

Naivni Bayes in umetna konvolucijska nevronska mreža za identifikacijo padcev s pomočjo pametnih tal

NIKI HROVATIN*

UP-FAMNIT

89182031@student.upr.si

14 avgust 2020

Povzetek

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 starosti doživi vsaj en padec letno. 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 na pomoč in padec je prepozno opažen ter oseba doživi dodatne poškodbe zaradi dodatnega časa. V prispevku bo predstavljen sistem za identifikacijo padcev osnovan na prototipu tal z vgrajenimi senzorji pritiska. Predstavili bomo celoten proces razvoja modelov strojnega učenja Naivni Bayes in umetne konvolucijske nevronske mreže, ter bodo podani rezultati.

I. UVOD

V prispevku bo predstavljen sistem za identifikacijo padcev osnovan na prototipu tal z vgrajenimi senzorji pritiska, kateri je opisan v prispevku [5]. Predstavili bomo proces zbiranja podatkov ter problematiko simulacije padcev, katera nas je obvezala po načrtovanju scenarijev simulacije padca. Sledi opis podatkov in

metod predobdelave podatkov, opisani bodo modeli strojnega učenja Naivni Bayes [1] in umetna konvolucijska nevronska mreža [3]. V zadnjem poglavju bodo opisani rezultati testiranja modelov nad testno množico in bodo podane smernice za prihodnji razvoj projekta.

II. OPIS SISTEMA

Predstavljen sistem za identifikacijo padcev je sestavljen iz dveh glavnih komponent. Kot je prikazano v sliki 1 smo ločili ti dve komponenti na programsko opremo, ki se izvaja na računalniku in tla za zaznavanje pritiska.



Slika 1: Globalna shema, ki prikazuje glavne komponente sistema.

*Niki Hrovatin UP-FAMNIT raziskovalni seminar

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 mikrokrmilnika preko analognega vhoda. Mikrokrmilnik izvaja program, ki prebere zaznano napetost na analognih vhodih in jo pretvorji v silo preko matematične formule. Vrednosti v celoštevilski obliki so pretvorjene v vrstico in so poslane preko serijskega vodila na računalnik.

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

III. PROBLEMATIKA SIMULACIJE PADCEV

Ker je padec po definiciji nenameren dogodek in v prispevku [4] 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 [4] 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 [2]. 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 na osnovi mere specifičnosti, senzitivnosti in točnosti.

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
Lateral fall to the left	Ending lying flat	Positive
Syncope	With recovery	Negative
	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 2: Scenariji za evalvacijo sistema za identifikacijo padcev. Slika iz prispevka [2].

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 2.

1. Izbrani scenariji padca

Izbrali smo sedem scenarijev simulacije padca, ki so bili predlagani v prispevku [2] in so omenjeni v sliki 2.

V naslednjem seznamu so opisani padci, ki bo vsak prostovolec izvedel, pri tem bomo nu-

dili 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 pade, 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.

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)

Za ustrezno 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.*

2. 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 [2] 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.

IV. PREDSTAVITEV PODATKOV

Podatki zajeti v procesu zbiranja podatkov opisanem v prejšnjem poglavju sestojijo iz 140 primerov padca ter vsaka registracija je sestavljena iz meritev v časovnem intervalu. Taki tip podatkov je imenovan časovna vrsta.

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

Tako strukturirani podatki so bili zajeti ob vsakem padcu, pri tem vsak padec je bil zает, kot posamezna datoteka. Vse datoteke

s podatki padca so bile nato združene v tri datoteke CSV (ang Comma Separated Values) formata, katere so dostopne na povezavi¹

V. PREDOBDELAVA PODATKOV

Ker omenjene podatkovne zbirke so osnovane na frekvenci registracije 100Hz, smo morali najprej podvzorčiti podatke na frekvenco 50Hz. Sledi postopek rotacije primerov padca na osnovi matrične rotacije, za omogočiti gradnjo modelov, kateri niso odvisni od smeri izvora padca. Podatkovne zbirke so bile nato pretvorjene v učno in testno množico, katere so posledično obdelane s eno izmed metod predobdelave podatkov med min-max normalizacijo in zaznavanje vzorca padca.

1. min-max normalizacija

Ker umetne konvolucijske nevronske mreže uporabljene za klasifikacijo časovnih vrst delujejo na osnovi tehnike premikajočega okna, 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.

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:

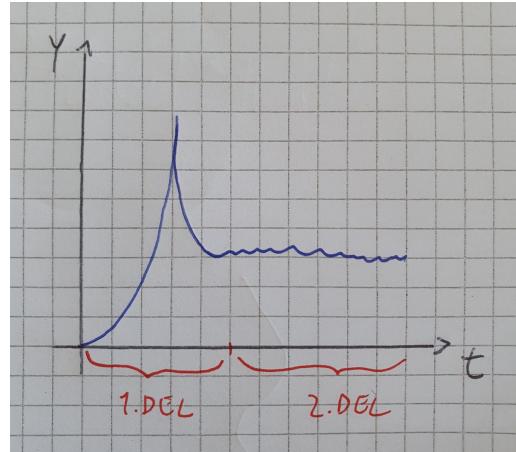
$$x'_{i,j} = \frac{x_{i,j} - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (1)$$

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 lamineata, 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

¹zenodo: <https://zenodo.org/record/3991751>

vrednost presega določeno mejo, drugače so vse vrednosti meritev v premikajočem oknu postavljene na 0.



Slika 3: Prikaz vzorca padca. Os y predstavlja vrednost senzorja in os t je časovna os.

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. Iz opazovanja smo ugotovili, da ob dogodku padca se pojavi veliko špic in vzorec, kjer vrednost senzorja, ostane visoka za določen čas. Tako smo si zamislili, da bi lahko izkoristili ta vzorec, ki se tvori ob padcu za identifikacijo padca. Omenjen vzorec je prikazan v sliki 3, 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.

VI. MODELIRANJE IN REZULTATI

V naslednjem poglavju bodo predstavljeni modeli strojnega učenja in rezultati evalvacije modelov nad testno množico.

1. Naivni Bayes

Model Naivni Bayes je bil treniran nad učno množico predobdelano s metodo za zaznavo vzorca padca in ker metoda Naivni Bayes 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. Izbrali smo mejo napovedovanja, ob 17 pozitivnih meritev v premikajočem oknu sestavljenem iz 100 meritev.

Ob testiranju metode Naivni Bayes nad testno množico smo dosegli naslednje rezultate: *točnost: 77.4%, specifičnost: 65.2% in senzitivnost: 95%*.

2. Konvolucijska nevronska mreža

Pri razvoju sistema za identifikacijo padcev smo poskusili implementirati model konvolucijske nevronske mreže. Sestavljena nevronska mreža ima vhodni 2D konvolucijski 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, 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 vsakim konvolucijskim slojem in slojem nevronov je vključen tudi sloj za regularizacijo preko izpuščanja in preko vključitve teh slojev želimo preprečiti prekomerno prileganje podatkom (ang. overfitting).

Konvolucijska nevronska mreža trenirana nad učno množico predobdelano s metodo za zaznavanje vzorca padca je bila testirana nad testno množico in je dosegla naslednje rezultate: *točnost: 89.2%, specifičnost: 93% in senzitivnost: 83.7%*.

Konvolucijska nevronska mreža trenirana nad učno množico predobdelano s metodo min-max normalizacije je bila testirana nad testno množico in je dosegla naslednje rezultate: *točnost: 89.2%, specifičnost: 93% in senzitivnost: 83.7%*.

VII. ZAKLJUČEK

V prispevku je bila predstavljena uporaba metod Naivni Bayes in konvolucijske nevronske mreže pri klasifikaciji padcev na osnovi pametnih tal. Najprej je bil opisan sistem nato smo predstavili proces zbiranja podatkov in problem simulacije padcev. Sledi opis podatkov in postopkov predobdelave ter opis modelov strojnega učenja, ki so bili trenirani nad učno množico in testirani nad testno množico.

Iz rezultatov smo opazili, da model Naivni Bayes se 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 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 metodo min-max normalizacije. Rezultati so dokazali pravilno klasifikacijo 95.3% primerov testne množice, pri tem je tudi senzitivnost mo-

dela 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. Menimo, da 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.

LITERATURA

- [1] 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. *Philosophical transactions of the Royal Society of London*, (53):370–418, 1763.
- [2] Norbert Noury, Anthony Fleury, Pierre Rumeau, AK Bourke, GO Laighin, Vincent Riaille, and JE Lundy. Fall detection-principles and methods. In *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 1663–1666. IEEE, 2007.
- [3] Frank Rosenblatt. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6):386, 1958.
- [4] Emma Stack. Falls are unintentional: Studying simulations is a waste of faking time. *Journal of Rehabilitation and Assistive Technologies Engineering*, 4:2055668317732945, 2017.
- [5] Jernej Vičič, Michael Burnard, and Aleksandar Tošić. Privacy preserving indoor location and fall detection system. 01 2019.