

2024 – 2025



EVROPSKA NOČ RAZISKOVALCEV



»Financira Evropska unija. Za izražena stališča in mnenja odgovarja samo avtor (ali avtorji) in ne odražajo nujno stališč Evropske unije ali Evropske izvajalske agencije za raziskave. Niti Evropska unija niti Evropska izvajalska agencija za raziskave ne moreta biti odgovorna zanje.«

Umetna inteligenca v dobro ljudi

Preprečevanje zamrznitve hoje in padcev pri starostnikih z demenco

Prof. dr. Jelka Geršak¹, doc. dr. Suzana Uran², Luka Kranjc¹, študent mehatronike

¹Fakultete za strojništvo, ² Fakulteta za elektrotehniko, računalništvo in informatiko

PRAVNO OBVESTILO

Na vseh dogodkih projekta oooZnanost! poteka snemanje in fotografiranje z namenom promocije in poročanja o dogodku. Če vstopite na lokacijo (spletnega) dogodka, boste lahko posneti in fotografirani. Z vstopom na to lokacijo, dajete dovoljenje organizatorjem in Evropski komisiji, da vas lahko snemajo, fotografirajo, zvočno snemajo in uporabijo vaše posnetke po lastni presoji. Obiskovalci zato ne boste uveljavljali nobene odgovornosti proti organizatorjem in Evropski komisiji v zvezi z zgoraj navedenim.



V kolikor se z zgoraj navedenim ne strinjate, vljudno prosimo, da s tem seznanite organizatorje na: ern@um.si. E-sporočilu obvezno priložite visokokakovostni sken fotografije z osebnega dokumenta, da vas lahko organizator izloči iz vseh posnetkov in fotografij skupaj z navedbo, na kateri lokaciji in katerega dne bi lahko bili posneti s strani organizatorjev. Pooblaščen oseb za varstvo podatkov Univerze v Mariboru je izr. prof. dr. Miha Dvojmoč (dpo@um.si).

Umetna inteligenca (UI)


- je področje računalništva, ki razvija sisteme, sposobne posnemati človeške miselne procese;
- ukvarja se z razvojem sistemov in programov, sposobnih opravljati naloge, za katere je običajno potrebna človeška inteligenca.

To pomeni, da lahko stroji in programi samostojno analizirajo podatke, prepoznavajo vzorce, se učijo iz izkušenj in celo sprejemajo odločitve.

Človeški možgani, nevronske mreže in nevroni



majhna nevronska mreža



biološki nevron

V naših možganih so številni nevroni povezani v nevronske mreže.

Viri slik: človeški možgani Patrick J. Lynch, medical illustrator CC BY 2.5

https://en.wikipedia.org/wiki/Human_brain#/media/File:Skull_and_brain_normal_human.svg,

majhna nevronska mreža, Neves a.C. et al: A new approach to damage detection in bridges using machine learning, Int. Conf. EVACES 2017, Neuron3.png Egm4313.s12 CC BY 3.0

<https://commons.wikimedia.org/wiki/File:Neuron3.png>

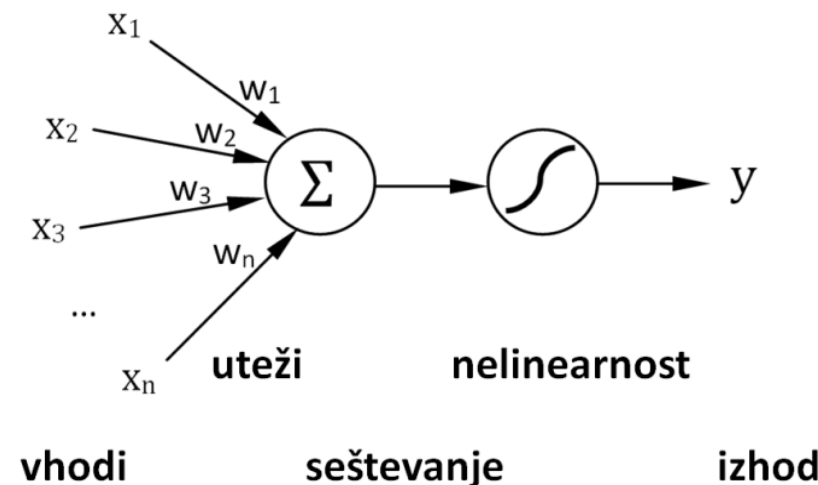
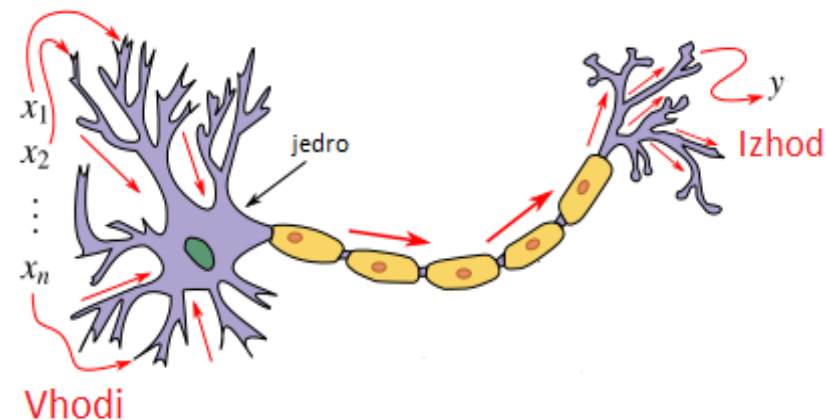
Umetni nevroni posnemajo zgradbo in delovanje bioloških

biološki

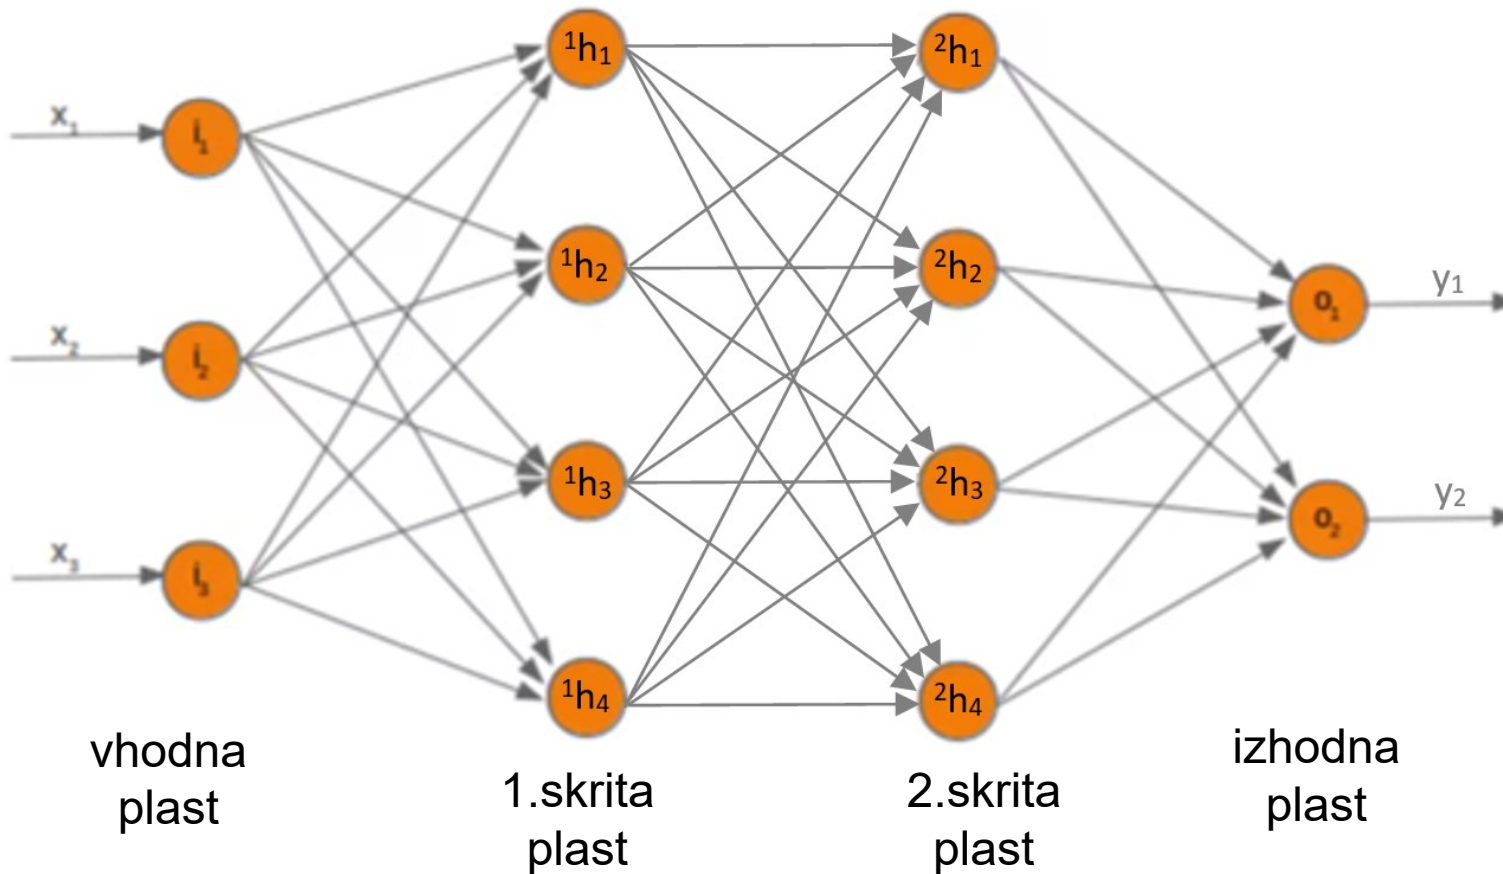
Električni impulzi prinašajo na izrastke nevrona **naboj**, ki se **zbira na celični steni**. Ko je zbranega naboja dovolj nevron **odda enega ali več impulzov** nevronom v nevronske mreži.

umetni

Zbiranje naboja na celični steni **posnemamo s seštevanjem in utežmi**. Z **nelinearno funkcijo** pa **določimo** kdaj se bo sprožil umetni nevron.



Nevronske mreže imajo mnogo plasti številnih nevronov




Nevronske mreže delimo na:

- plitve in
- globoke .

Na sliki **levo** je **plitva** nevronska mreža.

Globoka nevronska mreža ima najmanj 3 skrite plasti.

V računalniku so nevronske mreže zapisane z matrikami



Plitvo nevronske mrežo na levi zapišemo z dvema matrikama uteži.

W_{ih} in W_{ho} .

Izhoda nevronske mreže z linearno aktivacijsko funkcijo na sliki levo pa izračunamo z matrično enačbo.

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \underbrace{\begin{bmatrix} W_{1h1} & W_{1h2} & W_{1h3} & W_{1h4} \\ W_{2h1} & W_{2h2} & W_{2h3} & W_{2h4} \end{bmatrix}}_{W_{ho}} * \underbrace{\begin{bmatrix} W_{11} & W_{12} & W_{13} \\ W_{21} & W_{22} & W_{23} \\ W_{31} & W_{32} & W_{33} \\ W_{41} & W_{42} & W_{43} \end{bmatrix}}_{W_{ih}} * \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}$$

AlexNet - preboj globokih nevronske mreže 30.9.2012

AlexNet nevronska mreža je zgrajena iz:


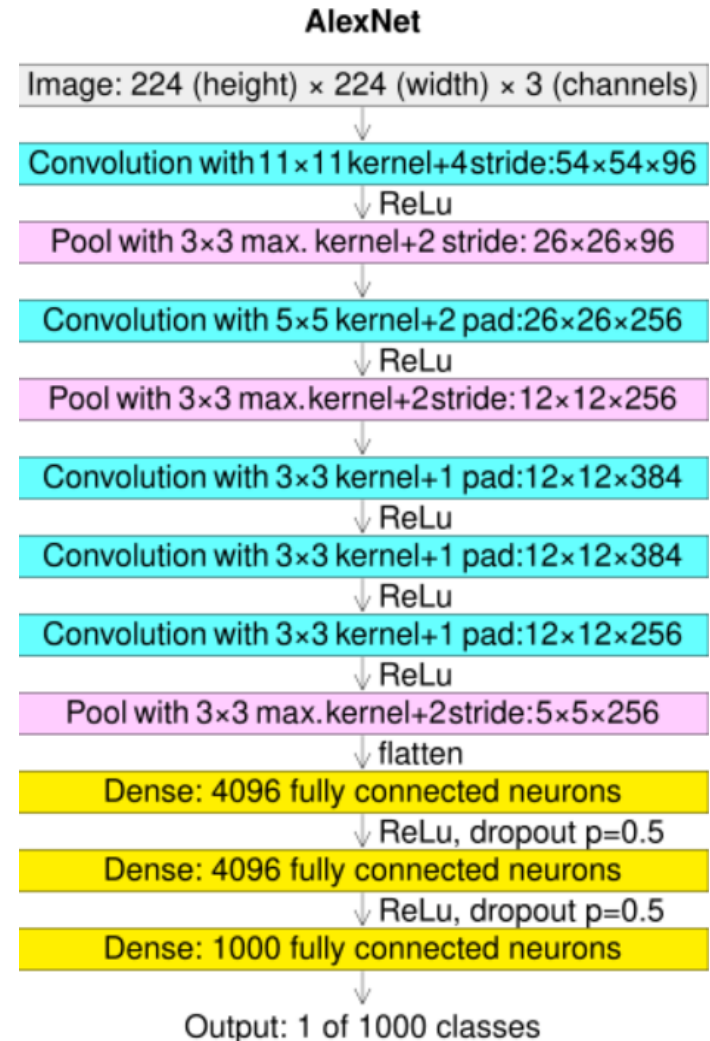
- 8 plasti nevronov (5x Conv, 3x Dense), oz.
- 650 000-tih nevronov, ki imajo
- skupaj 60 milijonov uteži.

Uteži se določijo s postopkom učenja.

AlexNet razpozna 1000 različnih predmetov.



Potrebna velika računaska moč in grafični procesorji



mačka

Umetna inteligenca v službi ljudi

Umetna inteligenca je danes prisotna na številnih področjih vsakdana. V nadaljevanju se bomo osredotočili na umetno inteligenco v neposredni službi **ljudi**, ki jim **težave** povzroča **demenca**.

Demenca postaja vedno večji problem sodobne družbe, saj število bolnikov, zaradi staranja prebivalstva, strmo narašča.

Po ocenah Svetovne zdravstvene organizacije (SZO) iz leta 2021 živi v svetu več kot 57 milijonov ljudi z demenco, v Sloveniji več kot 40 tisoč oseb, do leta 2050 pa pričakujejo, da se bo številka podvojila.

Kaj je demenca?

Demenca je po mednarodni klasifikaciji bolezni sindrom, ki je posledica bolezni možganov, pri čemer so okvarjene možganske funkcije, ki zajemajo spomin, razmišljanje, orientacijo, dožemanje, računanje, sposobnost učenja, govor in presojanje.

Parkinsonova bolezen kot druga za Alzheimerjevo demenco najpogostejša nevrodegenerativna bolezen, je kronična progresivna bolezen, za katero so značilni kronični motorični simptomi, kot so počasnost, majhnost gibov, tresenje in prostorska nestabilnost.

Zamrznitve hoje in padci

Z razvojem demence se lahko pojavljajo zamrznitve hoje, kjer oseba, kljub namenu, **ne more premakniti noge** in stoji na mestu. To se lahko zgodi med hojo, ko pride do preusmeritve pozornosti, med spremembo smeri hoje, med hojo skozi vrata, ipd.

Zamrznitve hoje trajajo od 1 do 20 sekund in lahko povzročijo padec ter s tem povezane poškodbe.

Zato so za dotično osebo zelo ovirajoče.



Na zamrznitev koraka je mogoče vplivati z zvokom ali ...

Preizkusi so pokazali:

da trajanje zamrznitve koraka je mogoče skrajšati s pomočjo zvoka, če se le-ta pojavi hitro po pojavu zamrznitve koraka.

To dejstvo daje upanje, da bi bilo mogoče

s pomočjo umetne inteligenca v nosljivi elektroniki:

- zaznati pojav zamrznitve koraka in
- zamrznitev koraka z zvočnimi signali prekiniti.


Kaj je nosljiva elektronika ?

So elektronska vezja, ki jih nosimo:

- pritrjena na roko (ročna ura),
- vgrajena v/na oblačila (hlače, majice, suknjiči, ipd.)

Slika desno: primer vgradnje elektronike

vir: Slemenšek Jan, Detekcija zamrznjenega koraka in stimulacija v realnem času s personaliziranim nosljivim sistemom za bolnike s Parkinsonovo boleznijo, doktorsko delo, UM FERi, september 2024



Levo:

Načrtovana postavite merilnih senzorjev, povezana z bakrenimi vodniki

Spodaj:



Zaščita žičnih povezav z oblogo iz silikonskega kavčuka



Vgrajena tiskana vezja

Nosljivost → nevronske mreže na majhnih krmilnikih

za izvedbo nevronskih mrež smo izbrali PSoC6 AI

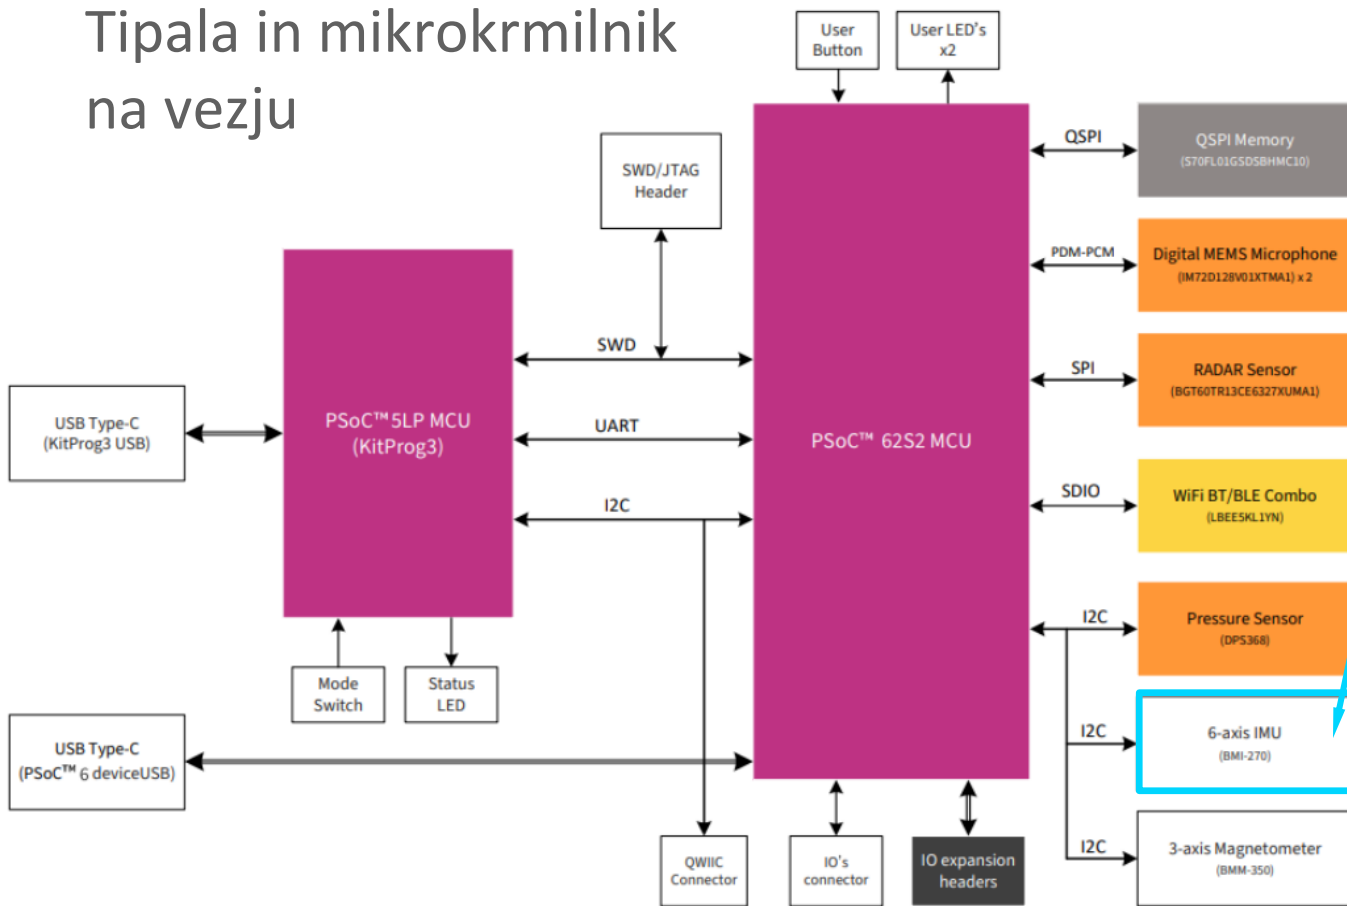


Infineon CY8CKIT-062S2-AI

Umetna inteligenca v dobro ljudi


Na vezju mikrokrmilnika PSoC 6 AI so radar, mikrofonski, ... in

Tipala in mikrokrmilnik na vezju



6-osni IMU

Pospeškometer in žiroskop (meritev kotne hitrosti)



Osnovni podatki o mikrokrmilniku PSoC 6 AI

Mikrokrmilnik **PSoC 6252** ima veliko računsko moč, in sicer:


- 1 x ARM Cortex **M4F** 150 MHz (za računanje s plavajočo vejico)
- 1 x ARM Cortex **M0+** 100 MHz (za računanje s končno natančnostjo).

Z razporejanjem računskih nalog med obe procesorski jedri lahko prilagajamo energijsko potrošnjo računanja zalogi električne energije v bateriji.

Z jedrom ARM Cortex M0+ lahko računamo energijsko varčnejše.

3-osni pospeškometer

S pomočjo signalov iz pospeškometra je mogoče zaznati trepetanje noge (3 do 8 Hz), ki je ni mogoče premakniti med zamrznitvijo koraka.



Koordinatni sistem pospeškometra

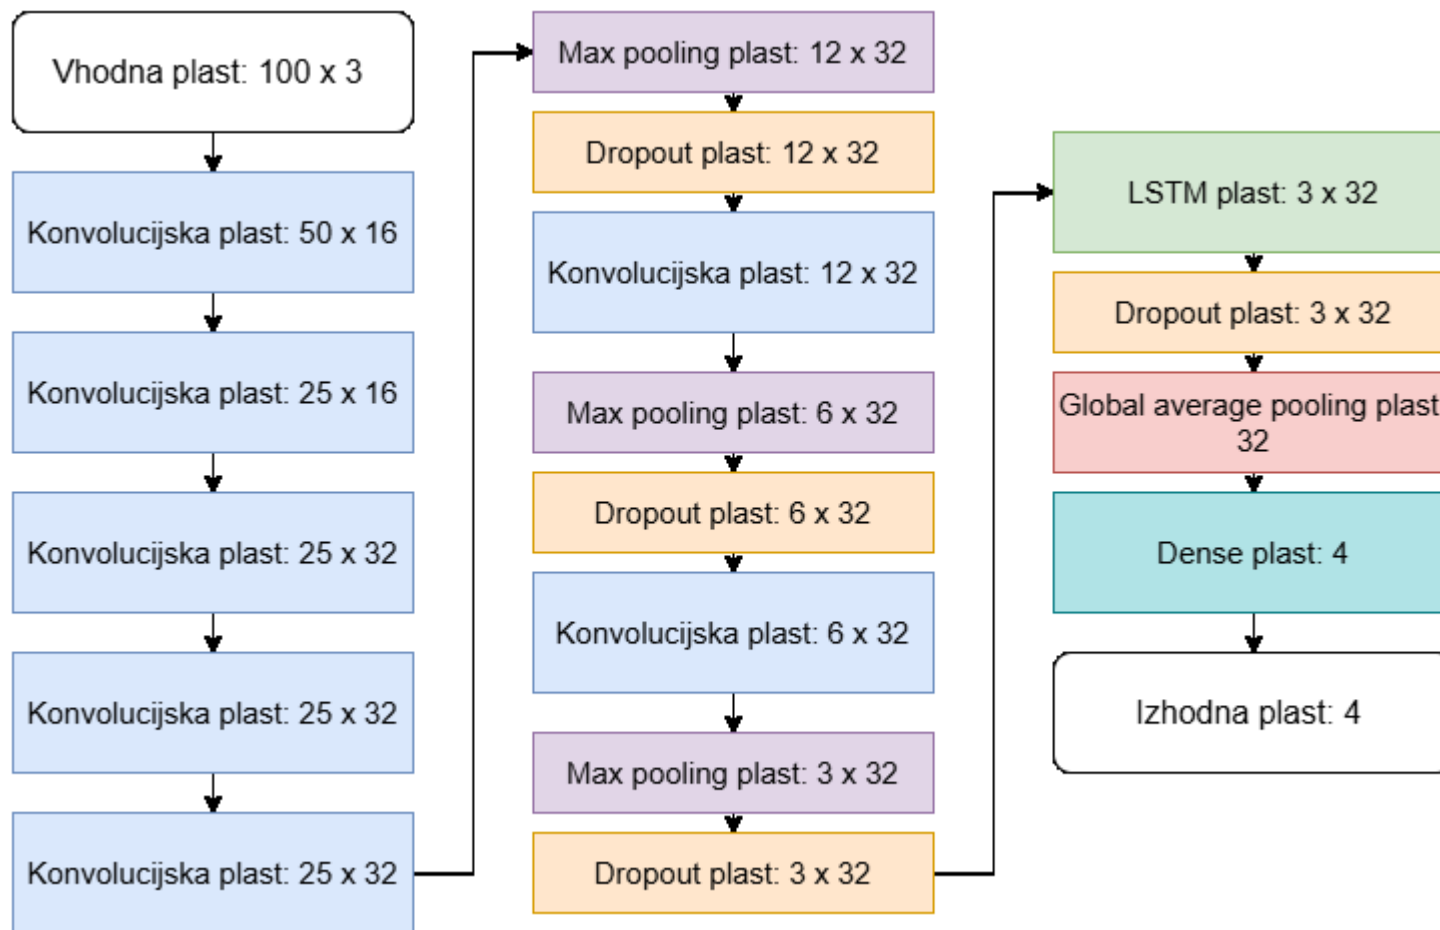
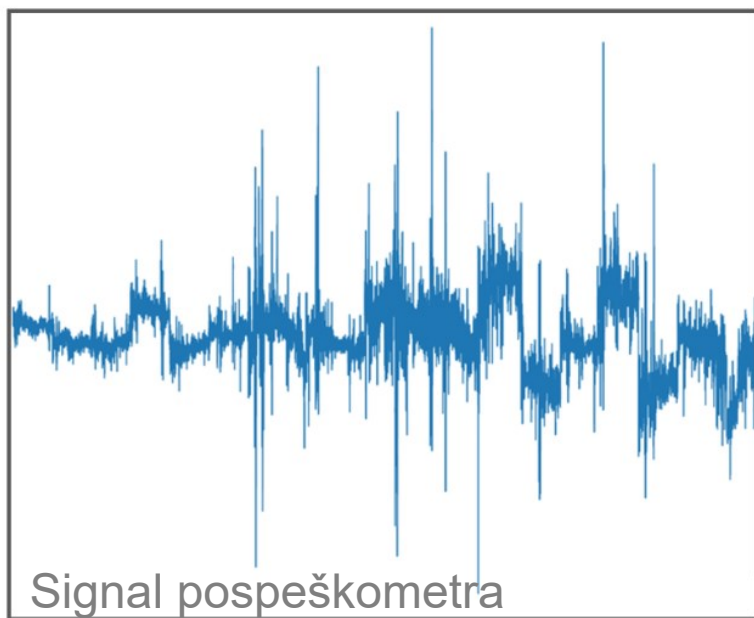
- Izhod so pospeški a_x , a_y in a_z
- 16-bitni pospeškometer
- Pogostost meritev: od 0.78 Hz do 1.6 kHz
- Nizko-pasovno sito

Prednosti uporabe nevronske mreže

- Vsestranska izvedba – model deluje ne glede na uporabnika in umerjanje ni potrebno
- Hiter odziv na dogodek, ki ga želimo zaznavati
- Lahko razvrščajo in najdejo povezave med lastnostmi, katere si ljudje težko predstavljamo.

Naša nevronska mreža za zaznavanje zamrznitve koraka

Vhod je časovno okno 100-tih zaporednih meritev pospeškov a_x , a_y in a_z



Opis posameznih plasti nevronske mreže

- Vhodna: V njo se vnesejo signalni podatki pospeškometra
- Konvolucijska: Določi značilke podatkov
- Max pooling: Zmanjša velikosti matrik podatkov
- Dropout: Delež uteži nevronske mreže naključno postavi na 0
- Global average pooling: Zmanjša dimenzije iz matrike v vektor
- LSTM: plast s „pomnjenjem preteklih vrednosti“
- Dense: Polno povezana plast – vsak nevron povezan z vsakim
- Izhodna: Določi rezultat nevronske mreže

Orodja za učenje nevronske mreže

- Scilab – obdelava podatkov za učenje
- DeepCraft Studio – program za učenje in ovrednotenje nevronske mreže



Potek učenja nevronske mreže s TensorFlow orodjem

- Vstavljanje in razporeditve podatkov – učenje, validacija in test
- Določanje pred procesiranja podatkov
- Generiranje splošnih modelov nevronske mreže – TensorFlow, AutoML
- Učenje in vrednotenje nevronske mreže preko oblaka

The screenshot displays the TensorFlow Playground interface for a classification project. The top section shows a table of data classes with their respective splits and weights. Below this, a table lists individual data tracks with their status and active labels. A notification at the bottom indicates that the project has been successfully validated.

Class	ID	Unassigned	Train (60 %)	Validation (20 %)	Test (20 %)	Weight	Total
StartHesitation	1	0 % (00:00)	62 % (17:17)	20 % (05:30)	18 % (04:54)	1	27:42
Turn	2	0 % (00:00)	63 % (67:38)	19 % (20:40)	17 % (18:29)	1	106:48
Walking	3	0 % (00:00)	56 % (09:35)	19 % (03:16)	25 % (04:15)	1	17:07
Total Annotated	-	0 % (00:00)	62 % (94:31)	19 % (29:27)	18 % (27:40)	-	151:38
Unlabeled Data	0	0 % (00:00)	54 % (68:20)	33 % (41:19)	14 % (17:24)	1	127:04
Total Data	-	0 % (00:00)	58 % (162:52)	25 % (70:46)	16 % (45:04)	-	278:43

Name	Set	Status	Active Label Track	Active Data Track	Sample Shape	Frequency	Labels	Length	Labeled
Podatek1	Train	✓	Labele	Podatki	[3]	100 Hz	6	11:31	11:27
Podatek10	Train	✓	Labele	Podatki	[3]	100 Hz	3	00:41	00:13
Podatek11	Train	✓	Labele	Podatki	[3]	100 Hz	4	01:45	00:56
Podatek12	Test	✓	Labele	Podatki	[3]	100 Hz	4	05:19	05:02
Podatek13	Train	✓	Labele	Podatki	[3]	100 Hz	4	00:29	00:14
Podatek14	Validation	✓	Labele	Podatki	[3]	100 Hz	3	01:07	00:24
Podatek15	Train	✓	Labele	Podatki	[3]	100 Hz	1	00:06	00:02

Umetna inteligenca v dobro ljudi

Data Build a preprocessor by combining different preprocessing layers. The preprocessor manipulates all data before it is input into models.

Preprocessor Input Shape: 3 Input Frequency: 100 Hz

Training

Settings Sliding Window (data points)
Window Shape: [100,3]
Stride: 3
Buffer Multiplier: 1

Data

Preprocessor Batch Size: 128 Split Count: 16

Training

Settings

Name	Class Weights	P	Layers	Epochs	Learning Rate	Weight Decay	Patience			
conv1dlstm-la	Shared	23	31	25	0.00100	0.00400	18			
conv1dlstm-la	Shared	66	31	25	0.00100	0.00400	18			
conv1dlstm-la	Shared	21	33	25	0.00100	0.00100	18			
conv1dlstm-la	Shared	62	33	25	0.00100	0.00100	18			

Vzporedno učimo 4 različice nevronske mreže, ki se razlikujejo po številu uteži

Job FOGclassification – LSTM nova proba 6-LeakyR
[edit]
Job completed
Job will expire and be deleted in 12d 7h 38m 23s [Extend time]


Name	Selected Best	Status	Message	Train Accuracy	Validation Accuracy	Test Accuracy	Train F1Score	Validation F1Score	Test F1Score	Train Best Loss	Validation Best Loss	Parameters	Download
conv1dlstm-large-accuracy-0		Completed	Training completed	0.8418	0.7544	0.7474	0.8460	0.7621	0.7131	0.6605	0.7329	23956	
conv1dlstm-large-accuracy-1		Completed	Training completed	0.8735	0.7649	0.5757	0.8740	0.7646	0.5326	0.5826	0.8133	66020	
conv1dlstm-large-accuracy-2		Completed	Training completed	0.7934	0.7212	0.6652	0.7973	0.7426	0.6363	0.6505	0.7995	21588	
conv1dlstm-large-accuracy-3		Completed	Training completed	0.8162	0.7379	0.7214	0.8222	0.7489	0.6921	0.5186	0.7990	62116	

Problemi pri učenju nevronske mreže

- Neuravnotežen nabor podatkov – dejanski dogodki zamrznitve se pojavljajo veliko redkeje kot dogodki brez zamrznitve
- Čas učenja – traja več ur pri velikem naboru podatkov
- Frekvenčno ne ujemanje – frekvenca tipanja pospeškometra s katerim so bili pridobljeni podatki se je razlikovala od frekvence tipanja ki je možna na našem pospeškometru
- Veliko nastavljenih parametrov – za ustrezno delovanje je potrebno ustrezno nastaviti več različnih parametrov

Odpravljanje problemov pri učenju

Podatke obdelamo
Sami pred učenjem



V primeru neuravnoteženega nabora podatkov, lahko določene podatke odvezemamo ali dodajamo, da pridobimo bolj enakovredno porazdelitev (angl. *Oversampling* ali *Undersampling*)

Priprava podatkov za učenje

- Obrezovanje podatkov – podatke, ki so nepotrebni ali v prevelikem številu lahko odrežemo da zmanjšamo količino podatkov za učenje in posledično tudi čas učenja (npr. iz cca. 1000 minut podatkov smo zmanjšali na 280 minut podatkov).
- Poenotenje frekvence podatkov (128 Hz) in frekvence našega pospeškometra (100 Hz) – to se je prav tako rešilo med stopnjo obdelave podatkov s t.i. postopkom zmanjšanja vzorčenja (angl. *Downsampling*)

Rezultati nevronske mreže za zaznavo zamrznitve koraka

- Zaznavanje zamrznitve koraka, se je izkazalo veliko bolj težavno kot sam padec saj imamo več kategorij zamrznitev, katere ni enostavno razlikovati.

		Actual				
		(unlabelled)	StartHesitation	Turn	Walking	Total
Predicted	(unlabelled)	90.53 %	2.03 %	25.17 %	5.88 %	-
	StartHesitation	0.87 %	79.39 %	9.54 %	22.04 %	-
	Turn	5.12 %	11.13 %	48.80 %	58.07 %	-
	Walking	3.49 %	7.45 %	16.48 %	14.00 %	-
	Total	100.00 %	100.00 %	100.00 %	100.00 %	Σ-

Display Unit:

(ACC) Accuracy: 75.144 %
(F1S) F1 Score: 75.603 %

Unabelled – Ni zamrznitve
StartHesitation – Zamrznitev ob dvigu iz sedečega položaja
Turn – Zamrznitev med obračanjem
Walking – Zamrznitev med hojo

Implementacija nevronske mreže na mikrokontrolerju

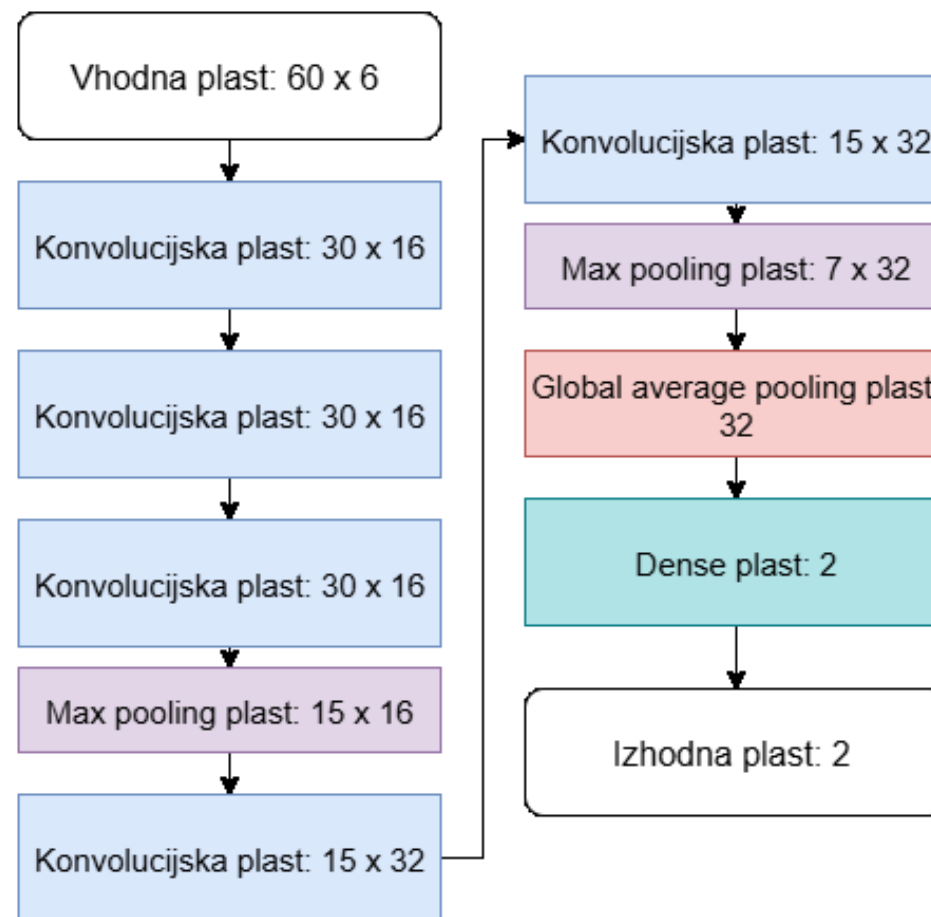
- Naučene mreže je možno naložiti kot datoteko in jih pretvoriti v programsko kodo v C jeziku, katero lahko vključimo v naš program – TensorFlow Lite
- Za celotno pretvorbo poskrbi Deepcraft Studio, potrebna je le ustrezna vključitev

The screenshot shows the configuration window for building a TensorFlow Lite model on an Infineon PSoC 6. The interface is divided into several sections:

- Architecture:** Infineon PSoC
- Target Device:** PSoC 6
- Output Directory:** Infineon
- Output File Prefix:** model
- C Prefix:** IMAI_
- Optimization:**
 - Preprocessor Acceleration: None - Don't use CMSIS
 - Enable Network Quantization:
 - Use Project File (.improj): (with a file selection button)
 - Recursive Directory Search: (with a file selection button)
 - Enable Sparsity:
- Validation:**
 - None:
 - Use Random Numbers:
 - Use Project File (.improj): (with a file selection button)
 - Recursive Directory Search: (with a file selection button)
 - Max Data Files: 1000

At the bottom, there are buttons for "Generate Code", "Cancel Build", and links for "Show Progress in Console" and "How do I use the generated code?".

Zgradba nevronske mreže za zaznavanje padca



Rezultati nevronske mreže za zaznavanje padca



Zaznavanje padca z nevronske mreže je bilo zelo uspešno, zaradi preproste izvedbe (je padec/ni padca).

		Actual		Total
		(unlabelled)	fall	
Predicted	(unlabelled)	98.55 %	14.63 %	-
	fall	1.45 %	85.37 %	-
Total		100.00 %	100.00 %	Σ-
Display Unit		Normalize		▼
(ACC) Accuracy		98.449 %		
(F1S) F1 Score		98.807 %		

(Unlabelled v našem primeru pomeni „ni padca“)

Umetna inteligenca v dobro ljudi




Strnjena izvedba vezij in pritrditev na usnjen pas



višina škatle 40 mm


Umetna inteligenca v dobro ljudi

Porazdeljena izvedba vezij za pritrditev na pas



Zmanjšana debelina sistema z mikrokrmilnikom na 15 mm

Porazdeljena pritrnitev na usnjen pas



Namestitev okoli pasu z usnjenim pasom je hitra in nevpadljiva



Umetna inteligenca v dobro ljudi

Za prikaz delovanja smo izbrali zaznavanja padca

Preizkušanje delovanja na zamrznitev koraka je težavno zaradi naključnosti pojava zamrznitve koraka in tveganja za padeč.

