

## ZNAČILKE PRI RAZPOZNAVANJU AKTIVNOSTI DNEVNEGA ŽIVLJENJA V PAMETNIH DOMOVH

DRAŽEN BAKETARIĆ<sup>1</sup>, GREGOR DONAJ<sup>2</sup> IN  
MIRJAM SEPESY MAUČEC<sup>3</sup>

**Sprejeto**

6. 2. 2024

**Recenzirano**

9. 10. 2024

**Izdano**

23. 12. 2024

<sup>1</sup> Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Maribor, Slovenija

[baketaric.drazen@student.um.si](mailto:baketaric.drazen@student.um.si)

<sup>2</sup> Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Maribor, Slovenija

[gregor.donaj@um.si](mailto:gregor.donaj@um.si)

<sup>3</sup> Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Maribor, Slovenija

[mirjam.sepesy@um.si](mailto:mirjam.sepesy@um.si)

## DOPISNI AVTOR

[mirjam.sepesy@um.si](mailto:mirjam.sepesy@um.si)

**Znanstvena veda:**

Tehnika

**Ključne besede:**

senzor,  
aktivnost,  
razpoznavanje  
aktivnosti,  
strojno  
učenje,  
klasifikacija

Slovenija se kot večina razvitih držav sooča s staranjem prebivalstva. Poraja se vprašanje, kako starostnikom zagotoviti varno bivanje v domačem okolju. Tehnološki razvoj na področju senzorskih tehnologij, strojnega učenja in umetne inteligence lahko prispeva k doseganju tega cilja. Sistemi za zaznavanje aktivnosti dnevnega življenja z visoko točnostjo razpoznavajo aktivnosti stanovalcev pametnih domov. Posledično lahko zaznajo motnje pri vsakodnevnem delovanju starostnika, kar lahko kaže na zdravstvene težave. Tovrstni sistemi temeljijo na senzorskih omrežjih in na podlagi aktivacije različnih senzorjev razpoznavajo aktivnosti stanovalcev. Točnost razpoznavanja aktivnosti je odvisna predvsem od kakovosti značilk, ki jih sestavimo iz senzorskih podatkov, in algoritma oz. modela za klasifikacijo, ki ga iz podatkov zgradimo v fazi učenja. V raziskavi se osredotočamo predvsem na izbiranje in izločanje značilk ter proučujemo kako le-to vpliva na končni rezultat razpoznavanja aktivnosti. Analiziramo, pri katerih aktivnostih je točnost razpoznavanja najboljša in pri katerih najslabša. Pri slednjih prikazemo tudi, s katerimi aktivnostmi le-te najpogosteje zamenjujemo.



<https://doi.org/10.18690/analipazu.14.2.1-21.2024>  
Besedilo © Baketarić, Donaj in Sepesy Maučec 2024



## FEATURES IN RECOGNIZING ACTIVITIES OF DAILY LIFE IN SMART HOMES

DRAŽEN BAKETARIĆ<sup>1</sup>, GREGOR DONAJ<sup>2</sup> AND  
MIRJAM SEPEŠY MAUČEČ<sup>3</sup>

<sup>1</sup> University of Maribor, Faculty of Electrical Engineering and Computer Science,  
Maribor, Slovenia  
[baketaric.drazen@student.um.si](mailto:baketaric.drazen@student.um.si)

<sup>2</sup> University of Maribor, Faculty of Electrical Engineering and Computer Science,  
Maribor, Slovenia  
[gregor.donaj@um.si](mailto:gregor.donaj@um.si)

<sup>3</sup> University of Maribor, Faculty of Electrical Engineering and Computer Science,  
Maribor, Slovenia  
[mirjam.sepesy@um.si](mailto:mirjam.sepesy@um.si)

CORRESPONDING AUTHOR  
[mirjam.sepesy@um.si](mailto:mirjam.sepesy@um.si)

The question arises of how to ensure a safe stay for the elderly in their home environment. Development in sensor technology, machine learning, and artificial intelligence can contribute to achieving this goal. Activities of daily life recognition systems recognize the activities of residents in smart homes with high accuracy. They can consequently detect anomalies in the daily functioning of the elderly, which may indicate health problems. Systems of this type are based on sensor networks and recognize the activities of residents based on the activation of various sensors. The accuracy of activity recognition depends primarily on the quality of the features that are compiled from sensor data and the classification model, which is built from the collection of data in the learning phase. In the presented research, we mainly focus on selecting and extracting features and studying how different features affect the final result of activity recognition. We analyze which activities have the best and which have the worst recognition accuracy. In the latter's case, we also show which activities are most often misidentified.

Accepted  
6. 2. 2024

Revised  
9. 10. 2024

Published  
23. 12. 2024

Science:  
Technique

Keywords:  
sensor,  
activity,  
activity  
recognition,  
machine  
learning,  
classification

## 1 Uvod

Ljudje po vsem svetu živijo dlje. Danes lahko večina ljudi pričakuje, da bo živela več kot 60 let. Napovedi kažejo, da se bo do leta 2050 svetovna populacija ljudi, starih 60 let in več, podvojila<sup>1</sup>. Glede na projekcije Združenih narodov je Slovenija uvrščena med deset najstarejših držav na svetu. Danes je v Sloveniji vsak peti prebivalec starejši od 65 let. Če se bo takšna dinamika nadaljevala, bo delež starejših od 65 let leta 2030 predstavljal 25 odstotkov prebivalstva, do leta 2050 pa bo vsak tretji prebivalec Slovenije starejši od 65 let (Kajzer, 2023). V teh razmerah je 2017 Urad RS za makroekonomske analize in razvoj pripravil, Vlada RS pa sprejela Strategijo dolgožive družbe, katere cilj je tudi blaginja vseh generacij ter dostojno in varno bivanje v domačem okolju z upoštevanjem visoke ravni človeških pravic.

Staranje je fiziološki proces, ki ga ne moremo preprečiti, lahko si pa prizadevamo za njegovo kakovost. Kakovost življenja je v pretežni meri odvisna od duševnih in telesnih funkcij, ki jih oseba zmore, lahko pa jih poslabšujejo različne s starostjo povezane bolezni, ki se odražajo tudi kot nezmožnosti opravljanja vsakodnevnih opravil kot so umivanje, oblačenje, kuhanje, pospravljanje ipd. Starostnik, pri katerem zaznamo odstopanja od ustaljenih časovnih okvirjev opravljanja vsakodnevnih aktivnosti, morda potrebuje pomoč oziroma določen nivo oskrbe na domu. Lahko so to tudi znaki določenih bolezni.

Danes je na voljo široka paleta pripomočkov, ki so lahko starostnikom v pomoč: ogrlice z gumbom za klic v sili, mobilni telefoni s senzorji padca in samodejno obveščanje služb za nujno pomoč ipd. To so večinoma zaprti, samostojni sistemi, s katerimi imajo starostniki pogosto težave, saj jih ne znajo uporabljati ali pa v kritičnih situacijah nanje pozabijo.

Sistemi za razpoznavanje aktivnosti dnevnega življenja (angl. ADL – Activity of Daily Living) so sistemi, s katerimi starostniki niso v neposredni interakciji, ampak so del okolja oz. so nameščeni v njihovih domovih. Zahvaljujoč napredku na področju senzorske tehnologije, strojnega učenja in umetne inteligence z relativno visoko točnostjo razpoznavajo aktivnosti, ki jih opravljajo stanovalci v domačem okolju. Cilj teh sistemov je omogočiti starejšim ljudem, da živijo dlje v domačem

---

<sup>1</sup> <https://www.who.int/health-topics/ageing>

okolju, so samostojni, imajo visok nivo kakovosti življenja in nenazadnje zmanjšujejo stroške družbe in zdravstvenih sistemov. Avtomatizirano spremljanje dnevne rutine starejših oseb, zaznavanje vzorcev vedenja in odkrivanje odstopanj so lahko zgodnji kazalci klica na pomoč (Sepesy Maučec & Donaj, 2021).

Glavni komponenti ADL sistemov sta senzorsko omrežje in algoritem razpoznavanja aktivnosti iz senzorskih podatkov. V raziskavi, ki jo predstavljamo v članku, smo uporabili javno dostopne zbirke podatkov, zato se s senzorskim omrežjem nismo ukvarjali in ga v članku samo na kratko predstavimo. Poudarek članka je na algoritmu za razpoznavanja aktivnosti, predvsem na študiju značilk, iz katerih se algoritem nauči razpoznati aktivnost. Raziskava, ki jo v nadaljevanju podrobneje predstavljamo, je bila v skrajšani obliki predstavljena na Mednarodni elektrotehniški in računalniški konferenci ERK (Baketarić idr., 2023).

Poglavje 2 vsebuje pregled sorodnih del. V poglavju 3 predstavimo posamezne korake gradnje ADL sistema. Poglavje 4 je posvečeno izločanju značilk. Primerjali smo dva tipa značilk pri dveh različnih algoritmih za razpoznavanje aktivnosti. V poglavju 5 so opisani eksperimenti in v poglavju 6 zaključek.

## 2 Sorodna dela

Razpoznavanje aktivnosti dnevnega življenja je intenzivno raziskovana tema zadnjih dvajset let (Hussain idr., 2019). Definiramo ga kot zmožnost zaznavanja trenutne aktivnosti uporabnika/stanovalca na osnovi prejetih informacij iz različnih senzorjev. Senzorji so lahko kamere, nosljivi senzorji in senzorji, pritrjeni na vsakodnevne predmete ali nameščeni v okolju. (Wang & Zhou, 2015). Pristopi, ki temeljijo na računalniškem vidu ali tehnologijah nosljivih senzorjev, odpirajo več pomembnih vprašanj, kot so zasebnost (npr. uporaba video kamere za spremljanje starejših doma) in praktičnost (npr. starejša osebo z demenco pozabi nositi napravo). Iz teh razlogov pridobivajo na popularnosti pristopi, ki temeljijo na senzorjih, nameščenih v okolju (Yao idr., 2017). Različne aktivnosti stanovalcev prožijo različne senzorje. Iz vzorčenja senzorjev nastajajo časovne vrste, iz katerih izluščimo vektorje značilk za posamezne aktivnosti. Wang in drugi (2021) so raziskovali učinkovitost različnih kodiranj značilk v povezavi z različnimi algoritmi razpoznavanja aktivnosti. Razpoznavanje aktivnosti lahko na področju strojnega učenja formuliramo kot klasifikacijo. Klasifikacija lahko temelji na določanju

podobnosti med novim vektorjem značilke in centriidi vektorjev značilke, ki pripadajo določeni aktivnosti. Novemu vektorju značilke pripišemo aktivnost najbližjega centroida. Tovrstni klasifikatorji izhajajo iz predpostavke, da so vektorji značilke, ki pripadajo isti aktivnosti porazdeljeni okrog centroida in dovolj oddaljeni od centroidov ostalih aktivnosti. Za določanje podobnosti se pogosto uporablja Evklidska ali Mahalanobisova razdalja (La Cava idr., 2019). Pri klasifikatorju k-najbližjih sosedov (angl. KNN – K-Nearest Neighbors) so uporabili Manhattanovo razdaljo (Al-Taei idr., 2021). Uveljavili so se tudi pristopi, ki temeljijo na verjetnostnih modelih. Kabir in drugi (2016) so uporabili prikriti modele Markova (angl. HMM – Hidden Markov Models) z dvema slojema. Donaj in Maučec (2019) sta HMM nadgradila z Markovskimi verigami aktivnosti in stroškovno funkcijo prehoda iz ene aktivnosti v drugo. Pogosto uporabljeni so tudi podporni vektorji (angl. SVM – Support Vector Machines), ki so v osnovi binarni klasifikatorji, a jih lahko uporabimo tudi za večrazredno klasifikacijo, tako da problem razdelimo v več binarnih klasifikacijskih problemov (Fleury idr., 2009). Pristop SVM temelji na konstrukciji hiperravnine, ki ima največjo razdaljo do najbližjih vektorjev značilke. Ker pogosto vektorji značilke niso linearno ločljivi, se pristop SVM uporablja na majhnih množicah podatkov. V zadnjem času pa se je najbolj razširila uporaba nevronske mreže. Nevronske mreže z dolgim kratkoročnim spominom (angl. LSTM – Long Short-Term Memory) so nevronske mreže s povratno zanko (angl. RNN – Recurrent Neural Network), ki so se izkazale kot učinkovite pri modeliranju časovnih vrst in odvisnosti na velikih razdaljah. Časovne odvisnosti modelirajo preko povratnih povezav v skritih plasteh. Konvolucijske nevronske mreže (angl. CNN – Convolutional Neural Network) uspešno modelirajo časovne in prostorske odvisnosti na majhnih in velikih razdaljah. Omogočajo gradnjo modelov, ki so neodvisni od merila. Pri razpoznavanju aktivnosti to pomeni, da so modeli aktivnosti gibanja neodvisni od hitrosti gibanja stanovalca. Wang in drugi (2021) so pokazali, da enodimenzionalne CNN uspešno posplošujejo čez različne scenarije. Tudi pri razpoznavanju aktivnosti so bili uporabljeni hibridni modeli, ki kombinirajo dva ali več pristopov, na primer HMM in nevronske mreže ali SVM (Ordóñez idr., 2013) ali CNN in SVM (Athavale idr., 2021).

Kako dober je klasifikacijski model je v veliki meri odvisno od načina, kako zgradimo vektorje značilke iz podatkov senzorjev. Wang in drugi (2021) so to pokazali pri modelih plitvega in globokega učenja. Pokazali so tudi problem nultega razreda (ko

stanovalec ne opravlja nobene aktivnosti), ki v veliki meri negativno vpliva na rezultat skupne natančnosti pristopa.

### 3 Sistem za ADL razpoznavanje

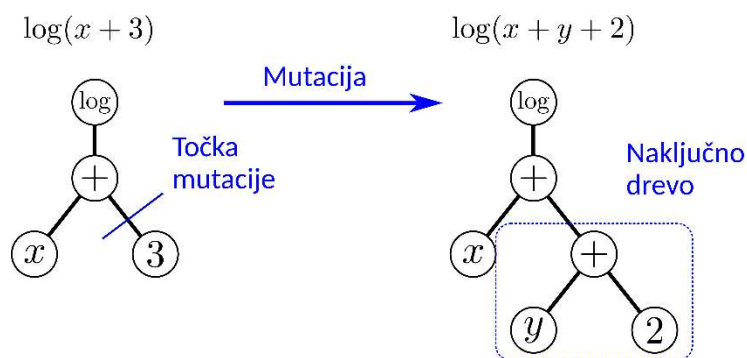
Gradnjo sistema za ADL razpoznavanje sestavljajo naslednje faze: 1. zbiranje podatkov, 2. predprocesiranje podatkov, 3. izbiranje in izločanje značilk, 4. učenje klasifikacijskega modela in 5. vrednotenje rezultatov. Zbiranje podatkov je časovno zahteven proces, povezan z visokimi stroški. Za raziskovalne namene se je uveljavila uporaba javno dostopnih zbirk podatkov, ki vsebujejo surove senzorske podatke, zbrane v daljšem časovnem obdobju (De-La-Hoz-Franco idr., 2018). Podatkom so običajno dodane označene aktivnosti. V fazi predprocesiranja v podatkih odkrivamo napake in morebitne manjkajoče vrednosti. Podatke uredimo za proces izločanja značilk, v katerem jih transformiramo v prostor manjših dimenzij. Izbiranje značilk je proces, v katerem izberemo tiste značilke, ki nosijo informacijo o aktivnostih stanovalca, oz. izločimo tiste, ki vnašajo motnje oz. šum. Izločanje značilk je zelo pomembna faza v razvoju sistema, saj neposredno vpliva na učinkovitost razpoznavanja aktivnosti, hkrati pa zmanjša časovno in prostorsko zahtevnost celotnega postopka. V nadaljevanju članka predstavimo primerjavo učinkovitosti uporabe značilk, ki jih tvorimo neposredno iz vhodnih podatkov, in značilk, ki jih tvorimo s transformacijo vhodnih podatkov, ki temelji na genetskem programiranju. Izločanju značilk sledi učenje klasifikacijskega algoritma. Obstaja širok spekter klasifikacijskih algoritmov. Nekaj smo jih predstavili v prejšnjem poglavju. Vsem je skupno, da iz odčitanih podatkov senzorjev v nekem trenutku in morebiti tudi krajše zgodovine le-teh razpoznajo aktivnost, ki jo opravlja stanovalec. Pred postavitvijo sistema v realno okolje opravimo validacijo, v kateri iz senzorskih podatkov, ki smo jih izločili iz zbirke podatkov za namene testiranja, razpoznavamo aktivnosti in jih primerjamo z dejanskimi oz. označenimi aktivnostmi.

V raziskavi nas zanimajo predvsem značilke, ki jih tvorimo s pomočjo genetskega programiranja, zato v nadaljevanju predstavimo njegove teoretične osnove.

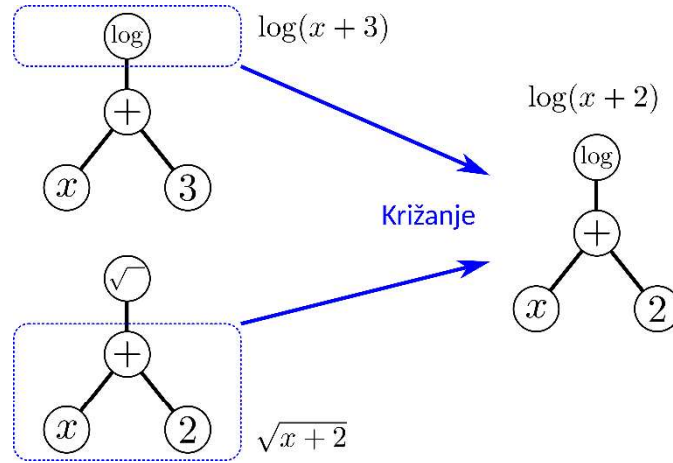
## 4 Genetsko programiranje

### 4.1 Osnovni algoritem

Genetsko programiranje (GP) je v zgodnjih devetdesetih definiriral John Koza (Koza, 1993) kot razširjena oblika genetskega algoritma. Sodi v skupino evolucijskih algoritmov. Populacijo sestavlja množica računalniških programov, ki so lahko tudi matematične enačbe. Začetno populacijo tvorijo naključno tvorjene enačbe. Algoritem posameznike začetne populacije najprej ovrednoti s funkcijo ustreznosti (angl. fitness function). Nato po izbrani verjetnostni porazdelitvi glede na vrednost funkcije ustreznosti izbere enega ali dva posameznika, nad katerima izvede genetske operacije in tako ustvari novega posameznika za novo populacijo. Postopek se iterativno ponavlja dokler ni izpolnjen ustavitveni pogoj. Ker izbira staršev temelji na vrednosti funkcije ustreznosti, velja da imajo boljši posamezniki več potomcev. Običajno se v vsaki generaciji zamenja celotna populacija. Posameznike lahko predstavimo z drevesno strukturo, v kateri notranja vozlišča predstavljajo operatorje, terminalni simboli ali listi drevesa pa operande, ki so lahko spremenljivke ali konstante. Genetske operacije se vršijo nad poddrevesi v strukturi. Osnovni genetski operaciji sta mutacija (angl. mutation) in križanje (angl. crossover). Pri mutaciji (slika 1) se naključno izbrano poddrevo (glej točko mutacije) zamenja z naključno generiranim drevesom. Pri križanju (slika 2) se naključno izbrano poddrevo enega starša nadomesti z naključno izbranim poddrevesom drugega starša.



Slika 1: Mutacija pri genetskem programiranju



Slika 2: Križanje pri genetskem programiranju

Pred uporabo genetskega programiranja je potrebno določiti množico terminalnih simbolov, množico operatorjev oz. funkcij, funkcijo ustreznosti, nastavitve kontrolnih parametrov in ustavitveni pogoj.

#### 4.2 Izločanje značilk

V procesu izločanja značilk želimo iz senzorskih podatkov tvoriti informativne značilke, hkrati pa tudi zmanjšati dimenzijo vektorja značilk. S pomočjo genetskega programiranja  $N$ -dimenzionalni vektor senzorskih podatkov  $s = (s_1, s_2, \dots, s_i, \dots, s_N)$  transformiramo v  $M$ -dimenzionalni vektor matematičnih enačb  $x = (x_1, x_2, \dots, x_i, \dots, x_M)$ .  $s_i$  označuje  $i$ -ti senzor,  $x_i$  pa  $i$ -to enačbo. Spremenljivke, ki nastopajo v enačbah, so senzorstvi, zato je množica terminalnih simbolov v drevesnih strukturah definirana kot:

$$T = \{s_i; i = 1, \dots, N\} \cup \mathbb{R}, \quad (1)$$

kjer razen spremenljivk nastopajo tudi konstantne vrednosti. Kot operacije v matematičnih enačbah smo uporabili:

$$F = \{+, -, \cdot, /, \sin x, \cos x, \log x, \sqrt{x}, x^2, x^3, e^x\} \quad (2)$$



Funkcijo ustreznosti je bila točnost klasifikacije. V nadaljevanju vektorje enačb imenujemo vektorji značilk.

## 5 Klasifikacijski algoritmi

Razpoznavanje aktivnosti definiramo kot klasifikacijski problem, pri katerem vektor značilk  $x$  klasificiramo v razred  $c_j$ , ki predstavlja aktivnost.

$$\hat{y}(x) = c_j; \quad c_j \in C = \{c_1, c_2, \dots, c_k\} \quad (3)$$

$\hat{y}$  je klasifikacijska funkcija in  $C$  množica razredov oz. aktivnosti. V raziskavi smo se omejili na uporabo dveh klasifikacijskih algoritmov, ki so tudi v literaturi najpogosteje citirani.

### 5.1 Podporni vektorji

Podporni vektorji (SVM) so v osnovi namenjeni binarni klasifikaciji, zato večrazredno klasifikacijo pretvorimo v več binarnih klasifikacij "eden-proti-preostalim" in iščemo klasifikatorje. Klasifikator SVM si lahko geometrijsko predstavljamo kot hiperravnino ki razmejuje primerke enega razreda od primerkov drugega razreda. Če številka vrednost  $+1$  predstavlja en razred in  $-1$  drugi razred, iščemo hiperravnino  $w \cdot x - b = 0$ , pri kateri je  $w$  vektor uteži enake dimenzije, kot je dimenzija vektorja značilk  $x$ .  $b$  je konstanta. Novi vzorec  $x'$  klasificiramo tako, da izračunamo:

$$\hat{y}(x') = \text{sign}(w \cdot x - b) \quad (4)$$

$\text{sign}$  operator vrne  $+1$ , če je argument pozitivno število in  $-1$ , če je negativno.

### 5.2 Nevronske mreže z dolgim kratkoročnim spominom

V splošnem je nevronska mreža sestavljena iz slojev, vsak sloj pa iz celic. Razen vhodnega in izhodnega sloja ima tudi enega ali več skritih slojev. Učenje nevronske mreže s skritimi sloji imenujemo globoko učenje (angl. deep learning). Nevronske mreže z dolgim kratkoročnim spominom (LSTM) sodijo v skupino nevronske mreže

s povratno zanko. To pomeni, da izhodne vrednosti celic kasnejših slojev vplivajo na posodobitve vrednosti v celicah predhodnih slojev. LSTM vpeljuje mehanizem vrat, ki določa ali se bo vrednost neke celice pretočila naprej ali ne. Z vsakim vhodnim vektorjem značilnik se osveži skrito stanje na osnovi funkcije vhodnih vrat, izhodnih vrat in vrat pozabe ter aktivacijske funkcije celice. Matematična formulacija dogajanja pri klasifikaciji z LSTM je v (Wang idr., 2021). V (Liciotti idr., 2020) pa je podrobneje opisana uporaba LSTM pri razpoznavanju aktivnosti dnevnega življenja.

## 6 Eksperimenti

### 6.1 Podatkovne zbirke

Eksperimenti so bili izvedeni s podatki iz javno dostopne zbirke CASAS (Szewczyk idr., 2009; Cook, 2010), ki je tudi v literaturi pogosto citirana. Izbrali smo pet zbirke podatkov: Milan, Cairo, Kyoto7, 8 in 11. Zbirke CASAS smo uporabili zato, ker okoljski senzorji ne posegajo v zasebnost stanovalcev. Zapisovalni format v vseh zbirkah je enak in enostavno razumljiv. Zbirke vsebujejo tisoče dogodkov senzorjev (podatkovnih točk), ki vsebujejo časovni žig, ime senzorja, vrednost odčitka senzorja (binarna ali številčna) in na ustreznih mestih oznake začetka ali konca aktivnosti. Tabela 1 prikazuje število stanovalcev v stanovanju za vsako zbirko podatkov, število opazovanih dni in uporabljene senzorje, ki generirajo dogodke senzorjev. Uporabljeni senzorji so naslednji: gibanje (M, vklop/izklop), temperatura (T, številčna), vrata (D, odprto/zaprto), predmet (I, prisoten/odsoten), poraba energije (P, številčna), gorilnik ter senzorja za vročo in hladno vodo (AD1-A, B in C, številčna). Stanovalce v zbirkah Milan in Cairo so občasno obiskovali prijatelji in sorodniki.

Zbirka podatkov Kyoto7 vsebuje tri datoteke z neobdelanimi podatki, in med njimi smo se odločili uporabiti datoteko "data" za bolj dosledno primerjavo z drugimi deli<sup>23</sup>, ki zagotavljajo javno dostopno kodo. Poudariti velja, da izbrana datoteka ne vsebuje podatkov za senzor porabe energije (P), zato nekatere aktivnosti, povezane s porabo energije, morda niso bile pravilno razpoznane. V navedenih delih so bile ugotovljene tudi nekatere nepravilnosti, na primer napačno število stanovalcev za zbirki podatkov Kyoto8 in 11.

---

<sup>2</sup> <https://github.com/danielelic/deep-casas>

<sup>3</sup> [https://github.com/funweb/HAR\\_WCNN](https://github.com/funweb/HAR_WCNN)

Tabela 1: Podatkovne zbirke, uporabljene v eksperimentih

	Štev. stanovalcev	Velikost (štev. dni)	Tipi senzorjev
Cairo	2+pes	57	M, T
Kyoto7	1+ hišni ljubljencek	72	M, D, T
Kyoto8	2	46	M, D, I, AD1-A, B, C
Kyoto11	2	62	M, D, I, T, P
Milan	2	232	M, D, I, T, P

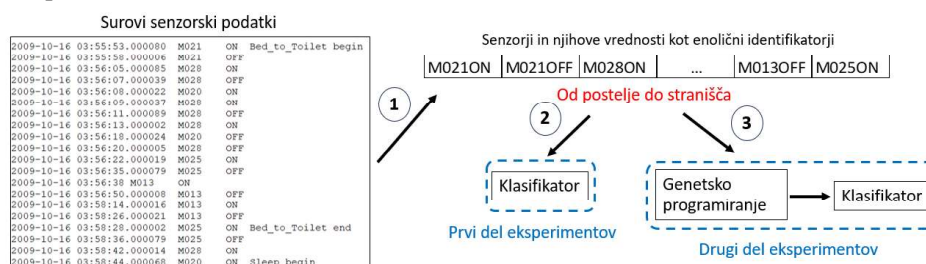
## 6.2 Predprocesiranje podatkov

V eksperimentih smo uporabili predprocesirane zbirke podatkov iz (Liciotti idr., 2020). V teh zbirkah podatkov so ohranjeni samo dogodki treh senzorjev: M, T in D. Natančneje, senzori M, T in D so bili uporabljeni v zbirkah Milan, Kyoto8 in 11, v Kairu sta bila uporabljena samo senzorja M in T, v Kyoto7 pa senzorja M in D. Avtorji v (Li idr., 2023) predlagajo metodo, s katero ugotovimo kateri senzorji se najbolj povezujejo z določenimi aktivnostmi. Na primer, ugotovili so, da senzori AD1-A, B in C v zbirkah podatkov Kyoto7 prispevajo veliko k aktivnosti Kuhanje, medtem ko senzor P v zbirkah podatkov Kyoto8 in 11 pomembno prispeva k nekaterim drugim aktivnostim. Ker ti senzori niso bili uporabljeni v eksperimentih v (Liciotti idr., 2020), jih tudi v tej raziskavi ne bomo uporabili, da zagotovimo nepristransko primerjavo.

Čeprav vsebuje vsaka zbirka podatkov veliko različnih aktivnosti, smo se zaradi skladnosti s sorodnimi raziskavami omejili le na enajst najpogostejših: *Osebna higiena*, *Spanje*, *Od postelje do stranišča*, *Prebranjevanje*, *Kuhanje*, *Delo*, *Odbod od doma*, *Vrnitev domov*, *Sprostitev*, *Jemanje zdravil* in *Kopanje*. Aktivnosti v zbirkah podatkov so zelo neuravnotežene, zato smo za omilitev tega problema v eksperimentih uporabili funkcijo "izračunaj utež razreda" iz knjižnice scikit-learn. V predprocesiranih podatkih ni ohranjena časovna informacija.

### 6.3 Izločanje značilnk

Eksperimente smo izvedli v dveh delih, ki jih prikazuje Slika 3. V prvem smo predprocesirane senzorske podatke neposredno pretvorili v vektorje značilnk, torej smo opravili koraka 1 in 2. V drugem delu eksperimentov smo vektorje senzorskih podatkov s pomočjo genetskega programiranja transformirali v matematične enačbe in opravili koraka 1 in 3.



Slika 3: Metodologija v izvedenih eksperimentih.

Pri tem smo uporabili naslednje vrednosti hiperparametrov. Velikost populacije (angl. population size) smo omejili na 1000, velikost turnirja (angl. tournament size) na 50 in število generacij na 200. Razmerje med križanjem in mutacijo je bilo 80:20. Velikost programa oz. matematične enačbe je bila na intervalu med 5 in 200. Funkcijo ustreznosti je bila točnost klasifikacije.

### 6.4 Klasifikacija

V raziskavi smo se omejili na uporabo dveh klasifikatorjev, ki smo jih predstavili v poglavju 5 in so tudi v literaturi najpogosteje uporabljeni. Pri klasifikatorju SVM smo za reševanje problema linearne nerazločljivosti uporabili radialno bazno funkcijo (angl. Radial Basis Function) jedro s  $C=10$  in skalirano vrednostjo  $\gamma$ . Večrazredno klasifikacijo smo izvedli s pristopom "eden-proti-preostalom". Število epoh pri klasifikatorju LSTM je bilo omejeno na 200, velikost paketa pa na 64.

### 6.5 Rezultati

Vsi rezultati se nanašajo na povprečje rezultatov prečnega preverjanja s tremi ponovitvami (angl. 3-fold cross validation). Za vsako ponovitev smo dve tretjini podatkov uporabili za učenje modela, eno tretjino pa za testiranje. Na ta način smo

zagotovili, da se učna in testna množica ne prekrivata. Razen tega smo v vsakem eksperimentu 20 % podatkov iz učne množice uporabili za sprotno validacijo. Glede na to, da so bili najslabši rezultati dobljeni na učni množici Kyoto7 (Liciotti et al., 2020), so bili hiperparametri GP optimizirani na tej učni množici. Enaki hiperparametri so bili nato uporabljeni pri vseh drugih učnih množicah. Pri klasifikaciji se isti klasifikator uporablja za v procesu učenja in testiranja.

Tabela 2 prikazuje točnosti (angl. accuracy) razpoznavanja aktivnosti v posameznih eksperimentih. Točnost smo izračunali po formuli:

$$accuracy = \frac{t}{n} \cdot 100 [\%], \quad (5)$$

pri čemer  $t$  označuje število pravilno razpoznanih aktivnosti,  $n$  pa število vseh aktivnosti.

Tabela 2: Točnost klasifikacije. Boljši rezultat je izpisan poudarjeno.

	SVM	GP+SVM	LSTM	GP+LSTM
Cairo	67,5	<b>73,6</b>	<b>83,8</b>	59,9
Kyoto7	51,6	<b>54,0</b>	<b>69,8</b>	56,5
Kyoto8	60,2	<b>84,3</b>	<b>88,7</b>	60,1
Kyoto11	<b>57,7</b>	55,6	<b>85,6</b>	47,9
Milan	54,7	<b>76,3</b>	<b>93,4</b>	60,6

V eksperimentih nas ni zanimalo, kateri klasifikator je učinkovitejši, ampak predvsem, katere značilke so primernejše v kombinaciji z izbranim klasifikatorjem. Pri klasifikatorju s podpornimi vektorji (SVM) smo z dodanim genetskim programiranjem dosegli pomembno izboljšanje (GP+SVM). Izjema je le najboljše zbirka podatkovna zbirka Kyoto11. Klasifikacija z LSTM je v vseh eksperimentih izrazito boljša, če uporabimo le predprocesirane senzorske podatke, ki jih ne transformiramo s pomočjo GP. Domnevamo, da smo s transformacijo izgubili za LSTM pomembne informacije. Sklep na osnovi vseh izvedenih eksperimentov je, da je učinkovitost transformiranih značilk odvisna tako od klasifikatorja kakor tudi od zbirke podatkov, predvsem njene velikosti.

Pri klasifikatorju SVM, kjer se je GP izkazalo kot učinkovito, nas je zanimalo, katere aktivnosti so napačno razpoznane oz. s katerimi jih klasifikator najpogosteje zamenjuje. Sliki 4 in 5 prikazujeta matriki zamenjav v eksperimentih s podatkovno zbirko Kyoto7, sliki 6 in 7 pa pri eksperimentih s podatkovno zbirko Kyoto11.

Vrednosti v matrikah so izražene v %. V matrikah smo zaradi lažje predstavitve aktivnost *Od postelje do stranišča* preimenovali v *Postelja->WC*.

	Postelja -> WC	Sprostitev	Delo	Kuhanje	Spanje	Osebna higiena	Drugo
Postelja -> WC	37,0	2,8	0,0	11,0	1,4	17,8	30,1
Sprostitev	3,4	3,4	10,3	27,6	17,3	10,3	27,6
Delo	0,9	2,9	50,5	17,1	6,7	4,8	17,1
Kuhanje	3,9	2,0	3,9	66,7	5,9	3,9	13,7
Spanje	2,9	0,0	8,6	12,9	51,4	5,7	18,6
Osebna higiena	18,3	4,9	2,5	8,5	2,5	57,3	6,1
Drugo	3,3	1,0	8,6	10,0	6,2	4,8	66,2

Slika 4: Matrika zamenjav klasifikatorja SVM pri zbirki podatkov Kyoto7. Vrstice predstavljajo dejanske aktivnosti, stolpci pa razpoznane aktivnosti.

	Postelja -> WC	Sprostitev	Delo	Kuhanje	Spanje	Osebna higiena	Drugo
Postelja -> WC	68,5	0,0	0,0	0,0	0,0	2,8	28,8
Sprostitev	6,9	0,0	41,4	3,4	6,9	24,1	17,3
Delo	9,5	0,0	40,9	0,9	6,7	20,0	21,9
Kuhanje	3,9	0,0	3,9	52,9	1,0	8,8	29,4
Spanje	8,6	0,0	32,9	1,4	30,0	14,3	12,9
Osebna higiena	31,7	0,0	15,8	1,2	0,0	43,9	7,3
Drugo	9,5	0,0	9,5	4,8	1,4	6,2	68,6

Slika 5: Matrika zamenjav klasifikatorja GP+SVM pri zbirki podatkov Kyoto7. Vrstice predstavljajo dejanske aktivnosti, stolpci pa razpoznane aktivnosti.

Pri zbirki Kyoto7 smo razlikovali 6 dejanskih aktivnosti in aktivnost *Drugo*, v katero se preslikajo preostale aktivnosti. Klasifikator z osnovnimi značilkami dosega največjo točnost pri aktivnosti *Kuhanje* in nekoliko manjšo pri aktivnosti *Osebna higiena*. Najmanjšo točnost ima pri aktivnosti *Sprostitev*. Druga najslabše razpoznana aktivnost je *Postelja->WC*, ki pa postane najboljše razpoznana aktivnost ob vpeljavi GP. Točnost vseh aktivnosti se z vpeljavo GP izboljša, razen pri aktivnosti *Kuhanje*, kjer točnost pade za 13,8 % absolutno. Vidimo tudi, da klasifikator GP+SVM ne ločuje med aktivnostjo *Delo* in *Sprostitev*. Aktivnost *Sprostitev* ni nikoli razpoznana.

	Postelja -> WC	Odhod od doma	Spanje	Drugo	Vrnitev domov	Kopanje	Prehranjevanje	Kuhanje	Osebna higiena	Delo	Sprostitev
Postelja -> WC	0,0	0,0	0,0	52,5	0,0	0,0	0,0	0,0	27,5	20,0	0,0
Odhod od doma	0,0	0,0	0,0	100,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Spanje	0,0	0,0	32,5	52,6	0,0	0,0	0,0	0,0	4,2	10,6	0,2
Drugo	0,0	0,0	1,4	89,5	0,0	0,0	0,0	0,0	5,6	3,6	0,0
Vrnitev domov	0,0	0,0	0,0	100,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Kopanje	0,0	0,0	1,6	85,9	0,0	0,0	0,0	0,0	12,5	0,0	0,0
Prehranjevanje	0,0	0,0	9,4	71,9	0,0	0,0	0,0	0,0	8,3	10,4	0,0
Kuhanje	0,0	0,0	1,9	60,4	0,0	0,0	0,0	0,0	16,3	21,4	0,0
Osebna higiena	0,0	0,0	0,0	30,8	0,0	0,0	0,0	0,0	64,9	4,3	0,0
Delo	0,0	0,0	5,8	56,4	0,0	0,0	0,0	0,0	13,2	24,6	0,0
Sprostitev	0,0	0,0	14,6	70,5	0,0	0,0	0,0	0,0	6,8	8,2	0,0

Slika 6: Matrika zamenjav klasifikatorja SVM pri zbirki podatkov Kyoto11. Vrstice predstavljajo dejanske aktivnosti, stolpci pa razpoznane aktivnosti.


	Postelja -> WC	Odhod od doma	Spanje	Drugo	Vrnitev domov	Kopanje	Prehranjevanje	Kuhanje	Osebna higiena	Delo	Sprostitev
Postelja -> WC	5,0	0,0	7,5	35,0	0,0	0,0	0,0	0,0	10,0	40,0	2,5
Odhod od doma	0,0	61,5	2,4	23,6	8,2	0,0	0,0	0,0	0,0	3,4	1,0
Spanje	1,4	0,0	34,6	29,6	1,2	0,0	1,4	3,7	1,4	22,4	4,2
Drugo	1,3	0,4	4,7	72,0	2,6	0,1	2,2	2,6	3,2	8,5	2,6
Vrnitev domov	0,0	10,5	0,7	56,0	29,1	0,7	0,0	0,0	0,0	0,0	3,0
Kopanje	0,0	0,0	0,0	26,6	0,0	57,8	1,6	0,0	14,1	0,0	0,0
Prehranjevanje	1,0	0,0	11,5	32,3	0,0	0,0	12,5	8,3	6,3	12,5	15,6
Kuhanje	0,3	0,0	12,8	30,7	0,0	0,0	6,1	21,1	1,0	19,5	8,6
Osebna higiena	0,5	0,0	1,8	21,7	0,4	0,2	0,7	0,7	64,7	9,0	0,5
Delo	4,8	0,0	17,9	29,9	0,6	0,0	2,1	4,8	3,7	32,5	3,8
Sprostitev	0,5	0,0	11,4	35,5	1,8	0,0	10,0	8,6	3,2	10,9	18,2

Slika 7: Matrika zamenjav klasifikatorja GP+SVM pri zbirki podatkov Kyoto11. Vrstice predstavljajo dejanske aktivnosti, stolpci pa razpoznane aktivnosti.

Pri zbirki Kyoto11 razlikujemo 10 dejanskih aktivnosti in aktivnost *Drugo*. Na sliki 6 vidimo, da klasifikator SVM z osnovnimi značilkami razpozna samo aktivnosti *Spanje*, *Osebna higiena* in *Delo*. Ostale aktivnosti niso nikoli razpoznane. Sprejemljivo točnost razpoznavanja ima samo aktivnost *Osebna higiena*. Z vpeljavo GP začne klasifikator razpoznavati tudi druge aktivnosti. Izrazito se izboljša točnost pri aktivnostih *Odhod od doma* in *Kopanje*. Vidimo tudi, da pri tej zbirki klasifikator nima težav z razlikovanjem med aktivnostjo *Delo* in aktivnostjo *Sprostitev*, oz. so zamenjave med njima manj izrazite. Aktivnost *Postelja->WC* je največkrat razpoznana kot aktivnost *Delo*, aktivnost *Kuhanje* pa je v skoraj enakem deležu razpoznana kot *Kuhanje* in kot *Delo*. Primerjava matrik zamenjav brez GP in z GP je pokazala, da smo z


vpeljavo GP izboljšali točnost razpoznavanja po aktivnostih. Skupna točnost (glej tabelo 2) se je zmanjšala predvsem zaradi aktivnosti *Drugo*.

Sliki 8 in 9 prikazujeta računski čas za procesa učenja in testiranja pri vseh naborih podatkov. Poskusi so bili izvedeni z uporabo procesorja Intel(R) Xeon(R) E5-2698 v4 @ 2,20 GHz s 512 GB pomnilnikom RAM in 80 jedri CPU. Na sliki 8 lahko vidimo, da je LSTM računsko najzahtevnejši in da se po uvedbi GP računski čas zmanjša. To je posledica tega, da se LSTM uči na celotnem naboru podatkov, po uporabi GP (oz. izločanju značilk) pa se nabor podatkov zmanjša. Pri SVM vidimo povsem nasproten trend, tj. čas učenja se po uvedbi GP poveča, čas testiranja pa zmanjša (slika 9). Pri SVM postopek izločanja značilk znatno poveča računski čas, vendar vodi do manj kompleksnega modela. Računski čas v procesu testiranja je odvisen predvsem od kompleksnosti modela. Slika 9 prikazuje računsko zahtevnost uporabljenih modelov.



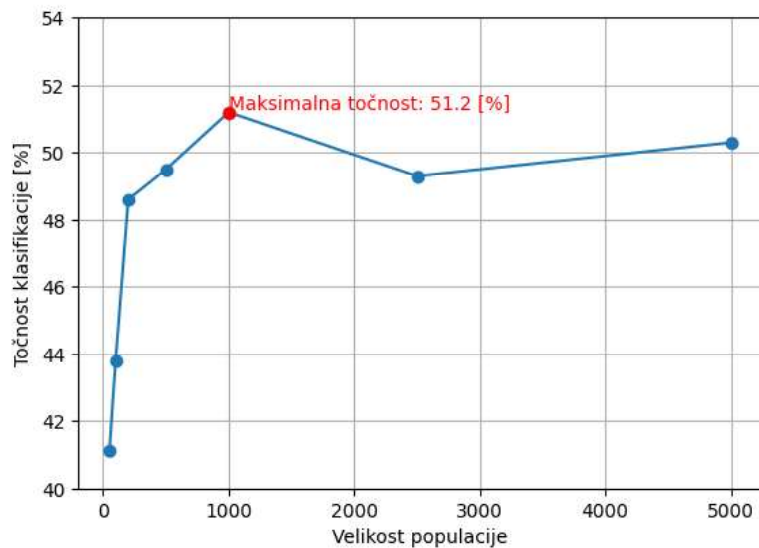
Slika 8: Računski čas za proces učenja



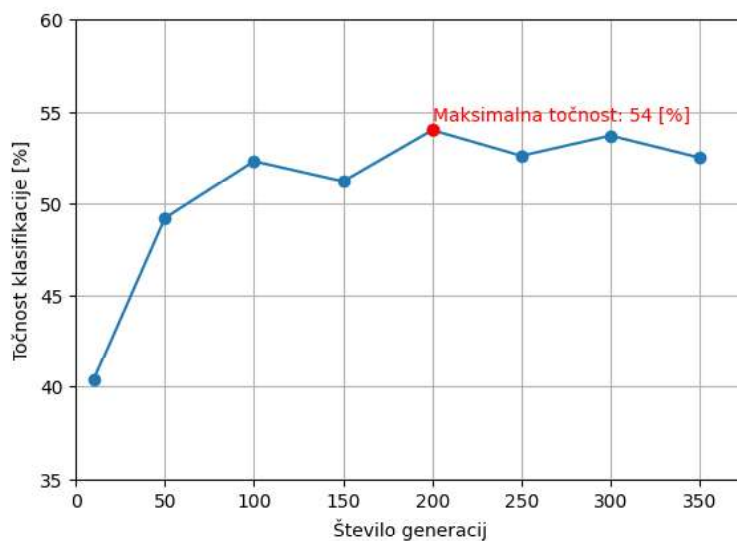


Slika 9: Računski čas za proces testiranja

Vsi hiperparametri genetskega programiranja so bili izbrani na podlagi eksperimentalnih rezultatov. Pri analizi hiperparametrov smo ugotovili, da na točnost klasifikacije najbolj vplivata število generacij in velikost populacije. Velikost programa oz. matematične funkcije smo definirali v razponu med 5 in 200, saj želimo omogočiti večjo »izrazno« moč pri izločanju značilke. Enako velja za matematične operacije, uporabljene v enačbi (2). Ostali parametri (velikost turnirja in razmerje med križanjem in mutacijo) nimajo bistvenega vpliva na točnost klasifikacije. Sliki 10 in 11 prikazujeta vpliv spreminjanja števila generacij in velikosti populacije na točnost klasifikacije. Na slikah je razvidno, da velikost populacije 1000 in število generacij 200 dajeta najboljše rezultate.



Slika 10: Vpliv spreminjanja velikosti populacije na točnost klasifikacije pri Kyoto7



Slika 11: Vpliv spreminjanja števila generacij na točnost klasifikacije pri Kyoto7

V vseh izvedenih eksperimentih smo klasifikator gradili in testirali na isti podatkovni zbirki. Kako splošen je klasifikator, lahko preverjamo tako, da ga učimo na eni, testiramo pa na drugi podatkovni zbirki, vendar tak eksperiment ni enostavno izvedljiv, saj podatki niso neposredno prenosljivi. Potrebno je definirati preslikave senzorskih podatkov in podatkov o aktivnostih, ki med drugim upoštevajo tudi

različne tipe in razporeditve senzorjev po prostorih. To področje raziskav se imenuje učenje prenosa znanja (angl. transfer learning) in presega obseg tega članka.

## **7 Zaključek**

Raziskave, ki smo jih predstavili v članku, potrjujejo vpliv izločanja značilk na uspešnost klasifikacije. Izločanje značilk s pomočjo genetskega programiranja se je v določenih eksperimentih izkazalo kot primerno, ne pa v vseh. Pri tem igra pomembno vlogo velikost zbirke podatkov, nabor podatkov in uporabljen klasifikator. Na zmanjšano točnost klasifikacije v izvedenih eksperimentih je vplivalo tudi predprocesiranje podatkov, v katerem so bili izločeni določeni senzori. Tudi združevanje oz. neupoštevanje določenih aktivnosti je imelo negativne učinke na klasifikacijo.

Genetsko programiranje se je izkazalo kot najbolj učinkovito pri SVM. Najbolj neučinkovito je bilo pri klasifikaciji z nevronskimi mrežami LSTM. Nevronske mreže se po svoji naravi naučijo razlikovati med bolj informativnimi značilkami in manj informativnimi značilkami v visokodimenzionalnem vektorju značilk. Naučijo se tudi korelacij med značilkami, ki jih prehod na vektorje značilk manjših dimenzij morda izgubi. Nevronske mreže so pri tem omejene z naborom operacij, ki jih izvajajo. To so seštevanje, množenje in aktivacijske funkcije. V Genetskem programiranju pa lahko sestavimo programe oz. matematične formule, ki vsebujejo tudi druge operacije, kot so logične operacije ali deljenje. Čeprav lahko nevronske mreže izrazijo tudi kompleksne operacije, pa za to potrebujejo nabor osnovnih nevronov in aktivacijskih funkcij, kaj lahko privede do večje računske zahtevnosti. Prav tako nevronske mreže potrebujejo večjo količino učnih podatkov, ki pa morda niso na voljo v vsakem okolju. Cilj genetskega programiranja je v tem primeru najti računsko nezahtevne formule, ki preslikajo senzorske podatke posameznega okolja v splošne vhodne značilke za nevronske mreže. Prenos znanja tako omejimo na genetsko programiranje.

V prihodnjih raziskavah se bomo poglobili v posamezne operacije genetskega programiranja. Iskali bomo predvsem njegovo komplementarnost s klasifikacijo LSTM, ki po trenutnih raziskavah daje najboljše rezultate.

## Zahvala

Raziskava je nastala delno v okviru raziskovalnega programa št. P2-0069, ki ga je sofinancirala Javna agencija za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije iz državnega proračuna.

Avtorji članka se zahvaljujejo avtorjem podatkovne zbirke CASAS za njeno prosto dostopnost.

## Literatura

- Al-Taei, A., Ibrahim, M. F., & Habeeb, N. J. (2021). Optimizing the performance of knn classifier for human activity recognition. In *Advances in Computing and Data Sciences: 5th International Conference, ICACDS 2021, Nashik, India, April 23–24, 2021, Revised Selected Papers, Part I* 5 (pp. 373-385). Springer International Publishing.
- Kajzer, A. (2023). Stanje na področjih Strategije dolgožive družbe. *Kratke analize, UMAR*. [https://www.umar.gov.si/fileadmin/user\\_upload/publikacije/kratke\\_analize/2023\\_10\\_Kajzer/Stanje\\_na\\_podrocju\\_SDD.pdf](https://www.umar.gov.si/fileadmin/user_upload/publikacije/kratke_analize/2023_10_Kajzer/Stanje_na_podrocju_SDD.pdf)
- Sepesy Maučec, M., & Donaj, G. (2021). Discovering daily activity patterns from sensor data sequences and activity sequences. *Sensors*, 21(20), 6920.
- Baketarić, D., Donaj, G., Sepesy Maučec, M. Integration of genetic programming into ADL recognition systems. V: ŽEMVA, Andrej (ur.), TROST, Andrej (ur.). Zbornik dvaintridesete mednarodne Elektrotehniške in računalniške konference ERK 2023 : Portorož, Slovenija, 28. - 29. september 2023, 342-345,
- Hussain, Z., Sheng, M., & Zhang, W. E. (2019). Different approaches for human activity recognition: A survey. arXiv preprint arXiv:1906.05074.
- Wang, S., & Zhou, G. (2015). A review on radio based activity recognition. *Digital Communications and Networks*, 1(1), 20-29.
- Yao, L., Sheng, Q. Z., Li, X., Gu, T., Tan, M., Wang, X., ... & Ruan, W. (2017). Compressive representation for device-free activity recognition with passive RFID signal strength. *IEEE Transactions on Mobile Computing*, 17(2), 293-306.
- Wang, A., Zhao, S., Zheng, C., Yang, J., Chen, G., & Chang, C. Y. (2021). Activities of daily living recognition with binary environment sensors using deep learning: A comparative study. *IEEE Sensors Journal*, 21(4), 5423-5433.
- La Cava, W., Silva, S., Danai, K., Spector, L., Vanneschi, L., & Moore, J. H. (2019). Multidimensional genetic programming for multiclass classification. *Swarm and evolutionary computation*, 44, 260-272.
- Kabir, M. H., Hoque, M. R., Thapa, K., & Yang, S. H. (2016). Two-layer hidden Markov model for human activity recognition in home environments. *International Journal of Distributed Sensor Networks*, 12(1), 4560365.
- Donaj, G., & Maučec, M. S. (2019). Extension of HMM-Based ADL Recognition with markov chains of activities and activity transition cost. *IEEE Access*, 7, 130650-130662.
- Fleury, A., Vacher, M., & Noury, N. (2009). SVM-based multimodal classification of activities of daily living in health smart homes: sensors, algorithms, and first experimental results. *IEEE Transactions on information technology in biomedicine*, 14(2), 274-283.

- Ordóñez, F. J., De Toledo, P., & Sanchis, A. (2013). Activity recognition using hybrid generative/discriminative models on home environments using binary sensors. *Sensors*, 13(5), 5460-5477.
- Athavale, V. A., Gupta, S. C., Kumar, D., & Savita, S. (2021). Human action recognition using CNN-SVM model. *Advances in Science and Technology*, 105, 282-290.
- De-La-Hoz-Franco, E., Ariza-Colpas, P., Quero, J. M., & Espinilla, M. (2018). Sensor-based datasets for human activity recognition—a systematic review of literature. *IEEE Access*, 6, 59192-59210.
- Koza, J. R. (1993). Genetic Programming: On the Programming of Computers by Means of Natural Selection (Complex Adaptive Systems). *A Bradford Book*, 1, 18.
- Szewczyk, S., Dwan, K., Minor, B., Swedlove, B., & Cook, D. (2009). Annotating smart environment sensor data for activity learning. *Technology and Health Care*, 17(3), 161-169.
- Liciotti, D., Bernardini, M., Romeo, L., & Frontoni, E. (2020). A sequential deep learning application for recognising human activities in smart homes. *Neurocomputing*, 396, 501-513.
- Cook, D. J. (2010). Learning setting-generalized activity models for smart spaces. *IEEE intelligent systems*, 2010(99), 1.
- Li, Y., Yang, G., Su, Z., Li, S., & Wang, Y. (2023). Human activity recognition based on multi-environment sensor data. *Information Fusion*, 91, 47-63.