

# Klasifikacija trajektorije roke z meritvami pozicije za podporo sodelovanju robota s človekom

Matija Mavsar<sup>1</sup>

<sup>1</sup>Laboratorij za humanoidno in kognitivno robotiko, Odsek za avtomatiko, biokibernetiko in robotiko, Institut Jožef Stefan, Jamova cesta 39, 1000 Ljubljana  
E-mail: matija.mavsar@ijs.si

## Hand Trajectory Classification from Position Measurements for Human-Robot Collaboration


*Human-robot collaboration enables higher efficiency in performing complex tasks, while relieving humans of stressful and repetitive work. In order to ensure safe and successful cooperation, it is necessary to monitor the motions of both the robot and the human, where information about the worker's intended movement can be especially useful. In this paper, we present a neural network structure, which, based on past position measurements, performs trajectory classification and thus predicts the target slot, where a person will move the hand when performing a collaborative task with a robot. The classification accuracy of the neural network was tested for different numbers of past consecutive position measurements. The results showed high accuracy in predicting the correct trajectory, with more measurements leading to better performance. The predictions allow the robot to be controlled safely and in a timely manner, thus preventing collision and optimizing the process.*

### 1 Uvod

Delovna mesta sodobnih robotov se v zadnjih letih premikajo iz zaprtih in predvidljivih prostorov v bolj kompleksna okolja, kjer je na voljo manj informacij, stanja pa se lahko spreminjajo hitro. Obenem se povečuje potreba po sodelovanju med robotom in človekom, saj to omogoča hitrejša in učinkovitejša opravljanje nalog, prav tako pa pri tem človeka razbremenimo najbolj stresnih, napornih in ponavljajočih se opravil.

Za zagotavljanje varnega in uspešnega sodelovanja med robotom in človekom je potreben ustrezen nadzor robota, ki se mora sproti prilagajati trenutnemu gibanju človeka oziroma njegovih okončin, kar pripomore k večji usklajenosti [1]. Kadar robot in človek delata na istem delovnem mestu, je še posebej koristna informacija o človekovi nameri, saj lahko s tem robot predvidi človekov gib in se mu pravočasno umakne oziroma prilagodi svoje delovne naloge. Sodobni merilni sistemi, kot je OptiTrack, omogočajo spremljanje trenutne lege človeka, kar lahko izkoristimo za ugotavljanje prihodnjih pozicij.

V članku predstavimo arhitekturo nevronske mreže, ki na podlagi preteklih zaporednih meritev pozicije človeške roke napove, v katerega izmed možnih ciljnih mest




Slika 1: Prikaz sestavljalnega procesa, ki ga delavec izvaja v sodelovanju z robotom. Predmet mora premakniti v eno izmed štirih mest, prikazanih na levi strani slike, nevronska mreža pa s pomočjo meritev pozicije roke izvede klasifikacijo trajektorije in s tem predvidi mesto odlaganja predmeta.

bo oseba premaknila objekt tekom preprostega sestavljalnega procesa (slika 1), pri katerem iz nasprotni smeri sodeluje tudi robot. Na podlagi pridobljene napovedi se lahko robot ustrezno odzove in s tem omogoča bolj tekoče sodelovanje. V eksperimentih preizkusimo in primerjamo več nevronskih mrež, ki kot vhod sprejmejo različno število preteklih meritev pozicije, in pokažemo, da lahko mreža z visoko natančnostjo klasificira trajektorijo človeške roke in s tem predvidi končno odlagalno mesto. Predlagani sistem je tako mogoče uporabiti kot podporo v delovnem okolju, kjer sodelujeta človek in robot, saj z njim lahko povečamo dinamičnost procesa.

### 2 Sorodne raziskave

Na področju sodelovanja robota s človekom so raziskave usmerjene v reševanje raznovrstnih problemov, kot je na primer napovedovanje človeških gibov [2] in učinkovitejše učenje robotskih gibov s pomočjo demonstracij [3, 4]. Pri različnih nalog so se kot uporabne izkazale metode globokega učenja, npr. za prepoznavanje kretenj [5] in aktivno vodenje robota z upoštevanjem trenutnih sil, hitrosti in pozicij [6], njihova učinkovitost pa seže tudi na preostala področja, kot so sledenje objektom [7] in spod-



Slika 2: Arhitektura nevronske mreže za klasifikacijo trajektorije na podlagi  $S$  vhodnih zaporednih meritev pozicije roke. Mreža je sestavljena iz polno povezanih, izpustnih in normalizacijskih plasti. Na izhodnih vrednostih se tekom treniranja za izračun napake izvede normalizirana eksponentna funkcija (angl. *softmax function*), s čimer pridobimo verjetnosti za posamezno odlagalno mesto.

bujevalno učenje [8].

Za prepoznavanje in predvidevanje človeških gibov pri sodelovanju robota in človeka so bile razvite številne metode; v [9] je predstavljen sistem sklepanja, ki predvidi, katere naloge človek trenutno opravlja in katera dejanja bodo tekom procesa še potrebna, s čimer optimizirajo delovni načrt robota. V [10] so avtorji predstavili interakcijske elementarne gibe, s katerimi je mogoče predvideti končno obliko črke na podlagi delnih vzorcev, podobno v [11] ocenjujejo parametre dinamičnih elementarnih gibov s Kalmanovim filtrom, v [12] pa predstavijo verjetnostne elementarne gibe za učenje robotskih gibov s pomočjo posnemovalnega učenja.

Na nevronskih mrežah temeljijo nekatere metode za razpoznavanje različnih kretenj [13] in za prepoznavanje namere, ali želi človek predati predmet robotu [14]. Napovedovanje prihodnjih telesnih poz na podlagi preteklih skeletnih meritev je bilo med drugim izvedeno z generativnimi modeli [2], kjer je sicer napoved mogoča le za določen interval v prihodnosti, in rekurenčnimi nevronskimi mrežami [15], ki sestojijo iz spominskih elementov in se zato dobro obnesejo v dinamičnih okoljih. Prav tako z rekurenčnimi mrežami so [16] napovedali verjetnost različnih izvajanih nalog na podlagi značilnega pogleda opazovane osebe in telesnih znakov. Predstavljena nevronska mreža kljub dinamični naravi problema nima rekurenčne strukture, vendar pa preprosta sestava omogoča klasifikacijo trajektorije brez potencialno motečih vplivov preteklih meritev, enostavnejše pa je tudi procesiranje različno dolgih gibov.

### 3 Klasifikacija trajektorije z uporabo nevronske mreže

Predlagana nevronska mreža tekom sodelovalne naloge robota in človeka izvaja klasifikacijo trajektorije roke in s tem napove, v katerega izmed končnih odlagalnih mest bo človek odložil predmet. Mreža je sestavljena iz polno povezanih plasti, kot vhod pa sprejme trenutno meritev pozicije roke ter poljubno število preteklih meritev. Na izhodu poda štiri vrednosti, ki se nanašajo na verjetnosti, da bo delavec predmet premaknil v določeno končno odlagalno mesto. V nadaljevanju podrobneje opišemo strukturo učnih podatkov in arhitekturo nevronske mreže.

#### 3.1 Struktura učnih podatkov

Vhod v nevronska mrežo za klasifikacijo trajektorije je enodimenzionalni vektor  $\mathbf{v} \in \mathbb{R}^{3 \cdot S}$  dolžine  $3 \cdot S$ , kjer  $S$  predstavlja število zaporednih meritev, vsaka meritev pa je pozicija roke v kartezičnem prostoru ( $\mathbf{y} \in \mathbb{R}^3$ ). Posameznemu vhodnemu zaporedju meritev  $\mathbf{v}$  pripada oznaka  $K \in \mathbb{N}$ ,  $K \in [1, 4]$ , ki predstavlja številko končnega mesta, v katerega je delavec odložil predmet pri izvajanju pripadajoče trajektorije. Pari podatkov, ki se uporabljajo za treniranje nevronske mreže so tako

$$\mathbf{D} = \{\mathbf{v}_j, K_j\}_{j=1}^M, \quad (1)$$

kjer je  $M$  število učnih vzorcev.

#### 3.2 Arhitektura nevronske mreže

Sestava predlagane nevronske mreže za klasifikacijo trajektorije je prikazana na sliki 2. Vhodna plast sestoji iz  $3 \cdot S$  nevronov in sprejme  $S$  zaporednih kartezičnih meritev pozicije roke, nato sledijo polno povezana plast z 2500 nevroni, normalizacijska plast, izpustna plast (angl. *dropout layer*) z izpustno verjetnostjo 0.3, polno povezana plast velikosti 400, normalizacijska plast, na koncu pa še izhodna plast s štirimi nevroni, ki se nanašajo na možna končna mesta odlaganja.

##### 3.2.1 Metoda treniranja nevronske mreže

Za treniranje nevronske mreže smo najprej na podlagi izhodnih vrednosti  $\mathbf{p} = (p_1, p_2, p_3, p_4)$  izračunali verjetnosti za posamezno končno mesto s pomočjo normalizirane eksponentne funkcije oz. funkcije ohlapnega maksimuma (angl. *softmax function*), nato pa implementirali napako negativne logaritmične verjetnosti (angl. *negative log likelihood loss*). Za posamezen izhod mreže  $\mathbf{p}$  pri vhodu  $\mathbf{v}$  smo glede na številko pravilnega končnega mesta  $K$  napako torej izračunali kot


$$\mathbf{E}(\mathbf{p}, K) = -\log\left(\frac{e^{p_K}}{\sum_{j=1}^4 e^{p_K}}\right). \quad (2)$$

## 4 Eksperimenti

Z eksperimenti smo preizkusili natančnost nevronske mreže pri klasifikaciji trajektorij. Pri tem smo število  $S$ , ki označuje število meritev, vključenih v vhodnem vektorju  $\mathbf{v}$ , spreminjali od 1 do 4. Tako smo primerjali natančnost klasifikacije glede na različno število zaporednih meritev. Temu primerno smo prilagodili tudi velikost vhodne plasti nevronske mreže. Število zaporednih meritev bi navzgor lahko povečevali, vendar pa pri tem izgubimo možnost klasifikacije kmalu po začetku giba. Prav tako smo želeli ohraniti zadosten časovni razmik med zaporednimi meritvami, saj tako zajamemo večje območje trajektorije, na podlagi katerega mreža izvaja klasifikacijo.

#### 4.1 Pridobivanje učnih podatkov in treniranje

Učni vzorci so bili pridobljeni v eksperimentu, kjer mora delavec v sodelovanju z robotom premikati predmet iz enega konca mize v enega izmed štirih možnih odlagalnih mest. Pri zbiranju meritev je delavec premikal predmet iz začetne točke v različna končna mesta, pri tem



Slika 3: Matrike pravih in napačnih klasifikacij na validacijskih (levo) ter testnih podatkih (desno) za različna števila zaporednih meritev  $S$ . V  $m$ -ti vrstici v  $n$ -tem stolpcu matrike je prikazan delež vseh odlagalnih mest  $m$ , ki so bila klasificirane kot  $n$ , zato so vsote vrstic vedno 100%. Natančnost se vidno izboljša pri večjem številu zaporednih meritev  $S$ .

pa je imel na roki pritrjene markerje za sistem OptiTrack V120:Trio. Ob začetku giba se je sprožilo snemanje pozicij s frekvenco 120 Hz, ob koncu giba pa je bilo snemanje prekinjeno. Poleg meritev pozicije smo po vsakem gibu shranili tudi številko končnega odlagalnega mesta  $K$ .

Pridobili smo bazo 1200 gibov oz. zaporedij izmerjenih pozicij roke, od česar smo 100 gibov prihranili za končno testiranje naučenih mrež. Preostalih 1100 gibov smo časovno podvzorčili z naključnim faktorjem, da je bilo končno število pozicijskih meritev za vsak gib med 10 in 20. Iz vsakega giba smo pridobili vsa zaporedja meritev v dolžine  $S$ . Skupno število učnih zaporedij je bilo  $26323 \cdot (5 - S)$ , od česar jih je bilo  $23963 \cdot (5 - S)$  uporabljenih za treniranje,  $2360 \cdot (5 - S)$  pa za validacijo mreže pri procesu učenja (manjši kot je  $S$ , večje je število vzorcev zaradi krajšega zaporedja). Na enak način smo iz 100 testnih gibov pridobili  $1272 \cdot (5 - S)$  zaporedij.

#### 4.1.1 Treniranje

Nevronska mreža je bila implementirana z orodjem PyTorch [17] na grafični kartici NVIDIA GeForce GTX 1080. Pri treniranju je bil uporabljen optimizacijski algoritem RMSprop [18], stopnja učenja je bila nastavljena na  $5 \cdot 10^{-5}$ , velikost učnih paketov pa je bila 128. Treniranje se je ustavilo po 60 epohah brez izboljšanja napake na validacijskih podatkih.

## 4.2 Rezultati

Slika 3 prikazuje matrike pravih in napačnih klasifikacij na validacijskih ter testnih podatkih za štiri različice nevronske mreže (število zaporednih meritev  $S$  od 1 do 4). Vrednosti v posamezni vrstici predstavljajo deleže klasifikacij za pripadajoče odlagalno mesto (vsota v vsaki vrstici je tako 100%), kjer natančnosti na validacijski bazi


(levo) segajo približno od 45% do 95%. Ta baza je bila uporabljena za ustavitev treniranja, zato so za bolj verodostojen prikaz uspešnosti mreže ustrežnejši rezultati testne baze, prikazani na sliki 3 desno. Natančnosti klasifikacije na testni bazi se podobno kot na validacijski bazi gibljejo približno od 36% do 95%, opaziti pa je boljše natančnost pri višanju števila zaporednih meritev  $S$ , kjer je izboljšanje najbolj očitno pri  $S > 1$ .

Na sliki 4a je graf natančnosti v odvisnosti od deleža izvedenega giba, iz katerega je razvidno, da s kasnejšimi meritvami lahko bolj natančno določimo, v katero končno odlagalno mesto bo delavec premaknil predmet, saj so si gibi v začetnem delu bolj podobni kot na koncu. Stolpični diagram slike 4b prikazuje primerjavo posameznih različic mreže pri natančnosti klasifikacije, kjer je upoštevana povprečna natančnost na vseh zaporedjih dolžine  $S$  v testnih podatkih. Podobno kot na sliki 3 je tudi tu razvidno izboljšanje natančnosti z večanjem  $S$ .

Rezultati eksperimentov kažejo, da se natančnost klasifikacije izboljša s procesiranjem večjega števila zaporednih meritev pozicije, vendar pa se največji skok v natančnosti pojavi že pri povečanju parametra  $S$  iz 1 na 2. Za najvišjo natančnost je zato najbolj primerna vrednost parametra  $S = 4$ , kadar pa je zaželen hitrejša odzivnost na trenutne meritve, pa  $S = 2$  zagotavlja zadovoljivo natančnost klasifikacije.

## 5 Zaključek

V članku smo predstavili arhitekturo nevronske mreže za klasifikacijo trajektorij, ki jih človek izvaja pri opravljanju naloge v sodelovanju z robotom, in pridobili bazo gibov, na kateri smo preizkusili več različic mreže z različnim številom vhodnih zaporednih meritev pozicije. Poka-



Slika 4: Graf a) predstavlja natančnost klasifikacije gibov iz testne baze v odvisnosti od deleža izvedenega giba tekom procesa premikanja predmeta do odlagalnega mesta. Vidno je postopno večanje natančnosti, saj se trajektorije proti koncu giba med seboj bolj razlikujejo kot na začetku. Na grafu b) pa so primerjane skupne natančnosti vseh zaporednih meritev v testnih podatkih za štiri različice mreže.

zali smo, da lahko mreža kljub svoji preprosti strukturi z visoko natančnostjo predvidi, v katero izmed končnih leg bo človek premaknil predmet, s čimer lahko omogočimo bolj tekoče sodelovanje med robotom in človekom.

Možnosti za nadaljnje raziskovanje vključujejo uporabo rekurenčnih nevronske mreže, ki so sposobne procesirati celotna zaporedja podatkov in lahko podajo napovedi že po obdelavi prvega vzorca (npr. prve meritve pozicije). Za večjo avtonomnost procesa klasifikacije bi bil koristen tudi dodaten sistem, ki bi ugotavljal, kdaj se gib delavca začne in konča, prav tako uporabna izboljšava mreže pa bi bila možnost klasificiranja neposredno iz barvno-globinskih slik delavca s pomočjo kamere, kar bi odstranilo potrebo po uporabi dražje opreme, kot je sistem OptiTrack.

## Literatura

- [1] G. Hoffman, "Evaluating fluency in human-robot collaboration," *IEEE Transactions on Human-Machine Systems*, let. 49, št. 3, str. 209–218, 2019.
- [2] J. Bätepage, H. Kjellström, in D. Kragic, "Anticipating many futures: Online human motion prediction and generation for human-robot interaction," *IEEE International Conference on Robotics and Automation (ICRA)*, 2018, str. 4563–4570.
- [3] A. Gams in A. Ude, "On-line coaching of robots through visual and physical interaction: Analysis of effectiveness

- of human-robot interaction strategies," *IEEE International Conference on Robotics and Automation (ICRA)*, 2016, str. 3028–3034.
- [4] M. Simonič, T. Petrič, A. Ude, in B. Nemec, "Analysis of methods for incremental policy refinement by kinesthetic guidance," *Journal of Intelligent & Robotic Systems*, let. 102, št. 1, 2021.
- [5] H. Liu in L. Wang, "Gesture recognition for human-robot collaboration: A review," *International Journal of Industrial Ergonomics*, let. 68, str. 355–367, 2018.
- [6] Y. Li in S. S. Ge, "Human-Robot Collaboration Based on Motion Intention Estimation," *IEEE/ASME Transactions on Mechatronics*, let. 19, št. 3, str. 1007–1014, 2014.
- [7] S. Krebs, B. Duraisamy, in F. Flohr, "A survey on leveraging deep neural networks for object tracking," *IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, 2017, str. 411–418.
- [8] V. François-Lavet, P. Henderson, R. Islam, M. G. Bellemare, in J. Pineau, "An introduction to deep reinforcement learning," *arXiv preprint arXiv:1811.12560*, 2018.
- [9] K. P. Hawkins, S. Bansal, N. N. Vo, in A. F. Bobick, "Anticipating human actions for collaboration in the presence of task and sensor uncertainty," *IEEE International Conference on Robotics and Automation (ICRA)*, 2014, str. 2215–2222.
- [10] H. Ben Amor, G. Neumann, S. Kamthe, O. Kroemer, in J. Peters, "Interaction primitives for human-robot cooperation tasks," *IEEE International Conference on Robotics and Automation (ICRA)*, 2014, str. 2831–2837.
- [11] D. Widmann in Y. Karayiannidis, "Human motion prediction in human-robot handovers based on dynamic movement primitives," *European Control Conference (ECC)*, 2018, str. 2781–2787.
- [12] G. J. Maeda, G. Neumann, M. Ewerton, R. Lioutikov, R. Lioutikov, O. Kroemer, in J. Peters, "Probabilistic movement primitives for coordination of multiple human-robot collaborative tasks," *Autonomous Robots*, let. 41, št. 3, str. 593–612, 2017.
- [13] P. Bao, A. I. Maqueda, C. R. del Blanco, in N. García, "Tiny hand gesture recognition without localization via a deep convolutional network," *IEEE Transactions on Consumer Electronics*, let. 63, št. 3, str. 251–257, 2017.
- [14] J. Kwan, C. Tan, in A. Cosgun, "Gesture recognition for initiating human-to-robot handovers," *arXiv preprint arXiv:2007.09945*, 2020.
- [15] J. Zhang, H. Liu, Q. Chang, L. Wang, in R. X. Gao, "Recurrent neural network for motion trajectory prediction in human-robot collaborative assembly," *CIRP Annals*, 2020.
- [16] P. Schydlo, M. Rakovic, L. Jamone, in J. Santos-Victor, "Anticipation in human-robot cooperation: A recurrent neural network approach for multiple action sequences prediction," *IEEE International Conference on Robotics and Automation (ICRA)*, 2018, str. 5909–5914.
- [17] A. Paszke, S. Gross, F. Massa, A. Lerer, J. Bradbury, G. Chanan, T. Killeen, Z. Lin, N. Gimelshein, L. Antiga, A. Desmaison, A. Kopf, E. Yang, Z. DeVito, M. Raison, A. Tejani, S. Chilamkurthy, B. Steiner, L. Fang, J. Bai, in S. Chintala, "PyTorch: An imperative style, high-performance deep learning library," *Advances in Neural Information Processing Systems*, 2019, let. 32, str. 8024–8035.
- [18] T. Tieleman, G. Hinton *idr*, "Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude," *COURSERA: Neural networks for machine learning*, let. 4, št. 2, str. 26–31, 2012.