

Viri

- [1] M. Weiser, “The computer for the 21st century,” *Scientific american*, vol. 265, no. 3, pp. 94–104, 1991. [1](#)
- [2] S. Helal, W. Mann, H. El-Zabadani, J. King, Y. Kaddoura, and E. Jansen, “The gator tech smart house: a programmable pervasive space,” *Computer*, vol. 38, no. 3, pp. 50–60, 2005. [1](#)
- [3] H. Kautz, L. Arnstein, G. Borriello, O. Etzioni, and D. Fox, “An overview of the assisted cognition project,” in *AAAI-2002 Workshop on Automation as Caregiver: The Role of Intelligent Technology in Elder Care*, pp. 60–65, 2002. [1](#)
- [4] P. Lukowicz, J. A. Ward, H. Junker, M. Stäger, G. Tröster, A. Atrash, and T. Starner, “Recognizing workshop activity using body worn microphones and accelerometers,” in *Pervasive Computing*, pp. 18–32, Springer, 2004. [1](#)
- [5] J. E. Bardram, A. Mihailidis, and D. Wan, *Pervasive computing in health-care*, vol. 1. CRC Press, 2007. [2](#)
- [6] F. W. Booth, S. E. Gordon, C. J. Carlson, and M. T. Hamilton, “Waging war on modern chronic diseases: primary prevention through exercise biology,” *Journal of Applied Physiology*, vol. 88, no. 2, pp. 774–787, 2000. [2](#)
- [7] M. S. Feigenbaum, M. L. Pollock, *et al.*, “Prescription of resistance training for health and disease,” *Medicine and Science in Sports and Exercise*, vol. 31, pp. 38–45, 1999. [2](#)

-
- [8] C. J. Hass, M. S. Feigenbaum, and B. A. Franklin, “Prescription of resistance training for healthy populations,” *Sports Medicine*, vol. 31, no. 14, pp. 953–964, 2001. [2](#), [44](#)
 - [9] D. E. Warburton, C. W. Nicol, and S. S. Bredin, “Health benefits of physical activity: the evidence,” *Canadian medical association journal*, vol. 174, no. 6, pp. 801–809, 2006. [2](#)
 - [10] C. K. Roberts and R. J. Barnard, “Effects of exercise and diet on chronic disease,” *Journal of Applied Physiology*, vol. 98, no. 1, pp. 3–30, 2005. [2](#)
 - [11] B. K. Pedersen and B. Saltin, “Evidence for prescribing exercise as therapy in chronic disease,” *Scandinavian Journal of Medicine & Science in Sports*, vol. 16, no. S1, pp. 3–63, 2006. [2](#)
 - [12] D. E. Warburton, C. W. Nicol, and S. S. Bredin, “Prescribing exercise as preventive therapy,” *Canadian Medical Association Journal*, vol. 174, no. 7, pp. 961–974, 2006. [2](#)
 - [13] B. J. Speck and S. W. Looney, “Effects of a minimal intervention to increase physical activity in women: daily activity records,” *Nursing research*, vol. 50, no. 6, pp. 374–378, 2001. [2](#), [44](#)
 - [14] E. Schlenk, J. Dunbar-Jacob, S. Sereika, T. Starz, A. Okifuji, and D. Turk, “Comparability of daily diaries and accelerometers in exercise adherence in fibromyalgia syndrome,” *Measurement in Physical Education & Exercise Science*, vol. 4, no. 2, pp. 133–134, 2000. [2](#), [44](#)
 - [15] E. T. Howley *et al.*, “Type of activity: resistance, aerobic and leisure versus occupational physical activity,” *Medicine and science in sports and exercise*, vol. 33, no. 6; SUPP, pp. S364–S369, 2001. [2](#), [3](#)
 - [16] C. J. Caspersen, K. E. Powell, and G. M. Christenson, “Physical activity, exercise, and physical fitness: definitions and distinctions for health-related research.,” *Public health reports*, vol. 100, no. 2, p. 126, 1985. [3](#), [4](#)
 - [17] S. A. Plowman, *Exercise physiology for health fitness and performance*. Lippincott Williams & Wilkins, 2013. [4](#), [30](#)

-
- [18] B. G. Steele, B. Belza, K. Cain, C. Warms, J. Coppersmith, J. Howard, *et al.*, “Bodies in motion: monitoring daily activity and exercise with motion sensors in people with chronic pulmonary disease,” *Journal of rehabilitation research and development*, vol. 40, no. 5; SUPP/2, pp. 45–58, 2003. [4](#)
 - [19] A. Baca, P. Dabnichki, M. Heller, and P. Kornfeind, “Ubiquitous computing in sports: A review and analysis,” *Journal of sports sciences*, vol. 27, no. 12, pp. 1335–1346, 2009. [4](#), [5](#), [19](#)
 - [20] A. D. Townshend, C. J. Worringham, and I. B. Stewart, “Assessment of speed and position during human locomotion using nondifferential gps,” *Medicine and science in sports and exercise*, vol. 40, no. 1, p. 124, 2008. [5](#)
 - [21] Y. Schutz, R. Herren, *et al.*, “Assessment of speed of human locomotion using a differential satellite global positioning system,” *Medicine and science in sports and exercise*, vol. 32, no. 3, pp. 642–646, 2000. [5](#)
 - [22] A. Bonfiglio, *Wearable monitoring systems*. Springer Science+ Business Media, 2011. [5](#)
 - [23] J. Healey and R. Picard, “Detecting stress during real-world driving tasks using physiological sensors,” *Intelligent Transportation Systems, IEEE Transactions on*, vol. 6, no. 2, pp. 156–166, 2005. [5](#)
 - [24] M. Chen, S. Gonzalez, A. Vasilakos, H. Cao, and V. C. Leung, “Body area networks: A survey,” *Mobile Networks and Applications*, vol. 16, no. 2, pp. 171–193, 2011. [5](#)
 - [25] A. Mannini and A. M. Sabatini, “Machine learning methods for classifying human physical activity from on-body accelerometers,” *Sensors*, vol. 10, no. 2, pp. 1154–1175, 2010. [6](#)
 - [26] H. J. Luinge, *Inertial sensing of human motion*. PhD thesis, University of Twente, 2002. [6](#)
 - [27] D. Roetenberg, H. J. Luinge, C. T. Baten, and P. H. Veltink, “Compensation of magnetic disturbances improves inertial and magnetic sensing of human

- body segment orientation,” *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 13, no. 3, pp. 395–405, 2005. [6](#)
- [28] S. Nylander, T. Lundquist, A. Brännström, and B. Karlson, “it’s just easier with the phone— a diary study of internet access from cell phones,” in *Proceedings of the 7th International Conference on Pervasive Computing, Pervasive ’09*, (Berlin, Heidelberg), pp. 354–371, Springer-Verlag, 2009. [6](#)
- [29] G. J. Wilson, A. J. Murphy, and A. Walshe, “The specificity of strength training: the effect of posture,” *European journal of applied physiology and occupational physiology*, vol. 73, no. 3-4, pp. 346–352, 1996. [7](#)
- [30] S. J. Fleck and W. J. Kraemer, *Designing Resistance Training Programs-3rd*. Human Kinetics 1, 2004. [7](#), [45](#), [89](#), [103](#)
- [31] G. Borg, “Psychophysical scaling with applications in physical work and the perception of exertion,” *Scandinavian journal of work, environment & health*, pp. 55–58, 1990. [7](#)
- [32] G. Borg, “Psychophysical scaling with applications in physical work and the perception of exertion,” *Scandinavian journal of work, environment & health*, pp. 55–58, 1990. [7](#)
- [33] R. Benson and D. Connolly, *Heart Rate Training*. Human Kinetics 1, 2011. [8](#)
- [34] J. Pansiot, B. Lo, and G.-Z. Yang, “Swimming stroke kinematic analysis with bsn,” in *Body Sensor Networks (BSN), 2010 International Conference on*, pp. 153–158, 2010. [12](#), [13](#), [14](#)
- [35] S. Reddy, K. Shilton, G. Denisov, C. Cenizal, D. Estrin, and M. Srivastava, “Biketastic: sensing and mapping for better biking,” in *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, CHI ’10*, (New York, NY, USA), pp. 1817–1820, ACM, 2010. [13](#)
- [36] A. Ahtinen, M. Isomursu, Y. Huhtala, J. Kaasinen, J. Salminen, and J. Häkkilä, “Tracking outdoor sports—user experience perspective,” in *Ambient Intelligence*, pp. 192–209, Springer, 2008. [13](#), [14](#), [44](#)

-
- [37] T. C. T. Ho and X. Chen, “Exertrek: A portable handheld exercise monitoring, tracking and recommendation system,” in *e-Health Networking, Applications and Services, 2009. Healthcom 2009. 11th International Conference on*, pp. 84–88, IEEE, 2009. [13](#), [14](#)
 - [38] P. Siirtola, P. Laurinen, J. Roning, and H. Kinnunen, “Efficient accelerometer-based swimming exercise tracking,” in *Computational Intelligence and Data Mining (CIDM), 2011 IEEE Symposium on*, pp. 156–161, IEEE, 2011. [13](#), [14](#)
 - [39] T. Denning, A. Andrew, R. Chaudhri, C. Hartung, J. Lester, G. Borriello, and G. Duncan, “Balance: towards a usable pervasive wellness application with accurate activity inference,” in *Proceedings of the 10th workshop on Mobile Computing Systems and Applications*, p. 5, ACM, 2009. [13](#), [15](#)
 - [40] L. Nachman, A. Baxi, S. Bhattacharya, V. Darera, P. Deshpande, N. Kodalapura, V. Mageshkumar, S. Rath, J. Shahabdeen, and R. Acharya, “Jog falls: a pervasive healthcare platform for diabetes management,” in *Proceedings of the 8th international conference on Pervasive Computing, Pervasive’10*, (Berlin, Heidelberg), pp. 94–111, Springer-Verlag, 2010. [13](#), [15](#)
 - [41] C. Mattmann, O. Amft, H. Harms, G. Troster, and F. Clemens, “Recognizing upper body postures using textile strain sensors,” in *Wearable Computers, 2007 11th IEEE International Symposium on*, pp. 29–36, IEEE, 2007. [13](#), [16](#)
 - [42] K.-H. Chang, M. Y. Chen, and J. Canny, “Tracking free-weight exercises,” in *Proceedings of the 9th international conference on Ubiquitous computing, UbiComp ’07*, (Berlin, Heidelberg), pp. 19–37, Springer-Verlag, 2007. [13](#), [16](#), [23](#), [24](#), [28](#), [29](#)
 - [43] C. Seeger, A. Buchmann, and K. Van Laerhoven, “myhealthassistant: A phone-based body sensor network that captures the wearer’s exercises throughout the day,” in *Proceedings of the 6th International Conference on Body Area Networks*, pp. 1–7, ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), 2011. [13](#), [16](#)

-
- [44] C. Seeger, A. Buchmann, and K. Van Laerhoven, “Adaptive gym exercise counting for myhealthassistant: poster abstract,” in *Proceedings of the 6th International Conference on Body Area Networks*, pp. 126–127, ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), 2011. [13](#), [16](#)
 - [45] M. Muehlbauer, G. Bahle, and P. Lukowicz, “What can an arm holster worn smart phone do for activity recognition?,” in *Wearable Computers (ISWC), 2011 15th Annual International Symposium on*, pp. 79–82, IEEE, 2011. [13](#), [16](#), [23](#), [24](#), [28](#), [29](#)
 - [46] I. Anderson, J. Maitland, S. Sherwood, L. Barkhuus, M. Chalmers, M. Hall, B. Brown, and H. Muller, “Shakra: tracking and sharing daily activity levels with unaugmented mobile phones,” *Mob. Netw. Appl.*, vol. 12, pp. 185–199, Mar. 2007. [13](#), [17](#)
 - [47] M. Ahn, S. Kwon, B. Park, K. Cho, S. P. Choe, I. Hwang, H. Jang, J. Park, Y. Rhee, and J. Song, “Running or gaming,” in *Proceedings of the International Conference on Advances in Computer Entertainment Technology*, ACE ’09, (New York, NY, USA), pp. 345–348, ACM, 2009. [13](#), [17](#)
 - [48] N. Oliver and F. Flores-Mangas, “Mptrain: a mobile, music and physiology-based personal trainer,” in *Proceedings of the 8th conference on Human-computer interaction with mobile devices and services*, pp. 21–28, ACM, 2006. [13](#), [17](#)
 - [49] R. de Oliveira and N. Oliver, “Triplebeat: enhancing exercise performance with persuasion,” in *Proceedings of the 10th international conference on Human computer interaction with mobile devices and services*, MobileHCI ’08, (New York, NY, USA), pp. 255–264, ACM, 2008. [13](#), [17](#)
 - [50] J. T. Biehl, P. D. Adamczyk, and B. P. Bailey, “Djogger: a mobile dynamic music device,” in *CHI ’06 Extended Abstracts on Human Factors in Computing Systems*, CHI EA ’06, (New York, NY, USA), pp. 556–561, ACM, 2006. [13](#), [17](#)

-
- [51] S. Bosch, M. Marin-Perianu, R. Marin-Perianu, P. Havinga, and H. Hermens, "Keep on moving! activity monitoring and stimulation using wireless sensor networks," in *Proceedings of the 4th European conference on Smart sensing and context*, EuroSSC'09, (Berlin, Heidelberg), pp. 11–23, Springer-Verlag, 2009. [13](#), [18](#)
 - [52] S. Consolvo, P. Klasnja, D. W. McDonald, D. Avrahami, J. Froehlich, L. LeGrand, R. Libby, K. Mosher, and J. A. Landay, "Flowers or a robot army?: encouraging awareness & activity with personal, mobile displays," in *Proceedings of the 10th international conference on Ubiquitous computing*, pp. 54–63, ACM, 2008. [13](#), [18](#)
 - [53] F. F. Mueller, S. O'Brien, and A. Thorogood, "Jogging over a distance: supporting a "jogging together"experience although being apart," in *CHI '07 Extended Abstracts on Human Factors in Computing Systems*, CHI EA '07, (New York, NY, USA), pp. 2579–2584, ACM, 2007. [13](#), [18](#)
 - [54] G. Stevens, A. Thorogood, S. O'Brien, V. Wulf, *et al.*, "Sports over a distance," *Personal and Ubiquitous Computing*, vol. 11, no. 8, pp. 633–645, 2007. [13](#), [18](#)
 - [55] G. Wijnalda, S. Pauws, F. Vignoli, and H. Stuckenschmidt, "A personalized music system for motivation in sport performance," *Pervasive Computing, IEEE*, vol. 4, no. 3, pp. 26–32, 2005. [13](#), [17](#)
 - [56] E. Heinz, K. Kunze, M. Gruber, D. Bannach, and P. Lukowicz, "Using wearable sensors for real-time recognition tasks in games of martial arts - an initial experiment," in *Computational Intelligence and Games, 2006 IEEE Symposium on*, pp. 98–102, 2006. [13](#), [18](#)
 - [57] S. Masuko and J. Hoshino, "A fitness game reflecting heart rate," in *Proceedings of the 2006 ACM SIGCHI international conference on Advances in computer entertainment technology*, ACE '06, (New York, NY, USA), ACM, 2006. [13](#), [18](#)

-
- [58] W. Ourique de Moraes, A. d. Sant'Anna, and N. Wickström, “A wearable accelerometer based platform to encourage physical activity for the elderly,” *Gerontechnology*, vol. 7, no. 2, p. 181, 2008. [13](#), [18](#)
 - [59] M.-K. Suh, A. Nahapetian, J. Woodbridge, M. Rofouei, and M. Sarrafzadeh, “Machine learning-based adaptive wireless interval training guidance system,” *Mob. Netw. Appl.*, vol. 17, pp. 163–177, Apr. 2012. [13](#), [19](#)
 - [60] Y. Fujiki, K. Kazakos, C. Puri, P. Buddharaju, I. Pavlidis, and J. Levine, “Neat-o-games: blending physical activity and fun in the daily routine,” *Comput. Entertain.*, vol. 6, pp. 21:1–21:22, July 2008. [13](#), [19](#)
 - [61] A. Moller, L. Roalter, S. Diewald, J. Scherr, M. Kranz, N. Hammerla, P. Olivier, and T. Plotz, “Gymskill: A personal trainer for physical exercises,” in *Pervasive Computing and Communications (PerCom), 2012 IEEE International Conference on*, pp. 213–220, IEEE, 2012. [13](#), [15](#)
 - [62] F. Buttussi, L. Chittaro, and D. Nadalutti, “Bringing mobile guides and fitness activities together: a solution based on an embodied virtual trainer,” in *Proceedings of the 8th conference on Human-computer interaction with mobile devices and services*, MobileHCI '06, (New York, NY, USA), pp. 29–36, ACM, 2006. [13](#), [15](#)
 - [63] F. Buttussi and L. Chittaro, “Mopet: A context-aware and user-adaptive wearable system for fitness training,” *Artif. Intell. Med.*, vol. 42, pp. 153–163, Feb. 2008. [13](#), [15](#), [44](#)
 - [64] M. Bächlin, K. Förster, and G. Tröster, “Swimmaster: A wearable assistant for swimmer,” in *Ubicomp '09: Proceedings of the 11th international conference on Ubiquitous computing*, (New York, NY, USA), pp. 215–224, ACM, Sept. 2009. [13](#), [14](#)
 - [65] D. Spelmezan, A. Schanowski, and J. Borchers, “Wearable automatic feedback devices for physical activities,” in *Proceedings of the Fourth International Conference on Body Area Networks*, BodyNets '09, (ICST, Brussels, Belgium, Belgium), pp. 1:1–1:8, ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), 2009. [13](#), [15](#)

- [66] C. Strohrmann, H. Harms, G. Tröster, S. Hensler, and R. Müller, “Out of the lab and into the woods: kinematic analysis in running using wearable sensors,” in *Proceedings of the 13th international conference on Ubiquitous computing*, pp. 119–122, ACM, 2011. [13](#), [15](#), [73](#)
- [67] C. Strohrmann, H. Harms, and G. Troster, “What do sensors know about your running performance?,” in *Wearable Computers (ISWC), 2011 15th Annual International Symposium on*, pp. 101–104, 2011. [13](#), [15](#), [73](#)
- [68] C. Strohrmann, M. Rossi, B. Arnrich, and G. Troster, “A data-driven approach to kinematic analysis in running using wearable technology,” in *Wearable and Implantable Body Sensor Networks (BSN), 2012 Ninth International Conference on*, pp. 118–123, IEEE, 2012. [13](#), [15](#), [73](#)
- [69] R. Asselin, G. Ortiz, J. Pui, A. Smailagic, and C. Kissling, “Implementation and evaluation of the personal wellness coach,” in *Distributed Computing Systems Workshops, 2005. 25th IEEE International Conference on*, pp. 529–535, IEEE, 2005. [13](#), [16](#)
- [70] H. Ghasemzadeh, V. Loseu, E. Guenterberg, and R. Jafari, “Sport training using body sensor networks: a statistical approach to measure wrist rotation for golf swing,” in *Proceedings of the Fourth International Conference on Body Area Networks, BodyNets '09*, (ICST, Brussels, Belgium, Belgium), pp. 2:1–2:8, ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), 2009. [13](#), [16](#), [25](#), [28](#), [29](#)
- [71] J. Music and R. Murray-Smith, “Virtual hooping: teaching a phone about hula-hooping for fitness, fun and rehabilitation,” in *Proceedings of the 12th international conference on Human computer interaction with mobile devices and services*, pp. 309–312, ACM, 2010. [13](#), [17](#)
- [72] S. Melzi, L. Borsani, and M. Cesana, “The virtual trainer: supervising movements through a wearable wireless sensor network,” in *Sensor, Mesh and Ad Hoc Communications and Networks Workshops, 2009. SECON Workshops' 09. 6th Annual IEEE Communications Society Conference on*, pp. 1–3, IEEE, 2009. [13](#), [16](#)

-
- [73] D. Nadalutti and L. Chittaro, “Visual analysis of users’ performance data in fitness activities,” *Comput. Graph.*, vol. 31, pp. 429–439, June 2007. [15](#)
 - [74] I. A. Li, A. K. Dey, and J. Forlizzi, “Monitoring and feedback to increase awareness of exercise activities,” in *Ubicomp 2005 Workshop on Monitoring, Measuring and Motivating Exercise: Ubiquitous Computing to Support Physical Fitness*, 2005. [19](#)
 - [75] A. Baca and P. Kornfeind, “Rapid feedback systems for elite sports training,” *Pervasive Computing, IEEE*, vol. 5, no. 4, pp. 70–76, 2006. [19](#), [20](#)
 - [76] D. Sturm, K. Yousaf, and M. Eriksson, “A wireless, unobtrusive kayak sensor network enabling feedback solutions,” in *Body Sensor Networks (BSN), 2010 International Conference on*, pp. 159–163, 2010. [19](#), [20](#)
 - [77] F. Michahelles and B. Schiele, “Sensing and monitoring professional skiers,” *Pervasive Computing, IEEE*, vol. 4, no. 3, pp. 40–45, 2005. [19](#), [20](#)
 - [78] A. Baca, P. Kornfeind, E. Preuschl, S. Bichler, M. Tampier, and H. Novatchkov, “A server-based mobile coaching system,” *Sensors*, vol. 10, no. 12, pp. 10640–10662, 2010. [19](#), [20](#)
 - [79] M. Beetz, B. Kirchlechner, and M. Lames, “Computerized real-time analysis of football games,” *Pervasive Computing, IEEE*, vol. 4, no. 3, pp. 33–39, 2005. [19](#), [20](#)
 - [80] D. A. James, N. Davey, and T. Rice, “An accelerometer based sensor platform for insitu elite athlete performance analysis,” pp. 1373–1376, 2004. [19](#), [20](#)
 - [81] E. H. Chi, “Introducing wearable force sensors in martial arts,” *IEEE Pervasive Computing*, vol. 4, pp. 47–53, July 2005. [19](#), [21](#)
 - [82] K. Fitzpatrick and R. Anderson, “Validation of accelerometers and gyroscopes to provide real-time kinematic data for golf analysis,” in *The Engineering of Sport 6*, pp. 155–160, Springer, 2006. [19](#), [21](#)

-
- [83] H. Ghasemzadeh and R. Jafari, "Body sensor networks for baseball swing training: Coordination analysis of human movements using motion transcripts," in *Pervasive Computing and Communications Workshops (PERCOM Workshops), 2010 8th IEEE International Conference on*, pp. 792–795, IEEE, 2010. [19](#), [21](#)
 - [84] M. Kusserow, O. Amft, H. Gubelmann, and G. Tröster, "Arousal pattern analysis of an olympic champion in ski jumping," *Sports Technology*, vol. 3, no. 3, pp. 192–203, 2010. [19](#), [21](#)
 - [85] S. Slawson, L. Justham, A. West, P. Conway, M. Caine, and R. Harrison, "Accelerometer profile recognition of swimming strokes (p17)," in *The Engineering of Sport 7*, pp. 81–87, Springer, 2008. [19](#), [21](#)
 - [86] S. Taherian, M. Pias, R. Harle, G. Coulouris, S. Hay, J. Cameron, J. Lasenby, G. Kuntze, I. Bezodis, G. Irwin, and D. Kerwin, "Profiling sprints using on-body sensors," in *Pervasive Computing and Communications Workshops (PERCOM Workshops), 2010 8th IEEE International Conference on*, pp. 444–449, 2010. [19](#), [22](#)
 - [87] R. Anderson, A. Harrison, and G. M. Lyons, "Rowing: Accelerometry-based feedback-can it improve movement consistency and performance in rowing?," *Sports Biomechanics*, vol. 4, no. 2, pp. 179–195, 2005. [19](#), [22](#)
 - [88] A. Wixted, D. V. Thiel, A. Hahn, C. Gore, D. Pyne, and D. James, "Measurement of energy expenditure in elite athletes using mems-based triaxial accelerometers," *Sensors Journal, IEEE*, vol. 7, no. 4, pp. 481–488, 2007. [19](#), [20](#)
 - [89] T. Huynh and B. Schiele, "Analyzing features for activity recognition," in *Proceedings of the 2005 joint conference on Smart objects and ambient intelligence: innovative context-aware services: usages and technologies, sOc-EUSAI '05*, (New York, NY, USA), pp. 159–163, ACM, 2005. [23](#), [24](#), [28](#)
 - [90] V. Könönen, J. Mäntyjärvi, H. Similä, J. Pärkkä, and M. Ermes, "Automatic feature selection for context recognition in mobile devices," *Pervasive Mob. Comput.*, vol. 6, pp. 181–197, Apr. 2010. [23](#), [24](#), [28](#)

-
- [91] S. Preece, J. Goulermas, L. P. J. Kenney, and D. Howard, “A comparison of feature extraction methods for the classification of dynamic activities from accelerometer data,” *Biomedical Engineering, IEEE Transactions on*, vol. 56, no. 3, pp. 871–879, 2009. [23](#), [24](#), [25](#), [28](#), [29](#)
 - [92] P. Siirtola, P. Laurinen, E. Haapalainen, J. Roning, and H. Kinnunen, “Clustering-based activity classification with a wrist-worn accelerometer using basic features,” in *Computational Intelligence and Data Mining, 2009. CIDM '09. IEEE Symposium on*, pp. 95–100, 2009. [23](#), [24](#), [25](#), [28](#), [29](#)
 - [93] M. Ermes, J. Parkka, J. Mantyjarvi, and I. Korhonen, “Detection of daily activities and sports with wearable sensors in controlled and uncontrolled conditions,” *Trans. Info. Tech. Biomed.*, vol. 12, pp. 20–26, Jan. 2008. [23](#), [24](#), [26](#), [28](#), [29](#)
 - [94] W. Wu, S. Dasgupta, E. E. Ramirez, C. Peterson, and G. J. Norman, “Classification accuracies of physical activities using smartphone motion sensors,” *Journal of medical Internet research*, vol. 14, no. 5, p. e130, 2012. [23](#), [24](#), [28](#), [29](#), [97](#)
 - [95] L. Bao and S. S. Intille, “Activity recognition from user-annotated acceleration data,” in *Pervasive Computing*, pp. 1–17, Springer, 2004. [23](#), [24](#), [28](#)
 - [96] N. Bicocchi, M. Mamei, and F. Zambonelli, “Detecting activities from body-worn accelerometers via instance-based algorithms,” *Pervasive Mob. Comput.*, vol. 6, pp. 482–495, Aug. 2010. [23](#), [24](#), [26](#), [28](#), [29](#)
 - [97] A. Czabke, S. Marsch, and T. C. Lueth, “Accelerometer based real-time activity analysis on a microcontroller,” in *Pervasive Computing Technologies for Healthcare (PervasiveHealth), 2011 5th International Conference on*, pp. 40–46, IEEE, 2011. [23](#), [27](#), [29](#)
 - [98] N. Győrbíró, Á. Fábián, and G. Hományi, “An activity recognition system for mobile phones,” *Mobile Networks and Applications*, vol. 14, no. 1, pp. 82–91, 2009. [23](#), [24](#), [27](#)

- [99] J. R. Kwapisz, G. M. Weiss, and S. A. Moore, “Activity recognition using cell phone accelerometers,” *SIGKDD Explor. Newsl.*, vol. 12, pp. 74–82, Mar. 2011. [23](#), [24](#), [28](#), [29](#)
- [100] N. Ravi, N. Dandekar, P. Mysore, and M. L. Littman, “Activity recognition from accelerometer data,” in *Proceedings of the national conference on artificial intelligence*, vol. 20, p. 1541, Menlo Park, CA; Cambridge, MA; London; AAAI Press; MIT Press; 1999, 2005. [23](#), [24](#), [28](#), [29](#)
- [101] E. Guenterberg, H. Ghasemzadeh, V. Loseu, and R. Jafari, “Distributed continuous action recognition using a hidden markov model in body sensor networks,” in *Proceedings of the 5th IEEE International Conference on Distributed Computing in Sensor Systems, DCOS ’09*, (Berlin, Heidelberg), pp. 145–158, Springer-Verlag, 2009. [25](#)
- [102] A. Henpraserttae, S. Thiemjarus, and S. Marukatat, “Accurate activity recognition using a mobile phone regardless of device orientation and location,” in *Body Sensor Networks (BSN), 2011 International Conference on*, pp. 41–46, 2011. [27](#)
- [103] N. Arzeno, Z.-D. Deng, and C.-S. Poon, “Analysis of first-derivative based qrs detection algorithms,” *Biomedical Engineering, IEEE Transactions on*, vol. 55, no. 2, pp. 478–484, 2008. [30](#)
- [104] M. Marschollek, M. Goevercin, K.-H. Wolf, B. Song, M. Gietzelt, R. Haux, and E. Steinhagen-Thiessen, “A performance comparison of accelerometry-based step detection algorithms on a large, non-laboratory sample of healthy and mobility-impaired persons,” in *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, pp. 1319–1322, 2008. [31](#)
- [105] B.-U. Kohler, C. Hennig, and R. Orglmeister, “The principles of software qrs detection,” *Engineering in Medicine and Biology Magazine, IEEE*, vol. 21, no. 1, pp. 42–57, 2002. [31](#)

-
- [106] H. Sakoe and S. Chiba, “Dynamic programming algorithm optimization for spoken word recognition,” *Acoustics, Speech and Signal Processing, IEEE Transactions on*, vol. 26, no. 1, pp. 43–49, 1978. [32](#)
 - [107] D. Berndt and J. Clifford, “Using dynamic time warping to find patterns in time series,” in *KDD workshop*, vol. 10, pp. 359–370, Seattle, WA, 1994. [32](#)
 - [108] J. Liu, L. Zhong, J. Wickramasuriya, and V. Vasudevan, “uwave: Accelerometer-based personalized gesture recognition and its applications,” *Pervasive and Mobile Computing*, vol. 5, no. 6, pp. 657–675, 2009. [32, 52](#)
 - [109] R. Muscillo, S. Conforto, M. Schmid, P. Caselli, and T. D’Alessio, “Classification of motor activities through derivative dynamic time warping applied on accelerometer data,” in *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*, pp. 4930–4933, IEEE, 2007. [32, 52](#)
 - [110] M. Müller, *Information Retrieval for Music and Motion*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2007. [33](#)
 - [111] T. M. Mitchell, *Machine learning*. McGraw-Hill Boston, MA:, 1997. [34, 35](#)
 - [112] P. Langley, *Elements of Machine Learning*. Machine Learning Series, Morgan Kaufmann Publishers, 1996. [35](#)
 - [113] I. H. Witten and E. Frank, *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann, 2005. [37, 39, 40, 42](#)
 - [114] G. D. Clifford, F. Azuaje, P. McSharry, *et al.*, *Advanced methods and tools for ECG data analysis*. Artech house London, 2006. [38](#)
 - [115] S. F. Suling, F. Guenther, and following earlier work by Marc, “neuralnet: Training of neural networks.” <http://cran.r-project.org/package=neuralnet>. Dostop: 6. junij 2013. [38](#)
 - [116] G. Stiglic, S. Kocbek, I. Pernek, and P. Kokol, “Comprehensive decision tree models in bioinformatics,” *PloS one*, vol. 7, no. 3, p. e33812, 2012. [41](#)

- [117] A. H. Eschenfelder, *Data mining and knowledge discovery handbook*, vol. 14. Springer-Verlag New York Incorporated, 1980. 41
- [118] C.-W. Hsu, C.-C. Chang, C.-J. Lin, *et al.*, “A practical guide to support vector classification,” 2003. 42, 78
- [119] I. Pernek, K. A. Hummel, and P. Kokol, “Exercise repetition detection for resistance training based on smartphones,” *Personal Ubiquitous Comput.*, vol. 17, pp. 771–782, Apr. 2013. 43
- [120] “Garmin.” <http://www.garmin.com/>. Dostop: 6. junij 2013. 43
- [121] “Polar.” <http://www.polar.com/>. Dostop: 6. junij 2013. 43
- [122] “Suunto.” <http://www.suunto.com/>. Dostop: 6. junij 2013. 43
- [123] “Apple app store.” <http://www.apple.com/iphone/from-the-app-store/>. Dostop: 6. junij 2013. 44
- [124] “Google Play.” <https://play.google.com/store>. Dostop: 6. junij 2013. 44
- [125] J. L. Alexander, “The role of resistance exercise in weight loss,” *Strength & Conditioning Journal*, vol. 24, no. 1, pp. 65–69, 2002. 44
- [126] “Jefit.” <http://www.jefit.com/>. Dostop: 6. junij 2013. 44
- [127] M. Kirwan, M. J. Duncan, C. Vandelanotte, and W. K. Mummery, “Using smartphone technology to monitor physical activity in the 10,000 steps program: a matched case-control trial,” 2012. 44
- [128] “ABI Research Report: Mobile device user interfaces.” <http://www.abiresearch.com/research/product/1005746-mobile-device-user-interfaces/>. Dostop: 6. junij 2013. 44
- [129] K. Sato, S. L. Smith, and W. A. Sands, “Validation of an accelerometer for measuring sport performance,” *The Journal of Strength & Conditioning Research*, vol. 23, no. 1, pp. 341–347, 2009. 44

-
- [130] M. L. Pollock, B. A. Franklin, G. J. Balady, B. L. Chaitman, J. L. Fleg, B. Fletcher, M. Limacher, I. L. Piña, R. A. Stein, M. Williams, *et al.*, “Resistance exercise in individuals with and without cardiovascular disease: benefits, rationale, safety, and prescriptionan advisory from the committee on exercise, rehabilitation, and prevention, council on clinical cardiology, american heart association,” *Circulation*, vol. 101, no. 7, pp. 828–833, 2000.
49
 - [131] T. R. Baechle and R. W. Earle, *Essentials of strength training and conditioning*. Human Kinetics 10%, 2008. 49
 - [132] F. Delavier, *Strength training anatomy*. Champaign, IL: Human Kinetics, 2010. 49
 - [133] P. Page and T. S. Ellenbecker, *Strength Band Training, 2E*. Human Kinetics 1, 2010. 49
 - [134] P. Tormene, T. Giorgino, S. Quaglini, and M. Stefanelli, “Matching incomplete time series with dynamic time warping: an algorithm and an application to post-stroke rehabilitation,” *Artif. Intell. Med.*, vol. 45, pp. 11–34, Jan. 2009. 52, 57
 - [135] A. Savitzky and M. J. Golay, “Smoothing and differentiation of data by simplified least squares procedures.,” *Analytical chemistry*, vol. 36, no. 8, pp. 1627–1639, 1964. 54
 - [136] D. Figo, P. C. Diniz, D. R. Ferreira, and J. M. Cardoso, “Preprocessing techniques for context recognition from accelerometer data,” *Personal and Ubiquitous Computing*, vol. 14, no. 7, pp. 645–662, 2010. 59, 65, 78
 - [137] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I. H. Witten, “The weka data mining software: an update,” *ACM SIGKDD Explorations Newsletter*, vol. 11, no. 1, pp. 10–18, 2009. 59, 64
 - [138] I. Pernek, G. Stiglic, and P. Kokol, “How hard am i training? using smart phones to estimate sport activity intensity,” in *Distributed Comput-*

- ing Systems Workshops (ICDCSW), 2012 32nd International Conference on*, pp. 65–68, 2012. [62](#)
- [139] M. L. Pollock, G. A. Gaesser, J. D. Butcher, J.-P. Després, R. K. Dishman, B. A. Franklin, and C. E. Garber, “Acsm position stand: the recommended quantity and quality of exercise for developing and maintaining cardiorespiratory and muscular fitness, and flexibility in healthy adults,” *Med Sci Sports Exerc*, vol. 30, no. 6, pp. 975–991, 1998. [62](#), [63](#)
- [140] S. Edwards, *The heart rate monitor book*. Polar Cic, 1992. [63](#)
- [141] J. Achten and A. E. Jeukendrup, “Heart rate monitoring,” *Sports medicine*, vol. 33, no. 7, pp. 517–538, 2003. [63](#)
- [142] R. Cozza, C. Milanesi, and T. Nguyen, “Market Share Analysis: Mobile Devices, Worldwide,” tech. rep., Gartner Group Research Report, 2011. [63](#)
- [143] R Development Core Team, *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2008. ISBN 3-900051-07-0. [64](#), [87](#)
- [144] M. Robnik-Šikonja and I. Kononenko, “Theoretical and empirical analysis of reliefF and rreliefF,” *Mach. Learn.*, vol. 53, pp. 23–69, Oct. 2003. [66](#)
- [145] R. G. Eston, A. V. Rowlands, and D. K. Ingledew, “Validity of heart rate, pedometry, and accelerometry for predicting the energy cost of children’s activities,” *Journal of Applied Physiology*, vol. 84, no. 1, pp. 362–371, 1998. [68](#)
- [146] A. C. Fry and W. J. Kraemer, “Resistance exercise overtraining and over-reaching,” *Sports medicine*, vol. 23, no. 2, pp. 106–129, 1997. [71](#)
- [147] A. Sant’Anna and N. Wickstrom, “A symbol-based approach to gait analysis from acceleration signals: Identification and detection of gait events and a new measure of gait symmetry,” *Information Technology in Biomedicine, IEEE Transactions on*, vol. 14, no. 5, pp. 1180–1187, 2010. [73](#)

- [148] G. Chambers, S. Venkatesh, G. A. W. West, and H. Bui, “Hierarchical recognition of intentional human gestures for sports video annotation,” in *Pattern Recognition, 2002. Proceedings. 16th International Conference on*, vol. 2, pp. 1082–1085 vol.2, 2002. [76](#)
- [149] T. Giorgino, “Computing and visualizing dynamic time warping alignments in r: the dtw package,” *Journal of Statistical Software*, vol. 31, no. 7, pp. 1–24, 2009. [87](#)



Univerza v Mariboru



Fakulteta za elektrotehniko,
računalništvo in informatiko

Smetanova ulica 17
2000 Maribor, Slovenija

IZJAVA KANDIDATOVEGA MENTORJA O USTREZNOSTI DOKTORSKE DISERTACIJE

Podpisani-a red. prof. dr. Peter Kokol, mentor-ica doktorskemu-i kandidatu-ki, izjavljam, da je doktorska disertacija z naslovom Uporaba vseprisotnega računalništva za kvalitativno vrednotenje vzorcev rekreativne fizične aktivnosti, ki jo je izdelal-a doktorski-a kandidat-ka Igor Pernek, v skladu z odobreno temo, Pravilnikom o pripravi in zagovoru doktorske disertacije ter mojimi navodili in predstavlja izviren prispevek k razvoju znanstvene discipline.

Datum in kraj:
Maribor, 8. 10. 2013

Podpis mentorja-ice:

A handwritten signature in blue ink, appearing to read "Igor Pernek".

Obrazec RŠZ



Fakulteta za elektrotehniko,
računalništvo in informatiko
Smetanova ulica 17
2000 Maribor, Slovenija



IZJAVA DOKTORSKEGA KANDIDATA

Podpisani-a Igor Pernek,
vpisna številka E9500376.

izjavljam,

da je doktorska disertacija z naslovom Uporaba vseprisotnega računalništva za kvalitativno vrednotenje vzorcev rekreativne fizične aktivnosti

- rezultat lastnega raziskovalnega dela,
- da predložena disertacija v celoti ali v delih ni bila predložena za pridobitev kakršnekoli izobrazbe po študijskem programu druge fakultete ali univerze,
- da so rezultati korektno navedeni in
- da nisem kršil-a avtorskih pravic in intelektualne lastnine drugih.

Podpis doktorskega kandidata-ke:

Obrazec RŠZ



Fakulteta za elektrotehniko,
računalništvo in informatiko
Smetanova ulica 17
2000 Maribor, Slovenija



**IZJAVA O OBJAVI ELEKTRONSKE VERZIJE DOKTORSKE DISERTACIJE IN OSEBNIH PODATKOV,
VEZANIH NA ZAKLJUČEK ŠTUDIJA**

Ime in priimek doktoranda-ke: Igor Pernek

Vpisna številka: E9500376

Študijski program: Računalništvo in informatika

Naslov doktorskega dela:

Uporaba vseprisotnega računalništva za kvalitativno vrednotenje vzorcev rekreativne fizične aktivnosti

Mentor-ica: red. prof. dr. Peter Kokol

Somentor-ica: _____

Podpisani soglašam z objavo doktorske disertacije v Digitalni knjižnici Univerze v Mariboru.

Tiskana verzija doktorske disertacije je istovetna elektronski verziji, ki sem jo oddal-a v Digitalno knjižnico Univerze v Mariboru.

Podpisani-a hkrati izjavljam, da dovoljujem objavo osebnih podatkov, vezanih na zaključek študija (ime, priimek, leto in kraj rojstva, datum diplomiranja, naslov diplomskega dela) na spletnih straneh in v publikacijah Univerze v Mariboru.

Datum in kraj:

Maribor, 8. 10. 2013

Podpis doktoranda-ke:

A handwritten signature in blue ink, appearing to read "Igor Pernek". It is placed over a horizontal line.

Obrazec RŠZ