

UNIVERZA NA PRIMORSKEM
FAKULTETA ZA MATEMATIKO, NARAVOSLOVJE IN
INFORMACIJSKE TEHNOLOGIJE

Magistrsko delo

Neintruzivna identifikacija padcev s pomočjo pametnih tal

(Non-intrusive fall recognition using smart floor)

Ime in priimek: Niki Hrovatin

Študijski program: Računalništvo in informatika, 2. stopnja

Mentor: izr. prof. dr. Jernej Vičič

Somentor: asist. Aleksandar Tošić

Koper, september 2020

Ključna dokumentacijska informacija

Ime in PRIIMEK: Niki HROVATIN

Naslov magistrskega dela: Neintruzivna identifikacija padcev s pomočjo pametnih tal

Kraj: Koper

Leto: 2020

Število listov: 85

Število slik: 31

Število tabel: 2

Število referenc: 45

Število prilog: 1

Število strani prilog: 1

Mentor: izr. prof. dr. Jernej Vičič

Somentor: asist. Aleksandar Tošić

UDK: 004.383.8(043.2)

Ključne besede: neintruzivna identifikacija padca, pametna tla, strojno učenje, konvolucijska nevronska mreža, arduino

Izvleček: Padci so pri starostnikih pogosti pojav in veljajo za vodilni vzrok poškodb oseb nad 65 letom starosti, tretjina oseb nad 65 letom in polovica oseb nad 85 letom doživi letni padec pri tem se tudi verjetnost hude poškodbe viša z letom starosti in ob padcu je treba nemudoma nuditi pomoč osebi. Da lahko nudimo takojšnjo pomoč, je potrebno v čim krajšem času zaznati padec, ampak v nekaterih primerih se oseba tako hudo poškoduje, da ne utegne klicati za pomoč in padec je prepozno opažen ter oseba doživi dodatne poškodbe zaradi pretečenega časa.

V magistrskem delu je opisana realizacija sistema za identifikacijo padca kateri sloni na metodah strojnega učenja in pametnih tal z vgrajenimi senzorji pritiska. Izbrali smo tlačno zaznavanje padca, ker ohrani zasebnost uporabnikov in omogoči čim višjo prostost uporabnika oziroma nobene obvezne po nosljivi tehnologiji.

Key document information

Name and SURNAME: Niki HROVATIN

Title of the thesis: Non-intrusive fall recognition using smart floor

Place: Koper

Year: 2020

Number of pages: 85

Number of figures: 31

Number of tables: 2

Number of references: 45

Number of appendices: 1

Number of appendix pages: 1

Mentor: Assist. Prof. Jernej Vičič, PhD

Co-mentor: Assist. Aleksandar Tošić

UDC: 004.383.8(043.2)

Keywords: non-intrusive fall recognition, smart floor, machine learning, convolutional neural network, arduino

Abstract: Falls are events that affect almost every aging human being above the age of 65. These incidents can have major consequences on the physical, psychological and socio-economical levels. The aim of the project is to successfully differentiate ordinal daily activities from the sudden fall event to provide immediate help and prevent further injuries. Most existing solutions that tries to solve this problem are based on wearable technology or image sensors that are very effective in the fall recognition task but at the same time they are very intrusive and can create a psychological discomfort for the person that is constantly monitored and aware of the system. In the thesis we propose a system based on a smart floor with embedded force sensors which using a machine learning approach is able to identify if an unintentional fall occurred.

Kazalo vsebine

1 Uvod	1
2 Pregled področja identifikacije padcev	2
2.1 Definicija sistema za identifikacijo padca	2
2.1.1 Običajen sistem za identifikacijo padca	3
2.2 Analiza padca	4
2.2.1 Zgodnja zaznava kritične faze padca	4
2.2.2 Zaznava konkluzije kritične faze	5
2.2.3 Identifikacija ležalne poze po padcu	5
2.2.4 Identifikacija odsotnosti gibanja po padcu	5
2.3 Senzorske tehnologije za identifikacijo padcev	6
2.3.1 Nosljiva tehnologija	6
2.3.2 Ambientna tehnologija	7
2.4 Vloga procesne enote sistema za identifikacijo padcev	8
2.4.1 Časovne vrste	9
2.4.1.1 Premikajoče okno	9
2.4.1.2 Odkrivanje značilk	9
2.4.2 Strojno učenje za identifikacijo padcev	9
2.4.2.1 Nadzorovano učenje in klasifikacija	10
2.4.2.2 Evalvacija sistema za identifikacijo padca	10
2.4.3 Naivni Bayes	11
2.4.4 Umetna nevronska mreža in konvolucija	12
2.4.4.1 Struktura običajne umetne nevronske mreže	12
2.4.4.2 Umetni nevron	13
2.4.4.3 Učenje umetne nevronske mreže	13
2.4.4.4 Konvolucijska nevronska mreža	14
2.4.4.5 Združevanje maksimalnih vrednosti	15
2.4.4.6 Regularizacija preko izpuščanja	15
2.4.4.7 One-hot encoding	15
3 Motivacija	16

3.1	Neintruzivna identifikacija padcev	16
3.2	Identifikacija padcev na osnovi senzorjev vgrajenih v tleh	18
4	Metodologija	20
4.1	Metodologija razvoja	20
4.2	Načrtovanje sistema	21
4.3	Strojna oprema	22
4.3.1	Opis tal z vgrajenimi senzorji pritiska	22
4.3.2	Senzor pritiska	23
4.3.3	Mikrokrmlnik in matrika senzorjev	24
4.4	Programska oprema	25
4.4.1	Programska oprema za identifikacijo padcev	25
4.4.1.1	Aktivna identifikacija padca na osnovi min-max normalizacije in konvolucijske nevronske mreže	25
4.4.1.2	Aktivna identifikacija padca na osnovi zaznavanja vzorca padca in konvolucijske nevronske mreže	26
4.4.1.3	Aktivna identifikacija padca na osnovi zaznavanja vzorca padca in modela Naivni Bayes	28
4.5	Zbiranje podatkov	28
4.5.1	Problematika simulacije padcev	28
4.5.2	Načrtovanje zbiranja podatkov	30
4.5.3	Izvedba	31
4.5.3.1	Nezgoda ob zbiranju podatkov	33
4.5.4	Zbiranje podatkov negativnega razreda	33
4.6	Predstavitev podatkov	34
4.6.1	Positivna podatkovna množica	34
4.6.2	Negativna podatkovna množica	35
4.6.3	Podatki zbrani preko ankete	35
4.7	Predobdelava podatkov	36
4.7.1	Razširitev podatkovne množice preko matrične rotacije	36
4.7.1.1	Rotacija podatkov in okvara senzorja	37
4.7.1.2	Problematika plasti laminata nad matriko senzorjev	37
4.7.2	Zaznavanje vzorca padca	39
4.7.3	Min-max normalizacija podatkov senzorja v premikajočem oknu	45
4.7.4	Podvzorčenje	45
4.7.5	Ekstrakcija aktivnosti iz zajetega intervala	46
4.7.6	Priprava učne in testne množice	46
4.7.6.1	Priprava testne množice	46

4.7.6.2	Priprava učne množice za metodo Naivni Bayes	47
4.7.6.3	Priprava učne množice za metodo umetne konvolucijske nevronske mreže	48
4.8	Modeliranje	49
4.8.1	Naivni Bayes	49
4.8.2	Umetna konvolucijska nevronska mreža	50
5	Rezultati	52
5.1	Rezultati evalvacije modela naivni Bayes	52
5.2	Rezultati evalvacije modela umetne konvolucijske nevronske mreže s po-stopkom predobdelave podatkov na osnovi zaznavanja vzorca padca . .	56
5.3	Rezultati evalvacije modela umetne konvolucijske nevronske mreže s po-stopkom predobdelave podatkov na osnovi min-max normalizacije . . .	59
6	Diskusija	63
7	Literatura in viri	66

Kazalo preglednic

Tabela 1	Osnovna statistična analiza teže in višine prostovoljcev.	32
Tabela 2	Osnovna statistična analiza ostalih vprašanj ankete.	32

Kazalo slik in grafikonov

Slika 1	Shema običajnega sistema za identifikacijo padcev	3
Slika 2	Dogodek padca razčlenjen v štiri faze: pred padcem, kritična faza, po padcu in povrnitev v pokončni položaj.[24]	4
Slika 3	Senzorji za identifikacijo padca razvrščeni po kategorijah. Slika iz prispevka [38]	6
Slika 4	Umetna nevronska mreža sestavljena iz treh slojev: vhodni, skriti in izhodni.	12
Slika 5	Umetni nevron prikazan, kot shema osnovnih komponent. . . .	13
Slika 6	V zgornji sliki je prikazana konvolucija matrike podatkov I s jedrom K velikosti 3x3. [33]	14
Slika 7	Globalna shema, ki prikazuje glavne komponente sistema. . . .	21
Slika 8	Prototip tal z vgrajenimi senzorji pritiska predstavljen v članku [42].	22
Slika 9	Upor za zaznavanje sile FSR 406. Vir: https://ezgif.com/webp-to-png/ezgif-2-16ae72f6229d.webp dostopano dne: 22.07.2020 .	23
Slika 10	Krivulja, ki prikazuje odvisnost med silo, ki učinkuje na senzor in upornostjo senzorja za senzor FSR 406. Iz slike je razvidno, da krivulja ni linearnej. vir: [10]	23
Slika 11	Prikaz tal brez zgornje plasti laminata. Iz slike je vidnih 16 senzorjev pritiska in mikrokontroler arduinoMega.	24
Slika 12	Odziv sistema za identifikacijo padcev v realnem času. Abscisna os predstavlja klasifikacijo v določenem časovnem trenutku in ordinatna os predstavlja verjetnost identifikacije padca.	27
Slika 13	Scenariji za evalvacijo sistema za identifikacijo padcev. Slika iz prispevka [25].	29
Slika 14	Telovadnica izbrana za proces zbiranja podatkov. V sliki je razviden prototip tal in varovalne blazine.	30
Slika 15	Grafi okvirjev z ročaji, ki prikazujejo starost, težo in višino prostovoljcev	32
Slika 16	Prikaz plasti laminata nad prototipom tal. Iz slike je opaziti šest desk laminata.	38

Slika 17	Prikaz vzorca padca. Os y predstavlja vrednost senzorja in os t je časovna os.	39
Slika 18	Graf prikazuje podatke zajete v posnetku 3 minutne naključne hoje s naključnim ustavljanjem. V grafu je prikazanih le 10s posnetka. Prikazani so podatki prvih desetih senzorjev, zaradi lažjega ogleda grafa in ker vrednosti ostalih senzorjev v tem časovnem intervalu so zanemarljive. Podatki vsakega senzorja so prikazani na dveh oseh, os x predstavlja čas v ms in os y predstavlja normalizirano vrednost senzorja.	43
Slika 19	Graf prikazuje podatke zajete ob simulaciji padca s trajanjem 8s. Prikazani so podatki prvih desetih senzorjev, zaradi lažjega ogleda grafa in ker vrednosti ostalih senzorjev v tem primeru padca so zanemarljive. Podatki vsakega senzorja so prikazani na dveh oseh, os x predstavlja čas v ms in os y predstavlja normalizirano vrednost senzorja.	44
Slika 20	Graf izrisan pri iskanju optimalne klasifikacijske meje. Graf je bil izrisan ob testiranju modela nad učno množico.	50
Slika 21	Konvolucijska nevronska mreža uporabljena za identifikacijo padcev sestavljena iz dveh 2D konvolucijskih slojev, dveh slojev za združevanje maksimalnih vrednosti, enega polno povezanega skritega sloja in izhodnega sloja sestavljenega iz dveh nevronov.	51
Slika 22	Evalvacija testiranja modela Naivni Bayes testiranega nad učno množico predobdelano z metodo zaznavanja vzorca padca. . . .	52
Slika 23	Evalvacija testiranja modela Naivni Bayes testiranega nad testno množico predobdelano z metodo zaznavanja vzorca padca.	53
Slika 24	ROC krivulja za model Naivni Bayes testiran nad testno množico. AUC = 0.90	54
Slika 25	Evalvacija testiranja modela konvolucijske nevronske mreže testiranega nad učno množico predobdelano z metodo zaznavanja vzorca padca.	56
Slika 26	Evalvacija testiranja modela konvolucijske nevronske mreže testiranega nad testno množico predobdelano z metodo zaznavanja vzorca padca.	57
Slika 27	ROC krivulja za model konvolucijske nevronske mreže testiran nad testno množico predobdelano z metodo zaznavanja vzorca padca. AUC = 0.95	57

Slika 28	Evalvacija testiranja modela konvolucijske nevronske mreže testiranega nad učno množico predobdelano z metodo min-max normalizacije.	59
Slika 29	Evalvacija testiranja modela konvolucijske nevronske mreže testiranega nad testno množico predobdelano z metodo min-max normalizacije.	60
Slika 30	ROC krivulja za model konvolucijske nevronske mreže testiran nad testno množico predobdelano preko min-max normalizacije. AUC = 0.98	61
Slika 31	Prototip ploščice z vgrajenim senzorjem pritiska. V ploščici je opaziti tudi vezje namenjeno krmiljenju komunikacije. V zadnji sliki je prikazan konektor za povezavo dveh ploščic.	64

Kazalo prilog

A Anketa

71

Seznam kratic

<i>PIR</i>	Passive InfraRed sensor (Pasivni infra-rdeči senzor)
<i>FSR</i>	Force Sensing Resistor (Upori za zaznavanje sile)
<i>CSV</i>	Comma Separated Values (z vejico ločene vrednosti)
<i>CNN</i>	Convolutional Neural Network (Konvolucijska nevronska mreža)
<i>ROC</i>	Receiver Operating Characteristic Curve (ROC krivulja)
<i>AUC</i>	Area Under the Curve (Površina pod krivuljo)
<i>FAMNIT</i>	Fakulteta za matematiko, naravoslovje in informacijske tehnologije

Zahvala

Zahvaljujem se mentorju, dr. Jerneju Vičiču, in somentorju, mag. Aleksandru Tošiću, za takojšen odziv na vsako potrebo in pomoč pri razvoju magistrskega dela. Zahvaljujem se tudi raziskovalnemu inštitutu InnoRenew CoE, ki je podprt proces zbiranja podatkov, ter se zahvaljujem vsem prostovoljcem, ki so se udeležili procesa zbiranja podatkov ter so simulirali padce na prototipu pametnih tal. Posebna zahvala je namenjena družini in prijateljem, ki so me moralno podprtli skozi celotno obdobje pisanja magistrskega dela.

1 Uvod

V magistrksem delu bo predstavljen razvoj sistema za neintruzivno identifikacijo padcev osnovan na pametnih tal. Razvoj predlaganega sistema se je začel s pregledom področja identifikacije padcev opisano v poglavju 2, kjer smo podali definicijo sistema za identifikacijo padca, predstavili smo osnovno arhitekturo sistemov namenjenih identifikaciji padca ter smo analizirali dogodek padca preko razčlenitve v štiri faze: *pred padcem, kritična faza, po padcu in povrnitev v pokončni položaj*. Sledi pregled obstoječih senzorskih tehnologij uporabljenih za identifikacijo padcev ter delitev teh v nosljivo in ambientno tehnologijo. Opisali smo vlogo procesne enote v sistemih za identifikacijo padca, ter smo uvedli vse potrebno znanje za ustrezno razumevanje magistrskega dela.

Poglavlje 3 predstavi motivacijo do razvoja sistema za neintruzivno identifikacijo padcev, pri tem je obrazložena potreba po neintruzivnem sistemu tako iz vidika občutka stalnega nadzora, ki ustvari v nadzorovani osebi, kot iz podatkov, ki jih sistem zaznava. Na koncu poglavja smo izrazili prednosti predlaganega sistema nad ostalimi obstoječimi rešitvami katere slonijo na senzorski tehnologiji vgrajeni v tleh.

V poglavju 4 bo predstavljena metodologija razvoja sistema, od strojne opreme, do programske komponente za aktivno identifikacijo padcev v realnem času. V poglavju bo predstavljen proces zbiranja podatkov in problematika simulacije padcev. Predstavljeni bodo rezultati ankete in bo podan opis podatkovnih množic zbranih v procesu zbiranja podatkov. Sledi opis metod predobdelave podatkov ter postopkov priprave učne in testne množice. Na koncu poglavja je opisan postopek učenja modelov strojnega učenja in v poglavju 5 so predstavljeni rezultati evalvacije modelov nad učno in testno množico.

2 Pregled področja identifikacije padcev

V poglavju bomo najprej podali definicijo sistema za identifikacijo padca, nato bo analiziran dogodek padca, kateri bo razčlenjen na štiri faze. Predstavljeni bodo različni principi in tehnologije uporabljene v sistemih za identifikacijo padca in na koncu bodo predstavljene metode strojnega učenja uporabljene v predlaganem sistemu za identifikacijo padcev.

2.1 Definicija sistema za identifikacijo padca

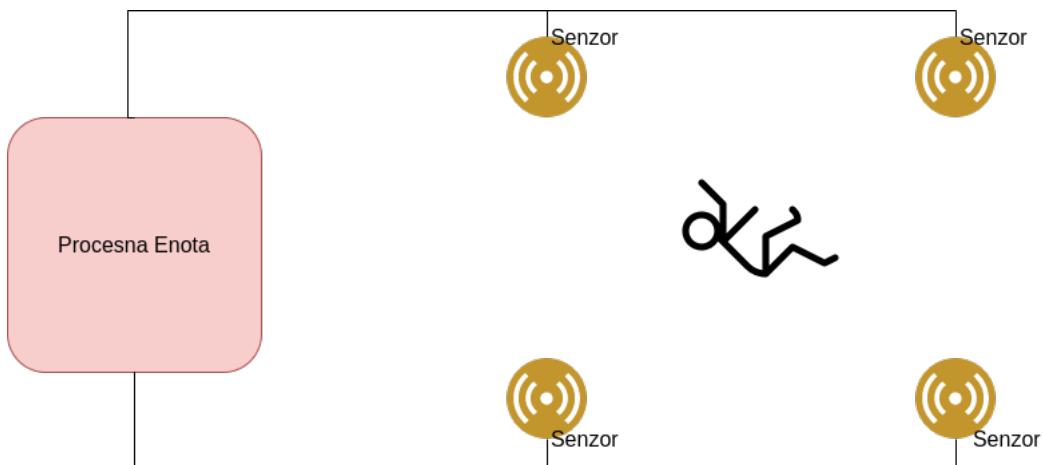
Vsaka oseba je že doživela nezaželeni padec, lahko med otroštvom, med treningom ali v odrasli dobi in pri tem je razvila obrambni mehanizem, ki omogoči pravilno izvedbo padca brez hudih poškodb. Obrambni mehanizem se razvija že od otroštva in doseže višek v mladostništvu, potem pa se postopoma slabí zaradi reduciranja športnih aktivnosti in oslabitve starejših oseb, katere sploh ne utegnejo reagirati na padec in se posledično poškodujejo.

V članku [7] so definirali dogodek padca pri starostnikih, kot ”Nenamerno padanje na tla ali na nižji višinski nivo, ki ni posledica hudega udarca, izgube zavesti, možganske kap ali epileptičnega napada”. Omenjena definicija je bila uporabljena v veliko raziskavah in je bila nato razširjena do vključitve epileptičnega napada in kardiovaskularnega kolapsa, kateri so potencialni vzrok za padec.

Na osnovi zgornje definicije sistem za identifikacijo padca mora biti sposoben zaznavanja nepričakovanih in nenadzorovanih padcev neodvisno od vzroka padca. Pri tem je pričakovano, da sistem razlikuje padec od ostalih namernih premikov. [24]

2.1.1 Običajen sistem za identifikacijo padca

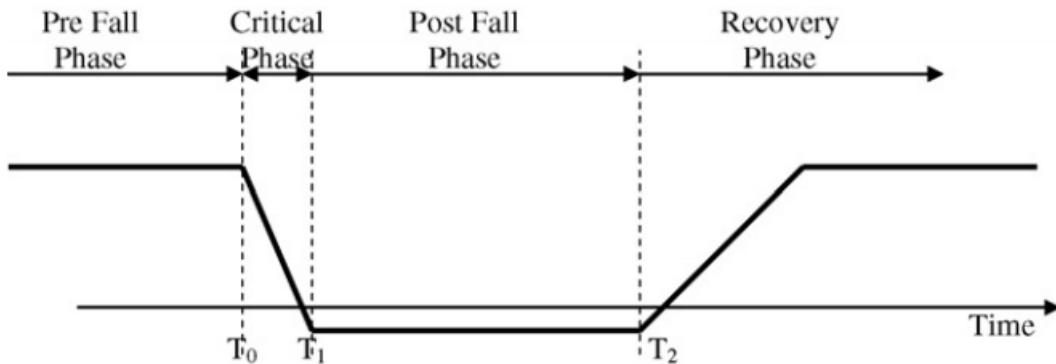
V sliki 1 je prikazana shema običajnega sistema za identifikacijo padcev. Iz slike je razvidno, da sistem sestavlja dve glavni komponenti, procesna enota in senzorji. Senzorji so uporabljeni za spremljati aktivnost osebe v nadzorovanem prostoru in tako pretvoriti zaznano aktivnost v električni signal, kateri je posredovan procesni enoti za posledično obdelavo. Procesna enota je tako jedro sistema, ki spremlja senzorjeve podatke in na podlagi vgrajenih metod strojnega učenja ali pragovnega zaznavanja klasificira zaznani signal, kot običajna dnevna aktivnost ali padec. Ko procesna enota zazna padec sproži alarm, ki obvesti reševalce ali odgovorno osebo.



Slika 1: Shema običajnega sistema za identifikacijo padcev

2.2 Analiza padca

V članku [24] so bili analizirani različni pristopi identifikacije padcev in raziskovalci so podrobneje razčlenili dogodek padca, kot pojav sestavljen iz štirih faz:



Slika 2: Dogodek padca razčlenjen v štiri faze: pred padcem, kritična faza, po padcu in povrnitev v pokončni položaj.[24]

1. **Pred padcem** (ang. prefall): faza v kateri oseba opravlja običajne dnevne aktivnosti kot so hoja, sedenje in ležanje, kateri so lahko izvedeni zelo hitro in morajo biti ustrezno razlikovani od dejanskega padca.
2. **Kritična faza** (ang. critical phase): premik telesa od pokončnega položaja do tleh, to je dejanski padec in trajanje te faze je zelo kratko ($T_1 - T_2 \approx 300 - 500ms$)
3. **Po padcu** (ang. postfall): faza v kateri oseba leži inaktivna na tleh. Ta faza mora biti čim krajsa za zmanjšati posledice padca in ne sme presegati 1h trajanja.
4. **Povrnitev v pokončni položaj** (ang. recovery): v tej fazi je oseba ponovno postavljena v pokončni ozziroma varen položaj samostojno ali s pomočjo reševalca.

V naslednjih poglavjih bodo preučeni različni pristopi identifikacije padca v različnih fazah.

2.2.1 Zgodnja zaznava kritične faze padca

Kritična faza padca je faza v kateri oseba pada v prostem padu in hitrost telesa se sorazmerno poveča s časom padanja zaradi gravitacijske sile. Raziskovalci so podrobno analizirali to fazo v [43] in so ocenili, da sta vertikalna in horizontalna hitrost trikrat višje med padcem, kot pri katerikoli drugi običajni aktivnosti. Na podlagi teh ugotovitev so bili razviti razni sistemi za identifikacijo padcev na osnovi kamer [22] [32], ki

nadzorujejo premike glave z metodami računalniškega vida in skušajo oceniti ali se je glava osebe tako hitro premaknila zaradi padca.

Ostali pristopi zaznave padca v kritični fazi pa slonijo na nosljivi tehnologiji (ang. wearable) [28][18], ki preko modula z vgrajenim merilnikom pospeška zaznavajo ali je hitrost osebe presegla določeno mejo in preverjajo tudi orientacijo osebe, katera ob padcu je leži na tleh.

2.2.2 Zaznava konkluzije kritične faze

Ob zaključku kritične faze se telo osebe običajno trči na tla oziroma na neko oviro. Ob trku s tlemi se sila telesa preusmeri v nasprotno stran in na tak način je mogoče zaznati padec s uporabo merilnika pospeška. Tak pristop je bil implementiran v [4], kjer so raziskovalci razvili sistem sestavljen iz triosnega merilnika pospeška in algoritma za zaznavanje praga, ki razlikuje običajne dnevne aktivnosti od nenadzorovanega padca.

2.2.3 Identifikacija ležalne poze po padcu

Ob zaključku kritične faze padca se večkrat zgodi, da oseba je v ležalni pozicii na tleh. Enostaven postopek za identifikacijo padca je lahko osnovan na detekciji ležalne poze preko merilnika pospeška, žiroskopa ali senzorja nagiba. Podobno bi lahko zaznavali ali oba stopala osebe so v kontaktu s tlemi.

Zgoraj omenjeni pristopi so enostavni in efektivni ampak lahko povzročijo veliko napačno razvrščenih negativnih primerov in so večkrat uporabljeni v kombinaciji z nekim drugim pristopom za zaznavanje padca, kot v [29], kjer so razvili sistem sestavljen iz tal z vgrajenimi tlačnimi senzorji za zaznavanje premikanja oseb ter so tem priredili kamere, ki stalno spremljajo osebe.

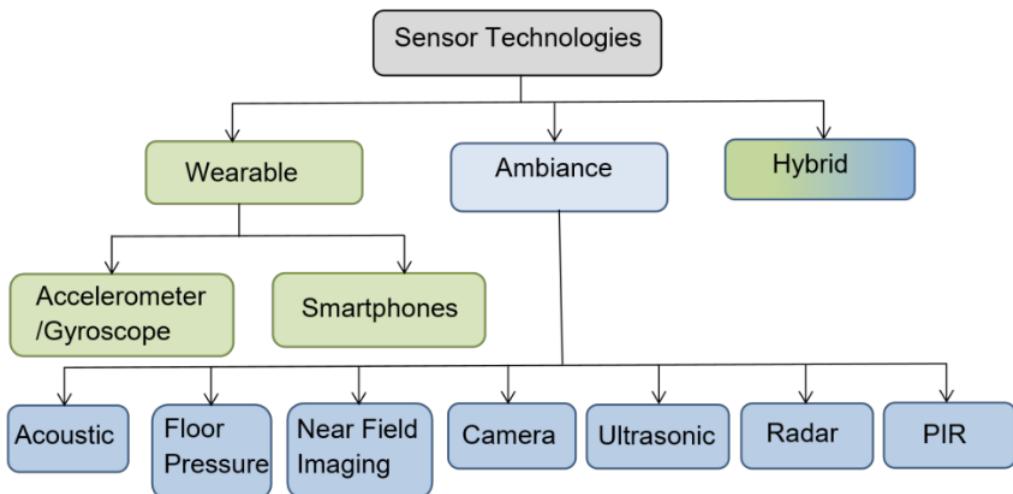
2.2.4 Identifikacija odsotnosti gibanja po padcu

V primeru padca ostarele osebe in posledične hude poškodbe oseba obleži na tleh. Na tak način je lahko odsotnost gibanja dejavnik za identifikacijo padca, katero lahko zaznamo s senzorjem premika oziroma merilnikom pospeška postavljenim na zapestje oziroma na nek del telesa, ki je običajno v gibanju.

V članku [45] je opisana rešitev za identifikacijo padca, ki sloni na triosnemu merilniku pospeška vgrajenem v telefonu in postopka, ki zaznava padce, kot zaporedje dogodkov, ki se začne z izvajanjem neke dnevne aktivnosti, padca in odsotnosti gibanja. Ko sistem zazna tako zaporedje dogodkov identificira padec in ga javi reševalcem.

2.3 Senzorske tehnologije za identifikacijo padcev

Kot opisano v [38] sistemi za identifikacijo padcev so lahko razvrščeni na osnovi vgrajene senzorske tehnologije v 3 kategorije: *nosljiva tehnologija*, *ambientna tehnologija* in *hybridna tehnologija*. Vsaka kategorija je osnovana na različnih principih delovanja senzorjev, pri tem hibridna tehnologija združuje rešitve nosljive in ambientne tehnologije v isti sistem.



Slika 3: Senzorji za identifikacijo padca razvrščeni po kategorijah. Slika iz prispevka [38]

2.3.1 Nosljiva tehnologija

Hiter razvoj IKT in stalno zmanjševanje elektronskih komponent je uvedlo v področje identifikacije padcev t.i. nosljivo tehnologijo (ang. wearable). Sistem osnovan na nosljivi tehnologiji je fizično nošen od nadzorovane osebe in je sestavljen iz množice kinematičnih senzorjev vezanih na procesno enoto. Pri tem senzorji so lahko merilniki pospeška, žiroskopi in magnetični senzorji, kateri stalno nadzorujejo premike osebe in posiljajo podatke procesni enoti, katera skuša razlikovati običajne dnevne aktivnosti od nenadzorovanega padca.

Pod kategorijo nosljive tehnologije spadajo tudi pametni telefoni, kateri so vstopili v vsakdanje življenje običajne osebe in celo ostareli ljudje so jih začeli uporabljati. Ker današnji pametni telefoni imajo že vgrajen merilnik pospeška in žiroskop, lahko istočasno merijo aktivnost uporabnika in preko procesne enote procesirajo podatke senzorjev ter tako identificirajo padce.

V članku [36] je bila predstavljen aplikacija *FallDroid* za identifikacijo padcev, ki deluje na pametnem telefonu. Aplikacija deluje na osnovi meritnika pospeška vgrajenega v pametnem telefonu ampak deluje pravilno le ko se pametni telefon nahaja v eni od dveh dovoljenih lokacijah na osebi v žepu na pasu ali v žepu na stegnu. Aplikacija nudi tudi grafični uporabniški vmesnik primeren za ostarele ljudi in ko zazna padec najprej sproži alarm, ki traja 30s. Če po minulih 30s uporabnik se ni odzval, bo aplikacija sama sprožila alarm za reševalce.

2.3.2 Ambientna tehnologija

Ambientni sistem za identifikacijo padcev je sestavljen iz množice senzorjev, kateri so fiksno postavljeni v prostor. Senzorji zaznavajo aktivnost osebe v prostoru in skušajo ločiti običajne dnevne aktivnosti od dogodka padca. Senzorji vgrajeni v ambientnih sistemih identifikacijo delujejo na osnovi različnih tehnoloških konceptov, ki bodo predstavljeni v sledečih odstavkih.[38]

Slikovni senzorji so bili na široko uporabljeni v področju identifikacije padcev. Sistemi osnovani na slikovnih senzorjih so sestavljeni iz RGB/IP kamer ali globinskih kamer, katere nadzorujejo aktivnosti osebe in skušajo identificirati padce. Sistemi osnovani na slikovnih senzorjih so zelo učinkoviti ampak lahko ustvarijo slabo počutje v nadzorovani osebi, saj je ta stalno pod video nadzorom.

Akustični senzorji so bili uporabljeni za razlikovanje različnih razredov zvoka od hrupa padca. V članku [27] je bil predstavljen ambientni sistem za identifikacijo padcev, osnovan na treh vertikalno postavljenih mikrofonih. Sistem je zaznaval zvočni signal v časovnem oknu 1s in na podlagi zaznavanja praga ter zamude med tremi senzorji je bil hrup klasificiran kot padec ali običajna dnevna aktivnost. Prototip sistema je dokazal dobro sposobnost zaznave padca, ampak je razkril tudi veliko količino lažnih alarmov, kjer običajna aktivnost je bila klasificirana kot padec.

Za identifikacijo padca so bili celo izkoriščeni senzorji, ki zaznavajo *pasivno infrardečo radiacijo* (PIR senzor), kateri zaznavajo dinamiko padca, kot premik iz višjega višinskega nivoja do tleh. Omenjen pristop je bil iskoriščen v [26], kjer so skušali identificirati padce na osnovi vertikalno postavljenih PIR senzorjev. Sistem je dosegel visoko točnost v nadzorovanem okolju, kar 85% pravilno klasificiranih primerov sicer je primeren le za majhne prostore zaradi omejenega dometa PIR senzorjev in zahtevane količine teh senzorjev.

Radarski senzorji so bili izkoriščeni za zaznavanje padca preko Doppler efekta, kateri sloni na oddajanju elektromagnetcnega valovanja z določeno frekvenco in zaznavanju razmika v signalu, ki se odbije od nadzorovane osebe, kot posledica gibanja osebe. Razmik v signalu je odvisen od hitrosti premikanja osebe in kot omenjeno v [43] hitrost padca je približno trikrat višja od katerekoli običajne aktivnosti, ki počne navadna oseba. Dopplerjev efekt je bil tako izkoriščen v [16], kjer so postavili dva radarska senzorja pravokotno drug od drugega.

Veliko raziskav v področju identifikacije padca sloni na *ultrazvočnih senzorjih*, ki oddajajo signale v ultrazvočnem pasu in merijo čas povrnitve signala za izračun razdalje med senzorjem in opazovano osebo. V članku [21] je bil implementiran sistem za identifikacijo padca na osnovi dveh matrik šestnajstih ultrazvočnih senzorjev. Sistem je deloval dobro z visoko točnostjo ampak je bil podvržen velikim problematikam zaradi odvisnosti med ultrazvočnim valovanjem in temperaturo.

Ob zaključku kritične faze padca se telo osebe trči na tla in tako generira silo, ki pretrese tla. Tla z vgrajenimi *senzorji pritiska* zaznavajo silo oziroma proizvedene vibracije in na podlagi teh identificirajo ali je proizведен signal običajna dnevna aktivnost oziroma padec.

2.4 Vloga procesne enote sistema za identifikacijo padcev

Procesna enota sistema za identifikacijo padcev je tako rečeno glava sistema, ki na podlagi aktivnosti zaznane preko senzorjev skuša razlikovati padec od običajne dnevne aktivnosti. Ker običajni senzorji uporabljeni v sistemih za identifikacijo padcev zaznavajo padec v času in ne le kot diskreten dogodek, je potrebno obravnavati te signale, kot časovne vrste.

V tem poglavju bo najprej uvedena definicija časovne vrste, sledi metoda za analizo časovnih vrst imenovana premikajoče okno in definicija postopka odkrivanja značilk. Nato bo uvedeno področje strojnega učenja, proces nadzorovanega učenja in klasifikacija, ter bodo podrobno opisane metode naivni Bayes in umetne konvolucijske nevronske mreže.

2.4.1 Časovne vrste

Časovna vrsta (ang. time series) je časovno urejeno zaporedje številčnih podatkov, ki izražajo vrednost neke spremenljivke. Podatki se navadno izmerijo v enakih časovnih intervalih, npr. vsako minuto, vsako sekundo ali vsako milisekundo.[11]

2.4.1.1 Premikajoče okno

Pri analizi časovnih vrst se pogosto uporabi tehniko premikajočega okna (ang. moving window), ki omogoči zajeti del časovne vrste v določenem trenutku v času. Tehnika je imenovana premikajoče okno, ker okno je premaknjeno skozi časovno za konstanten premik.

2.4.1.2 Odkrivanje značilk

Zelo važen postopek pri analizi časovnih vrst je odkrivanje značilk (ang. feature extraction), kateri deluje na osnovi matematičnih in statističnih metod, ki na podlagi podatkov zajetih v premikajočem oknu tvorijo nove atributi, ki s enako natančnostjo opisujejo originalne podatke, pri tem pa zmanjšajo količino podatkov za obdelavo.

2.4.2 Strojno učenje za identifikacijo padcev

Strojno učenje (ang. machine learning) je lahko mišljeno kot samodejno učenje oziroma sposobnost nekega stroja (računalnika), da se nauči nekih pravil, ne da bi bila ta pravila predčasno programirana. Torej strojno učenje omogoči, da se računalnik sam nauči iz izkušenj iz preteklosti, oziroma nek program, ki ima vgrajene algoritme strojnega učenja se izvaja nad podatki in se nauči neka pravila ter samodejno izboljša svoje delovanje med časom izvajanja. Postopek strojnega učenja poteka samodejno brez interakcije uporabnika oziroma uporabnik prepusti računalniku da sam reši problem, ne da bi uporabnik programiral ustrezno rešitev.

Izraz strojno učenje je bil prvič uporabljen v članku, ki je objavil Ameriški pionir v področju umetne inteligenčne Arthur Lee Samuel leta 1959 [35]. Najbolj uporabljeno definicijo pa jo je izrazil Tom M. Mitchell in pravi, da nek program se uči iz izkušnje E na podlagi neke naloge T z meritvijo učinkovitosti P, če učinkovitost P pri izvajanju naloge T narašča z izkušnjo E [41].

2.4.2.1 Nadzorovano učenje in klasifikacija

V magistrskem delu bo uporabljena tehnika nadzorovanega učenja, kjer računalnik se uči na podlagi primerov, za katere se že pozna pripadajoči razred, ta množica podatkov je imenovana učna množica in vsebuje atribut razred, ki točno določa razred objekta. Običajno nadzorovano učenje se uporablja za klasifikacijo oziroma regresijo in deluje tako, da računalnik se uči na podlagi učne množice in nato skuša napovedati razred podatkov iz testne množice. Testna množica vsebuje podobne podatke, kot učna množica ampak brez razrednega atributa, vrednost razrednega atributa je samodejno napovedana od računalnika na podlagi izkušnje pridobljene od učne množice.

Klasifikacija je proces iskanja modela ali funkcije, ki opiše in razdeli podatke v vnaprej definirane razrede ali koncepte [13]. Klasifikacija je uporabljena za napovedovanje diskretnih razredov podatkov.

2.4.2.2 Evalvacija sistema za identifikacijo padca

Identifikacija padca je lahko pozitivna, če je sistem pravilno prepoznal padec ali je negativna, če padec je bil klasificiran, kot običajna dnevna aktivnost. Posledično je izhod sistema oblike binarne vrednosti, ki zavzame vrednost 0 če se izvaja običajna dnevna aktivnost oziroma 1 če sistem je zaznal padec.

Na tak način kakovost sistema za identifikacijo padcev ni moč oceniti le na podlagi samostojnjega testa ampak je potrebno izpeljati statistično analizo na osnovi množice testov za pregled vseh različnih izidov. Pri binarni klasifikaciji obstaja štiri možnih izidov:

- **TP:** Pravilno razvrščeni pozitivni primeri (ang. True positive): ko se ponesreči padec in sistem ga pravilno zazna
- **FP:** Napačno razvrščeni negativni primeri (ang. False positive): ko sistem napačno javi padec ob zaznavi običajne dnevne aktivnosti
- **TN:** Pravilno razvrščeni negativni primeri (ang. True negative): sistem zazna običajno dnevno aktivnost in ne razglasiti padca
- **FN:** Napačno razvrščeni pozitivni primeri (ang. False negative): zgodil se je padec ampak sistem ga ni zaznal

Iz zgornjih možnih situacijah so v članku [25] izbrali 2 kriterija za oceniti kakovost sistema to so: **Senzitivnost:** sposobnost sistema, da pravilno zazna padec

$$Senzitivnost = \frac{TP}{TP + FN} \quad (2.1)$$

Specifičnost: sposobnost sistema, da ustrezno razlikuje običajne dnevne aktivnosti od padca in javi čim manj napačnih napovedovanj pozitivnega razreda

$$Specifičnost = \frac{TN}{TN + FP} \quad (2.2)$$

Senzitivnost in specifičnost sta zelo važni meri pri razvoju sistema za identifikacijo padcev, saj si želimo, da sistem prepozna vsak padec in si ne moremo dovoliti, da sistem ne razpozna padca, ter da bi oseba ostala na tleh brez potrebne pomoči. Torej idealen sistem za identifikacijo padca ima zelo visoko senzitivnost in tudi zelo visoko specifičnost, saj ne sme stalno javiti dogodek padca, ko se ta v resnici ni pripetil.

$$Točnost = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.3)$$

Pri poročanju kakovosti sistema bo uporabljena tudi mera **točnosti**, ki izraža odstotek pravilno klasificiranih primerov. Dodatno bo izrisana tudi ROC krivulja, ki izrazi odvisnost med senzitivnostjo in specifičnostjo ob spremnjanju praga napovedovanja. Kakovost izrisane krivulje pa bo podana preko izračuna AUC, ki predstavlja površino pod ROC krivuljo. Večja je ta površina višja je kakovost sistema za identifikacijo padcev.

2.4.3 Naivni Bayes

Naivni Bayes je klasifikacijska metoda, ki deluje na osnovi Bayesovega izreka [3] s predpostavko, da atributi so med sabo neodvisni. Neodvisnost atributov ni zahtevana ampak metoda deluje s to predpostavko, da prisotnost neke lastnosti v razredu ni posledica prisotnosti neke druge lastnosti, zato ta metoda je imenovana naivna. Predpostavka neodvisnosti atributov dramatično zmanjša število parametrov, ki je potrebno obdelati za sestavo modela od $2(2^n - 1)$ na $2n$ [20]. Metoda deluje tako, da najprej izračuna pojavitve vsakega razreda za posamezen atribut in izdela t.i. tabelo frekvence. Iz tabele frekvenc izračuna verjetnost pojavitve razreda, verjetnost pojavitve posameznega atributa in pogojno verjetnost. Izračunane verjetnosti so uporabljene za klasifikacijo preko Bayesove formule:

$$P(C|X) = \frac{P(C|X)P(C)}{P(X)} \quad (2.4)$$

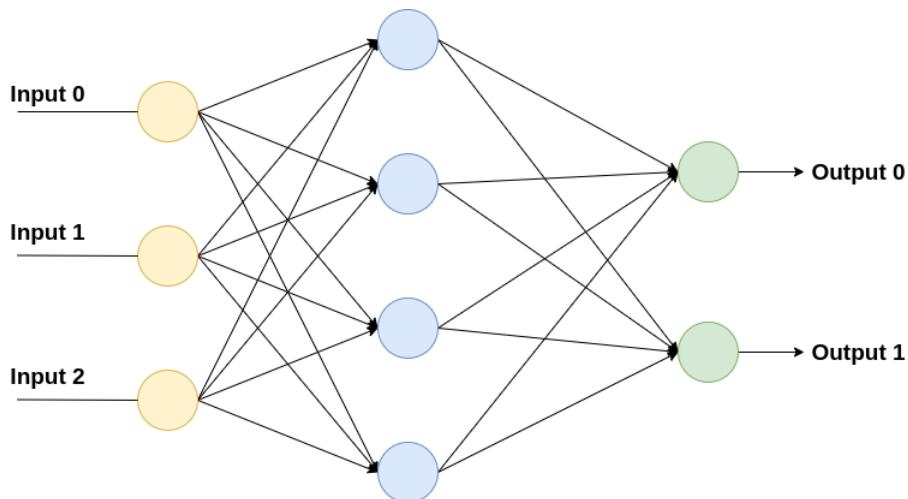
, kjer C predstavlja razred in X so vrednosti atributov.

V magistrskem delu je bila implementirana različica imenovana Gaussian Naive Bayes, kateri deluje na osnovi predpostavke normalne porazdelitve atributov [2].

2.4.4 Umetna nevronska mreža in konvolucija

Umetna nevronska mreža je metoda strojnega učenja osnovana na strukturi bioloških možganov. Biološki možgani so sestavljeni iz velikega števila med sabo vezanih nevronov, ki se obnašajo kot biološka stikala oziroma na osnovi določenega vhoda proizvedejo posledičen izhod. Ta lastnost in ogromna množica nevronov v možganih omogočijo človeku, da se lahko uči iz izkušnje in tako izboljša svoje sposobnosti.[14]

Ta lastnost je navdihnila raziskovalca Franka Rosenblatta, ki je leta 1958 prvi uvedel koncept umetnega nevrona v prispevku [30] pod imenom *perceptron*. Koncept je bil postopoma razširjen ter je bil uspešno apliciran v področju strojnega učenja za probleme prepoznavanja govora, identifikacije objektov, finančnega napovedovanja itd.



Slika 4: Umetna nevronska mreža sestavljena iz treh slojev: vhodni, skriti in izhodni.

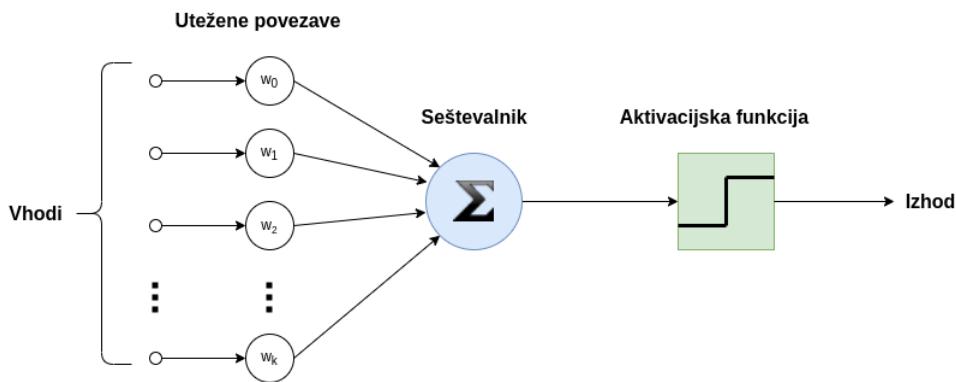
2.4.4.1 Struktura običajne umetne nevronske mreže

Običajna umetna nevronska mreža je lahko opisana kot poln usmerjen acikličen graf sestavljen iz vhodnega sloja, poljubnega števila skritih slojev in enega izhodnega sloja. Vsak sloj v nevronske mreži je sestavljen iz poljubnega števila nevronov pri tem je število nevronov vpliva na končno kakovost nevronske mreže in mora biti natančno izbrano pri obravnavi določenega problema. V sliki 4 je prikazana umetna nevronska mreža sestavljena iz treh slojev, prvi je vhodni sloj in je sestavljen iz treh nevronov, vsi nevroni so nato vezani na naslednji skriti sloj ter nevroni skritega sloja so vezani na nevrone izhodnega sloja, kateri proizvedejo odziv nevronske mreže na dani vhod. [14] [23]

2.4.4.2 Umetni nevron

Kot je bilo opisano v zgornjih vrsticah so umetne nevronske mreže sestavljene iz množice povezanih umetnih nevronov, kateri na osnovi vhoda proizvedejo nek izhod, ki se širi po nevronske mreži in vpliva na kumulativen izhod nevronske mreže.

Umetni nevron lahko razdelimo na tri osnovne komponente: *uteženo povezavo*, *seštevalnik* in *aktivacijsko funkcijo*. Vse omenjene komponente so lahko vidne na sliki: 5, pri tem je opaziti, da umetni nevron zbir vhodne signale preko uteženih vhodov ter preko seštevalne funkcije jih sešteje in če te vrednost presega določen prag aktivacijska funkcija sproži izhodni signal.[14]



Slika 5: Umetni nevron prikazan, kot shema osnovnih komponent.

2.4.4.3 Učenje umetne nevronske mreže

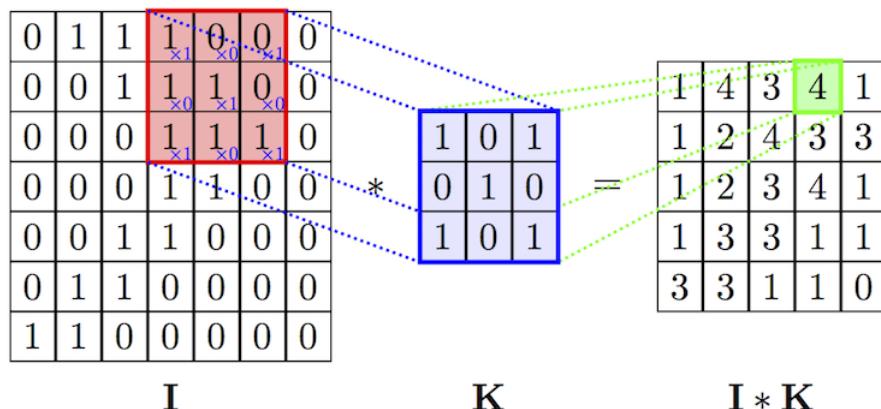
Široko uporabljen pristop nadzorovanega učenja nevronske mreže je imenovan gradiencki spust (ang. gradient descent). To je optimizacijski algoritem na podlagi katerega posodabljam uteži nevronov z namenom minimizacije napake. Ker je nevronska mreža sestavljena tudi iz skritih slojev, je potrebno uporabljati tehniko vzvratnega širjenja napake (ang. backpropagation), katera posodablja uteži nevronov preko izbranega optimizacijskega algoritma od vhodnega sloja proti izhodnem za minimizirati redundanco računanja. [14][23]

2.4.4.4 Konvolucijska nevronska mreža

Konvolucijska nevronska mreža je običajna umetna nevronska mreža s dodanim slojem za izvajanje konvolucije nad vhodnimi podatki. Konvolucija je matematična operacija, ki na podlagi vhodnega signala in izbranega jedra izračuna rezultanten izhodni signal, kot prikazano v sliki 6. Na sliki je prikazana konvolucija 2D matrike s jedrom velikosti 3x3 in posledičnim izračunom konvoluirane matrike.

Sloji konvolucijske nevronske mreže so osnovani na enakem konceptu tako, da na osnovi vhodnih podatkov in izbranega konvolucijskega jedra izračunajo izhodne konvoluirane podatke. Tudi konvolucijski sloj v nevronski mreži se uči preko metod opisanih v prejšnjem poglavju 2.4.4.3 pri tem niso posodobljene uteži nevronov, ampak spremembe so aplicirane na konvolucijske filtre.

Vsak konvolucijski sloj nevronske mreže bo tako vzdrževal več konvolucijskih filtrov in vsak filter bo namenjen razpoznavanju določene značilnosti v podatkih. Ker vsaka konvolucija filtra s podatki proizvede enako število podatkov kot je velikost vhodnih podatkov, bodo tako izhodni podatki konvolucijskega sloja velikosti *število konvolucijskih filtrov X velikost vhodnih podatkov*. Velika količina izhodnih podatkov konvolucijskega sloja lahko predstavlja problem in jo zato moramo zreducirati s uporabo metode združevanja maksimalnih vrednosti opisane v naslednjem poglavju: 2.4.4.5.[23]



Slika 6: V zgornji sliki je prikazana konvolucija matrike podatkov I s jedrom K velikosti 3x3. [33]

2.4.4.5 Združevanje maksimalnih vrednosti

Združevanje maksimalnih vrednosti (ang. max pooling) je dejanski sloj konvolucijske nevronske mreže namenjen zmanjševanju parametrov z ohranjanjem informacije v podatkih. Metoda deluje tako, da z določeno velikostjo premikajočega okna drsimo po podatkih s korakom velikosti okna in ob vsakem koraku ohranimo le največjo vrednost, ostale vrednosti pa zavrzemo. Na tak način učinkovito zmanjšamo količino podatkov in pri tem ohranimo prenešeno informacijo tako, da naslednji sloji konvolucijske nevronske mreže bodo učinkovito in efektivno delovali.[23]

2.4.4.6 Regularizacija preko izpuščanja

Regularizacija preko izpuščanja (ang. Dropout Regularization) je postopek, ki naključno izpusti nevrone med postopkom učenja tako, da njihov prispevek je začasno odstranjen in na tak način je nevronska mreža prisiljena uporabiti druge nevrone za napovedovanje. Postopek učinkuje tako, da nevronska mreža postane manj občutljiva na uteži specifičnih nevronov in posledično je manj podvržena problemu prekomernega prileganja podatkom (ang. Overfitting).

2.4.4.7 One-hot encoding

(ang. One-hot encoding) je metoda strojnega učenja za kvantifikacijo kategoričnih spremenljivk. Metoda deluje tako, da za vsako podatkovno točko proizvede vektor dolžine števila kategorij v podatkovni množici. Če podatkovna točka pripada i -ti kategoriji, potem vse komponente vektorja vsebujejo vrednost 0, razen i -te komponente, ki bo vsebovala vrednost 1.

3 Motivacija

Padci so pri starostnikih pogosti pojav in veljajo za vodilni vzrok poškodb oseb nad 65 letom starosti, kot opisano v [5] tretjina oseb nad 65 letom in polovica oseb nad 85 letom doživi letni padec. Pri starostnikih padec je kritični dogodek, ki lahko ima smrtonosne posledice ozziroma lahko povzroči hude telesne poškodbe[34] pri tem lahko povzroči dramatične psihološke posledice, katere reducirajo neodvisnost oškodovane osebe[17]. Zaradi omenjenih vzrokov je dogodek padca zelo aktualen problem, pri tem pa je postavljena velika pozornost na zaznavo padca, saj velika večina ostarelih oseb ob padcu se ne utegne samostojno postaviti v začetni pokončni položaj in potrebuje takojšnjo pomoč. V članku [12] je bila pokazana odvisnost med preteklim časom od padca do intervencije in stopnje poškodbe osebe.

Cilj magistrskega dela je razvoj sistema, ki omogoči neintruzivno identifikacijo padcev, da bi lahko v čim krajšem času nudili pomoč osebi in tako preprečili dodatne poškodbe zaradi minulega časa. Sistem je namenjen za ostarele osebe ozziroma za bolnike bolnice ali posebnega centra za zdravljenje, kjer pacienti so motorično omejeni, imajo hude patologije kot Alzheimer ali so podvrženi epileptičnim napadom, ki lahko povzročijo padec in nujo po takojšnji pomoči. Tak primer bolnika zahteva stalen nadzor ampak velika večina obstoječih sistemov za nadzor bolnikov je osnovana na zelo intruzivnih principih in lahko negativno vpliva na počutje nadzorovane osebe. V okviru magistrskega dela se bomo osredotočili na izdelavo sistema za identifikacijo padcev, ki je čim manj intruziven za nadzorovanu osebo.

3.1 Neintruzivna identifikacija padcev

Neintruzivnost sistema je obravnavana tako iz podatkov, ki jih sistem zajema od okolja in nadzorovane osebe, kot iz počutja stalnega nadzora, ki lahko ustvari sistem v nadzorovani osebi. V poglavju 2 je bilo pregledano področje identifikacije padcev in so bile predstavljene obstoječe rešitve za identifikacijo padcev pri tem smo opazili, da velika večina obstoječih rešitev za identifikacijo padcev sloni na zelo intruzivnih principih kateri so lahko zelo moteči za nadzorovanu osebo.

Največ obstoječih prispevkov za identifikacijo padcev je osnovanih na nosljivi tehnologiji, katera je opisana v poglavju 2.3.1. Nosljiva tehnologija nudi veliko prednosti nad

ambientno tehnologijo, saj je lahko nošena kamorkoli in tudi stroški za sistem osnovan na nosljivi tehnologiji so nizki v primeru s ambientno tehnologijo. Pri tem je nosljiva tehnologija tesno vezana na uporabnika, saj jo mora stalno nositi ob vsaki situaciji drugače postane neuporabna. In ker nevarne situacije so nepričakovane se lahko zgodi, da ostarela oseba doživi padec ravnokar, ko ne nosi sistema za identifikacijo padcev. Drugi problem vezan na nosljivo tehnologijo je ta, da uporabnik mora sam skrbeti za pravilno delovanje sistema in v primeru sistema osnovanega na pametnem telefonu je to lahko problematično zaradi potrebe po vzdrževanju telefona, tako polnjenja baterije, kot problematike vezane z posodobitvijo in upravljanjem pametnega telefona. Na podlagi teh opazkov lahko zaključimo, da nosljiva tehnologija ni primerna za razvoj našega sistema, ker je zelo intruzivna in moteča za uporabnika.

V poglavju 2.3.2 smo pregledali ambientno tehnologijo za identifikacijo padcev in smo našeli nekaj rešitev osnovanih na različnih tehnologijah senzorjev. Pri tem je samoumevno, da slikovni senzorji ne pridejo v poštev pri razvoju neintruzivnega sistema, saj tak sistem spremi aktivnost osebe na podlagi kamer, ki povzročijo v nadzorovani osebi visok vtis intruzivnosti in stalnega nadzora. Akustični senzorji so tudi preveč intruzivni saj stalno poslušajo zvočne signale in tako lahko ustvarijo v nadzorovani osebi nek občutek prisluškovanja in intruzivnosti. Sistemi za identifikacijo padcev osnovani na PIR tehnologiji pa so dokazali slabo učinkovitost v velikih prostorih, ter ne bodo upoštevani za razvoj predlaganega sistema. Radarski in ultrazvočni senzorji so zelo stroškovno zahtevne tehnologije in tudi oblika samih senzorjev je zelo podobna kameram, kar lahko povzroči vtis intruzivnosti in stalnega nadzora v osebi.

Kategorija senzorjev vgrajenih v tleh je najbolj obetavna za neintruziven sistem, ki omogoči identifikacijo padcev. Tak sistem ni v direktnem stiku z nadzorovano osebo, saj so senzorji vgrajeni v tleh. Na podlagi tega lahko izjavimo, da tak pristop identifikacije padcev ni intruziven, saj ko se oseba premika po sobi se sploh ne zave, da hodi po tleh z vgrajenimi senzorji. Sistem je tudi zelo varen in hrani zasebnost nadzorovanih oseb, saj signal zaznan od senzorjev je v obliki sile oziroma vibracij in ne omogoči enostavnega načina za enolično identifikacijo osebe.

3.2 Identifikacija padcev na osnovi senzorjev vgrajenih v tleh

Veliko raziskav je bilo že izpeljanih v okviru identifikacije padcev na osnovi senzorjev vgrajenih v tleh in rešitve v tem področju so bile osnovane na raznih tehnoloških konceptih. V članku [9] je bil predstavljen sistem osnovan na plastičnem optičnem vlačnku, ki preko merjenja deformacije optičnih vlaken skuša razlikovat padec od običajne dnevne aktivnosti. V tem sistemu je padec identificiran preko zaznavanja ležeče poze, kar lahko privede do obveščanja napačnih pozitivnih zaznavanj oziroma se lahko pojavi problem, da sistem identificira nek položeni predmet, kot padec.

Piezoelektrični senzorji oblike traku širine 60cm in variabilne dolžine so bili razviti v [19]. Sistem deluje tako, da ko neka sila pritisne na senzor, ta generira električni signal, ki ga procesna enota analizira in iz njega izvleče lastnosti. Signal je nato klasificiran kot padec ali običajna dnevna aktivnost z uporabo metode podatkovnega rudarjenja naključni gozd (ang. Random Forest). Omenjen pristop je učinkovito zaznal padce ampak je podvržen problematiki napačne klasifikacije negativnih primerov, saj sistem ne zaznava prostorske informacije padca, katera je ključnega pomena za razlikovanje padca od istočasne aktivnosti dveh ali več oseb.

V članku [6] je bila razvita pametna preproga, osnovana na štirih tlačnih senzorjih, ki zazna padce preko pragovnega zaznavanja. Predlagan sistem je bil testiran le z omejenim številom primerov padca, pri tem pa je sistem pametne preproge, kjer senzorji zaznavajo razliko v pritisku med tlakom v preprogi in izven preproge zelo občutljiv na okvare in ni primeren za trajno uporabo.

Poleg omenjenih pristopov je bil tudi razvit komercialni produkt imenovan SensFloor [37], kateri preko kapacitivnega senzorja vgrajenega v tleh zaznava premike oseb in je zmožen identifikacije močnih padcev. Sistem omogoči identifikacijo padca preko zaznavanja aktivnosti pred dogodkom padca in identifikacije ležalne poze v fazi po padcu, kot opisano v poglavju 2. Ni bilo mogoče pridobiti dodatnih informacij o omenjenem sistemu, ker je prispevek dostopen le preko plačila [40].

V magistrski nalogi predlagamo nov pristop neintruzivne identifikacije padca, ki ni še bil raziskovan. Sistem temelji na osnovi senzorjev pritiska postavljenih pod poljubno talno površino. Izbrani senzor je upor za zaznavanje sile (ang. Force Sensing Resistor) FSR in deluje tako, da upornost senzorja se manjša s povečanjem sile, ki potiska na senzor. V magistrski nalogi bo razširjen že obstoječ prototip tal za zaznavanje sile, predstavljen v [42]. Prototip je sestavljen iz 16 senzorjev pritiska vezanih na mikrokrnilnik, kateri zbirajo podatke iz senzorjev, ter jih pretvori v primerno obliko za prikazovanje pritiska na zaslonu. Obstojeci sistem bo razširjen s programsko komponento osnovano na konvolucijski nevrosnki mreži za omogočiti razlikovanje padcev

od ostalih običajnih dnevnih aktivnostih. Predlagan sistem je neintruziven in zagotovi zasebnost nadzorovanih oseb ter nizki stroški komponent zagotavljajo omejeno ceno končnega sistema.

4 Metodologija

V tem poglavju bo opisan potek razvoja sistema za neintruzivno identifikacijo padcev s pomočjo pametnih tal, najprej bomo pregledali metodologijo na podlagi katere smo razvili končni prototip nato se bomo spustili v implementacijo strojne opreme. Opisani bodo uporabljeni senzorji, mikrokrmlnik in struktura pametnih tal, sledi opis programske opreme za aktivno identifikacijo padcev v realnem času. Opisan bo proces zbiranja podatkov na podlagi katerega smo sestavili podatkovno množico, sledi predstavitev podatkov in opis uporabljenih metod za predobdelavo podatkov. Na koncu poglavja je predstavljen postopek učenja modelov Naivni Bayes in umetne konvolucijske nevronske mreže.

4.1 Metodologija razvoja

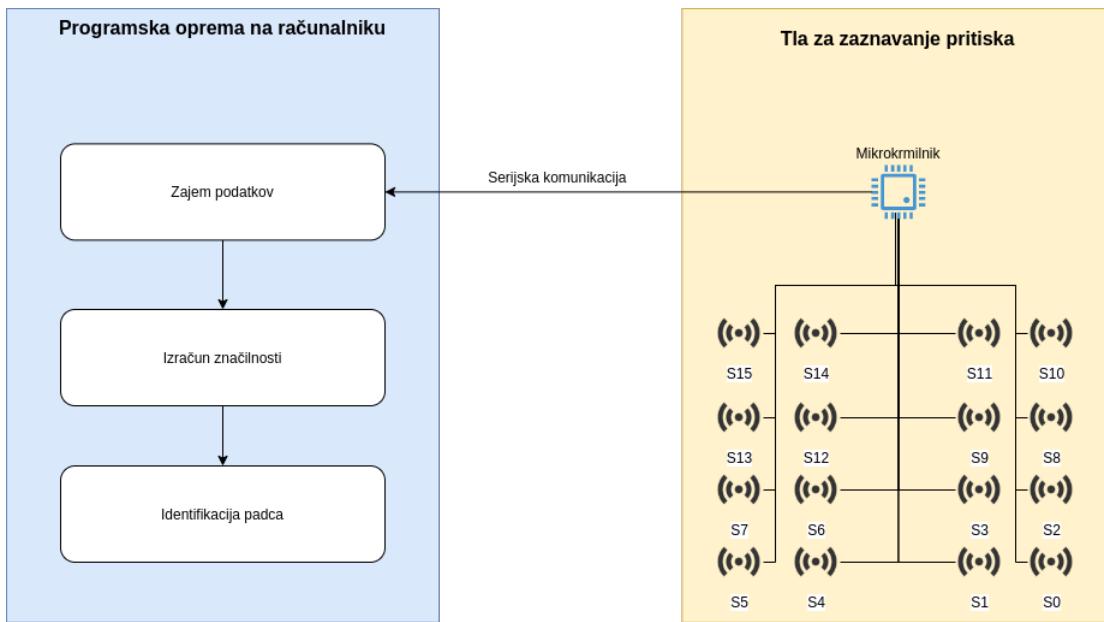
Na podlagi dejstva, da predlagan sistem implementira metode strojnega učenja za identifikacijo padcev smo se odločili, za iterativno metodologijo razvoja sistema, katera podpira problematiko selekcije modela, ki se pojavi pri razvoju metodah strojnega učenja.

Omenjena metodologija sestoji iz faze razumevanja problema, kjer je potrebno razumeti cilje in potrebe projekta, ter natančno definirati problem. Sledi faza razumevanja podatkov, v kateri so podatki zbrani in temeljito analizirani. V naslednji fazi priprave podatkov bodo podatki prečiščeni in preoblikovani v končno obliko ustrezno za učenje modela strojnega učenja. Sledi faza modeliranja v kateri bodo metode trenirane nad učno množico, ter bo potrebno nastavljati parametre metod za zgraditi čim natančnejši model. Sledi faza evalvacije, v kateri bodo modeli testirani nad testnimi podatki ter bodo primerjani za identificirati najučinkovitejšo metodo. Po identifikaciji najprimernejših modelov, bodo ti modeli vgrajeni v sistem za aktivno identifikacijo padcev v realnem času.

Ker je metodologija osnovana na iterativnem paradigmu se bodo faze priprava podatkov, modeliranje in evalvacija iterativno ponavljale do identifikacije končnega modela.

4.2 Načrtovanje sistema

Predstavljen sistem za identifikacijo padcev je sestavljen iz dveh glavnih komponent. Kot je prikazano v sliki 7 smo ločili ti dve komponenti na programsko opremo, ki se izvaja na računalniku in tla za zaznavanje pritiska.



Slika 7: Globalna shema, ki prikazuje glavne komponente sistema.

Tla za zaznavanje pritiska so sestavljena iz šestanjstih senzorjev pritiska, kateri zaznavajo aktivnost nadzorovane osebe s spremenjanjem upornosti in posledično variacijo napetosti katera je zaznana od mikrokrmlnika preko analognega vhoda. Mikrokrmlnik izvaja program, ki prebere zaznano napetost na analognih vhodih in jo pretvoriti v silo preko matematične formule. Vrednosti v celoštevilski obliki so pretvorjene v vrstico in so poslane preko serijskega vodila na računalnik.

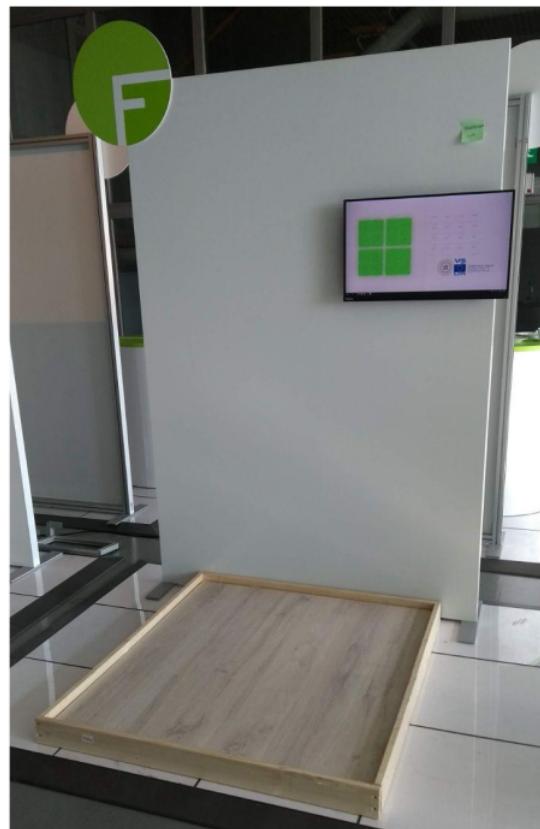
Sedaj vstopi v poštov programska oprema na računalniku, katera je sestavljena iz komponente za branje podatkov, ki pretvori podatke serijske komunikacije v ustrezeno obliko. Podatki so nato zbrani preko funkcije premikajočega okna ter jih posledično obdelata komponenta za izračun značilnosti signalov, ki pretvori surove podatke v primerno obliko za evalvacijo preko metode strojnega učenja. Komponenta z vgrajeno metodo strojnega učenja obdelava podatke in klasificira aktivnost nadzorovane osebe, kot padec ali običajna dnevna aktivnost.

4.3 Strojna oprema

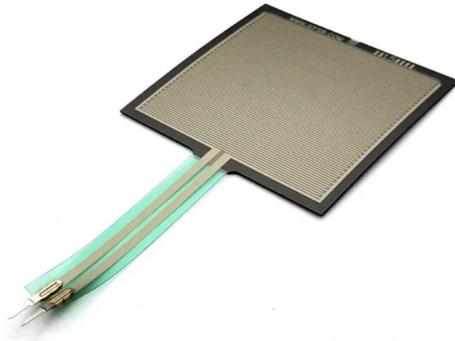
V sledečem poglavju bomo pregledali strojno opremo na kateri je osnovan predlagan sistem. Najprej bomo opisali fizično zgradbo tal, nato se bomo osredotočili na uporabljen senzor pritiska in na koncu bo opisan mikrokrmilnik, ki zbira podatke iz senzorjev.

4.3.1 Opis tal z vgrajenimi senzorji pritiska

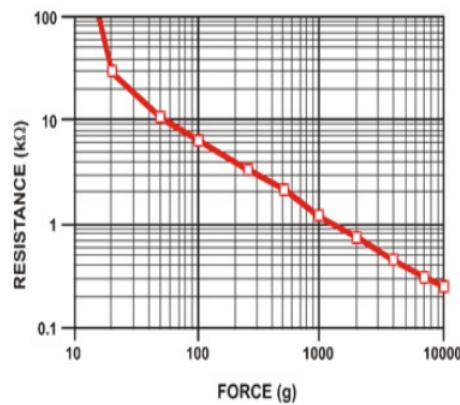
Tla z vgrajenimi senzorji pritiska, ki obravnava magistrska naloga so dejanski prototip opisan v [42]. Prototip tal meri 120cm za 120cm sestavljen je iz dveh slojev, spodnji sloj je penasta izolacijska podlaga višine 5cm na katero so prilepljeni senzorji pritiska, zgornji sloj pa je sestavljen iz 6 ploskev laminata 120cm dolžine in 20cm širine. Raziskovalci so izbrali laminat zaradi nizke cene in visoke rigidnosti, kar omogoči čim bolj enakomerno širjene sile od laminata na senzorje pritiska. V prototipu je vgrajenih šestnajst senzorjev tipa FSR upor za zaznavanje sile (ang. Force Sensing Resistor) pri tem je vsak senzor vezan na analogni vhod mikrokrmilnika ArduinoMega [1]. Iz slike 11 je lahko opaziti, da so senzorji obkroženi s plastjo črnega lepilnega traku. Lepilni trak je bil postavljen za ublažiti direkten stik med senzorjem in položenim laminatom drugače je sam laminat pritiskal preveč na senzor in povzročil nezaželeno zaznavo sile.



Slika 8: Prototip tal z vgrajenimi senzorji pritiska predstavljen v članku [42].



Slika 9: Upor za zaznavanje sile FSR 406. Vir: <https://ezgif.com/webp-to-png/ezgif-2-16ae72f6229d.webp> dostopano dne: 22.07.2020



Slika 10: Krivulja, ki prikazuje odvisnost med silo, ki učinkuje na senzor in upornostjo senzorja za senzor FSR 406. Iz slike je razvidno, da krivulja ni linearна. vir: [10]

4.3.2 Senzor pritiska

Uporabljen senzor pritiska je osnovan na tehnologiji FSR upor za zaznavanje sile (ang. Force Sensing Resistor), kateri je opisan v prispevku [44], kot kakovostno natančen, robusten in poceni senzor za zaznavanje pritiska. FSR senzor je sestavljen iz dveh polimernih plasti polprevodnika med katerimi je postavljen vzorec prevodnega materiala. Če nobena sila ne pritiska na zunanje plasti senzorja, potem je upornost snzorja nad $100\text{k}\Omega$, s večanjem zunanje sile pa se upornost senzorja zmanjša do približno 200Ω [10]. Odvisnost med silo aplicirano na senzorju in izmerjeno upornost ni linearne oblike ampak je eksponentne oblike, tipična krivulja sile za izbrani senzor je prikazana v sliki 10.

Izbran senzor omogoča zaznavanje sile do 10kg, ampak ker laminat ni položen direktno na senzorju in ker se sila razporedi preko ploskve, razpoložljivi interval zadostuje za izvedbo našega sistema.

Senzor pritiska je kvadratne oblike s stranico dolžine 43.7mm in višino 0.45mm, prikazan je v sliki 9.



Slika 11: Prikaz tal brez zgornje plasti laminata. Iz slike je vidnih 16 senzorjev pritiska in mikrokontroler arduinoMega.

4.3.3 Mikrokrmilnik in matrika senzorjev

Pri razvoju tal z vgrajenimi senzorji pritiska smo se odločili za uporabo mikrokrmilnika Arduino Mega [1] zaradi nizke cene, odprtakodnega in enostavnega programskega okolja ter zaradi razpoložljivosti s šestnajstimi analognimi vhodi. Analogni vhodi so potrebni za vezavo analognih senzorjev na mikrokrmilnik pri tem so senzorji vezani v konfiguraciji delilnika napetosti preko upora vrednosti $5.7k\Omega$.

Izbrana konfiguracija ustvari obratno sorazmerno odvisnost med silo aplicirano na senzor pritiska in zaznano napetostjo na vhodu mikrokrmilnika. Izvajani program na mikrokrmilniku bere vhodne napetosti senzorjev, ter preko matematične formule pretvoriti te vrednosti v meritev dejanske sile aplicirane na senzorju pritiska. Meritve sil vseh šestnajst senzorjev so celoštevilske oblike v intervalu vrednosti od 0 do 65535. Mikrokrmilnik izvede 50 meritve na sekundo in ob vsaki meritvi sestavi vrstico

z vrednostmi vseh šestnajstih senzorjev, vrstica je nato poslana na osnovi serijske komunikacije preko USB vodila na računalnik za sledečo analizo signala, ki je opisana v poglavju 4.4.

4.4 Programska oprema

V prejšnjem poglavju 4.3 je bila na široko opisana uporabljenja strojna oprema, pri razvoju sistema za identifikacijo padcev s pomočjo pametnih tal. V tem poglavju bo predstavljen del sistema, ki se izvaja na računalniku, kateri je povezan preko serijskega vodila na tla z vgrajenimi senzorji pritiska in je uporabljen za aktivno identifikacijo padcev.

4.4.1 Programska oprema za identifikacijo padcev

V tem poglavju bo predstavljena programska oprema, ki omogoči identifikacijo padcev v realnem času. Kot prikazano v sliki 7 komponente, ki sestavljajo omenjeno programsko opremo so: *zajem podatkov*, *izračun značilnosti* in *identifikacija padca*. Komponenta za zajem podatkov se ukvarja z branjem podatkov iz mikrokrnilnika, ter jih pretvori v primerno obliko za kasnejšo predobdelavo preko izračuna značilnosti signala. Izračunane značilke so nato obdelane od komponente za identifikacijo padcev, katera javi ali aktivnost, ki se dogaja na prototipu tal je padec ali običajna dnevna aktivnost.

V tem poglavju bomo predstavili tri različice sistema za identifikacijo padca v realnem času, ki so strukturirane na osnovi zgoraj omenjenih komponent, ampak omenjene komponente so vključene v različnih programskih komponentah zaradi razlik v implementaciji metod. Vse omenjene programske komponente se nahajajo v projektu na povezavi¹.

4.4.1.1 Aktivna identifikacija padca na osnovi min-max normalizacije in konvolucijske nevronske mreže

V tem poglavju bo predstavljena programska oprema za identifikacijo padcev osnovana na min-max normalizaciji opisani v poglavju 4.7.3 in konvolucijski nevronske mreže opisani v poglavju 4.8.2.

Implementacija se nahaja v imeniku *active_CNN_norm*, kjer datoteka *CNN_activePredictor.py* vsebuje vse tri komponente sistema oziroma: *zajem podatkov*, *izračun značilnosti* in *identifikacija padca*. Komponenta deluje tako, da najprej vključi že treniran model konvolucijske nevronske mreže *CCN.best.hdf5* ter začne brati podatke

¹gitlab: <https://gitlab.com/Dormage/forcedetection>

iz mikrokrmlnika preko serijskih vrat. Podatki najprej hranijo premikajoče okno velikosti 100 meritev, in vsakih pet meritev se preko min-max normalizacije, kot opisano v 4.7.3 ustvari novo okno uporabljeno za klasifikacijo preko konvolucijske nevronske mreže opisane v 4.8.2. Klasifikacija je izvedena vsakih pet meritev zaradi časovne zahtevnosti klasifikacije preko konvolucijske nevronske mreže. Rezultat klasifikacije je izražen v obliki verjetnosti identifikacije padca, ter je izpisani na standardni izhod. Datoteka *ProgBar.jar* je uporabljena za vizualizacijo odziva klasifikacije v obliki grafa, kot prikazano v sliki 12.

Programsko opremo je mogoče izvesti v operacijskem sistemu linux s ukazom:

```
python3 CNN_activePredictor.py | java -jar ProgBar.jar.
```

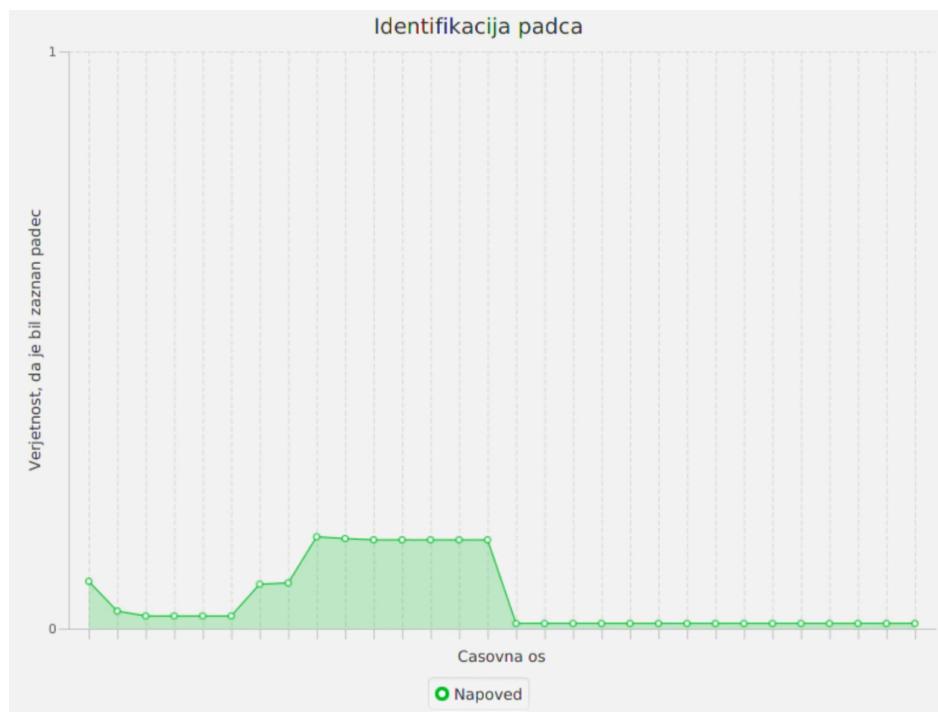
4.4.1.2 Aktivna identifikacija padca na osnovi zaznavanja vzorca padca in konvolucijske nevronske mreže

V tem poglavju bo predstavljena programska oprema za identifikacijo padcev osnovana na metodi zaznavanja vzorca padca opisani v poglavju 4.7.2 in konvolucijski nevronski mreži opisani v poglavju 4.8.2.

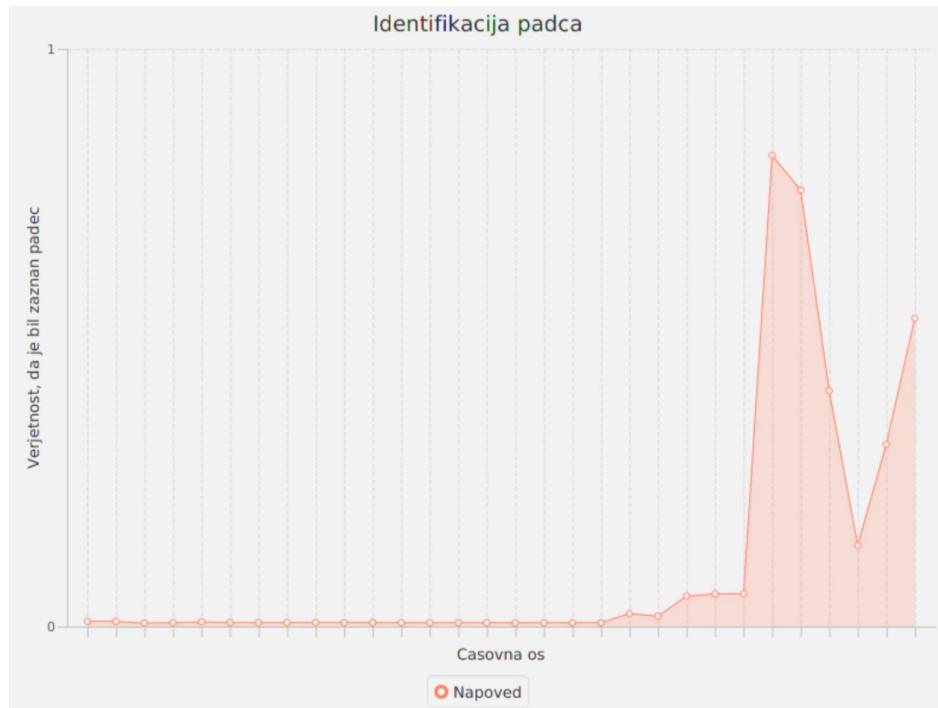
Implementacija se nahaja v imeniku *active_CNN_feature* v kateri se nahaja prva komponenta *ForceDetection.jar*, katera je namenjena zajemu podatkov in izračunu značilnosti. Komponenta deluje tako, da bere meritve iz mikrokrmlnika preko serijskih vrat in hrani premikajoče okno velikosti 100 meritev. Ob vsaki novi meritvi se izračuna značilke preko metode opisane v poglavju 4.7.2, ter rezultat je izpisani na standardni izhod.

Naslednja komponenta *CNN_features_activePredictor.py* je namenjena *identifikaciji padca* in deluje tako, da najprej vključi že učen model konvolucijske veronske mreže hranjen v datoteki *CCN.best.hdf5*, nato komponenta bere podatke iz standardnega vhoda s katerimi hrani premikajoče okno velikosti 100 meritev. In vsakih pet meritev se izvede klasifikacija premikajočega okna preko konvolucijske nevronske mreže opisane v 4.8.2. Rezultat klasifikacije je izražen v obliki verjetnosti identifikacije padca, ter je izpisani na standardni izhod. Datoteka *ProgBar.jar* je uporabljena za vizualizacijo odziva klasifikacije v obliki grafa, kot prikazano v sliki 12.

Programsko opremo je mogoče izvesti v operacijskem sistemu linux s ukazom: `java -jar ForceDetection.jar | python3 CNN_features_activePredictor.py | java -jar ProgBar.jar.`



(a) Prikaz odziva sistema za identifikacijo padcev v realnem času ob zaznani običajni dnevni aktivnosti.



(b) Prikaz odziva sistema za identifikacijo padcev v realnem času ob zaznamem dogodku padca.

Slika 12: Odziv sistema za identifikacijo padcev v realnem času. Abscisna os predstavlja klasifikacijo v določenem časovnem trenutku in ordinatna os predstavlja verjetnost identifikacije padca.

4.4.1.3 Aktivna identifikacija padca na osnovi zaznavanja vzorca padca in modela Naivni Bayes

V tem poglavju bo predstavljena programska oprema za identifikacijo padcev osnovana na metodi zaznavanja vzorca padca opisani v poglavju 4.7.2 in metodi Naivni Bayes opisani v poglavju 4.8.1.

Implementacija se nahaja v imeniku *active_NB_features* pri tem je prva komponenta *ForceDetection.jar* enaka, kot v poglavju 4.4.1.2 in v tem poglavju je ne bomo opisali. Naslednja komponenta *NB_features_activePredictor.py* je namenjan identifikaciji padcev in deluje tako, da najprej vključi že treniran model Naivni Bayes hranjen v datoteki *naiveBayes.pkl*, sledi branje iz standardnega vhoda in klasifikacija vsake prebrane vrstice. Rezultat klasifikacije je vstavljen v premikajoče okno dolžine 100 vrednosti na osnovi katerega je izračunana verjetnost identifikacije padca, pri tem padec je identificiran, ko več kot 17 izidov klasifikacije seznaní padec. Rezultat je posledično izpisani na standardni izhod in je prebran od komponente *ProgBar.jar*, katera je že opisana v poglavju 4.4.1.2.

Programsko opremo je mogoče izvesti v operacijskem sistemu linux s ukazom: `java -jar ForceDetection.jar | python3 NB_features_activePredictor.py | java -jar ProgBar.jar`.

4.5 Zbiranje podatkov

V tem poglavju bo opisan proces zbiranja podatkov, najprej bo predstavljena problematika simulacije padcev, nato bo opisano načrtovanje dogodka zbiranja podatkov ter bodo predstavljeni scenariji, na podlagi katerih smo zbrali podatke. Predstavljena bo izvedba zbiranja podatkov, opisane bodo značilnosti prostovoljcev in nezgoda, ki se je pripetila ob dogodku zbiranja podatkov. Nazadnje bo predstavljen postopek zbiranja podatkov negativnega razreda.

4.5.1 Problematika simulacije padcev

Kot omenjeno v poglavju 2.1 je padec po definiciji nenameren dogodek in v prispevku [39] so raziskovalci ugotovili, da večina sistemov za identifikacijo padcev deluje efektivno le v testni uporabi medtem, ko ob namestitvi v delovno okolje se ti sistemi slabo obnašajo.

V prispevku [39] so razglasili, da vzrok za nekvalitetno delovanje sistema za identifikacijo padca v delovnem okolju je razvoj algoritmov, ki sloni na podatkih zbranih preko simulacije padca. Simulacija padca je v direktnem nasprotju z zgoraj omenjeno definicijo, ki pravi, da padec je nenameren dogodek in preko simulacije ne bo nikoli

mogoče doseči enak rezultat, kot pri resnem padcu.

Tako smo preko pregleda literature našli članek, ki obravnava problematiko evalvacije sistemov za identifikacijo padcev [25]. V prispevku so predstavljeni principi in algoritmi za identifikacijo padcev ter so podani kriteriji za učinkovito evalvacijo sistema za identifikacijo padcev, kateri bodo uporabljeni za oceniti kakovost sistema predstavljenega v magistrskem delu. Omenjeni kriteriji so osnovani na meri specifičnosti in senzitivnosti, ter so opisani v 2.4.2.2.

TABLE I
SCENARIOS FOR THE EVALUATION OF FALL DETECTORS

Category	Name	Outcome
Backward fall (both legs straight or with knee flexion)	Ending sitting	Positive
	Ending lying	Positive
	Ending in lateral position	Positive
	With recovery	Negative
Forward fall	On the knees	Positive
	With forward arm protection	Positive
	Ending lying flat	Positive
	With rotation, ending in the lateral right position	Positive
	With rotation, ending in the lateral to the left position	Positive
	With recovery	Negative
Lateral fall to the right	Ending lying flat	Positive
	With recovery	Negative
Lateral fall to the left	Ending lying flat	Positive
	With recovery	Negative
Syncope	Vertical slipping against a wall finishing in sitting position	Negative
Neutral	To sit down on a chair then to stand up (consider the height of the chair)	Negative
	To lie down on the bed then to rise up	Negative
	Walk a few meters	Negative
	To bend down, catch something on the floor, then to rise up	Negative
	To cough or sneeze	Negative

Slika 13: Scenariji za evalvacijo sistema za identifikacijo padcev. Slika iz prispevka [25].

V citiranem prispevku so bili celo predlagani scenariji na osnovi katerih testirati sistem za identifikacijo padcev. Scenariji so sestavljeni iz 17 aktivnosti med katerimi je 12 padcev, 5 primerov običajne dnevne aktivnosti ter nekatere aktivnosti so izvedene kot kombinacija padca in ponovnega vstajanja v pokončni položaj. Omenjeni scenariji so prikazani v sliki 13.

4.5.2 Načrtovanje zbiranja podatkov

Za omogočiti tekočo izpeljavo procesa zbiranja podatkov je bilo potrebno dogodek ustrezeno načrtovati in natančno določiti vse potrebne aktivnosti. Prva problematika s katero smo se srečali je bila izbira primerenega prostora, ki omogoči postavitev prototipa tal in varovalnih blazin ob prototipu. Identificirali smo primeren prostor v prostorih športne arene Bonifika Koper, kjer smo začasno najeli malo telovadnico.



Slika 14: Telovadnica izbrana za proces zbiranja podatkov. V sliki je razviden prototip tal in varovalne blazine.

Po najemu primerenega prostora je bilo potrebno določiti potek zbiranja podatkov oziroma aktivnosti, ki bodo prostovoljci izvedli. Izbrali smo sedem scenarijev, ki so bili predlagani v prispevku [25] in so omenjeni v sliki 13.

1. Padec na kolena (ang. forward fall on the knees)
2. Padec v naprej in zaščita s rokami (ang. forward fall with forward arm protection)
3. Padec v naprej s ležečim zaključkom (ang. forward fall ending laying flat)

4. Padec na kolen s rotacijo in zaključkom na bokih (ang. forward fall on the knees with rotation, ending in the lateral position)
5. Bočni padec s ležečim zaključkom (ang. lateral fall ending lying flat)
6. Bočni padec s ležečim zaključkom ter vračanje v pokončno pozicijo (ang. lateral fall ending lying flat with recovery)
7. Padec v naprej s ležečim zaključkom ter vračanje v pokončno pozicijo (ang. forward fall ending laying flat with recovery)

V zgornjem seznamu so opisani padci, ki bo vsak prostovolec izvedel, pri tem bomo nudili ščitnike za kolena in komolce. Prvih pet padcev bodo prostovoljci izvedli v časovnem intervalu petih sekund, kjer po padcu bo potrebno zadržati končno pozicijo do konca intervala. Zadnja dva padca bosta izvedena v intervalu desetih sekund, kjer prostovolec pada, leži eno sekundo ter se nato dvigne v pokončno pozicijo in odkoraka iz tleh.

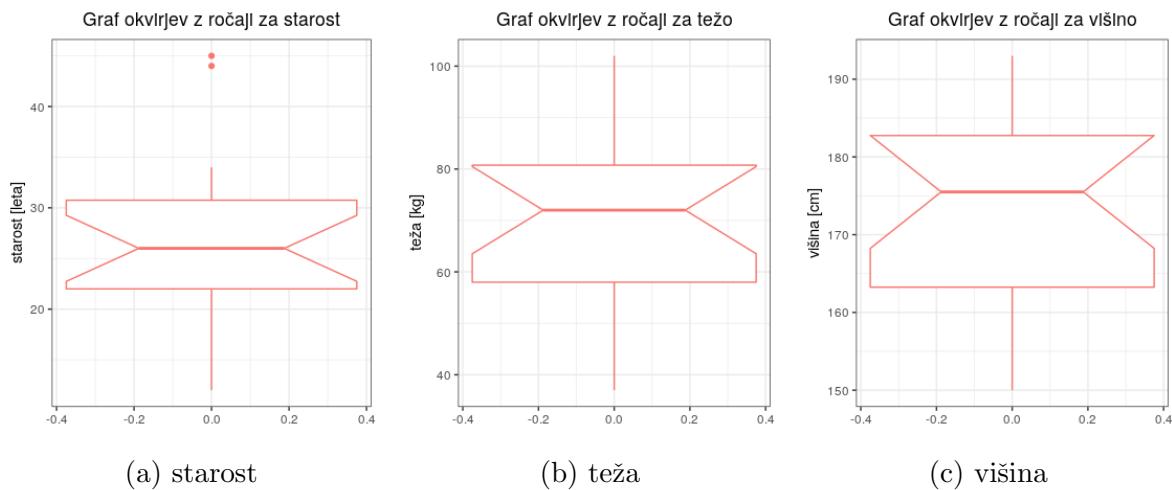
Vsak dogodek padca se bo začel tako, da prostovolec se nahaja pred desno stranico torej izven pametnih tal. Desna stanica pametnih tal je prikazana na sliki 14, kot stranica pametnih tal na desni strani računalnika.

Za ustrezeno dopolniti postopek zbiranja podatkov je bila pripravljena anonimna anketa, ki preko identifikatorja veže podatke padcev s anonimnimi podatki od prostovoljca. V pripravljeni anketi se zbira naslednje podatke: *spol, starost, teža, višina, športna aktivnost, zaskrbljenost do poškodb ob testiranju in število doživelih padcev v zadnjem letu.*

Poleg ankete, za ustrezni uvod v proces zbiranja podatkov je bil pripravljen protokol v angleškem jeziku, ki natančno opiše celoten postopek zbiranja podatkov in tako pripravi prostovoljca za ustrezeno izvedbo aktivnosti.

4.5.3 Izvedba

Dogodek zbiranja podatkov je bil izveden v sredo 29.07.2020 od 10:00 do 13:00. Na dogodku je sodelovalo 18 prostovoljev med katerimi je bilo devet žensk. V grafu okvirjev z ročaji na sliki 15a, ki prikazuje starost prostovoljev je opaziti, da velika večina prostovoljev je mladih in imamo le dva primera nad 40 let. To lahko predstavlja težavo, ker sistem za identifikacijo padcev je namenjen ostarelim osebam, starosti (65+) in v naši podatkovni množici ni takega primera. Kot prikazano v grafu na sliki 15b, je teža prostovoljev primerno porazdeljena, saj polovica meritev je med 60kg in 80kg, ter imamo nekaj primerov težjih oseb 90kg+ in lažjih pod 40kg. Tudi višina prostovoljev



Slika 15: Grafi okvirjev z ročaji, ki prikazujejo starost, težo in višino prostovoljcev

je primerno porazdeljena, saj višina polovice prostovoljcev spada v interval od 160cm do 185cm. Pri tem tudi pri višini imamo nekaj primerov visokih oseb 190cm in nizkih oseb 150cm. Osnovna statistična analiza ostalih vprašanj ankete prikazana v tabeli 2 je razkrila, da so prostovoljci zelo aktivni saj je mediana polja športna aktivnost zavzela vrednost 4, proces zbiranja podatkov jih ne posebno skrbi in, da v zadnjem letu je večina udeležencev doživelva vsaj en dogodek padca.

Tabela 1: Osnovna statistična analiza teže in višine prostovoljcev.

spol	število	teža [kg]		višina [cm]	
		povprečje	± std	povprečje	± std
F	9	58.4	17.8	163	7.25
M	9	80.4	8.06	185	5.79
skupaj	18	69.4	17.6	173.6	12.9

Tabela 2: Osnovna statistična analiza ostalih vprašanj ankete.

športna aktivnost	zaskrbljenost do poškodb	doživeti padci v trenutnem letu
1 - ne aktiven	1 - ne zaskrbljen	od 0 do 4 ali več
5 - zelo aktiven	5 - zelo zaskrbljen	
mediana	mediana	mediana
4	2	1

4.5.3.1 Nezgoda ob zbiranju podatkov

Navidezno se je proces zbiranja podatkov pravilno izvedel v celoti, ampak po kasnejši obdelavi in pregledu podatkov smo opazili, da je vrednost enega senzorja stalno 0. Ob podrobnejšem pregledu in raziskovanju napake v prototipu tal smo opazili, da se je žica, ki veže senzor na podnožje pretrgala ob prenosu prototipa do telovadnice. Vsi zajeti podatki so tako oškodovani, saj vrednosti enega od šestnajstih senzorjev so stalno na nuli. Omenjen problem je obravnavan v poglavju 4.7.1.1.

4.5.4 Zbiranje podatkov negativnega razreda

Ob dogodku zbiranja podatkov so bili zbrani le podatki pozitivnega razreda, kjer padec se dejansko zgodi. Podatki negativnega razreda pri katerih se obravnava običajne dnevne aktivnosti pa so bili zajeti le na osnovi enega subjekta. To je bilo tako izvedeno zaradi časovnih omejitev in ker smo se osredotočili na problem identifikacije padca.

Tako, kot za primere pozitivnega razreda, smo enako izkoristili prispevek [25] na kateremu osnovat scenarije negativnega razreda in na podlagi predlaganih scenarijev smo izbrali sledeče aktivnosti:

1. Usesti se na stol, registrirano trikrat v intervalu 5s
2. Dvigniti se iz stola, registrirano trikrat v intervalu 5s
3. Pobrati predmet iz tleh, registrirano trikrat v intervalu 5s
4. Sonožni skok iz tleh, registrirano trikrat v intervalu 5s
5. Naključna hoja z naključnim ustavljanjem, trajanje 8min
6. Prazna tla, trajanje 10s
7. Korak v naprej in ustavljanje 5s ponovljeno skozi 2min

Podatki točke 5, 6, 7 bodo uporabljeni za učenje napovedovalnega modela in ostali podatki točk 1, 2, 3, 4, bodo uporabljeni le za testiranje.

4.6 Predstavitev podatkov

Podatki zajeti v procesu zbiranja podatkov opisanem v prejšnjem poglavju 4.5 sestojijo iz meritov v časovnem intervalu. Taki tip podatkov je imenovan časovna vrsta ter je bil opisan v poglavju 2.4.1.

Obravnavani podatki so dejanske meritve šestnajstih senzorjev pritiska vezanih na mikrokrmilnik. Mikrokrmilnik izvede 100 meritov na sekundo in ob vsaki meritvi zame vrednost vseh senzorjev. Vrednost senzorja je pozitivno celo število v intervalu od 0 do 65535.

Tako strukturirani podatki so bili zajeti ob vsakem padcu opisanem v poglavju 4.5 pri tem vsak padec je bil zajet, kot posamezna datoteka. Vse datoteke s podatki padca so bile nato združene v tri datoteke CSV (ang Comma Separated Values) formata, ki bodo predstavljene v tem poglavju in na koncu poglavja bo predstavljena še zadnja datoteka s podatki ankete. Podatkovne zbirke omenjene v tem poglavju so dostopne na povezavi ²

4.6.1 Pozitivna podatkovna množica

Pozitivna podatkovna množica se nahaja v datoteki *positiveSet.csv* in vsebuje 140 primerov padca, kjer padec se je dejansko zgodil.

Vsaka meritev v datoteki ima 20 atributov, kateri bodo predstavljeni v sledečih točkah:

- *fall_ID*: enolični identifikator padca
- *person_ID*: enolični identifikator prostovoljca, vezan s podatki ankete predstavljeni v poglavju 4.6.3
- *fall_Category*: identifikator tipa padca, kateri definira padec simuliran od prostovolca. Izbrani padci so opisani v 4.5.2.
- *time_10ms*: atribut, ki razvrsti meritve v času
- *S0, ..., S15*: vrednosti senzorjev pritiska

²zenodo: <https://zenodo.org/record/3991751>

4.6.2 Negativna podatkovna množica

Negativna podatkovna množica, katera sestoji iz aktivnosti, kjer se ne pripeti dogodek padca je shranjena v dveh ločenih datotekah. Prva datoteka *negativeSet.csv* vsebuje registrirane aktivnosti opisane v poglavju 4.5.4 pod točkami 5, 6, 7. Druga datoteka *testSet.csv* vsebuje ostale primere negativnega razreda, ki so opisani v poglavju 4.5.4 pod točkami 1, 2, 3, 4. Vsi podatki negativne podatkovne množice so bili zajeti le na osnovi enega prostovoljca in to je *person_ID:17*.

Vsaka meritev v datotekah ima 20 atributov, kateri bodo predstavljeni v sledečih točkah:

- *neg_ID*: enolični identifikator negativnega primera
- *person_ID*: enolični identifikator prostovoljca, vezan s podatki ankete predstavljeni v poglavju 4.6.3
- *neg_Category*: identifikator tipa negativnega primera, kateri definira primer simuliran od prostovoljca. Izbrani primeri so opisani v 4.5.4.
- *time_10ms*: atribut, ki razvrsti meritev v času
- *S0, ..., S15*: vrednosti senzorjev pritiska

4.6.3 Podatki zbrani preko ankete

Podatki zbarsni preko ankete so bili pretvorjeni v digitalno obliko v CSV format in se nahajajo v datoteki *surveyData.csv*. Vsaka meritev v datoteki opiše prostovoljca in preko atributa *person_ID* veže podatke v anketi s podatki padca tako pozitivnega, kot negativnega razreda.

Atributi datoteke so predstavljeni v sledečih točkah:

- *person_ID*: enolični identifikator prostovoljca, kateri veže podatke ankete s podatkovno množico pozitivnega in negativnega razreda.
- *sex*: kategorični atribut, ki definira spol prostovoljca
- *age*: skalarni atribut, ki definira starost prostovoljca
- *weight*: skalarni atribut, ki definira težo prostovoljca v *kg*
- *height*: skalarni atribut, ki definira višino prostovoljca v *cm*

- *sportActive*: kategorični atribut, ki označi koliko je športno aktiven prostovolec. Vrednost atributa se razpenja od 1 (ne aktiven) do 5 (zelo aktiven)
- *worried*: kategorični atribut, ki označi koliko je prostovolec zaskrbljen do poškodb med postopkom zbiranja podatkov. Vrednost atributa se razpenja od 1 (ne zaskrbljen) do 5 (zelo zaskrbljen)
- *fallEvents*: kategorični atribut, ki označi koliko padcev je doživel prostovolec v trenutnem letu. Vrednost atributa se razpenja od 0 (nič padcev) do 4 (štiri ali več padcev)

4.7 Predobdelava podatkov

V tem poglavju bo predstavljena faza predobdelave podatkov, v kateri bo najprej opisana metoda, ki je aplicirana na celotno podatkovno množico z namenom razširitve podatkovne množice in omogočiti gradnjo modelov, ki zaznavajo padce neodvisno od smeri izvora padca. Nato bosta predstavljena dva postopka odkrivanja značilk, ki sta samostojno uporabljena v kasnejši fazi modeliranja. Sledi predstavitev metode za podvzorčenje meritev in ekstrakcijo aktivnosti iz zajetega intervala, ki omogoči, da pri učenju napovedovalnega modela se osredotočimo le na obravnavano aktivnost in ne na celoten zajeti interval v katerem se je zgodila aktivnost. Na koncu poglavja bo predstavljena priprava učne in testne množice na osnovi katerih bomo učili in testirali napovedovalne modele.

4.7.1 Razširitev podatkovne množice preko matrične rotacije

Pozitivna podatkovna množica, zbrana preko procesa zbiranja podatkov, vsebuje le 140 primerov padca, tako številčno omejena podatkovna množica lahko predstavlja problem pri učenju napovedovalnega modela.

Za ustrezno razširitev podatkovne množice smo izkoristili dejstvo, da vsi primeri padca so zajeti iz enake začetne pozicije prostovoljca, kot opisano v 4.5.2. Ker so vsi prostovoljci začeli padec iz enake stranice prototipa tal, potem vsi padci so usmerjeni v isto smer. Na tak način je mogoče razširiti podatkovno množico preko rotacije primerov padca za 90° , 180° in 270° ter istočasno izboljšati sposobnosti napovedovalnega modela, kateri bo sedaj učen nad podatkovno množico, kjer padec izvora iz vseh štirih stranic prototipa tal. Na tak način bo tako treniran napovedovalni model neodvisen od smeri izvora padca.

Pri implementaciji metode za rotacijo podatkovne množice smo izkoristili dejstvo, da senzorji vgrajeni v prototipu tal so strukturirani v matrični obliki, kot je opaziti v

sliki 11. Matrična struktura množice senzorjev omogoči enostavno rotacijo primerov padca preko matrične rotacije tako, da se vsako meritve podatkovne množice najprej preoblikuje v matriko 4×4 , pri tem je potrebno paziti na pravilni vrstni red senzorjev in nato se matriko pomnoži z 2D rotacijsko matriko, ki rotira meritve za 90° . Tako generirana matrika je ponovno pretvorjena v vrstico in shranjena v podatkovno množico. Metoda je rekurzivno ponovljena nad novo generiranimi podatki tako, da končna podatkovna množica je sestavljena iz originalnih primerov padca in rotacij za $90^\circ, 180^\circ$ in 270° .

Aplikacija metode rotacije nad pozitivno podatkovno množico sestavljeni iz 140 primerov padca je zgenerirala novo podatkovno množico sestavljeni iz 560 primerov padca.

4.7.1.1 Rotacija podatkov in okvara senzorja

Okvara senzorja omenjena v poglavju 4.5.3.1 ne oškoduje projekt le iz vidika izgubljenih informacij padca, ampak model učen nad tako popačeno podatkovno množico bo asociral vrednost ničle senzorja $s4$ z dogodkom padca. Za preprečiti to asociacijo moramo dodelit tudi senzorju $s4$ neko vrednost ob dogodku padca.

Omenjen problem je rešen preko aplikacije metode matrične rotacije na podatkovno množico padcev. Ker omenjena metoda rotira podatkovno množico za $90^\circ, 180^\circ$ in 270° stopinj, se rotirane vrednosti senzorjev v meritvi preslikajo v vrednost nekega drugega senzorja. Na tak način tudi senzor $s4$ zavzame neko vrednost, ki je različna od 0 v nekaterih meritvah.

4.7.1.2 Problematika plasti laminata nad matriko senzorjev

Kot omenjeno v poglavju 4.3, je prototip tal sestavljen iz dveh slojev med katerimi se nahaja matrika senzorjev pritiska. Spodnji sloj je le penasta podlaga in nima pomembnega vpliva na meritve senzorjev, medtem ko zgornja plast laminata lahko vpliva na zajete podatke in nekoliko popači podatke razširjene preko metode rotacije.

Struktura plasti laminata je vzrok za vpliv na meritve senzorjev, saj je plast laminata sestavljena iz šest desk širokih $20cm$ in dolgih $120cm$, kot prikazano v sliki 16. Ob aplikaciji sile na deski laminata, se sila prenese direktno na spodnji senzor, kot tudi na bližnje, saj rigidnost deske laminata omogoči prenos sile tudi na ostale senzorje, ki ležijo pod to desko. Prenos sile iz deske laminata na senzorje pod desko je optimalen, saj je deska v direktnem stiku s senzorji. Problem se pojavi, ker sila aplicirana na desko laminata se prenese tudi na bližnje deske laminata preko klick spoja. Klick spoj dobro veže deske laminata, ampak preko opazovanja in testiranja smo ugotovili, da sila se ne optimalno prenese iz deske na desko. Posledica klick spoja je, da se sila aplicirana



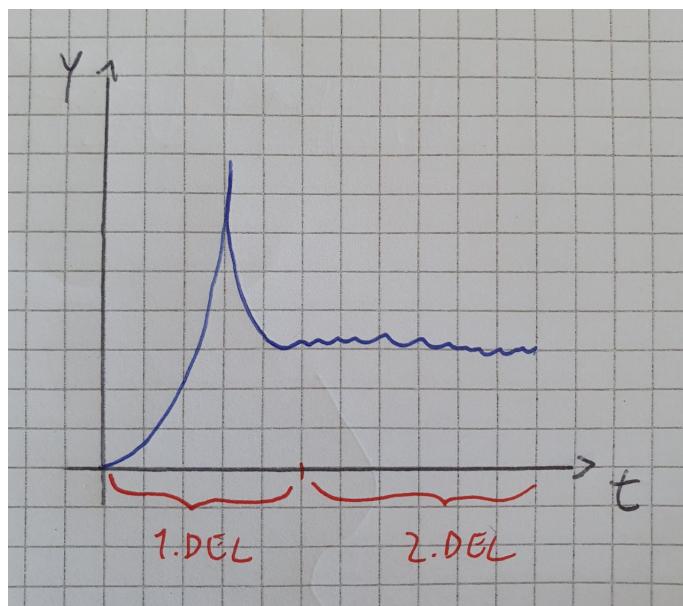
Slika 16: Prikaz plasti laminata nad prototipom tal. Iz slike je opaziti šest desk lamineata.

na desko bolje prenese na senzorje pod desko, kot na senzorje sosednjih desk. Pojav je mogoče opaziti v sliki 18, kjer med naključnim korakanjem se je prostovolec ustavil nad senzorjem 5 in se je tako sila prenesla na senzorje 2 in 9, ki ležijo pod isto desko kot senzor 5. Na senzorje 4 in 6, ki ležita ob senzorju 5, ampak pod različno desko se sila ni učinkovito prenesla in ti senzorji niso zaznali nobenega pritiska.

Omenjena problematika, lahko učinkuje na model treniran nad rotirano podatkovno množico, saj ob postopku rotacije so bile rotirane meritve senzorjev in tako je bil rotiran tudi učinek plasti laminata. Vpliv plasti laminata je bil rotiran ampak je ostal enak, medtem ko bi moral biti različen na osnovi smeri padca, če ta prihaja vzporedno s dolžino laminata ali pravokotno.

4.7.2 Zaznavanje vzorca padca

Prva zamisel sistema za identifikacijo padcev je bila osnovana na opazovanju podatkov iz senzorjev pritiska. Zajeli smo deset primerov padca in posnetek 3 minutne naključne hoje s naključnim ustavljanjem, ter smo podatke primerjali. V sliki 18 je prikazan del posnetka 3 minutne hoje v obliki grafa. Iz grafa se takoj opazi nekaj špic, ki so verjetno posledica korakanja ter iz podatkov senzorja 5 je enostavno opaziti vrednost senzorja, ki ostane visoka za določen čas, kar je posledica ustavljanja prostovolca nad senzorjem 5.



Slika 17: Prikaz vzorca padca. Os y predstavlja vrednost senzorja in os t je časovna os.

V sliki 19 so prikazani podatki ob primeru padca in iz grafa je razvidno, da ob padcu imamo najprej veliko špic, to je zaključek kritične faze padca, kot opisano v poglavju 2.2 in v fazi po padcu vrednosti nekaterih senzorjev ostanejo visoke, ker oseba leži na prototipu tal. Tako smo si zamislili, da bi lahko izkoristili ta vzorec, ki se tvori ob padcu za identifikacijo padca.

Omenjen vzorec je prikazan v sliki 17, iz katere je opaziti, da vzorec padca je sestavljen iz dveh delov. V prvem delu se pojavi visoka špica, ki je posledica zaključka kritične faze in v drugem delu vrednost senzorja ostane visoka, ker ponesrečenec leži na tleh in tla zaznavajo silo teže.

Iz opazovanja podatkov in kot prikazano v sliki 19 se ob primeru padca pojavi malo vzorcev padca, na sliki sta le dva, senzor številka 5 in 9. Ampak ob zaključku kritične faze padca se pojavi veliko špic, v tem primeru jih je opaziti kar 4 v sliki 19 senzorji številka 5,6,7 in 9. Tako smo se odločili, da ne bomo zaznavali le vzorca padca ampak

Algorithm 1: ExtractFeatures

Data: moving window of size 100 – > movingWindow

Result: array of integers of size 16

```

1 result = new int[16];
2 for each column in movingWindow do
3     firsts = firstHalf(column);
4     second = secondHalf(column);
5     if not findPeak(first) then
6         | result.push(0);
7     else if findTail(second) then
8         | result.push(2);
9     else
10        | result.push(1);
11    end
12 end
13 return result;

```

tudi špice, ki se pojavijo ob padcu. Vzrok za veliko število špic ob padcu izvira iz dejstva, da sta horizontalna in vertikalna hitrost trikrat višje med padcem, kot pri katerikoli drugi običajni dnevni aktivnosti, kot je bilo opisano v poglavju 2.2.1.

Na osnovi zgoraj omenjenih ugotovitev smo implementirali metodo za odkrivanje značilk, ki sloni na zaznavi špic in vzorca padca. Omenjena metoda je prikazana v algoritmu 1 in deluje tako, da ob klicu sprejme prenikajoče okno dolžine 100 meritev oziroma 2s zajetega intervala. Za vsako kolono v prenikajočem oknu se izračunana metoda *findPeak()* prikazana v algoritmu 2 in metoda *findTail()* prikazana v algoritmu 3. Metoda *findPeak()* zaznava špico v prvi polovici prenikajočega okna in metoda *findTail()* zaznava visoko vrednost v drugi polovici signala. Na tak način metoda prikazana v algoritmu 1 proizvede nov tok podatkov oblike polja šestnajstih vrednosti, kjer vsaka vrednost polja je izračunana na osnovi kolone v prenikajočem oknu na podlagi naslednjih pravil: če v prenikajočem oknu metoda ni zaznala nobene špice, potem je vrednost polja za dano kolono 0. Če je bila zaznana samo špica vrednost polja je 1. Če metoda je zaznala tako špico, kot tudi visoko vrednost signala v drugi polovici okna vrednost polja je 2.

Metoda *findPeak()* prikazana v algoritmu 2 deluje tako, da za celoštevilsko polje sprejeto, kot argument poišče, če polje vsebuje špico, za katero veljajo naslednje lastnosti: špica je zajeta v intervalu petih meritev oziroma 100ms časa, minimum pred maksimalno vrednostjo je manjši od minimuma po maksimalni vrednosti s namenom,

Algorithm 2: FindPeak

Data: array of int values – > arr

Result: boolean True or False

```

1 w = 5;                                     */
2 h = 500;                                    */
3 k = 8;                                     */
4 for i = 0 to arr.length - w do
5     min1 = MAXINT;
6     min2 = MAXINT;
7     max = MININT;
8     for j = 0 to w do
9         value = arr[i+j];
10        if (min1 > value) and (max < 0) and (min2 == MAXINT) then
11            | min1 = value;
12        else if (max < value) and (min2 == MAXINT) then
13            | max = value;
14        else if (min2 > value) then
15            | min2 = value;
16        else if (max < value) and (min2 != MAXINT) then
17            | max = value;
18            if (min1 > min2) then
19                | min1 = min2;
20            end
21            min2 = MAXINT;
22        end
23        if (min1 ≤ min2) and ((max - min2) > (max - min1) /k) and ((max -
24            min1) > h) then
25            | return True;
26        end
27    end
28 return False;
```

da zaznavamo le signal, ki narašča. Razlika med maksimumom in minimumom po maksimalni vrednosti mora biti večja od razlike med maksimalno in minimalno vrednostjo pred maksimumom deljeno faktor k , ker je potrebno efektivno zaznati špice in ne višanje vrednosti signala. Razlika med prvim minimumom in maksimalno vrednostjo mora biti večja od vrednosti h , ki predstavlja mejo za zaznavo špice tako, da efektivno odpravimo šum. Vse opisane lastnosti lahko opazimo v vzorcu padca prikazanem na sliki 17.

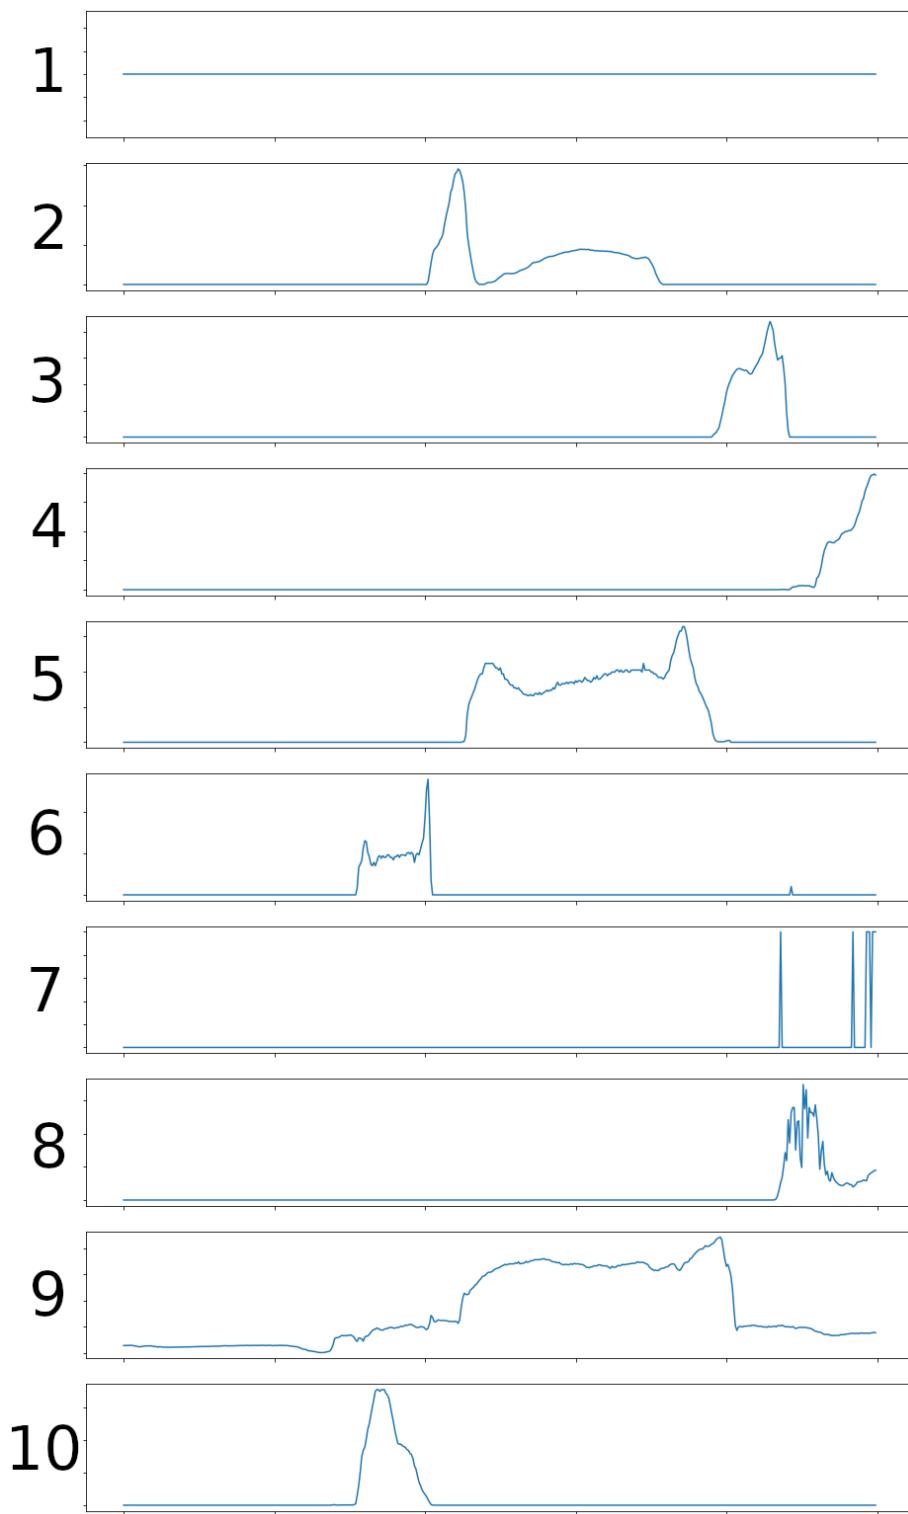
Algorithm 3: FindTail

Data: array of int values – > arr
Result: boolean True or False

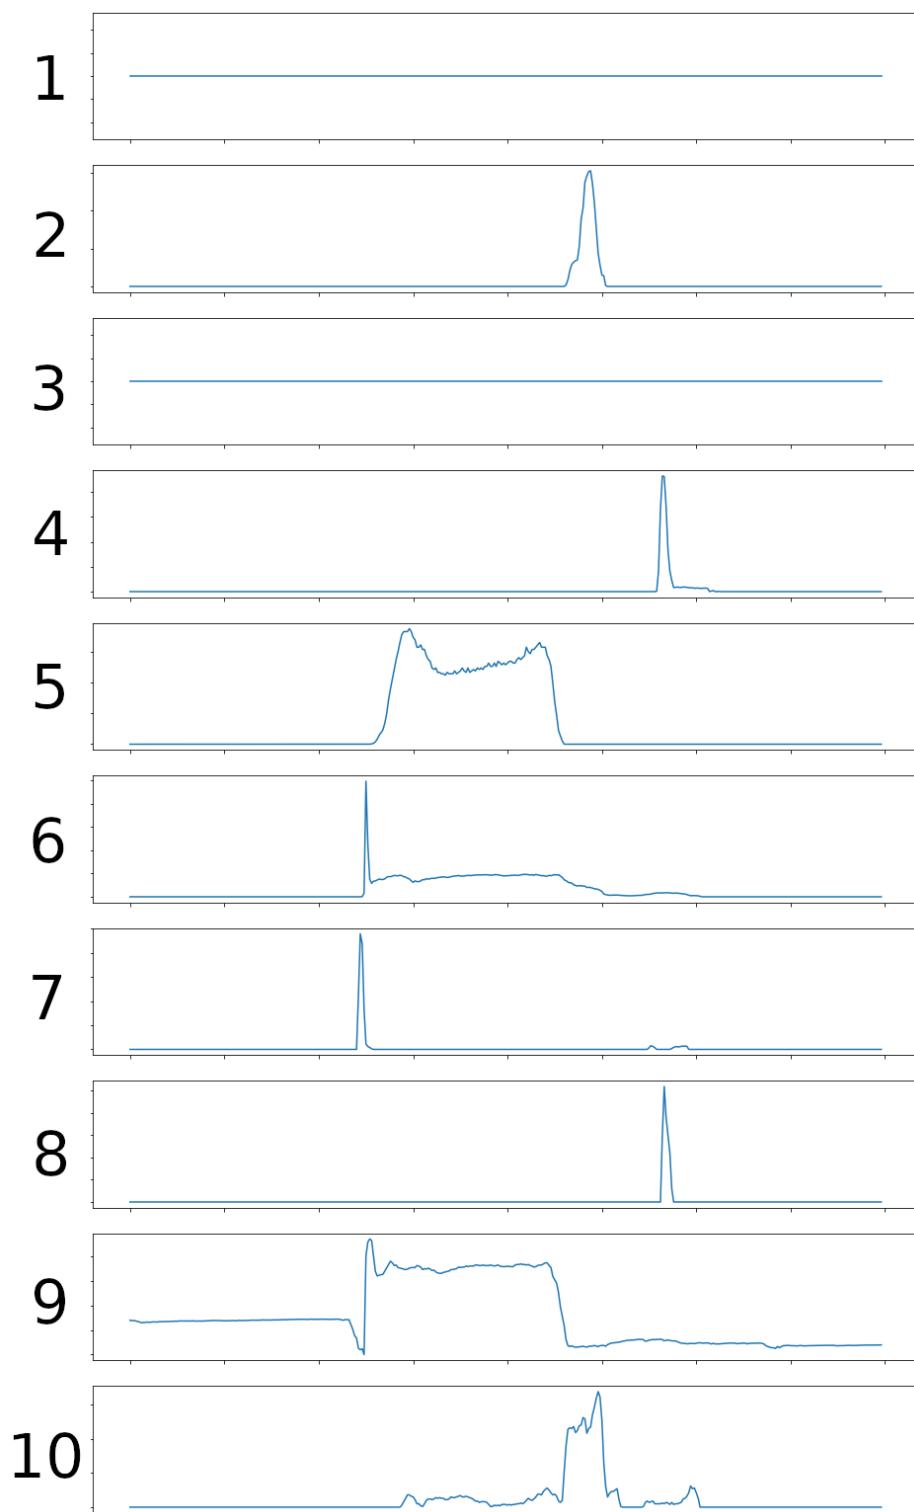
```

1 mean = mean(arr);
2 meja = 0.2f;
3 upper = mean + (mean * meja);
4 lower = mean - (mean * meja);
5 for i = 0 to arr.length do
6   if (arr[i] < lower) or (arr[i] > upper) then
7     return False;
8   end
9 end
10 return True;
```

Metoda *findTail()* prikazana v algoritmu 3 deluje tako, da za celoštevilsko polje sprejeto, kot argument poišče, če polje vsebuje signal, ki se ne oddali za več kot faktor *meja* od povprečne vrednosti signala.



Slika 18: Graf prikazuje podatke zajete v posnetku 3 minutne naključne hoje s naključnim ustavljanjem. V grafu je prikazanih le 10s posnetka. Prikazani so podatki prvih desetih senzorjev, zaradi lažjega ogleda grafa in ker vrednosti ostalih senzorjev v tem časovnem intervalu so zanemarljive. Podatki vsakega senzorja so prikazani na dveh oseh, os x predstavlja čas v ms in os y predstavlja normalizirano vrednost senzorja.



Slika 19: Graf prikazuje podatke zajete ob simulaciji padca s trajanjem 8s. Prikazani so podatki prvih desetih senzorjev, zaradi lažjega ogleda grafa in ker vrednosti ostalih senzorjev v tem primeru padca so zanemarljive. Podatki vsakega senzorja so prikazani na dveh oseh, os x predstavlja čas v ms in os y predstavlja normalizirano vrednost senzorja.

4.7.3 Min-max normalizacija podatkov senzorja v premikajočem oknu

Ker umetne konvolucijske nevronске mreže uporabljene za klasifikacijo časovnih vrst delujejo na osnovi tehnike premikajočega okna, katera je bila opisana v poglavju 2.4.1.1. Smo se odločili za implementacijo metode, ki normalizira podatke v premikajočem oknu. Min-max normalizacija je aplicirana na vsak senzor posebej tako, da skušamo postaviti na enako skalo zaznane vrednosti senzorjev. Izbrali smo min-max normalizacijo, ker prenos sile na sosednje senzorje je odvisen tako od padca, kot od plasti laminata, kot omenjeno v poglavju 4.7.1.2.

Z min-max normalizacijo na osnovi senzorja skušamo izpostaviti vzorec padca neodvisno od jakosti signala in tako doseči visoko učinkovitost identifikacije padcev. Min-max normalizacija deluje na osnovi naslednje formule:

$$x'_{i,j} = \frac{x_{i,j} - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (4.1)$$

Formula opisuje izračun nove vrednosti $x'_{i,j}$ iz vrednosti $x_{i,j}$ za dani senzor i ob premikajočem oknu dolžine n , kjer $0 \leq j \leq n$.

Ker prototip tal stalno zaznava neko silo oziroma šum, ki ga proizvede zgornja plast laminata, katera pritiska s svojo težo na senzorje in proizvede minimalno meritev in ker je min-max normalizacija zelo občutljiva na šum pri majhni širini premikajočega okna, smo razširili min-max normalizacijo s postopkom, ki izračuna normalizirano vrednost, le če maksimalna vrednost presega določeno mejo, drugače so vse vrednosti meritev v premikajočem oknu postavljene na 0.

4.7.4 Podvzorčenje

V procesu zbiranja podatkov smo zajeli aktivnosti s frekvenco 100Hz ter smo ugotovili, da tako hitro izvajanje meritev je pretirano in da lahko dosežemo enake rezultate s izvajanjem meritev pri frekvenci 50Hz. Na podlagi te ugotovitve, smo osnovoli celoten razvoj sistema za identifikacijo padcev na frekvenci 50Hz, ter smo uvedli metodo za podvzorčenje podatkovne množice, ki zavrne vsako drugo meritve in tako podvzorči meritve iz frekvence 100Hz na 50Hz.

4.7.5 Ekstrakcija aktivnosti iz zajetega intervala

Ker so pozitivna podatkovna množica *positiveSet.csv* in delno tudi negativna podatkovna množica oziroma datoteka *testSet.csv*, sestavljeni iz primerov aktivnosti zajetih v različnih časovnih intervalih, ter obravnavana aktivnost se lahko pripeti naključno nekje med zajetim intervalom, je potrebno to aktivnost izvleči iz zajetega intervala vrednosti.

Za implementirati ekstrakcijo aktivnosti, smo izkoristili dejstvo, da pred začetkom aktivnosti na prototipu tal ni nič oziroma če nekaj je postavljeno na prototipu tal se ne giba, naj bo to predmet ali oseba. Nato smo opazovali diferencial vrednosti prejšnje in trenutne meritve posameznega senzorja in če je diferencial enega izmed šestnajstih senzorjev prekoračil določno mejo smo začeli registracijo meritov. Registrirali smo petnajst meritov pred zaznavo diferenciala in naslednjih 75 meritov skupno 100 meritov oziroma dve sekundi časa. Postopek smo ponovili za vse meritve v obdelani datoteki. Na tak način vsaka aktivnost v obdelani podatkovni množici naj bo ta zajeta v intervalu 5s ali 10s je bila zreducirana na interval 2s oziroma 100 meritov.

4.7.6 Priprava učne in testne množice

Priprava učne in testne množice se začne s aplikacijo metode za podvzorčenje opisane v poglavju 4.7.4 nad podatkovnimi zbirkami v datotekah: *positiveSet.csv*, *negativeSet.csv* in *testSet.csv*. Rezultat obdelave datoteke *positiveSet.csv* bo imenovan množica padcev, rezultat obdelave datoteke *negativeSet.csv* bo imenovan množica negativnih aktivnosti in rezultat obdelave datoteke *testSet.csv* bo imenovan testna množica.

Množica padcev in testna množica sta nato obdelani s metodo za ekstrakcijo aktivnosti iz zajetega intervala opisane v poglavju 4.7.5. Ker omenjena metoda za ekstrakcijo aktivnosti registrira aktivnost le če diferencial preseže določeno vrednost, nekateri padci sploh ne sprožijo registracije in metoda jih zavrže. Na tak način množica padcev je sestavljena le iz 127 primerov iz originalnih 140-ih primerih padca. Sledi priprava testne množice in na zadnje bo predstavljena priprava učne množice, katera se razlikuje v odvisnosti od implementirane metode strojnega učenja.

4.7.6.1 Priprava testne množice

Priprava testne množice se začne s naključno ekstrakcijo 20 primerov iz množice padcev. Izvlečeni primeri so zbrisani iz množice padcev in vključeni v testno množico. Testna množica je nato rotirana preko metode za razširitev podatkovne množice na osnovi matrične rotacije opisane v 4.7.1. V testno množico so nato vključeni primeri iz množice negativnih aktivnosti. Vključenih je 50 primerov aktivnosti opisane v poglavju 4.5.4 pod točko 5, 10 primerov aktivnosti pod točko 6 in 7 primerov aktivnosti pod

točko 7. Izvlečeni primeri so zbrisani iz množice negativnih aktivnosti. Testna množica je nato obdelana v odvisnosti od primera uporabe s aplikacijo metode min-max normalizacije opisane v 4.7.3 ali metodo odkrivanja značilk opisane v poglavju 4.7.2.

Končna testna podatkovna množica je sestavljena iz naslednjih primerov:

- Pozitivni razred: 80 primerov
 - 80 primerov padca
- Negativni razred: 115 primerov
 - 12 primerov usesti na stol
 - 12 primerov dvigniti se iz stola
 - 12 primerov pobrati predmet iz tleh
 - 12 primerov sonožni skok iz tleh
 - 50 primerov naključne hoje z naključnim ustavljanjem
 - 7 primerov korak v naprej in ustavljanje
 - 10 primerov registracije praznih tal

Vsek primer aktivnosti je sestavljen iz 100 meritev šestnajstih senzorjev zajetih s frekvenco 50hz skupno 2s registracije.

4.7.6.2 Priprava učne množice za metodo Naivni Bayes

Priprava učne množice za metodo Naivni Bayes se začne po sestavi testne množice, sledi aplikacija metode odkrivanja značilk opisane v poglavju 4.7.2 nad množico padcev in množico negativnih aktivnosti. Predprocesirani podatki množice padcev so nato rotirani preko metode za razširitev podatkovne množice na osnovi matrične rotacije opisane v 4.7.1.

Ker metoda odkrivanja značilk opisana v poglavju 4.7.2 generira vrednosti iz množice 0, 1, 2 ter javi vrednost 1 le v primeru zaznave špice, vrednost 2 le v primeru zaznave špice v prvem delu premikajočega okna in visokega signala v drugem delu premikajočega okna ter javi vrednost 0 v vseh ostalih primerih. Zaradi tega večina meritev množice padcev, bo imelo vse vrednosti atributov enake 0. Tega pojava si ne želimo, drugače podatki množice padcev bodo preveč podobni podatkom množici negativnih aktivnosti in tako učeni model, ne bo pravilno napovedoval. Na podlagi te ugotovitve in, ker metoda naivnega Bayesa opisana v poglavju 2.4.3 napoveduje le na podlagi trenutnih podatkov in ne na osnovi podatkov zajetih v časovnem intervalu, smo se odločili, da

bomo odstranili iz množice padcev vse podatke, kjer vrednost vseh atributov je 0. Tako obdelano množico padcev smo vključili v učno množico.

Negativne primere učne množice smo izbrali le iz podatkov osemminutne naključne hoje s naključnim ustavljanjem iz množice negativnih aktivnosti. Izbrali smo te podatke, ker metoda Naivni Bayes napoveduje le na podlagi trenutnih podatkov in ne na osnovi podatkov zajetih v časovnem intervalu, ter omenjena aktivnost najverjetno vsebuje vse različne oblike meritev, ki se lahko pojavijo pri ostalih aktivnostih opisanih v poglavju 4.5.4 pod točko 6 in 7. Iz omenjene podatkovne množice smo črpali 10000 meritev, ter smo aplicirali metodo za razsiritev podatkovne množice preko matrične rotacije.

Končna učna podatkovna zbirka za metodo Naivni Bayes je sestavljena iz naslednje količine meritev:

- Pozitivni razred: 24104
- Negativni razred: 40000

4.7.6.3 Priprava učne množice za metodo umetne konvolucijske nevronske mreže

Priprava učne množice za metodo umetne konvolucijske nevronske mreže se začne po sestavi testne množice s aplikacijo metode min-max normalizacije opisane v 4.7.3 ali metodo odkrivanja značilk opisane v poglavju 4.7.2 nad množico padcev in množico negativnih aktivnosti.

Množica padcev je nato v celoti vključena v učno množico, sledi vključitev podatkov negativnega razreda iz množice negativnih aktivnosti. Vključenih je 50 primerov aktivnosti opisane v poglavju 4.5.4 pod točko 5, 40 primerov iz aktivnosti pod točko 6 in 40 primerov aktivnosti pod točko 7. Tako sestavljena učna množica je nato rotirana s metodo matrične rotacije opisane v 4.7.1.

Končna učna podatkovna zbirka je sestavljena iz naslednje količine primerov:

- Pozitivni razred: 416
- Negativni razred: 480

Vsak primer aktivnosti je sestavljen iz 100 meritev šestnajstih senzorjev zajetih s frekvenco 50hz skupno 2s registracije.

Oznake razredov učne množice so dodatno obdelane s metodo (ang. one-hot encoding) opisano v poglavju 2.4.4.7.

4.8 Modeliranje

V naslednjem poglavju bo predstavljena implementacija modelov strojnega učenja Naivni Bayes in umetna konvolucijska nevronška mreža. Opisan bo proces izbire parametrov modela, ki sloni na iterativnem testiranju modela nad učno množico in na koncu bodo predstavljeni parametri najboljšega modela.

4.8.1 Naivni Bayes

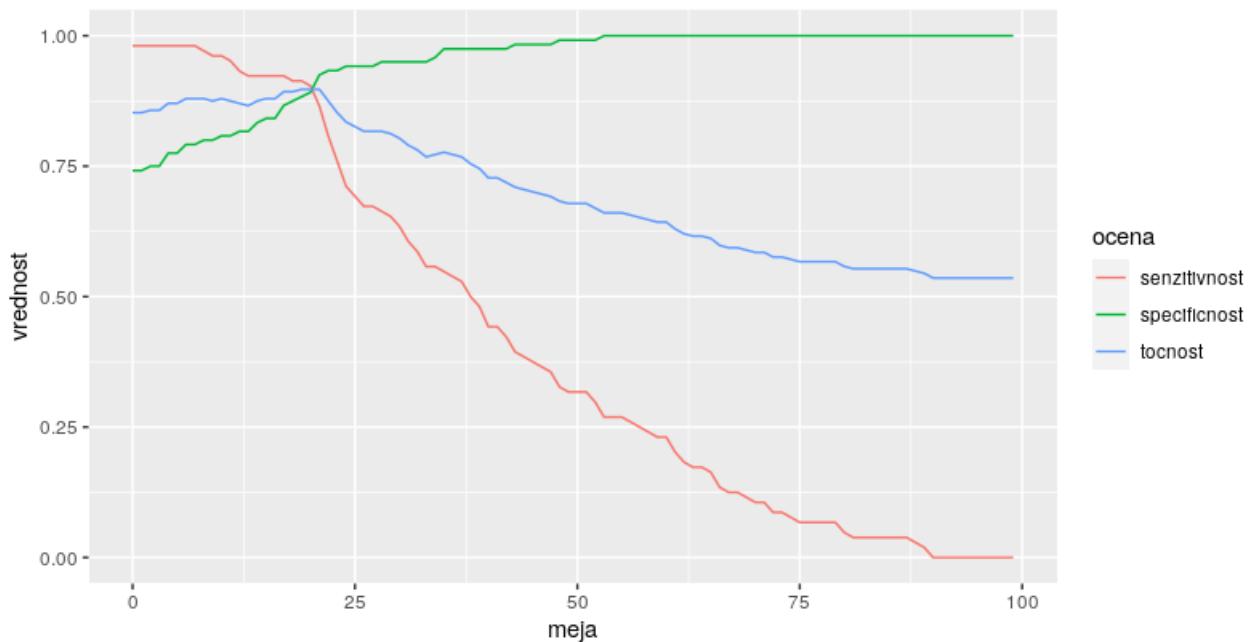
Metoda Naivni Bayes je bila že opisana v poglavju 2.4.3, v tem poglavju bo predstavljena naša implementacija metode Naivni Bayes za napovedovanje časovnih vrst. Metoda Naivni Bayes je bila uporabljena za gradnjo modelov na surovinih podatkih, normaliziranih podatkih preko min-max normalizacije in na podatkih predobdelanimi z metodo odkrivanja značilk opisano v poglavju 4.7.2. Zaradi slabih rezultatov doseženih pri aplikaciji metode nad surovimi in normaliziranimi podatki ne bomo podrobno opisali teh primerov ampak se bomo osredotočili na aplikacijo metode Naivni Bayes nad podatki predobdelanimi z metodo odkrivanja značilk.

Omenjena implementacija metode Naivni Bayes se nahaja v datoteki *NaiveBayes.py*, kjer v prvem delu kode so vključene potrebne knjižnice, nato je pripravljena učna in testna podatkovna zbirka, kot opisano v 4.7.6.

Sledi učenje običajnega modela Naivni Bayes nad učno množico in ker metoda ne napoveduje na podlagi časovnega intervala ampak na osnovi trenutnih vrednosti smo implementirali funkcijo, ki na osnovi napovedanih vrednosti za trenutno aktivnost, javi ali je aktivnost napovedana, kot padec ali običajna dnevna aktivnost. Funkcija deluje tako, da najprej klasificira vsako meritev v zajetem časovnem intervalu preko modela Naivni Bayes in če število meritev klasificiranih, kot padec presega določeno mejo, je aktivnost klasificirana kot padec. Drugače je aktivnost klasificirana, kot običajna dnevna aktivnost.

Ker učni podatki so zajeti v časovnem intervalu 100 meritev je proces izbire meje napovedovanja potekel tako, da smo testirali model nad vsemi vrednosti meje od 0 do 100. Ob vsakemu testiranju smo izračunali mero specifičnosti, senzitivnosti in točnosti, katere so opisane v poglavju 2.4.2.2. Pridobljene rezultate smo pretvorili v graf prikazan v sliki 20 in na podlagi njega smo izbrali idealno mejo napovedovanja, ob 17 pozitivnih meritev v premikajočem oknu sestavljenem iz 100 meritev.

Omenjena implementacija naivnega bayesa je bila testirana in rezultati so predstavljeni v poglavju 5.



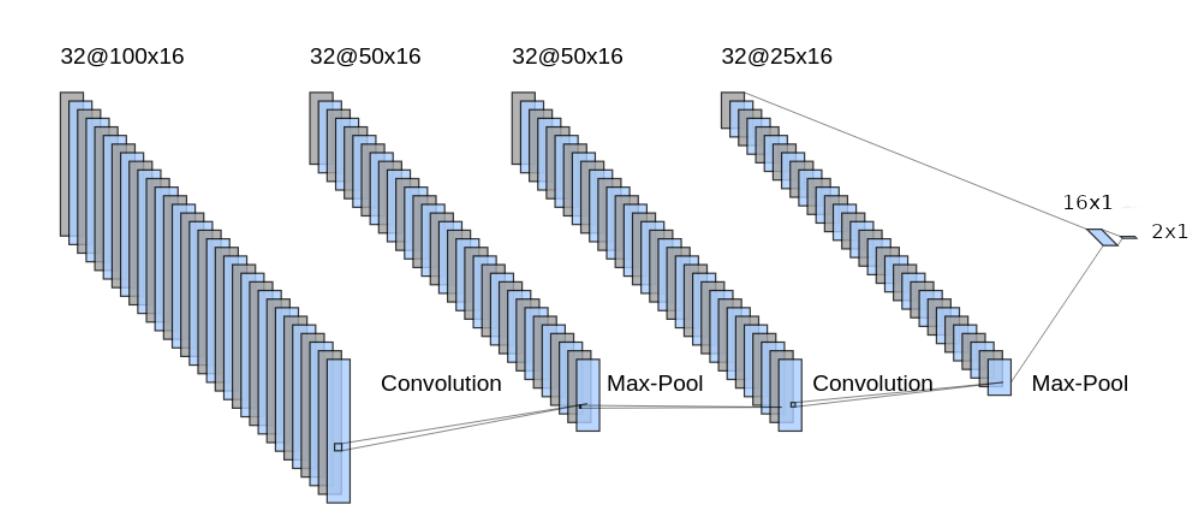
Slika 20: Graf izrisan pri iskanju optimalne klasifikacijske meje. Graf je bil izrisan ob testiranju modela nad učno množico.

4.8.2 Umetna konvolucijska nevronska mreža

Metoda umetne konvolucijske nevronske mreže je bila že uvedena v poglavju 2.4.4 in v tem poglavju bo predstavljena naša implementacija umetne konvolucijske nevronske mreže (ang. Convolutional Neural Network) za identifikacijo padcev. Izbrali smo model CNN, ker v prispevku [8] je bila opisana primernost tega modela pri klasifikaciji časovnih vrst.

Zaradi velikega števila parametrov CNN smo se soočali s problemom selekcije modela, pri katerem smo morali večkrat učit model nad podatkovno množico, ga testirati in izbrati nove parametre za ponovno učenje modela, ki bo sedaj točneje klasificiral podatke. Končni model sestavljen po velikemu številu testiranj je prikazan v sliki 21.

CNN prikazana v sliki je sestavljena iz vhodnega 2D konvolucijskega sloja, ki na osnovi jedra velikosti 5×5 izračuna 32 filtrov iz premikajočega okna velikosti 100×16 . Izhodni filtri so obdelani preko sloja združevanja maksimalnih vrednosti opisanega v 2.4.4.5, sloj aplicira združevanje maksimalnih vrednosti s uporabo 2×1 premikajočega okna tako, da ohranimo prostorsko informacijo o senzorju in združujemo podatke preko časovne osi. Aplikacija združevanja maksimalnih vrednosti preoblikuje filtre v velikost 50×16 . Sledi drugi 2D konvolucijski sloj, ki na osnovi jedra velikosti 3×3 izračuna 32 novih filtrov. Obdelani filtri so nato pretvorjeni v polje vrednosti, katero je vezano na polno povezan skriti sloj sestavljen iz 16 nevronov. Nevroni so nato vezani na izhodni sloj sestavljeni iz dveh polno povezanih nevronov, ki izvajajo končno klasifikacijo. Med



Slika 21: Konvolucijska nevronska mreža uporabljena za identifikacijo padcev sestavljena iz dveh 2D konvolucijskih slojev, dveh slojev za združevanje maksimalnih vrednosti, enega polno povezanega skritega sloja in izhodnega sloja sestavljenega iz dveh nevronov.

vsakim konvolucijskim slojem in slojem nevronov je vključen tudi sloj za regularizacijo preko izpuščanja, katero delovanje je opisano v 2.4.4.6 in preko vključitvije teh slojev želimo preprečiti prekomerno prileganje podatkom (ang. overfitting).

Omenjeni model CNN je bil treniran za 10 obdobji (ang. epochs) na osnovi paketnega načina (ang. batch) velikosti 32 podatkov. Izbrali smo Nadam (ang. Nesterov-accelerated Adam) optimizator, ker se je odzval boljše od adam [15] in sgd (ang. Stochastic Gradient Descent) optimizatorja in, ker v prispevku [31] so omenili, da je primeren za uporabo s CNN. Po večkratnem testiranju modela smo za stopnjo učenja (ang. learning rate) izbrali vrednost 0.01. Model je bil treniran s delitvijo učne množice v validacijsko množico na osnovi 20% deleža, pri tem je bila učna množica premešana pred delitvijo na osnovi konstantnega semena. Implementacija CNN je bila testirana in rezultati so predstavljeni v poglavju 5.

5 Rezultati

V tem poglavju bodo predstavljeni rezultati evalvacije modelov opisanih v poglavju 4.8. Postopek evalvacije modelov se začne s testiranjem modela nad učno in testno podatkovno množico, katere so bile pripravljene, kot opisano v poglavju 4.7.6. Po testiranju sledi evalvacija modela na osnovi mer opisanih v poglavju 2.4.2.2. Za vsak model bodo predstavljeni v obliki seznama napačno klasificirani primeri iz testne množice. Rezultati modelov bodo opisani ter modeli bodo med sabo primerjani v naslednjem poglavju 6.

5.1 Rezultati evalvacije modela naivni Bayes

V tem poglavju bodo predstavljeni rezultati evalvacije modela Naivni Bayes, kateri je bil opisan v poglavju 4.8.1. Model je bil učen nad podatkovno množico predobdelano preko metode za zaznavanje vzorca padca opisane v 4.7.2, celoten proces priprave podatkovne množice je opisan v poglavju 4.7.6. V naslednjih vrsticah bodo predstavljeni rezultati evalvacije omenjenega modela nad učno in testno množico pripravljeno, kot opisano v poglavju 4.7.6.

mera	Točnost (%)	Specifičnost (%)	Senzitivnost (%)
vrednost	89.3	86.7	92.3

(a) Ocena točnosti, specifičnosti in senzitivnosti.

Klasifikacijska kontingenčna tabela		Napovedi			tot
		Padec	ODA	tot	
Dejanski razredi	Padec	384	32	416	
	ODA	64	416	480	
					896

*ODA-običajna dnevna aktivnost

(b) Klasifikacijska kontingenčna tabela.

Slika 22: Evalvacija testiranja modela Naivni Bayes testiranega nad učno množico predobdelano z metodo zaznavanja vzorca padca.

V sliki 22 je ocenjeno testiranje modela Naivni Bayes nad učno množico predobdelano z metodo zaznavanja vzorca padca. Iz slike 22a je opaziti dobro točnost modela, kar 89.3% pravilno klasificiranih aktivnosti. Pri tem je opaziti, da model ima višjo senzitivnost od specifičnosti, ter v sliki 22b je opaziti, da model je napačno klasificiral le 32 primerov padca.

mera	Točnost (%)	Specifičnost (%)	Senzitivnost (%)
vrednost	77.4	65.2	95

(a) Ocena točnosti, specifičnosti in senzitivnosti.

Klasifikacijska kontingenčna tabela		Napovedi		
		Padec	ODA	tot
Dejanski razredi	Padec	76	4	80
	ODA	40	75	115
		195		

*ODA-običajna dnevna aktivnost

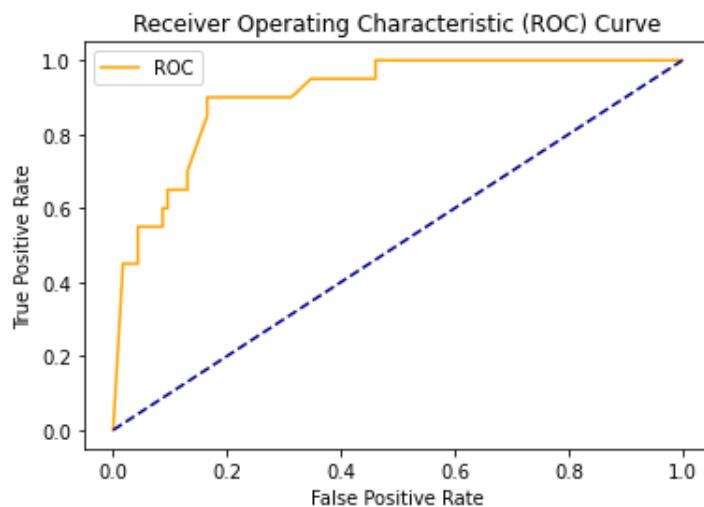
(b) Klasifikacijska kontingenčna tabela.

Slika 23: Evalvacija testiranja modela Naivni Bayes testiranega nad testno množico predobdelano z metodo zaznavanja vzorca padca.

V sliki 22 je ocenjeno testiranje modela Naivni Bayes nad testno množico predobdelano z metodo zaznavanja vzorca padca. Pri tem v sliki 23a je prikazana ocena točnosti, specifičnosti in senzitivnosti, iz katere je opaziti, da model je dosegel boljše rezultate ob testiranju nad učno množico, kot pri testiranju modela nad testno množico. Iz slike 23a in 23b je razviden učinek visoke senzitivnosti modela, ki je napačno klasificiral le 4 primere padca. Pri tem zaradi slabe specifičnosti je napačno klasificiral kar 40 primerov običajne dnevne aktivnosti.

Slaba uteženost mere specifičnosti in senzitivnosti je posledica dejstva, da v testni množici so prisotni primeri običajne dnevne aktivnosti, kateri niso vključeni v učno množico. Drugi vzrok pa je proces izbire optimalne meje klasifikacije osnovan le na učni množici, kateri je bil opisan v poglavju 4.8.1.

Slika 24 prikazuje ROC krivuljo, katera označi odvisnost med senzitivnostjo in specifičnostjo ob spremembami napovedovalnega praga. Iz izrisane ROC krivulje, je opaziti, da sprememba klasifikacijskega praga, bi lahko pozitivno vplivala na omenjen model. Lahko bi spremenili klasifikacijski prag tako, da bi povečali specifičnost, posledično bi izgubili malo senzitivnosti ampak končni model, bi javil veliko manj napačno



Slika 24: ROC krivulja za model Naivni Bayes testiran nad testno množico. AUC = 0.90

razvrščenih negativnih primerov.

V naslednjem seznamu bodo predstavljeni napačno klasificirani primeri aktivnosti, ob testiranju modela nad testno množico:

(V seznamu so prisotna podvojena imena aktivnosti, ob takih primerih aktivnost je bil simulirana od različnega prostovoljca ali je bila izvedena v različni registraciji.)

- 4 primerov padca opisanih v poglavju 4.5.2:
 1. Padec v naprej in zaščita s rokami
 2. Padec na kolena rotiran za 270°
 3. Padec na kolena rotiran za 180°
 4. Bočni padec s ležečim zaključkom rotiran za 90°
- 19 primerov iz naključne hoja z naključnim ustavljanjem opisane v poglavju 4.5.4
- 21 testnih primerov negativnega razreda opisanih v poglavju 4.5.4:
 1. Dva primera usesti se na stol
 2. Dvigniti se iz stola
 3. Dva primera sonožni skok iz tleh
 4. Usesti se na stol rotiran za 90°
 5. Usesti se na stol rotiran za 180°
 6. Usesti se na stol rotiran za 270°

7. Dva primera dvigniti se iz stola rotiran za 90°
8. Dvigniti se iz stola rotiran za 180°
9. Tri primere dvigniti se iz stola rotiran za 270°
10. Dva primera pobrati predmet iz tleh rotiran za 90°
11. En primer pobrati predmet iz tleh rotiran za 180°
12. Dva primera pobrati predmet iz tleh rotiran za 270°
13. Sonožni skok iz tleh rotiran za 90°
14. Sonožni skok iz tleh rotiran za 270°

Iz zgornjega seznama se takoj opazi, da model osnovan na metodi Naivni Bayes slabo klasificira običajne dnevne aktivnosti, ki pripadajo testnim primerom opisanih v poglavju 4.5.4, saj je model napačno klasificiral 21 primerov na 48.

5.2 Rezultati evalvacije modela umetne konvolucijske nevronske mreže s postopkom predobdelave podatkov na osnovi zaznavanja vzorca padca

V tem poglavju bodo predstavljeni rezultati evalvacije modela umetne konvolucijske nevronske mreže, kateri je bil opisan v poglavju 4.8.2. Model je bil učen nad učno množico predobdelano preko metode zaznavanja vzorca padca opisane v poglavju 4.7.2, celoten proces priprave podatkovne množice je opisan v poglavju 4.7.6. V naslednjih vrsticah bodo predstavljeni rezultati evalvacije omenjenega modela nad učno in testno množico pripravljeno, kot opisano v poglavju 4.7.6.

mera	Točnost (%)	Specifičnost (%)	Senzitivnost (%)
vrednost	97	98.75	95.2

(a) Ocena točnosti, specifičnosti in senzitivnosti.

Klasifikacijska kontingenčna tabela		Napovedi		tot
		Padec	ODA	
Dejanski razredi	Padec	396	20	416
	ODA	6	474	480
				896

*ODA-običajna dnevna aktivnost

(b) Klasifikacijska kontingenčna tabela.

Slika 25: Evalvacija testiranja modela konvolucijske nevronske mreže testiranega nad učno množico predobdelano z metodo zaznavanja vzorca padca.

V sliki 25 je ocenjeno testiranje modela konvolucijske nevronske mreže nad učno množico predobdelano z metodo zaznavanja vzorca padca. Iz slike 25a je takoj opaziti visoko točnost modela pri klasifikaciji primerov iz učne množice. Tudi specifičnost in senzitivnost sta zelo visoki, kar seznanji kakovostni model.

V sliki 26 je ocenjeno testiranje modela konvolucijske nevronske mreže nad testno množico predobdelano z metodo zaznavanja vzorca padca. Iz slike 26a je opaziti visoko točnost modela, kar 89.2% pravilno klasificiranih primerov, pri tem je opaziti tudi visoko specifičnost modela, ki izrazi, da model bo zelo dobro klasificiral negativne primerne. Medtem, ko senzitivnost modela je nizka v nasprotju s specifičnostjo, komaj 83.7%. Ker pri sistemih za identifikacijo padcev želimo razpoznati vse padce, tako nizka senzitivnost lahko predstavlja problem.

mera	Točnost (%)	Specifičnost (%)	Senzitivnost (%)
vrednost	89.2	93	83.7

(a) Ocena točnosti, specifičnosti in senzitivnosti.

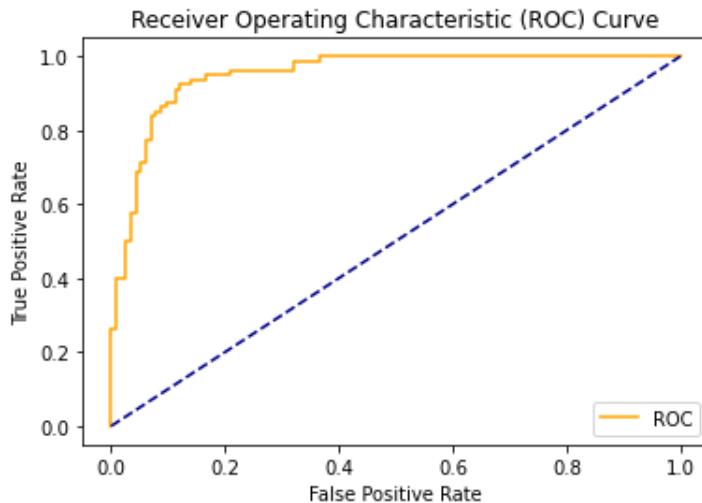
Klasifikacijska kontingenčna tabela		Napovedi		tot
		Padec	ODA	
Dejanski razredi	Padec	67	13	80
	ODA	8	107	115
		195		

*ODA-običajna dnevna aktivnost

(b) Klasifikacijska kontingenčna tabela.

Slika 26: Evalvacija testiranja modela konvolucijske nevronske mreže testiranega nad testno množico predobdelano z metodo zaznavanja vzorca padca.

V sliki 26b je prikazana klasifikacijska kontingenčna tabela, iz katere je takoj opaziti, veliko število napačno klasificiranih primerov padca in nizko število napačno klasificiranih primerov običajne dnevne aktivnosti, kot napovedano od mere senzitivnosti in specifičnosti.



Slika 27: ROC krivulja za model konvolucijske nevronske mreže testiran nad testno množico predobdelano z metodo zaznavanja vzorca padca. AUC = 0.95

Iz ROC krivulje prikazane v sliki 27 je opaziti visoko vrednost AUC = 0.95, katera označi kakovostni model. Iz slike je opaziti, da ob višanju klasifikacijskega praga, bi lahko učinkoviti zvišali senzitivnost modela ob žrtvovanju male količine specifičnosti.

V naslednjem seznamu bodo predstavljeni napačno klasificirani primeri aktivnosti, ob testiranju modela nad testno množico:

(V seznamu so prisotna podvojena imena aktivnosti, ob takih primerih aktivnost je bil simulirana od različnega prostovoljca ali je bila izvedena v različni registraciji.)

- 13 primerov padca opisanih v poglavju 4.5.2:
 1. Padec v naprej in zaščita s rokami
 2. Padec na kolena
 3. Padec v naprej in zaščita s rokami
 4. Padec v naprej s ležečim zaključkom ter vračanje v pokončno pozicijo
 5. Padec v naprej s ležečim zaključkom
 6. Padec na kolena rotiran za 270°
 7. Padec v naprej in zaščita s rokami rotiran za 180°
 8. Padec v naprej s ležečim zaključkom rotiran za 90°
 9. Padec na kolena rotiran za 180°
 10. Padec v naprej s ležečim zaključkom ter vračanje v pokončno pozicijo rotiran za 90°
 11. Padec na kolena rotiran za 270°
 12. Bočni padec s ležečim zaključkom rotiran za 90°
 13. Padec v naprej s ležečim zaključkom rotiran za 180°
- 8 primerov iz naključne hoja z naključnim ustavljanjem opisane v poglavju 4.5.4

Iz zgornjega seznama je opaziti, da omenjen model je pravilno klasificiral vse testne primere negativnega razreda opisane v poglavju 4.5.4 pod točkami: 1, 2, 3, 4. Ampak zaradi nizke senzitivnosti modela se je pojavilo veliko napačno klasificiranih primerov padca. Kot je bilo prej omenjeno tako nizka senzitivnost lahko predstavlja problem za sisteme namenjene identifikaciji padca.

5.3 Rezultati evalvacije modela umetne konvolucijske nevronske mreže s postopkom predobdelave podatkov na osnovi min-max normalizacije

V tem poglavju bodo predstavljeni rezultati evalvacije modela umetne konvolucijske nevronske mreže, kateri je bil opisan v poglavju 4.8.2. Model je bil učen nad podatkovno množico predobdelano preko min-max normalizacije opisane v poglavju 4.7.3, celoten proces priprave podatkovne množice je opisan v poglavju 4.7.6. V naslednjih vrsticah bodo predstavljeni rezultati evalvacije omenjenega modela nad učno in testno množico pripravljeno, kot opisano v poglavju 4.7.6.

mera	Točnost (%)	Specifičnost (%)	Senzitivnost (%)
vrednost	99.5	99.8	99.2

(a) Ocena točnosti, specifičnosti in senzitivnosti.

Klasifikacijska kontingenčna tabela		Napovedi		tot
		Padec	ODA	
Dejanski razredi	Padec	413	3	416
	ODA	1	479	480
				896

*ODA-običajna dnevna aktivnost

(b) Klasifikacijska kontingenčna tabela.

Slika 28: Evalvacija testiranja modela konvolucijske nevronske mreže testiranega nad učno množico predobdelano z metodo min-max normalizacije.

V sliki 28 je ocenjeno testiranje modela konvolucijske nevronske mreže nad učno množico predobdelano z metodo min-max normalizacije. Iz slike 28a je opaziti zelo visoko točnost modela 99.5%, kar lahko seznanji prekomerno prilaganje modela nad podatkovno množico. V sliki 28b je prikazano, da model je napačno klasificiral samo 3 dogodke padca in eno običajno dnevno aktivnost.

mera	Točnost (%)	Specifičnost (%)	Senzitivnost (%)
vrednost	95.3	98.2	91.2

(a) Ocena točnosti, specifičnosti in senzitivnosti.

Klasifikacijska kontingenčna tabela	Napovedi			tot
	Padec	ODA		
Dejanski razredi	Padec	73	7	80
	ODA	2	113	115
				195

*ODA-običajna dnevna aktivnost

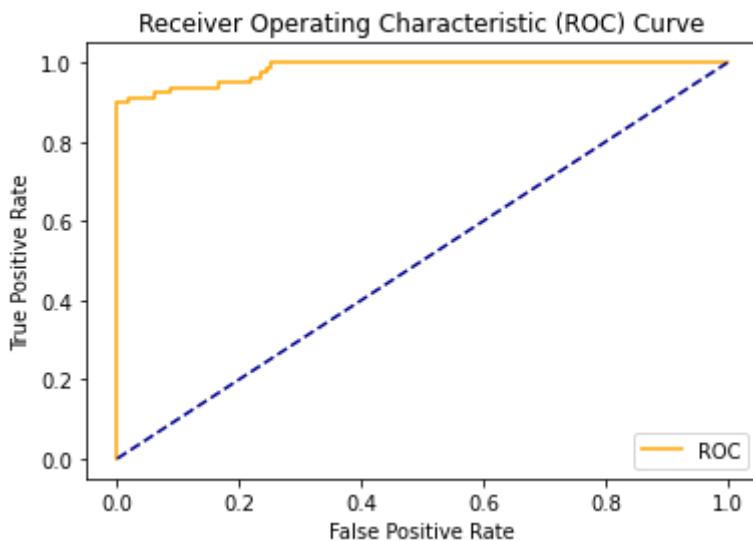
(b) Klasifikacijska kontingenčna tabela.

Slika 29: Evalvacija testiranja modela konvolucijske nevronske mreže testiranega nad testno množico predobdelano z metodo min-max normalizacije.

V sliki 29 je ocenjeno testiranje modela konvolucijske nevronske mreže nad testno množico predobdelano z metodo min-max normalizacije. V sliki 29a je takoj opaziti visoko točnost modela, ki je pravilno klasificiral 95.3% primerov, pri tem model ima zelo visoko specifičnost, kar pomeni, da sistem osnovan na tem modelu bo javil zelo malo napačno klasificiranih običajnih dnevnih aktivnosti. Tudi senzitivnost modela je zelo visoka, sicer ni še optimalna, saj od sistema za identifikacijo padcev, si želimo, da razpozna vse primere padca.

V sliki 29b je prikazana klasifikacijska kontingenčna tabela, iz katere je takoj opaziti, kar je bilo prej napovedano oziroma višjo specifičnost od senzitivnosti. Omenjen model je napačno klasificiral le dva primera običajne dnevnih aktivnosti in je napačno klasificiral 7 primerov padca.

Iz visoke točnosti modela ob testiranju nad testno množico, lahko zaključimo, da model se ne prekomerno prilega na podatke učne množice, saj podatki v testni množici so različni od tistih v učni.



Slika 30: ROC krivulja za model konvolucijske nevronske mreže testiran nad testno množico predobdelano preko min-max normalizacije. AUC = 0.98

V sliki 30 je prikazana ROC krivulja omenjenega modela, iz katere je opaziti visoko vrednost AUC = 0.98, katera označi kakovostni model. Iz slike je tudi opaziti, da ob višanju klasifikacijskega praga, ne bi učinkovito zvišali senzitivnost modela.

V naslednjem seznamu bodo predstavljeni napačno klasificirani primeri aktivnosti, ob testiranju modela nad testno množico:

(V seznamu so prisotna podvojena imena aktivnosti, ob takih primerih aktivnost je bil simulirana od različnega prostovoljca ali je bila izvedena v različni registraciji.)

- 7 primerov padca opisanih v poglavju 4.5.2:
 1. Padec v naprej s ležečim zaključkom
 2. Padec v naprej s ležečim zaključkom ter vračanje v pokončno pozicijo
 3. Padec na kolena rotiran za 90°
 4. Padec v naprej in zaščita s rokami rotiran za 180°
 5. Padec v naprej in zaščita s rokami rotiran za 270°
 6. Padec v naprej s ležečim zaključkom ter vračanje v pokončno pozicijo rotiran za 90°
 7. Bočni padec s ležečim zaključkom rotiran za 180°
- 2 testna primera negativnega razreda opisana v poglavju 4.5.4:
 1. Dvigniti se iz stola rotiran za 180°

2. Sonožni skok iz tleh rotiran za 180°

Iz zgornjega seznama opazimo, da omenjen model je pravilno klasificiral vse aktivnosti negativnega razreda opisane v poglavju 4.5.4 pod točkami 5, 6, 7, pri tem je napačno klasificiral le dve običajne dnevne aktivnosti iz množice testnih primerov.

6 Diskusija

Razvoj magistrskega dela se je začel s definicijo sistema za identifikacijo padca nato je bil podrobno analiziran dogodek padca ter so bile pregledane obstoječe tehnologije, ki omogočajo identifikacijo padca in na koncu poglavja 2 je bilo uvedeno vse potrebno znanje za ustrezno razumevanje magistrskega dela.

V poglavju 3 je bil predstavljen cilj magistrske naloge, ter je bila preučena neintruzivnost predlaganega sistema tako iz vidika občutka stalnega nadzora ustvarjenega v nadzorovani osebi, kot iz podatkov, ki jih sistem zaznava. Na koncu poglavja smo izrazili prednosti predlaganega sistema nad ostalimi obstoječimi rešitvami katere slonijo na senzorski tehnologiji vgrajeni v tleh.

Poglavlje 4 predstavi metodologijo razvoja sistema, od strojne opreme do programske opreme za aktivno identifikacijo padcev v realnem času. V poglavju je tudi opisan proces zbiranja podatkov in metode predprocesiranja podatkov na katerih smo osnovali gradnjo učne in testne množice. Na koncu poglavja so opisani modeli strojnega učenja, kateri so bili testirani nad testno in učno množico, ter rezultati so predstavljeni v poglavju 5.

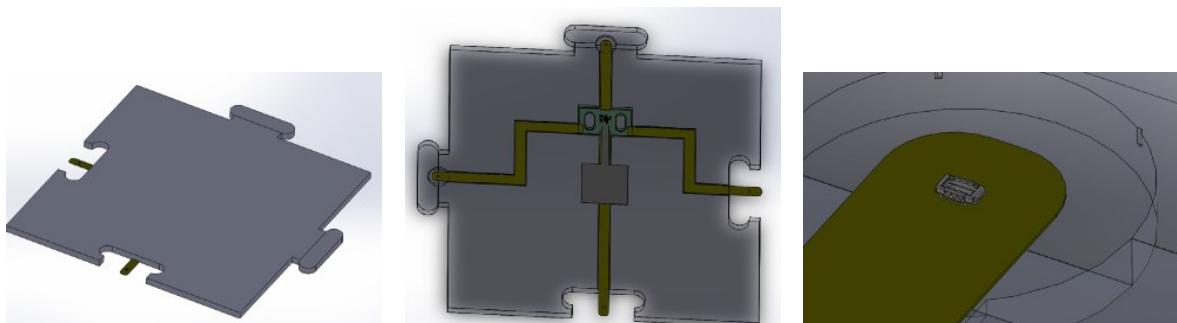
Iz poglavja 5 je opaziti, da model Naivni Bayes doseže zelo dobre rezultate nad učno množico ampak pri klasifikaciji testne množice model dokaže zelo nizko specifičnost, kar označi pretežno prileganje modela nad podatki učne množice. Model, ki se tako slabo odziva pri napovedovanju testne množice ni zato primeren za implementacijo v končnem sistemu.

Model osnovan na metodi konvolucijske nevronske mreže je dosegel zelo dobre rezultate pri obeh metodah predobdelave učne množice, kar dokaže, da ob aplikaciji metode predobdelave podatkov na osnovi vzorca padca opisane v poglavju 4.7.2 se izgubi le minimalna količina informacije in posledično dokaže primernost tega postopka predobdelave podatkov. Najboljše rezultate je dosegel model konvolucijske nevronske mreže ob predobdelavi podatkovne množice s meodo min-max normalizacije opisano v poglavju 4.7.3. Rezultati so dokazali pravilno klasifikacijo 95.3% primerov testne množice, pri tem je tudi senzitivnost modela zelo visoka, celo 91.2%. Tudi če omenjeni model je dosegel zelo dobre rezultate, ni še zadosten aplikacijo v delovno okolje, saj od sistema za identifikacijo padcev se pričakuje, da zazna vsaki padec in zato potrebujemo 100%

senzitivnost. Vsi predstavljeni modeli ne dosežejo 100% senzitivnosti ampak rezultati so zelo obetavni. Klasifikacijska sposobnost modelov je sigurno tudi oškodovana od nezgode, ki se je pripetila ob dogodku zbiranja podatkov in je opisana v poglavju 4.5.3.1. Na osnovi zgornjega dejstva bi lahko izboljšali točnost modelov tako, da bi ponovili dogodek zbiranja podatkov in posledično razširili podatkovno množico z novimi primeri padca in novimi primeri običajne dnevne aktivnosti. Podatkovno množico bi bilo potrebno razširiti tudi s primeri padca zbrani na osnovi starejših prostovoljcev, saj je identifikacija padcev pretežno namenjena ostarelim osebam in v zbrani podatkovni množici ni podatkov zbranih preko padca starejše osebe. Ob razširitviji podatkovne množice, bi lahko izkoristili podatke zbrane preko ankete za izpeljati zanimive analize, ki bi lahko pokazale, kako lastnosti različnih oseb vplivajo na zbrane podatke.

Omenjeni modeli so bili testirani tudi ob aktivni identifikaciji padcev v realnem času, katera je bila izvedena tako, da prostovolec je izvajal serijo običajnih dnevnih aktivnosti na pametnih tleh in je nato simuliral nekaj dogodkov padca. Rezultati so dokazali, da razvit sistem je zmožen identifikacije padcev ampak ne doseže visoke učinkovitosti, kot v testnih primerih. Omenjen pojav je bil že napovedan od prispevka [39], kateri je opisan v poglavju 4.5.1.

Iz raziskovanja izvedenega preko magistrskega dela smo prišli do zaključka, da pametna tla z vgrajenimi senzorji pritiska so učinkovita komponenta na osnovi katere razvit sistem za neintruzivno identifikacijo padcev, dokazali smo primernost modela konvolucijske nevronske mreže pri klasifikaciji aktivnosti na pametnih tleh in smo predlagali različne metode predobdelave podatkov na podlagi katerih osnovati prihodnji razvoj sistema.



Slika 31: Prototip ploščice z vgrajenim senzorjem pritiska. V ploščici je opaziti tudi vezje namenjeno krmiljenju komunikacije. V zadnji sliki je prikazan konektor za povezavo dveh ploščic.

V magistrskem delu smo se osredotočili le na identifikacijo padca in nismo obravnavali dogodek, ko oseba pada in se samostojno postavi v pokončni položaj, v tem primeru oseba ne potrebuje pomoči in sistem ne sme javiti padca. Ta lastnost bo morala biti implementirana za postaviti sistem v delavno okolje. Potrebno bo tudi testirati odziv sistema ob pojavu, da dve osebi se istočasno nahajata na pametnih tleh. V nadaljnjem razvoju sistema bi bilo zelo zanimivo izmeriti vpliv plasti laminata oziroma klick spoja na zajete podatke, kot opisano v poglavju 4.7.1.2. Zaradi matrične postavitve senzorjev predlagamo testiranje modela konvolucijske nevronske mreže na osnovi 3D konvolucije, katero ni bilo izvedeno zaradi časovnih omejitev.

V prihodnosti želimo povečati velikost prototipa pametnih tal katere bodo vsebovale več mikrokrmilnikov. Sledi razvoj komunikacijskega protokola, kateri bo omogočil poljubno razširitev pametnih tal. In zadnji postopek procesa razvoja projekta je razvoj ploščic z vgrajenimi senzorji pritiska za enostavno, po ceni in skalabilno implementacijo sistema za neintruzivno identifikacijo padcev.

7 Literatura in viri

- [1] Arduino. *Arduino Mega*. URL: <https://store.arduino.cc/arduino-mega-2560-rev3>. (dostopano: 21.07.2020).
- [2] D Kishore Babu, Y Ramadevi in KV Ramana. "RGNBC: Rough Gaussian Naive Bayes classifier for data stream classification with recurring concept drift". V: *Arabian Journal for Science and Engineering* 42.2 (2017), str. 705–714.
- [3] Thomas Bayes. "LII. An essay towards solving a problem in the doctrine of chances. By the late Rev. Mr. Bayes, FRS communicated by Mr. Price, in a letter to John Canton, AMFR S". V: *Philosophical transactions of the Royal Society of London* 53 (1763), str. 370–418.
- [4] A.K. Bourke, J.V. O'Brien in G.M. Lyons. "Evaluation of a threshold-based tri-axial accelerometer fall detection algorithm". V: *Gait & Posture* 26.2 (jul. 2007), str. 194–199. DOI: 10.1016/j.gaitpost.2006.09.012. URL: <https://doi.org/10.1016/j.gaitpost.2006.09.012>.
- [5] A. K. EXADAKTYLOS C. A. PFTORMUELLER G. LINDNER. "Reducing fall risk in the elderly: risk factors and fall prevention, systematic review". V: *Minerva Medica* 105 (2014), str. 275–281.
- [6] Kabalan Chaccour in Rony Darazi. "Smart Carpet using differential piezoresistive pressure sensors for elderly fall detection". V: (okt. 2015). DOI: 10.1109/WiMOB.2015.7347965.
- [7] Mary Jo Storey Gibson; Robert O Andres; Thomas E Kennedy; Larry C Coppard. "The prevention of falls in later life : a report of the Kellogg International Work Group on the Prevention of Falls by the Elderly". V: *Danish Medical Bulletin* (1987), str. 1–24.
- [8] Hassan Ismail Fawaz in sod. "Deep learning for time series classification: a review". V: *Data Mining and Knowledge Discovery* 33.4 (2019), str. 917–963.
- [9] Guodong Feng in sod. "Floor Pressure Imaging for Fall Detection with Fiber-Optic Sensors". V: *IEEE Pervasive Computing* 15 (mar. 2016), str. 40–47. DOI: 10.1109/MPRV.2016.27.

- [10] *FSR 400 Series Square Force Sensing Resistor*. Teh. poročilo P/N: 94-00009. Rev. A. Interlink electronics, 2010. URL: <https://cdn.sparkfun.com/assets/c/4/6/8/b/2010-10-26-DataSheet-FSR406-Layout2.pdf>.
- [11] M Golmajer. *Desezoniranje časovnih vrst*. Ljubljana, Statistični urad RS: 57 str. 2015.
- [12] R Jan Gurley in sod. “Persons found in their homes helpless or dead”. V: *New England Journal of Medicine* 334.26 (1996), str. 1710–1716.
- [13] Jiawei Han, Jian Pei in Micheline Kamber. *Data mining: concepts and techniques*. Elsevier, 2011.
- [14] Simon S Haykin in sod. *Neural networks and learning machines/Simon Haykin*. 2009.
- [15] Diederik P Kingma in Jimmy Ba. “Adam: A method for stochastic optimization”. V: *arXiv preprint arXiv:1412.6980* (2014).
- [16] Liang Liu in sod. “Automatic Fall Detection Based on Doppler Radar Motion Signature”. V: *Pervasive Computing Technologies For Healthcare (PervasiveHealth), 2011 5th International Conference On* 222 (jan. 2011), str. 222–225. DOI: 10.4108/icst.pervasivehealth.2011.245993.
- [17] Gostynski M. “Prevalence, circumstances and consequences of falls in institutionalized elderly; a pilot study”. V: *Soz Praventivmed* 6 (1991), str. 341–345.
- [18] M. J. Mathie in sod. “Classification of basic daily movements using a triaxial accelerometer”. V: *Medical & Biological Engineering & Computing* 42.5 (sep. 2004), str. 679–687. DOI: 10.1007/bf02347551. URL: <https://doi.org/10.1007/bf02347551>.
- [19] Ludovic Minvielle in sod. “Fall detection using smart floor sensor and supervised learning”. V: *Conference proceedings: ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference* 2017 (jul. 2017), str. 3445–3448. DOI: 10.1109/EMBC.2017.8037597.
- [20] Tom M Mitchell. “Generative and discriminative classifiers: Naive bayes and logistic regression”. V: *Machine learning* (2010), str. 1–17.
- [21] C. Nadee in K. Chamnongthai. “Ultrasonic array sensors for monitoring of human fall detection”. V: (2015), str. 1–4.
- [22] Hammadi Nait-Charif in Stephen Mckenna. “Activity summarisation and fall detection in a supportive home environment”. V: zv. 4. Sep. 2004, 323–326 Vol.4. ISBN: 0-7695-2128-2. DOI: 10.1109/ICPR.2004.1333768.

- [23] Michael A Nielsen. *Neural networks and deep learning*. Zv. 2018. Determination press San Francisco, CA, 2015.
- [24] Norbert Noury in sod. “A Proposal for the Classification and Evaluation of Fall Detectors”. V: *Irbm* 29 (dec. 2008), str. 340–349. DOI: [10.1016/j.irbm.2008.08.002](https://doi.org/10.1016/j.irbm.2008.08.002).
- [25] Norbert Noury in sod. “Fall detection-principles and methods”. V: *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE. 2007, str. 1663–1666.
- [26] M. Popescu in sod. “VAMPIR- an automatic fall detection system using a vertical PIR sensor array”. V: (2012), str. 163–166.
- [27] Mihail Popescu in sod. “An Acoustic Fall Detector System that Uses Sound Height Information to Reduce the False Alarm Rate”. V: *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference* 2008 (feb. 2008), str. 4628–31. DOI: [10.1109/IEMBS.2008.4650244](https://doi.org/10.1109/IEMBS.2008.4650244).
- [28] Manuel Prado-Velasco, J. Reina-Tosina in L. Roa. “Distributed intelligent architecture for falling detection and physical activity analysis in the elderly”. V: zv. 3. Nov. 2002, 1910–1911 vol.3. ISBN: 0-7803-7612-9. DOI: [10.1109/IEMBS.2002.1053088](https://doi.org/10.1109/IEMBS.2002.1053088).
- [29] Sankar Rangarajan in sod. “Design Optimization of Pressure Sensing Floor for Multimodal Human-Computer Interaction”. V: okt. 2008. ISBN: 978-953-7619-19-0. DOI: [10.5772/6305](https://doi.org/10.5772/6305).
- [30] Frank Rosenblatt. “The perceptron: a probabilistic model for information storage and organization in the brain.” V: *Psychological review* 65.6 (1958), str. 386.
- [31] Allison M Rossetto in Wenjin Zhou. “Improving Classification with CNNs using Wavelet Pooling with Nesterov-Accelerated Adam”. V: *Proceedings of 11th International Conference*. Zv. 60. 2019, str. 84–93.
- [32] Caroline Rougier, Et Recherche Opérationnelle in Jean Meunier. “Demo : Fall Detection Using 3D Head Trajectory Extracted From a Single Camera Video Sequence”. V: *International Journal* (2007), str. 2–3.
- [33] Ihab S. Mohamed. “Detection and Tracking of Pallets using a Laser Rangefinder and Machine Learning Techniques”. Doktorska disertacija. Sep. 2017. DOI: [10.13140/RG.2.2.30795.69926](https://doi.org/10.13140/RG.2.2.30795.69926).

- [34] Siv Sadigh in sod. “Falls and Fall-Related Injuries Among the Elderly: A Survey of Residential-Care Facilities in a Swedish Municipality”. V: *Journal of community health* 29 (maj 2004), str. 129–40. DOI: 10.1023/B:JOHE.0000016717.22032.03.
- [35] Arthur L Samuel. “Some studies in machine learning using the game of checkers”. V: *IBM Journal of research and development* 3.3 (1959), str. 210–229.
- [36] Ahsan Shahzad in Kiseon Kim. “FallDroid: An Automated Smart-Phone-Based Fall Detection System Using Multiple Kernel Learning”. V: *IEEE Transactions on Industrial Informatics* 15.1 (jan. 2019), str. 35–44. DOI: 10.1109/tii.2018.2839749. URL: <https://doi.org/10.1109/tii.2018.2839749>.
- [37] Future Shape. *SensFloor®*. URL: <https://future-shape.com/en/system/>. (dostopano: 21.07.2020).
- [38] Anuradha Singh in sod. “Sensor Technologies for Fall Detection Systems: A Review”. V: *IEEE Sensors Journal* 20.13 (jul. 2020), str. 6889–6919. DOI: 10.1109/jsen.2020.2976554. URL: <https://doi.org/10.1109/jsen.2020.2976554>.
- [39] Emma Stack. “Falls are unintentional: Studying simulations is a waste of faking time”. V: *Journal of Rehabilitation and Assistive Technologies Engineering* 4 (2017), str. 2055668317732945.
- [40] Axel Steinhage in Christl Lauterbach. “SensFloor® and NaviFloor®: Robotics Applications for a Large-Area Sensor System”. V: *International Journal of Intelligent Mechatronics and Robotics (IJIMR)* 3.3 (2013), str. 43–59.
- [41] M Tom. “Mitchell. Machine Learning. McGraw-Hill Science/Engineering/Math”. V: (1997).
- [42] Jernej Vičič, Michael Burnard in Aleksandar Tošić. “Privacy preserving indoor location and fall detection system”. V: (jan. 2019).
- [43] Ge Wu. “Distinguishing fall activities from normal activities by velocity characteristics”. V: *Journal of biomechanics* (2000), str. 1497–1500.
- [44] SI Yaniger. “Force sensing resistors: A review of the technology”. V: *Electro International, 1991*. IEEE. 1991, str. 666–668.
- [45] Tong Zhang in sod. “Fall Detection by Embedding an Accelerometer in Cellphone and Using KFD Algorithm”. V: *Int. J. Comput. Sci. Netw. Secur.* 6 (nov. 2005).

Priloge

A Anketa

29.07.2020

ID (-leave blank-) :

Survey for the data collection of the project
Non-intrusive fall recognition using smart floor

1. What is your gender?

- M
- F

2. What is your age?

- _____

3. Estimate your weight.

- _____ kg

4. What is your height?

- _____ cm

5. Estimate your sport activity ranging from 1 (not active) to 5 (very active).

- _____

6. Are you worried to hurt yourself during the fall test?
Ranging from: 1 (not at all) to 5 (very worried)

- _____

7. During this year have you experienced any fall event? If so, how many?

- 0 - 1 - 2 - 3 - 4 or more