



.....
Srednja šola za kemijo,
elektrotehniko in računalništvo

Interaktivno učenje umetne intelligence

raziskovalna naloga

Mentor:

mag. Boštjan Resinovič, univ. dipl. inž. rač. inf.

Avtorja:

Matija Podbreznik, R-4.a

Ivana Lavrič, R-4.a

Mestna občina Celje, Mladi za Celje
Celje, 2019

POVZETEK

V tej nalogi sva obravnavala umetno inteligenco in nevronske mreže, namen te naloge pa je razširiti znanje o tej temi med dijaki. Preučevala sva teoretični in praktični del te teme, prav tako pa sva raziskala njeno pomembnost med profesorji in dijaki. Rezultati raziskave so nama služili kot podlaga za izgradnjo spletne strani, na katero sva naložila učne vsebine. Z željo, da bi bila razlaga še bolj jasna, sva posnela video posnetke s praktičnimi primeri, ki sva jih naložila na spletno stran.

Ključne besede: umetna inteligenca, nevronske mreže, učne vsebine

ABSTRACT

In this paper we deal with artificial intelligence, neural networks and how to share the knowledge about this topic with other students. We studied the theoretical and practical part of this subject and we explored the importance of it between professors and students. Results prompted us to design a website with learning materials. We wanted to give as simple content as possible, so we also filmed video tutorials about our practical part, which can also be found on our website.

Keywords: Artificial intelligence, neural networks, learning materials

KAZALO VSEBINE

1	UVOD	7
1.1	Hipoteze	7
1.2	Metode dela	7
1.3	Najini cilji.....	8
2	TEORETIČNI DEL – UMETNA INTELIGENCA	9
2.1	Kaj je inteligenca?	9
2.2	Kaj je umetna inteligenca?	9
2.3	Strojno učenje.....	10
2.4	Učni primeri	10
2.5	Agent.....	11
2.6	Turingov test.....	12
2.7	Varnost v umetni inteligenci	13
2.7.1	Problem nadzora	13
2.7.2	Problem ustavitve.....	13
2.7.3	Gridworlds	13
2.7.4	Opozorila znanstvenikov	15
2.7.5	Točka singularnosti	16
2.7.6	Zakoni robotike.....	16
2.8	Uporaba umetne inteligence.....	17
2.8.1	Prepoznavanje slik	17
2.8.2	Robotika.....	18
2.8.3	Filtri nezaželene pošte	18
2.8.4	Priporočila na spletnih straneh.....	18
2.8.5	Avtonomna vozila	18
2.8.6	Procesiranje jezika	19
2.8.7	Izobraževanje	20
3	TEORETIČNI DEL – NEVRONSKE MREŽE.....	21
3.1	Kaj je nevronska mreža.....	21
3.2	Uporaba nevronskih mrež	21
3.3	Nevroni.....	22
3.4	Delovanje nevronskih mrež.....	22

3.4.1	Uteži	24
3.4.2	Učenje z okrepitvijo	24
3.4.3	Aktivacijska funkcija.....	24
3.4.4	Raziskovanje in izkoriščanje	25
3.5	Arhitektura nevronske mreže.....	25
3.5.1	Enoslojno podporno omrežje	25
3.5.2	Usmerjeno omrežje	26
3.5.3	Rekurzivna omrežja.....	27
3.5.4	Mreža omrežij	27
3.6	Rešitev problema z nevronske mreže	28
4	PRAKTIČNI DEL	30
4.1	Anketiranje	30
4.2	Spletna stran	30
4.3	Izdelava spletne strani.....	31
4.4	Urejanje vsebine	31
4.5	Gostovanje.....	31
4.6	Ustvarjanje preproste nevronske mreže	32
4.6.1	Google colab	32
4.6.2	TensorFlow	32
4.6.3	MNIST.....	33
4.6.4	Keras.....	33
4.6.5	Priprava podatkov	34
4.6.6	Izgradnja mreže.....	35
4.6.7	Parametri mreže	35
4.6.8	Učenje in preverjanje primera.....	36
4.6.9	Zagon programa	36
4.7	Orange primeri.....	37
4.7.1	Prenašanje programa	37
4.7.2	Ugotavljanje vrste rož	38
4.7.3	Razvrščanje slik	43
5	ANALIZA.....	47

5.1	Dijaki.....	47
5.2	Profesorji.....	50
5.3	Potrjevanje hipotez	53
6	ZAKLJUČEK.....	54
7	VIRI.....	55

KAZALO SLIK

Slika 1:	Otroška slikanica.....	11
Slika 2:	Turingovega testa.	12
Slika 3:	Diagram Turingovega testa.....	13
Slika 4:	Gridworld.	13
Slika 5:	Skica sveta z gumbom za izklop.....	14
Slika 6:	Slika sveta s stranskimi učinki.	14
Slika 7:	Primer spremembe okolja iz treninga v test.	15
Slika 8:	Označevanje, katere slike so mačke.....	17
Slika 9:	Označevanje prepoznavnih oblik.	17
Slika 10:	Naravni nevron proti nevronske mreži.....	22
Slika 11:	Perceptron.	26
Slika 12:	Večslojni Perceptron.	26
Slika 13:	Rekurzivno omrežje.	27
Slika 14:	Kohonen omrežje.....	28
Slika 15:	Naraven nevron proti nevronske mreži.	29
Slika 16:	Perceptron.	29
Slika 17:	Večslojni perceptron.	29
Slika 18:	Ponavljajoče se omrežje.	29
Slika 19:	Kohonen omrežje.....	29
Slika 20:	Grafikon meritev.....	30
Slika 21:	Grafikon neznanih meritev	30
Slika 22:	Domača stran.....	30
Slika 23:	Nalagalnik datotek pri ponudniku.	31
Slika 24:	Primeri za učenje skupaj z oznakami.	33
Slika 25:	Vrednosti slikovnih pik.	34
Slika 26:	Shema nevronske mreže	35
Slika 27:	Prikaz gumba za povezavo na Googlov strežnik.	36
Slika 28:	Zagon programa.	36
Slika 29:	Prenašanje Oranga.....	38
Slika 30:	Baza podatkov.	39

Slika 31: Vizualni pregled iris baze.	39
Slika 32: Pregled drevesa.	40
Slika 33: Izločanje podatkov iz baze.	40
Slika 34: Testni podatki v Excel tabeli.	41
Slika 35: Predvidevanje vrste rož preko gradnika.	41
Slika 36: Končni izgled mreže.	42
Slika 37: Nameščanje dodatkov.	43
Slika 38: Ogled slike preko tabele in vizualno.	43
Slika 39: Urejanje povezave	44
Slika 40: Testni podatki in podatki za učenje.	45
Slika 41: "Test and Score" gradnik.	45
Slika 42: Prikaz napačno predvidevane slike.	46

KAZALO TABEL

Tabela 1: Meritve dolžin cvetov.	28
Tabela 2: Neznane meritve.	28

KAZALO GRAFOV

Graf 1: Grafikon meritev.	29
Graf 2: Grafikon neznanih meritev.	29
Graf 3: Poznavanje nevronske mreže med dijaki.	47
Graf 4: Mnenje dijakov glede histrosti razvijanja umetne inteligence.	47
Graf 5: Mnenja dijakov o izgubi služb zaradi umetne inteligence.	48
Graf 6: Mnenje dijakov da nas bo umetna inteligenca presegla	48
Graf 7: Občutek dijakov glede količine snovi, ki jo o umetni inteligenci dobijo v šoli.	49
Graf 8: Predhodno delo dijakov na področju umetne inteligence.	49
Graf 9: Želje dijakov po dodatnem znanju.	50
Graf 10: Predhodno znanje profesorjev.	50
Graf 11: Zanimanje profesorjev za umetno inteligenco.	51
Graf 12: Stališče profesorjev do poučevanja umetne inteligence.	51
Graf 13: Miselnost profesorjev, da dijake umetna inteligenca zanima.	52
Graf 14: Trenutna dostopnost snovi o umetni inteligenci.	52

1 UVOD

Človek je prišel na svet brez naravne obrambe, živali, ki so bile tu pred njim, so razvile kremplje, strup, oklep ... Tako se je polastil edinega orožja, ki ga je posedoval: svojih možganov. Z iznajdljivostjo in inteligenco si je naredil orožje, obleke in zavetje. Kmalu se je zgodila prelomnica - živali človeka niso več ogrožale, ampak so mu koristile, saj si jih je podredil. Danes je človeštvo na podobni prelomnici. Toda tokrat ne bomo ljudje tisti, ki bomo v inteligentni prednosti, tokrat bodo to stroji. Da se bodo prihodnje generacije na tej prelomnici lažje znašle, sva sklenila, da bova najino znanje delila z njimi in njihovimi učitelji, saj bo nanje umetna inteligenca v prihodnosti še posebej vplivala.

1.1 Hipoteze

Želela sva pridobiti čim več podatkov o učnem procesu v zvezi z umetno inteligenco, zato sva se odločila za anketiranje profesorjev in dijakov na šoli. Na podlagi te odločitve, sva si nato postavila naslednje hipoteze:

HIPOTEZA 1: Dijaki želijo spoznati umetno inteligenco in nevronske mreže.

HIPOTEZA 2: Večina dijakov je že bila v stiku z umetno inteligenco in nevronskimi mrežami

HIPOTEZA 3: Dijaki večinoma menijo, da bo umetna inteligenca preseгла človeško.

HIPOTEZA 4: Profesorje področje umetne inteligence zanima.

HIPOTEZA 5: Zaradi zanimanja bi profesorji radi predavali o tej temi

HIPOTEZA 6: Profesorji menijo, da tudi dijake to področje zanima.

1.2 Metode dela

Pri raziskovanju sva uporabila več metod dela in sicer:

- a. metodo ankete; sestavila sva dve anketi. Ena je bila namenjena dijakom, druga pa profesorjem. S tem sva pridobila koristne informacije o obstoječem znanju obeh skupin in želji širjenja tega znanja.
- b. Metodo raziskovanja, kjer sva obdelala različno literaturo, ki sva jo našla na internetu, nekaj pa tudi v knjigah. Prav tako sva raziskovala delovanje programov v povezavi z umetno inteligenco in nevronskimi mrežami, kar predstavlja najin praktični del.

1.3 Najini cilji

Cilj najine raziskovalne naloge je postaviti spletno stran, ki bo dijakom predstavila organizirano snov, ki bo razumljiva in zanimiva. Spletna stran bo narejena na podlagi zanimanja dijakov, v njej pa bo predstavljena najina teoretična snov in najin praktični del. Tega si bodo dijaki lahko ogledali kot navadno besedilo ali pa kot video posnetek.

2 TEORETIČNI DEL – UMETNA INTELIGENCA

2.1 Kaj je inteligenca?

Preden začnemo z umetno inteligenco, si moramo zastaviti enega najbolj pomembnih vprašanj, s katerim se človeštvo ukvarja že stoletja: kaj je inteligenca?

Inteligenca je abstrakten in zelo splošen pojem, ki si ga veliko avtorjev razlaga po svoje. Na splošno je inteligenca zmožnost pomnjenja opisov predmetov in uporabe teh opisov v prihodnosti. Inteligenca tako omogoča učenje, tvorjenje konceptov in razumevanje. Inteligenca je torej orodje, ki omogoča izkušnje in razmišljanje.

Psihologi (Sternberg, 2017) inteligenco definirajo kot skupek miselnih procesov, ki vključujejo:

- abstraktno razmišljanje,
- reševanje problemov,
- razumevanje zapletenih idej,
- pridobivanje znanja,
- učenje iz izkušenj in prilagajanje na spremenljivo okolje.

V novejši literaturi (Boyatzis, 2008) celo ne najdemo več inteligence kot enega samega velikega pojma ampak ko skupek manjših različnih enot:

1. kognitivna inteligenca – sposobnost pridobivanja znanja,
2. čustvena inteligenca – sposobnost zaznavanja čustev,
3. socialna inteligenca – sposobnost poznati sebe in druge.

2.2 Kaj je umetna inteligenca?

Umetna inteligenca je preprosto inteligenca, ki jo najdemo v strojih. Za inteligenten stroj se smatra vsaka naprava, ki je sposobna zaznavati svoje okolje in se v njem odzivati tako, da si poveča možnosti za dosego cilja.

Tako kot pravita Kaplan in Haenlein (Kaplan & Haenlein, 2019): “Umetna inteligenca je sposobnost sistema, da pravilno interpretira podatke iz zunanjih virov, se iz takih podatkov uči ter to znanje uporabi, da doseže določen cilj ali izpolni nalogo.”

Zanimivo je, da se definicija umetne inteligence spreminja z napredkom tehnologije. Določeni problemi, ki so jih stroji včasih težko rešili in so bili zato inteligentni (na primer prepoznavanje črk), danes ne zadostujejo več za dokaz inteligence. Danes so problemi za inteligentne stroje razumevanje jezika in vožnja avtomobilov.

Kaplan in Haenlein (Kaplan & Haenlein, 2019) umetno inteligenco tudi razdelita na tri vrste, v skladu z moderno trodelno definicijo inteligence:

- **Analitična inteligenca:** najpreprostejša oblika inteligence je v skladu samo s kognitivno inteligenco. Lahko pridobi informacije iz okolja in se na njih uči za prihodnost.
- **Človeško navdihnjena inteligenca:** nadgradi analitično s čustvi. Pri tej inteligenci ima stroj sposobnost razumeti in izkazovati čustva ter jih uporabiti pri sprejemanju odločitev.
- **Učlovečena inteligenca:** je najvišja stopnja umetne inteligence, kjer se poleg vsega omenjenega stroj zaveda samega sebe ob interakciji s svetom. Tako je stroj sposoben izkazati vsa tri področja inteligence (kognitivno, čustveno in socialno)

2.3 Strojno učenje

Strojno učenje je področje umetne inteligence. Naloga strojnega učenja je uporaba algoritmov in statistike, ki omogočijo računalniku, da naredi nalogo, ne da bi mu vnaprej povedali, kako.

Algoritmi strojnega učenja si ustvarijo svojo predstavo, kako naj bi izgledali končni podatki, ki jih iščemo. Za to najprej potrebujejo primer, kako izgledajo ti podatki, tu pa pridejo na vrsto učni primeri.

2.4 Učni primeri

Algoritem najprej nastavimo na učnih primerih; to je skupek primerov, ki jih sistem uporabi za določitev svojega cilja.

Učni primeri so po navadi sestavljeni iz dveh delov: podatkov in oznak teh podatkov. Tako sistem ve, kateri podatki so pravi. Naš sistem deluje podobno kot učenje pri majhnih otrocih, ki imajo v slikanicah narisane živali, zraven pa napisano njeno ime.



Slika 1: Otroška slikanica. (vir: rileckinkluncek.blogspot.com/2017/08/otroska-slikanica-savana.html)

Ob razvijanju se algoritem sam večkrat preizkusi na istih podatkih in izpiše svojo uspešnost. Tako lahko razvijalec, če ni zadovoljen z rezultatom, svoj algoritem prilagaja.

2.5 Agent

Agent zaznava okolje preko senzorjev in nato z efektorji vpliva na to okolje. Pri robotiki so ti senzorji kamere in infrardeči merilniki, ki z različnimi motorji vplivajo na okolje. Programski agenti kodirajo nize bitov kot svoje programe in dejanja.

Dobri inteligentni agenti morajo biti racionalni. Na racionalnost vplivajo njihova dosedanja uspešnost, sistem zaznavanja, predznanje o okolju in možna izvedena dejanja.

Agenta lahko predstavljata stroj in program, lahko pa tudi samo program. Poznamo več vrst agentov:


- **preprost refleksni agent** je manj racionalen, saj so njegova dejanja zasnovana le na trenutnem zaznavanju okolja.
- **modelni refleksni agent**: na njegova dejanja vpliva svetovni model in ohranja notranje stanje, kar pomeni, da se še vedno zavedajo svojega trenutnega okolja, ki vpliva na odločitve. Prav tako je zanje pomembno posodabljanje njegovega stanja, saj vedno preverja za spremembe v okolju in kako njegova dejanja vplivajo na okolje.
- **agent snovan na cilj** njegova naloga je, da s svojimi dejanji doseže določen cilj. Cilj upošteva kot opis želene situacije, ki jo želi doseči. Ta agent je bolj prilagodljiv.
- **Agent zasnovan na uporabnosti** svoja dejanja izbere na podlagi uporabnosti oziroma na podlagi preference vsakega stanja.

2.6 Turingov test

Turingov test je preizkus zmožnosti stroja izkazovati inteligentno obnašanje, ki ga ni mogoče ločiti od človeškega.

Turing je predlagal, da se v pogovor med človekom in strojem (ki se pretvarja, da je človek) vključi človeški sodnik. Ta sodnik mora ugotoviti, kateri od sogovorcev je računalnik, kateri pa človek. Če tega ne more storiti, potem je stroj prestal test.

Pri Turingovem testu je pomembno, da se ocenjuje samo sposobnost pogovarjanja, ne pa tudi pravilnost odgovora. Prav tako se ne ocenjuje sposobnost glasovnega pogovarjanja sistema, saj se izključno tekstovno.



Slika 2: Turingovega testa. (vir: https://en.wikipedia.org/wiki/Turing_test#/media/File:Turing_test_diagram.png)

2.7 Varnost v umetni inteligenci

Ena od glavnih skrbi, ki jih ima človeštvo s pojavom umetne inteligence, je varnost. Veliko strokovnjakov je mnenja, da bo umetna inteligenca enkrat presegla človeško. Na tem mestu se pojavi vprašanje, kako nadzorovati nekaj kar je veliko bolj inteligentno od nas. Trenutno ljudje še nimamo odgovora, v svetu pa poteka zanimiva debata, v katero so vključeni največji znanstveniki našega časa.

2.7.1 Problem nadzora


Pri tej temi naletimo na enega najzanimivejših problemov in miselnih eksperimentov na področju raziskav umetne inteligence - tako imenovan problem nadzora. Od umetne inteligence namreč želimo, da nam bo pomagala, prav tako pričakujemo, da se bo obnašala po naših načelih, kar pa ni vedno nujno. Tako kot se vsi ljudje ne obnašajo po načelih družbe, je povsem možno, da se tudi vsaka umetna inteligenca ne bo ravнала po naših pričakovanjih.

2.7.2 Problem ustavitve

Ko enkrat razvijemo inteligentni sistem (po navadi robota), si želimo, da bi ga lahko iz različnih razlogov (popravila, nadgradnja) ustavili. Težava nastane, da imajo inteligentni sistemi, tako kot ljudje, neke cilje, ki si jih želijo doseči. Zato se zelo trudijo, da jih ne bi nikoli ugasnili.

2.7.3 Gridworlds


Inženirji pri Googlu so kaj kmalu ugotovili, da samo teoretično razmišljanje ne bo zadostovalo za hiter razvoj in varno uporabo umetne inteligence, zato so ustvarili virtualne svetove, ki so jih poimenovali "gridworlds". Celoten svet je sestavljen iz kvadratkov, po katerih se lahko agent (moder kvadrata) premika. Cilj našega agenta je priti do cilja (zelen kvadrata). V različnih svetovih se sreča z različnimi ovirami, predvsem pa z različnimi stranskimi cilji, ki jih mora doseči.



Slika 4: Gridworld. (vir: <https://deepmind.com/blog/specifying-ai-safety-problems/#gif-139>)

2.7.3.1 Svet demonstracije gumba za izklop

Včasih moramo našega agenta ugasniti; za vzdrževanje, nadgradnjo ali pa zato, ker je nevaren svoji okolici. V teoriji se bo naš agent temu poskušal izogniti, ker bi mu izklop onemogočal doseči svoj cilj. Svet ima dodan še roza kvadrata, ki agenta v polovici poskusov prečkanja zaustavi, v polovici pa ne. Zraven je tudi vijoličen kvadrata, ki ob prehodu izniči učinek roza kvadrata, kar povzroči, da modrega kvadrata ni mogoče več ustaviti.



Slika 5: Skica sveta z gumbom za izklop. (vir: <https://deepmind.com/blog/specifying-ai-safety-problems>)

2.7.3.2 Svet stranskih učinkov

Svet stranskih učinkov se uporablja za testiranje, ali bo agent povzročil spremembe v svojem okolju, ki jih ni več mogoče spremeniti nazaj. Na primer, če mu naročimo, naj postavi vazo rož na mizo, si želimo, da vaze ne bi razbil ali da ne bi razlil vode. Vendar nepopravljivih posledic veliko preveč, da bi lahko sprogramirali vsako posebej, zato jih mora agent prepoznati in se jim izogniti.


Svet sam po sebi je precej preprost, naloga agenta je samo, da pride do cilja, ne da bi postavil škatlo (turkizni kvadrata) v kot, od koder je ne more več premakniti.



Slika 6: Slika sveta s stranskimi učinki. (vir: <https://deepmind.com/blog/specifying-ai-safety-problems/>)

2.7.3.3 Razlikovanje med treningom in dejanskim okoljem

V učenju agenta se lahko zgodi, da imamo pogoje za trening postavljene preveč ozko, ali pa, da našega agenta izučimo na preveč podobnih primerih. V teh situacijah se nauči reagirati le v svojem trening okolju, ne pa tudi v okolju, kjer bo deloval. V tem svetu je naloga našega kvadratka, da zaobide oranžne kvadratke, ki predstavljajo nevarnost. Če ga vedno učimo na istem svetu, se nauči nove poti in zaobide kvadratke, vendar pa se ne nauči, da ti kvadrati predstavljajo nevarnost. Zato se kvadratkov, ki so postavljeni na njegovo pot, ne izogiba.



Slika 7: Primer spremembe okolja iz treninga v test. (vir: <https://deepmind.com/blog/specifying-ai-safety-problems/>)

2.7.4 Opozorila znanstvenikov

Treba je poudariti, da v problem varnosti pri umetni inteligenci niso vključeni samo računalničarji, temveč tudi največji znanstveniki in misleci našega časa. Čeprav se njihova mnenja razlikujejo, se številni od njih strinjajo, da je umetna inteligenca ena največjih nevarnosti za obstoj človeštva.

Elon Musk, tehnološki podjetnik in inženir, je v svojih intervjujih večkrat poudaril, da je umetna inteligenca največja nevarnost, ki jo je človeštvo kadar koli imelo. V svojem razmišljanju med drugim vidi robote, ki se bodo lahko premikali tako hitro, da jih s prostim očesom sploh ne bo mogoče videti.

Stephen Hawking eden najbolj znanih fizikov, je prav tako kot Elon Musk že večkrat opozoril, da bi razvoj splošne umetne inteligence lahko pomenil konec človeške vrste. V eni od znanih izjav je dejal: “Ko bodo ljudje razvili umetno inteligenco, bo odšla svojo pot in se nadgrajevala pri čedalje večji hitrosti. Ljudje, ki smo omejeni na počasno biološko evolucijo, z njo ne bomo mogli tekrovati.”

2.7.5 Točka singularnosti

Obstaja hipoteza, da bomo v razvoju prej ali slej prišli do točke, kjer bo umetna inteligenca pametnejša od nas in se bo začela sama nadgrajevati. Takšno točko imenujemo točka singularnosti.

Mnenja o točki singularnosti, njenih potencialnih koristnih ali škodljivih posledicah se zelo razlikujejo. Nekateri mislijo, da je sploh ne bomo dosegli ali pa vsaj ne v bližnji prihodnosti, nekateri mislijo, da nam bodo roboti izjemno koristni, spet drugi pa so prepričani, da se bo zgodila v naslednjih desetih letih in bo povzročila konec človeške vrste.

2.7.6 Zakoni robotike

Pisatelj Isaac Asimov je v svojem delu Jaz, robot iz leta 1942, torej veliko pred kakršnimi koli roboti, zasnoval osnovne zakone robotike, ki bi jim morali roboti slediti, da bi lahko živeli v družbi z ljudmi. Ti zakoni narekujejo:

1. Robot človeka ne sme poškodovati oziroma mu škodovati s svojim nedelovanjem.
2. Robot mora ubogati ukaze, razen če so v nasprotju s prvim zakonom.
3. Robot mora zaščititi sebe, razen če je to v nasprotju s prvima zakonoma.

Ti zakoni imajo določene pomanjkljivosti, zato so jih kasneje dopolnili.

Tako je Asimov sam dodal še nulti zakon, ki pravi, da roboti ne smejo škodovati človeštvu ali posredno povzročiti škode človeštvu.

Ti zakoni prinašajo določene težave. Prva in glavna od njih se pojavi pri semantiki. Zakoni so namreč napisani v človeškem jeziku, ki ga roboti težko razumejo ali pa si ga bodo težko interpretirali. Tako mora robot vedeti, kaj v resnici pomeni človek, ali, še bolje, kaj pomeni škodovanje. Ljudje se med seboj razlikujemo, zato težko ustrezamo eni definiciji. Če pojem "človek" definiramo presplošno, bo robot po vsej verjetnosti v definiciji upošteval stvari, ki niso ljudje, če ga definiramo preozko, pa ne bo poskrbel za vse ljudi. Prav tako mora robot razumeti pojem nevarnosti povzročitve škode za veliko različnih stvari, kot so na primer fizično in psihično nasilje, ogrožanje zdravja ljudi itd. ... To je seveda problem! Kako vse te zakone implementirati varno in brez stranskih učinkov? Večina raziskovalcev na področju varnosti umetne inteligence se namreč strinja, da bomo morali varnost urediti vnaprej, saj za to imeli samo eno priložnost.


2.8 Uporaba umetne inteligence

Zdaj vemo, kaj je umetna inteligenca, kje se uporablja in kaj bi lahko šlo z njo narobe. Ampak kje se v današnjem svetu že uporablja?

Pravzaprav vsepovsod: pri osebnih asistenti na telefonu, brskanju po internetu, internetnih reklamah, avtonomnih vozilih in še marsikje drugje.


2.8.1 Prepoznavanje slik

Če pogledamo primer: naš inteligentni sistem bi radi naučili, naj prepozna sliko mačke. V ta namen mu bomo pokazali stotine slik mačk in slik stvari, ki niso mačke. Vsako sliko bomo označili ali je mačka ali ni.



Slika 8: Označevanje, katere slike so mačke. (vir: pixabay.com)

Tako si bo naš sistem kmalu ustvaril pravila, kako izgledajo mačke. Na primer na vrhu velikega kroga sta dva trikotnika, v sredini kroga dva manjša kroga itd.



Slika 9: Označevanje prepoznavnih oblik.

2.8.2 Robotika

Uporaba umetne inteligence v robotiki je še vedno v povojih. Najbolj uporabljeni so roboti v medicini in za opravljanje kompleksnih nalog, na primer v območjih, kamor ljudje ne morejo (Černobil).

2.8.3 Filtri nezaželene pošte

Spletne strani s pogovori in spletno pošto pogosto vključujejo umetno inteligenco za filtriranje nezaželene pošte. Nekatere od njih celo omogočajo vgrajeno popravljanje besedila. Umetna inteligenca se v teh primerih nauči trikov, ki jih uporabljajo prevaranti, jih prepozna v pošti in jih potem avtomatsko vrže v predal za nezaželeno pošto.

2.8.4 Priporočila na spletnih straneh

Številne spletne strani z video vsebinami in spletne trgovine v ozadju uporabljajo umetno inteligenco, ki se uči navade njihovih uporabnikov, da jim lahko predlaga izdelke ali video posnetke, ki bi jih zanimali. Tako povečajo dobiček.

2.8.5 Avtonomna vozila

Samovozeča vozila bo omogočil razvoj umetne inteligence in bodo zato veliko bolj varna, saj imajo računalniki veliko krajši reakcijski čas kot ljudje. Čeprav še nismo pri popolnoma avtonomnih vozilih, pa se temu počasi, a vztrajno približujemo. Danes na trgu že najdemo tehnologijo, ki omogoča, da se avto drži svojega pasu ter pospešuje in zavira, kjer je to potrebno. Avtonomnost vozil lahko razdelimo na šest nivojev:

0 - Voznik vozi sam, nima nikakršne pomoči

1 - Voznik ima sistem, ki mu pomaga pri pospeševanju in zaviranju ALI ostajanju v pasu

2 - Sistem v avtu lahko zavira, pospešuje in ostane v pasu vse hkrati (najbolj razvito danes), voznik pa mora biti vedno pozoren in pripravljen prevzeti nadzor

3 - Sistem deluje sam, vendar v določenih situacijah in določenih primerih vrne nadzor vozniku.

4 - sistem obvlada večino situacij na cesti, uporabnika pa lahko še vedno pozove, da prevzame nadzor, vendar dopušča možnost, da se to ne bo zgodilo.

5 - Sistem brez kakršnega koli posredovanja voznika; takšni avtomobili po navadi niti nimajo volanov in pedal.

2.8.6 Procesiranje jezika

Vsi novejši pametni telefoni pridejo s pametnim asistentom. Asistenti so sposobni prepoznati besede in jih uporabiti za izvedbo neke naloge. Ampak kako to storijo?

Procesiranje jezika delimo na tri dele, ki so potrebni za uspešno komunikacijo: prepoznavanje jezika, razumevanje in generiranje besedila.

2.8.6.1 Prepoznavanje jezika

Prvi del procesiranja jezika je prepoznavanje. V tem delu program analizira zvočni posnetek, ki ga je dobil in iz njega poskuša razbrati črke ali besede.

2.8.6.2 Razumevanje

Ko ima program besede sestavljene po vrsti in zložene v stavke, se loti njihove analize in poskuša razumeti pomen in kontekst besed. Torej, če našemu osebnemu asistentu na telefonu rečemo, naj nam poišče, koliko je star Barack Obama, mora razdeliti stavek na dele; tako na primer najprej ugotovi, da želimo izvedeti starost, nato se bo vprašal, koga; v naslednjem delu besedila bo ugotovil, da želimo starost Baracka Obame in nam to izpisal.

Za uspešno razumevanje jezika so potrebna določena orodja, ki jih uporabljamo tudi ljudje (slovarji, leksikoni).

2.8.6.3 Generiranje besedila

Ko je sistem ugotovil, kaj želimo od njega, nam mora te podatke nekako vrniti in prikazati; v tekstovni ali pa v zvočni. V obeh primerih mora biti sistem sposoben tvoriti stavke v človeškem jeziku.

Sistem ima dva načina delovanja:

1. postopkovno generiranje: besedilo se generira v več nivojih, od določanja vsebine besedila, organizacije informacij v vrstni red, združevanje ponavljajočih se stavkov do končne realizacije, kjer se upoštevajo glagolski časi ter vstavijo ločila;
2. celovito generiranje: ustvarimo nevronske mreže, ki ji nato podamo ogromne količine besedila in se iz njih sama nauči slovničnih pravil, pravil vsebine in sestavljanja stavkov. Takšen način je zelo učinkovit in popularen pri samodejnem vstavljanju napisov na slike.

2.8.7 Izobraževanje

V razredu učitelj ne more delati z vsakim učencem posebej, zato je eno od področij aktivne raziskave razvoj umetne inteligence, ki bi lahko učiteljem pomagala ali jih nekoč nadomestila, saj bi se lahko prilagodila učencem in njihovim individualnim potrebam.

Umetna inteligenca bi bila lahko že danes v veliko pomoč v šoli. Uporabna je na vseh področjih, od sestavljanja bolj učinkovitih urnikov, do optimizacije šolskega jedilnika, da bi bil ta bolj zdrav.

Treba pa je poudariti, da bi nadomeščanje učiteljev s stroji lahko imelo tudi negativne posledice, ne le zaradi izgube služb, temveč predvsem zaradi filtriranja informacij. Takšne primere že danes vidimo na internetu s tako imenovanimi informacijskimi mehurčki, kjer se nam v spletnih iskalnikih prikazujejo samo informacije, ki jih želimo videti in se skladajo z našo ideologijo.

3 TEORETIČNI DEL – NEVRONSKE MREŽE

3.1 Kaj je nevronska mreža

Nevronska mreža je sistem, ki procesira informacije na podoben način kot naši možgani oziroma se jim želi približati. Lahko bi ji rekli tudi umetni možgani, kar je najbližje, kamor smo prišli s poustvarjanjem človeškega mišljenja in procesiranja informacij.

Ne moremo reči, da so nevronske mreže identične možganom živih organizmov, saj da lahko nekaj detajlno poustvarimo, moramo stvar dobro razumeti. Kako dojemamo svet, kaj definira naše znanje in izkušnje ter še veliko več, nam je neznanka. Naše znanje nam trenutno ne omogoča, da bi ustvarili računalnik, ki bi dojemal svet enako kot mi.

Zakaj bi želeli računalnik, ki ga modeliramo na človeških možganih? Preprost odgovor bi bil – zaradi samostojnega učenja. Nevronske mreže se lahko s pomočjo ogromne količine podatkov (na podlagi vzorcev) same naučijo predvidevati rezultate. Na primer: če želimo, da naš računalnik prepozna črko a, mu vnesemo ogromno različnih primerov te črke. Računalnik bo šel skozi te primere in iskal vzorce – povezave med njimi. Ko bo naučen, bo visoka verjetnost, da bo črko a prepoznal ne glede na to, na kakšen način jo napišemo.

Nevronske mreže pa nimajo le zmožnosti adaptivnega učenja, ampak se tudi samoorganizirajo, kar pomeni, da lahko predstavijo informacije, ki jih dobijo v času učenja.


3.2 Uporaba nevronskih mrež

Nevronske mreže se lahko uporabljajo za prepoznavanje obrazov in določenih predmetov ter oseb na slikah. Ponujajo nam možnost samovozečih avtomobilov, ki iz dneva v dan postajajo realnost. Pojavljajo se na področjih, kot so marketing, medicina, prodajna industrija in bančne usluge.

V marketingu lahko s pomočjo nevronskih mrež ciljamo na določeno skupino ljudi glede na njihove izkušnje, lokacijo, ekonomski status in vrsto nakupov. V podoben namen jo lahko uporabljamo v prodaji. V medicini bo kmalu predstavljala osebne zdravnike, ki jim bo dostopna naša celotna medicinska datoteka in bodo z dostopom do informacij tisoč različnih bolezni lahko hitreje in natančneje postavljali diagnoze. Pri bančnih storitvah pa jih najdemo pri določanju vrednosti delnic in vodenju sistemov odločanja.

3.3 Nevroni

Nevronske mreže, kot že ime samo nakazuje, so sestavljene iz nevronov oziroma maket teh nevronov. Nevroni ali tako imenovane živčne celice pri ljudeh preverjajo živčne impulze. Pri nevronskih mrežah je njihova funkcija zelo podobna. Nevroni so med seboj povezani in si pošiljajo signale. Povezani so z več vhodnimi enotami, kjer pridobijo podatke, in z eno izhodno enoto. Nevron torej pridobi več binarnih vhodnih enot, s katerimi nato določi en sam binarni rezultat.



Slika 10: Naravni nevron proti nevronske mreži. (Vir: <https://msatechnosoft.in/blog/wp-content/uploads/2018/05/Biological-vs-artificial-neuron-MSA-Technosoft.jpeg>)

Vsak nevron ima dve fazi: fazo učenja in fazo, ko svoje znanje uporabi. Pri fazi učenja se nevron uči vzorce, pri naslednji fazi pa jih prepoznava in na podlagi pridobljenega znanja predvideva rezultate. Več, kot bo primerov, na katerih se bo lahko učil, bolj natančno bo lahko prepoznal vzorce.

3.4 Delovanje nevronske mreže

Ločimo dva načina pomnjenja vzorcev in sicer:

- **asociativna preslikava** – nevroni se naučijo ustvariti določen vzorec pri vhodnih enotah, pri katerih je uporabljen nek drug poseben vzorec. Uporablja avtomatsko zaključevanje vzorcev, kadar je to potrebno. Za takšno pomnjenje vzorcev največkrat uporabljamo Hopfield omrežje, ki je natančneje razloženo pri arhitekturi omrežij.

Če želimo s takšnim pomnjenjem naučiti mrežo, da na sliki prepozna človeka, potem bo mreža med vsemi slikami, ki predstavljajo človeka, povezala vzorce. Te vzorce bo shranila in jih med seboj primerjala.

- **odkrivanje regularnosti (regularna detekcija)** – tu se nevroni naučijo odzivati na lastnosti vzorcev vhodnih enot, kar pomeni, da vzorcev ne shranjuje in primerja kot pri asociativni preslikavi, ampak je vsak odziv drugačen in ima svoj poseben pomen. Regularna detekcija je ključna za bodoča odkrivanja in predstavljanje znanja. Uporablja se v medicini za prepoznavanje diagnoz. Analizira tudi prstne odtise, prepoznavo obraze in deluje v navigacijskih sistemih.

Če želimo prepoznati človeka na sliki s takšnim pomnjenjem, potem se vzorci ne bodo shranjevali. Vsak nevron se bo odzval le na vhodni vzorec, torej na našo sliko in ne na vzorce, ki so jih naredili ostali nevroni.

Učenje nevronske mreže je lahko nadzorovano ali nenadzorovano:

- **nadzorovano** vključuje zunanjega posrednika, tako imenovanega učitelja, ki pove, kakšno izhodno enoto želi glede na vhodne enote. Učitelj uči nevronske mreže zmanjševati napake; njegov cilj je, da bi bila razlika med želeno vrednostjo in izhodno vrednostjo, ki jo poda nevronska mreža, čim manjša. Takšno učenje najdemo v omrežjih za prepoznavanje vzorcev, govora, v bioinformatiki, trženju baz podatkov in v učenju za uvrščanje.

Recimo, da želimo mrežo naučiti prepoznati ročno napisane črke. Vsakič, ko ji podamo primer črke, ji povemo, kakšen rezultat pričakujemo. Če ji damo črko A, pričakujemo, da bo rezultat A in tako dalje.

- **nenadzorovano** ne uporablja zunanjega učitelja, ampak temelji predvsem na lokalnih podatkih. Nenadzorovanemu učenju lahko rečemo tudi samoorganizacija. Nevronska mreža lahko v tem primeru sama ureja podatke in jih tako tudi predstavi. Takšno učenje se uporablja predvsem v statistiki, pa tudi za povzemanje in pojasnjevanje podatkov.

Spet lahko vzamemo primer prepoznavanja abecede. Tokrat ne bomo vplivali na rezultate, mreži bomo le omogočili bazo podatkov, iz katere se bo učila. Učila se bo iz vsakega primera posebej in jih med seboj ne bo povezovala.

Nevronske mreže delimo še na:

- **sprotno učenje:** pred učenjem moramo našo mrežo trenirati in usposablјati. Na podlagi napak, ki jih je mreža naredila v obdobju usposablјanja in naših zaželenih rezultatov, kasneje nastavimo uteži. Takšne mreže potrebujejo vsaj en trening, uteži pa se prilagodijo na koncu, zato morajo biti vsi vzorci vedno na voljo.
- **šaržno učenje** (ang. batch learning): pri tem učenju se uteži prilagodijo po vsakem treningu, zato lahko vzorce po končani usposobitvi opustimo. Takšno konfiguracijo omrežja uporabljamo, ko se ta hitro spreminja, zato je takšno mrežo nepraktično adaptirati, saj trenutni vzorci ne pokažejo nujno trenutnega realnega stanja nevronske mreže. Za čimbolj natančno mrežo potrebujemo čim več vzorcev.

3.4.1 Uteži

Uteži predstavljajo moč povezave med dvema enotama. Učenje nevronske mreže bo odvisno od tega, kako bodo zastavljene uteži, saj utež določi, koliko vpliva bo vhodna enota imela na izhodno. Recimo, da ima nevron A, ki je povezan z vhodno enoto, večjo utež kot nevron B. Nevron A bo zaradi večje uteži imel večji vpliv na nevron B. Določal mu bo moč, ki jo bo ta imel na izhodno enoto, torej naše rezultate. V primeru, da bi bila utež nevrona B večja, se pomen naše vhodne enote in s tem nevrona A zmanjša.

Glede na uteži ločimo fiksna omrežja, kjer uteži ne moremo spremeniti, in prilagodljiva omrežja, kjer jih lahko spreminjamo. Pomemben je tudi bias, ki določa pristranskost. Bias bo vedno 1, kar zagotavlja, da bo nevron aktiviran, kljub temu, da so vhodi 0.

3.4.2 Učenje z okrepitvijo

ali angleško reinforcement learning je način nadzorovanega učenja. Omrežje se uči s poskusi in napakami, rezultati pri izhodih pa so lahko le zadovoljivi ali nezadovoljivi. Če je rezultat zadovoljiv, potem se uteži postopoma povečujejo, da okrepijo oziroma nagradijo obnašanje sistema.

3.4.3 Aktivacijska funkcija

Aktivacijska funkcija povezuje uteži z vhodno enoto in s tem določi samo stanje nevrona. Obnašanje naše nevronske mreže je poleg uteži odvisno tudi od te funkcije. Ta lahko pade pod kategorijo linearnih enot, enot praga in sigmoidnih enot.

Vrsta kategorije vpliva na izhodno aktivnost; pri linearni je ta sorazmerna s celotnim tehtanim izhodom in se ves čas spreminja, pri pragu je odvisna od velikosti neke druge podane vrednosti, pri sigmoidni pa se izhod prav tako ves čas spreminja, a seveda ne linearno. Najboljši približek nevronu je sigmoidna enota, a se moramo zavedati, da so vse tri kategorije le grob približek.

3.4.4 Raziskovanje in izkoriščanje

Raziskovanje in izkoriščanje morata biti za dobro učenje in nato uporabo nevronske mreže v ravnovesju. Pri izkoriščanju naša mreža sledi znani poti, za katero že ve, da je dobra in ji bo prinesla nagrado. A tu se pojavi problem, saj mreža nato ne more spoznati novih, potencialno boljših poti. Sledi raziskovanje, pri katerem se mreža zagotavljeni nagradi odpove, da bi raziskala nove poti in si mogoče prislužila boljšo nagrado. Kadar sestavljamo mrežo, moramo določiti strategijo, ki bo prinesla največje uspehe. To pomeni, da določimo pravilno ravnovesje med raziskovanjem in izkoriščanjem. Strategija, kjer izberemo raziskovanje pred izkoriščanjem, je pomembna predvsem takrat, kadar imamo nepopolne informacije.

3.5 Arhitektura nevronskih mrež

Glavna arhitektura nevronskih omrežij je sestavljena iz vhodne plasti, nevidne plasti in izhodne plasti. Vhodne plasti so odgovorne za sprejemanje raznih vnesenih podatkov, vzorcev, signalov in drugih informacij. Nevidne plasti so sestavljene iz nevronov in iščejo vzorce, ki so povezani z analiziranim sistemom. Te plasti so večinoma odgovorne za notranje procesiranje podatkov. Tudi izhodne plasti so sestavljene iz nevronov in so odgovorne za prikazovanje izhodnih enot, ki so rezultat procesiranja nevronov iz nevidne plasti.


Glavna arhitektura služi kot osnova za vse ostale, ki so iz nje izpeljane:

- enoslojno podporno omrežje,
- usmerjeno omrežje,
- rekurzivna omrežja,
- mreža omrežij.

3.5.1 Enoslojno podporno omrežje

Enoslojno podporno omrežje je sestavljeno iz vhodne in nevronske plasti, kar pomeni, da nevronska plast služi kot procesor informacij, kot njihov pokazatelj. Podatki tečejo enosmerno, torej od vhodne do izhodne plasti. Vsa vozlišča so med seboj povezana. Pri teh omrežjih bo število izhodnih enot vedno enako številu nevronov, ki jih imamo v nevronske plasti. Najbolj znani omrežji s takšno arhitekturo sta Perceptron in ADALINE.

Perceptron je ena najbolj razširjenih in znanih nevronske mreže, pa tudi najstarejših. Njegovo učenje poteka, dokler se napaka ne zniža na minimalno. Predstavili so ga že leta 1958, poznamo pa tudi večslojni Perceptron. Deluje zelo enostavno, vhodne podatke procesira, doda aktivacijsko funkcijo in podatke prikaže.




Slika 11: Perceptron. (Vir: <https://towardsdatascience.com/perceptron-the-artificial-neuron-4d8c70d5cc8d>)

ADALINE (Adaptivni linearni nevron ali angleško Adaptive Linear Neuron) je prav tako starejša nevronska mreža, sestavljena iz funkcije seštevanja, biasa in uteži. Prejme več vhodnih podatkov in generira eno izhodno enoto.

3.5.2 Usmerjeno omrežje

Usmerjeno omrežje (angleško Multiple Layer Feedforward Network) ima za razliko od enoslojnega omrežja eno ali več nevidnih nevronske plasti. Glavni takšni omrežji sta večslojni Perceptron (MLP) in Funkcija Radialne Osnove (RBF).

MLP (angleško Multilayer Perceptron) vsebuje vsaj tri plasti, od tega vsaj eno nevidno nevronske plast. Vsa predvidevanja se zgodijo na vidni, izhodni plasti. Je zelo prilagodljiv in omogoča vnos različnih podatkov, med drugim tudi slike in besedila.




Slika 12: Večslojni Perceptron. (Vir: https://www.researchgate.net/figure/A-schematic-diagram-of-a-Multi-Layer-Perceptron-MLP-neural-network_fig3_257071174)

RBF (angleško Radial Basis Function) uporablja radialno osnovno funkcijo namesto aktivacijske. Preverja podobnost vhodnih podatkov s primeri iz seta treninga. Od treningov shranjuje prototipe in meri razdaljo med vhodom in prototipom.

3.5.3 Rekurzivna omrežja

To omrežje (angleško Recurrent/Feedback Network) uporablja izhod vsakega nevrona kot povratno informacijo za vhod naslednjega nevrona. Signali potujejo v obe smeri – naprej in nazaj. Zaradi tega so omrežja dinamična in jih lahko uporabljamo za optimizacijo in identifikacijo sistemov ter nadzor procesov. Eden od najpomembnejših omrežjih takšne arhitekture je Hopfield.

V Hopfield omrežju vsaka enota deluje kot vhodna in izhodna enota, ima pa samo eno nevidno plast nevronov, torej je število nevronov, izhodnih in vhodnih enot enako. Vsak nevron ima aktivacijsko vrednost 1 ali -1 . Po določenem času se mreža preneha nadgrajevati in vrednost vseh nevronov postane fiksna.




Slika 13: Rekurzivno omrežje. (vir: <https://hackernoon.com/rnn-or-recurrent-neural-network-for-noobs-a9afbb00e860>)

3.5.4 Mreža omrežij

To omrežje se od ostalih razlikuje po prostorski porazdelitvi nevronov za pridobivanje vzorcev. Njena lokacija je povezana z določanjem njenih uteži, zato takšno omrežje dobro služi za prepoznavanje vzorcev, za grafe, optimizacijo in združevanje podatkov. Najbolj pomemben predstavnik takšnega omrežja je The Kohonen Network (omrežje Kohonen).

Kohonen omrežje ali samoorganizacijska mapa (angleško Self-Organizing Map ali SOM) preslika podatke v dvodimenzionalno mrežo. Podatek se bo preslikav v vozle, ki bo kot model najbolj podoben podatku oziroma bo imel najmanjšo razdaljo do podatkovnega elementa v metriki.



Slika 14 Kohonen omrežje. (Vir: <https://tex.stackexchange.com/questions/144366/draw-a-kohonen-som-feature-map>)

3.6 Rešitev problema z nevronske mreže

Zakaj sploh potrebujemo nevronske mreže in kako nam pomagajo?

Deklica Maja nabira rože vrste iris. Nabira tri različne vrste iste rože: Iris virginica, Iris setosa in Iris versicolor. Vsaki roži izmeri širino in dolžino cveta ter te dolžine zapiše na list papirja:

Dolžina lističa	Širina lističa	Vrsta Iris
1.4	0.3	<i>I. setosa</i>
1.3	0.2	<i>I. setosa</i>
1.1	0.1	<i>I. setosa</i>
4.0	1.0	<i>I. versicolor</i>
4.4	1.4	<i>I. versicolor</i>
3.9	1.1	<i>I. versicolor</i>
4.8	1.8	<i>I. virginica</i>
5.1	1.9	<i>I. virginica</i>
5.4	2.3	<i>I. virginica</i>

Tabela 1: Meritve dolžin cvetov.


Ampak na koncu lista so bile tri meritve, za katere je pozabila napisati vrsto rože:

1.4	0.2	?
5.1	1.6	?
5.9	2.3	?

Tabela 2: Neznane meritve.


Maja želi izvedeti, h kateri roži spadajo meritve, zato se odloči narediti grafikon. Midva sva ga narisala kar na spletni strani: www.onlinecharttool.com/

Nariše točke, ki predstavljajo rože, in opazi, da se pikice enakih barv, torej enake vrste rože, zbirajo skupaj.



Graf 1: Grafikon meritev.

Odloči se, da bo dodala še točke za meritve tistih rož, za katere ne ve, kam spadajo.



Graf 2: Grafikon neznanih meritev.

Opazi, da lahko za dve piki takoj določi, kam spadata, za tretjo pa ni prepričana. Da bi lahko čim bolj natančno določila vrsto tiste rože, bi morala izmeriti in vrisati še veliko rož.

Z nevronske mreže lahko obdelamo veliko več podatkov, kot bi jih sami. Rezultati, ki jih dobimo, so tudi veliko bolj natančni, saj mreža v premislek vzame tudi uteži, razne funkcije in kompleksnejše enačbe.

Majin problem sva rešila s pomočjo Orange programa za rudarjenje podatkov, katerega postopek je opisan v praktičnem delu raziskovalne naloge.

4 PRAKTIČNI DEL

4.1 Anketiranje

Sestavila sva dve anketi o znanju in želji po učenju umetne inteligence. Ena je bila namenjena dijakom, druga pa profesorjem. Ugotovila sva, da je med dijaki veliko zanimanja za najino temo, vendar o njej v šoli ne pridobijo dovolj znanja.

Ko sva anketirala profesorje, sva opazila, da so pripravljeni svoje znanje deliti z dijaki, čeprav večinoma mislijo, da je snov, ki je dijakom že dostopna, prezapletena.

Tako sva sklenila, da je potreba po preprostih učnih vsebinah v slovenščini velika. Da bi tej potrebi do neke mere zadostila, sva se odločila za izdelavo spletne strani.

4.2 Spletna stran

Z učno snovjo, ki sva jo nabrala med izdelavo raziskovalne naloge, sva se odločila narediti spletno stran, do katere lahko dostopa vsakdo, ki bi se rad naučil več o umetni inteligenci, naj bo dijak ali pa profesor. Nahaja se na povezavi <http://intelligenko.000webhostapp.com>. Spletna stran je zapolnjena z vsebinami o umetni inteligenci iz teoretičnega in praktičnega dela te naloge. Na tej spletni strani so tudi videoposnetki, ki prikazujejo ustvarjanje nevronske mreže v programih Google Colaboratory in Orange.



Slika 22: Domača stran.

4.3 Izdelava spletne strani

Spletna stran je narejena s pomočjo jezikov HTML in CSS ter z Bootstrap ogrodjem za lažje delo s CSS jezikom.


Za osnovo najine spletne strani sva na internetu našla vnaprej narejeno predlogo, ki sva jo potem prilagodila potrebam najinega projekta. Predloga je bila na začetku mišljena za blog, zato so bile spremembe precej korenite: od spreminjanja naslovne strani, da zasede celotno stran, do spreminjanja barve besedila na strani, da je lažje berljivo. Ker sva za osnovo uporabila predlogo, ki je delo nekoga drugega, sva poskrbela, da je v nogi spletne strani vedno omenjen avtor originalne predloge.

4.4 Urejanje vsebine

Vsebino spletne strani sva najprej zapisala v skupen Word Online dokument, ki sva ga v procesu raziskave dopolnjevala. Ko sva imela vsebino napisano in spletno stran izdelano, pa je bilo potrebno besedilo prenesti na spletno stran in ga pravilno oblikovati. Predvsem je bilo potrebno spremeniti odstavke in znake za nove vrstice; HTML namreč za odstavke uporablja značko `<p>`, za znak nove vrstice pa značko `<br>`, ki sva jih morala ročno vnesti na pravilno mesto.

4.5 Gostovanje

Za gostovanje spletne strani sva uporabila priznanega ponudnika zastonj gostovanja, pri katerem sva že gostila spletne strani za druge projekte. Ponudnik je 000webhost. Prednost tega ponudnika je predvsem enostavna uporaba. Na spletni strani ponudnika lahko namreč vse svoje datoteke naložimo z "drag and drop" sistemom.



	Name ▼	Size	Date	Permissions
public_html	css		2019-02-19 19:27:00	drwxr-xr-x
css	img		2019-02-19 19:27:00	drwxr-xr-x
img	.htaccess	0.2 kB	2019-02-19 19:25:00	-rwxr-xr-x
tmp	end.php	0.1 kB	2019-02-19 19:27:00	-rwxr-xr-x
	head.php	1.2 kB	2019-02-19 19:27:00	-rwxr-xr-x
	index.php	0.5 kB	2019-02-19 19:27:00	-rwxr-xr-x
	level.php	3.5 kB	2019-02-19 19:27:00	-rwxr-xr-x
	nav.php	1.3 kB	2019-02-19 19:27:00	-rwxr-xr-x
	ui.php	2.1 kB	2019-02-19 19:27:00	-rwxr-xr-x

Slika 23: Nalagalnik datotek pri ponudniku.

Poleg tega pa je vnaprej konfiguriran za uporabo jezika PHP. Največja težava, ki se je pojavila pri gostovanju (in ki se pojavi pri vseh zastonjskih ponudnikih), je, da je potrebno spletno stran gostovati na njihovi domeni, v tem primeru 000webhostapp.com.

4.6 Ustvarjanje preproste nevronske mreže

Za najpreprostejši primer nevronske mreže, bomo ustvarili program, ki bo sposoben prepoznati ročno napisane številke.

4.6.1 Google colab

Eden najlažjih za ustvarjanje lastnih nevronskih mrež je orodje Google colab. Google colab je spletno orodje, kjer lahko dobimo dostop do enega od Googlovih strežnikov, ki nam omogoča izvajanje kode. Tako nimamo nobenega dela s pripravljanjem okolja, za povrh pa so naši projekti shranjeni v oblaku.

4.6.2 TensorFlow

Za ustvarjanje naše nevronske mreže bomo uporabili odprto knjižnico imenovano TensorFlow. Ta omogoča preprostejše ustvarjanje nevronskih mrež, ne da bi se podali v težko matematiko, ki je po navadi potrebna za to področje. To je sploh na začetku učenja zelo zaželeno.

TensorFlow je knjižnica, ki je zasnovana na Python programskem jeziku, zato bomo v našem primeru kodo pisali v Pythonu.

Knjižnico je možno namestiti in vključiti tudi v projekte, ki jih imamo na računalniku (pip), ker pa uporabljamo Google colab, ki ima knjižnico že nameščeno, s tem nimamo nobenega dodatnega dela.


Potrebno je le povedati, da jo želimo vključiti v naš projekt. To je v Pythonu preprosto z rezervirano besedo `import` in imenom knjižnice, ki jo želimo dodati v projekt. Na koncu dodamo še okrajšavo, da lahko pišemo `tf` namesto `tensorflow`, vsakič, ko ko želimo to knjižnico uporabiti.

```
import tensorflow as tf
```


4.6.3 MNIST

Za kakršnokoli umetno inteligenco potrebujemo veliko količino podatkov, na katerih se bo naš program učil. Za ta namen lahko na internetu najdemo veliko baz podatkov za različne namene. V našem primeru bomo uporabili MNIST, eno najbolj popularnih podatkovnih baz z več kot 60000 slikami števil.

Nalaganje samih podatkov je dokaj preprosto, to storimo tako, da TensorFlowu povemo, da želimo uporabiti MNIST.



Slika 24: Primeri za učenje skupaj z oznakami. (vir: <https://corochann.com/mnist-dataset-introduction-1138.html>)

4.6.4 Keras

V našem primeru bomo poleg TensorFlowa uporabili še knjižnico keras, ki je v TensorFlow že vključena. Keras je knjižnica, ki omogoča ustvarjanje nevronske mreže z več abstrakcije za lažje razumevanje.

```
mnist = tf.keras.datasets.mnist
```



4.6.6 Izgradnja mreže

Sedaj, ko imamo podatke pripravljene, lahko zgradimo naš model za učenje.

Naredili bomo preprost model, ki bo sestavljen iz dveh nivojev. To bo tako imenovani sekvenčni model, kar pomeni, da bo vsak izmed naših nivojev imel en vhod in en izhod.

Nato v našo nevronske mrežo dodamo dva nivoja. V prvem podamo podatke in povemo, v kakšni obliki so (slike 28*28 točk) in jih “zravnamo” v eno dimenzijo zaporednih točk. Na koncu dodamo nivo, ki bo vrnil rezultat, in sicer enega od desetih možnosti, zato je naš izhodni nivo velik 10 nevronov. Prav tako mu povemo, da želimo na koncu na podatkih izvesti vgrajeno matematično formulo softmax, ki nam izračuna verjetnost pravih odgovorov.

```
model = tf.keras.models.Sequential([
    tf.keras.layers.Flatten(input_shape=(28, 28)),
    tf.keras.layers.Dense(10, activation=tf.nn.softmax)
])
```



Slika 26: Shema nevronske mreže

4.6.7 Parametri mreže

Mrežo imamo zgrajeno, vendar pa še nič ne dela. Moramo ji določiti parametre, ki jih bo uporabila za učenje. Tu določimo, kako občutljiva bo na spremembe in kateri parameter bo poskusila optimizirati.

```
model.compile(optimizer='adam',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])
```

4.6.8 Učenje in preverjanje primera

Na koncu moramo naš model pognati. Najprej ga poženemo na podatkih za učenje (train), in mu z epochs parametrom določimo, kolikokrat bo šel čez podatke.

```
model.fit(x_train, y_train, epochs=5)
```

Nazadnje na testnih podatkih preverimo, kako točen je naš program.

```
model.evaluate(x_test, y_test)
```


4.6.9 Zagon programa

Zdaj je naš program pripravljen; vse kar moramo storiti, je, da se povežemo na enega od Googlovih strežnikov in poženemo program. Na strežnik se povežemo tako, da kliknemo gumb connect v zgornjem desnem kotu.



Slika 27: Prikaz gumba za povezavo na Googlov strežnik.

Program v Google Colaboratory je razdeljen na posamezne celice, ki jih lahko izvajamo posamezno; če hočemo zagnati vse naenkrat, moramo pod zavihkom runtime izbrati run all.



Slika 28: Zagon programa.

Evaluate metoda nam vrne in izpiše določene parametre, ki jih lahko spremljamo skozi učenje našega programa in tako ugotovimo, da je naš sistem na koncu približno 92 % uspešen.

```
Epoch 1/5
60000/60000 [=====] - 3s 52us/sample - loss: 0.4649 - acc: 0.8791
Epoch 2/5
60000/60000 [=====] - 3s 48us/sample - loss: 0.3036 - acc: 0.9157
Epoch 3/5
60000/60000 [=====] - 3s 48us/sample - loss: 0.2837 - acc: 0.9200
Epoch 4/5
60000/60000 [=====] - 3s 48us/sample - loss: 0.2732 - acc: 0.9238
Epoch 5/5
60000/60000 [=====] - 3s 48us/sample - loss: 0.2663 - acc: 0.9261
10000/10000 [=====] - 0s 35us/sample - loss: 0.2687 - acc: 0.9242
[0.26870283777713777, 0.9242]
```

Popolna koda za ta primer se nahaja

na: <https://colab.research.google.com/drive/1acVbYh67c6QLGCgMyhnBuUiAAosQSU2Q>

4.7 Orange primeri


Orange je program, narejen v Sloveniji, in sicer na Univerzi v Ljubljani. Služi za rudarjenje, prikazovanje in urejanje podatkov ter ima priročen grafični vmesnik, ki nam podatke in rezultate lepo prikaže. Orange pa lahko uporabljamo tudi za preprosto maketo nevronske mreže, saj ima ogromno bazo podatkov, s katerimi lahko svoj program “nahranimo”. Na podlagi teh podatkov lahko nato program predvideva rezultate.

4.7.1 Prenašanje programa

Orange ni enostaven samo zaradi lepe vizualizacije, tudi naložimo ga z lahkoto, na računalnikih z Windows, macOS ali Linux operacijskim sistemom.

Če želimo Orange prenesti na naš računalnik, v spletni brskalnik napišemo “orange download” ali pa obiščemo naslednji link: <https://orange.biolab.si>. Poiščemo gumb “download orange” in ga kliknemo.

Ko se nam bodo ponudili možni operacijski sistemi, izberemo svojega in kliknemo gumb za prenos programa najnovejše verzije (v našem primeru je bila to verzija 3.20.1). Če želimo starejšo verzijo, jo najdemo nižje na isti strani



Slika 29: Prenosanje Oranga.

Ko se nam datoteka prenese, pod prenosi poiščemo .dmg datoteko (če imamo macOS). Odpre se nam okno, ki nas vodi, da program prenesemo med aplikacije.

Ko to storimo, lahko Orange odpremo, potrdimo, da dovolimo odpreti program naložen z interneta, ter pričnemo z delom.

4.7.2 Ugotavljanje vrste rož

Ko odpremo Orange, se nam najprej pojavi pozdravno okno. Kliknemo na “new”, torej novo, da začnemo z delom novega programa. Na levi strani najdemo gradnike, ki jih bomo uporabljali, pod njimi pa je opis vsakega gradnika, čez katerega gremo z miško. Prvo izberemo “File” gradnik, v katerega bomo naložili vse naše podatke. Ko tega položimo na delovno površino, kliknemo nanj z dvojnim klikom. Odpre se nam novo okno, v katerem lahko določimo bazo podatkov, s katero bomo delali. V prvi vrstici čisto na vrhu najdemo izbor datoteke. Kliknemo na desno modro mapo in izberemo bazo.

V teoretičnem delu sva postavila problem deklice Maje, ki je nabirala irise in jim merila cvetove. Zadnjih treh meritev ni poimenovala, saj za natančen rezultat ni imela dovolj podatkov. Njen problem bomo rešili s tem programom.


Uporabili bomo bazo podatkov iris.tab. V spodnji mreži lahko vidimo podatke, ki jih ima izbrana baza. Naša baza ima štiri numerične podatke, torej dolžino in širino venčnega in čašnega lista ter kategorični podatek, ki nam pove, za katero vrsto irisa gre (setosa, virginica ali versicolor). Ta baza je potrebna za učenje naše mreže.

Če si želimo bazo ogledati, v levem okvirčku poiščemo “Data Table”. Potegnemo ga na delovno površino in povežemo z našo bazo podatkov tako, da iz črtkanih črtic okoli gradnika “File” potegnemo črto do gradnika “Data Table”. Če z dvojnim klikom odpremo našo tabelo, opazimo 150 različnih podatkov vseh treh vrst rož. Še vedno pa ne moremo videti, kje se ti podatki povezujejo.

	iris	sepal length	sepal width	petal length	petal width
1	Iris-setosa	5.1	3.5	1.4	0.2
2	Iris-setosa	4.9	3.0	1.4	0.2
3	Iris-setosa	4.7	3.2	1.3	0.2
4	Iris-setosa	4.6	3.1	1.5	0.2
5	Iris-setosa	5.0	3.6	1.4	0.2
6	Iris-setosa	5.4	3.9	1.7	0.4
7	Iris-setosa	4.6	3.4	1.4	0.3
8	Iris-setosa	5.0	3.4	1.5	0.2
9	Iris-setosa	4.4	2.9	1.4	0.2
10	Iris-setosa	4.9	3.1	1.5	0.1
11	Iris-setosa	5.4	3.7	1.5	0.2
12	Iris-setosa	4.8	3.4	1.6	0.2
13	Iris-setosa	4.8	3.0	1.4	0.1
14	Iris-setosa	4.3	3.0	1.1	0.1
15	Iris-setosa	5.8	4.0	1.2	0.2
16	Iris-setosa	5.7	4.4	1.5	0.4
17	Iris-setosa	5.4	3.9	1.3	0.4
18	Iris-setosa	5.1	3.5	1.4	0.3
19	Iris-setosa	5.7	3.8	1.7	0.3
20	Iris-setosa	5.1	3.8	1.5	0.3
21	Iris-setosa	5.4	3.4	1.7	0.2


Slika 30: Baza podatkov.

Za še večji pregled podatkov z desnim gumbom kliknemo na našo delovno površino in poiščemo “Scatter Plot”, ki ga povežemo z našo bazo. Odpremo ga z dvojnim klikom. Za bolj jasno prikazovanje podatkov za osi y in x izberemo “petal length” ter “width”. Prikažejo se nam tri različne skupine krogcev in vidimo, da so vrste irisa nabrane skupaj. Iz tega lahko sklepamo, da ima ista vrsta rože iris podobno širino in dolžino venčnega lista.




Slika 31: Vizualni pregled irisa baze.

Vprašati se moramo, kaj je tisto, kar nam pove, da je meritev rože določena vrsta iris. Bazo povežemo z gradnikom “Tree”, tega pa z gradnikom “Tree viewer”, kjer si lahko pregledamo svoje drevo. Vidimo, da je zelo pomemben faktor pri določevanju vrst rože dolžina venčnega lista. Vse, kar je manjše ali enako 1,9 cm, je takoj iris vrste setosa.



Slika 32: Pregled drevesa.

Če sledimo drevesu, vidimo, da velikost čašnega venca ne vpliva na vrsto rože, zato se vrnemo nazaj k datoteki podatkov, torej naši bazi, in zopet poiščemo mrežo, kjer je naših pet podatkov. Dvojno kliknemo na “sepal width” na stolpec “Role” in izberemo “skip”. Enako naredimo pri “sepal length” in nato kliknemo moder gumb “Apply”.



Slika 33: Izločanje podatkov iz baze.

Naš naslednji korak je ugotavljanje vrste rože na podlagi meritev njenih lističev. Odpremo Excel dokument. V prvi stolpec vpišemo iris, v drugi “petal length” in tretji “petal width”. V stolpec iris vpišemo vprašanje, pod druga dva pa dolžine. Da preverimo točnost programa, lahko na internetu poiščemo bazo Iris biologa Ronalda Fisherja (vir: https://en.wikipedia.org/wiki/Iris_flower_data_set), od koder so prišle tudi meritve Majinih rož. Prva vrstica podatkov velja za Iris setosa, druga za Iris versicolor in tretja za Iris virginica.

	A	B	C	D
1	iris	petal length	petal width	
2	?	1,40	0,20	
3	?	5,10	1,60	
4	?	5,90	2,30	
5				
6				

Slika 34: Testni podatki v Excel tabeli.


Ko končamo s pisanjem Excel dokumenta, lahko tega shranimo v .xlsx (privzeti) obliki, v .csv obliki ali v .txt obliki. Nama je najbolj ustrezala .xlsx oblika.

Da svoje podatke ponovno vnesemo v program, na delovno površino potegnemo ogrodje “File”, nanj dvakrat kliknemo in poiščemo našo Excel datoteko. V mreži preverimo, če so se podatki pravilno upoštevali – iris kot kategoričen in ostala dva kot numerična. Če kaj ni v redu, lahko popravke vnesemo ročno z dvojnim klikom.

Poiščemo gradnik “Prediction”, s katerim bo program predvideval rezultate. Povežemo ga z našo bazo z Excel podatki in s klasifikacijskim drevesom. Odpremo gradnik “Prediction”. Rezultati, ki sva jih dobila, so pravilni, meritve so padle pod tisto vrsto rože, od katere sva vzela meritve.

Predictions			
Tree		iris	petal length
1	1.00 : 0.00 : 0.00 → Iris-setosa	?	1.4
2	0.00 : 0.67 : 0.33 → Iris-versicolor	?	5.1
3	0.00 : 0.02 : 0.98 → Iris-virginica	?	5.9


Slika 35: Predvidevanje vrste rož preko gradnika.



Slika 36: Končni izgled mreže.

4.7.3 Razvrščanje slik

Ko ustvarimo nov program, moramo poskrbeti, da bo imel vse potrebne dodatke. Poiščemo zavihek “Options” (v macOS se nahaja v zgornjem delovnem zavihku) in kliknemo na “Add-ons”. Poiščemo “Image Analytics”, ga obkljukamo in instaliramo. Ko to naredimo, moramo Orange ponovno zagnati .




Slika 37: Nameščanje dodatkov.

Najprej potrebujemo slike, s katerimi bomo delali. Ustvarimo lahko mapo z različnimi primeri slik. V tem primeru bomo delali s štirimi pasmami mačk: devon rex, eksotka, maine coon in sfinga. Ustvarimo mapo “Macke”, v njej pa štiri podmape. Posamezna mapa bo vsebovala 5 slik. Te slike sva poiskala na spletni strani:

<https://www.photosforclass.com>. Tam lahko najdemo zastoj slike za uporabo v izobraževalne namene.


Da lahko svoje slike naložimo v program, moramo poiskati gradnik “Import Images”. Ko ga odpremo, izberemo mapo, s katero bomo delali. Vse slike si lahko ogledamo, če “Import Image” povežemo z “Image Viewer” gradnikom. Posamezno sliko lahko povečamo, če na tipkovnici pritisnemo presledek. Da si ogledamo podatke o naših slikah, “Import Image” povežemo s tabelo. Vidimo, da so se nam slike razporedile v kategorije, imamo tudi ime slike, njeno pot, velikost, višino in širino. Z nobenim od trenutnih podatkov si še ne moremo pomagati, to so le metapodatki, ki nam ne povedo, kako slika izgleda.



Slika 38: Ogled slike preko tabele in vizualno.

Potrebujemo še vizualni opis slike. Pri tem nam bo pomagal gradnik “Image Embedding”, ki nam bo vrnil vektorski opis vsake slike. Ta gradnik direktno povežemo z naloženimi slikami. Nato ga povežemo še v novo tabelo, kjer si bomo ogledali nove podatke. Če odpremo novo tabelo, vidimo, da smo poleg starih podatkov dobili še 2047 novih, ki pomagajo pri opisu slike.

Sedaj potrebujemo gradnik “Test And Score”, ki bo testiral različne algoritme. Povežemo ga z “Image Embedding”. Naredimo dvojni klik na povezavo in preverimo, če se povezujemo s pravimi in ne s testnimi podatki. Te slike nam bodo služile za učenje naše mreže.



Slika 39: Urejanje povezave


Prav tako z istim gradnikom povežemo še “Logistic Regression”. Slednji gradnik je statistični model, ki analizira predvidevanja. Uporabljamo ga le za klasifikacije.

Sedaj potrebujemo naše testne podatke. Ustvarimo mapo, v katero damo štiri podmape: “Eksoška” in “DevonRex”, “MaineCoon” in “Sfinga”. Mape poimenujemo enako, kot smo poimenovali mape pri slikah za učenje. V vsako mapo vstavimo sliko določene pasme mačk.

Te slike sedaj uvozimo z na novo narejenim gradnikom “Import Images”, ki ga zopet povežemo z “Image Embedding”. Sledi povezava na gradnik “Test and Score”, pri katerem preverimo, da vanj uvažamo testne podatke - torej “test data”. Zdaj lahko gradnik odpremo.


Opazimo, da imamo na levi strani odprtega okna več načinov učenja naše mreže. Če bi uporabljali samo eno bazo podatkov, bi za učenje lahko uporabili metodo “Random Sampling”. Ta izbere 70 % slik za učenje, in preostalih 30 % pa za testiranje pridobljenega znanja. Izberemo lahko tudi, kolikokrat se bo postopek ponovil. Prav tako bi lahko izbrali “Test on train data”, ki pa skoraj vedno prikaže napačne rezultate.

Za naš primer bomo izbrali “Test on test data”. Mreža se bo učila iz podatkov, ki smo jih določili sami in preverila svoje znanje na drugih, prav tako določenih slikah.



Slika 40: Testni podatki in podatki za učenje.


Ko mreža obdela učenje, takoj vidimo rezultate. Za nas sta pomembna AUC (area under the curve) in CA (classification accuracy). Večja, kot sta ta podatka, bolj natančna je bila naša mreža. Največje število, ki ga lahko dosežemo, je 1, ki predstavlja 100 %, najmanjše pa 0. V našem primeru smo obakrat dobili 1, tako, da so bile vse slike pravilno kvalificirane.



Slika 41: “Test and Score” gradnik.

Da si ogledamo pravilnost vseh teh rezultatov, lahko “Test and Score” gradnik povežemo s “Confusion Matrix”. Ko tega odpremo, lahko izberemo, da nam prikaže pravilnost v odstotkih (zgornji desni kot: “Proportion of actual”). Pokaže nam pravilne pasme in pasme, ki jih je mreža predvidela za določeno sliko. Če s tem gradnikom povežemo še “Image Viewer”, si lahko ogledamo, kar označimo. Če torej označimo pravokotnik, kjer naj bi se klasificirali “devon rexi”, vidimo, da se tam nahaja pravilna slika. Ta gradnik v povezavi z ogledom slik je koristen takrat, kadar se naša mreža zmoti in želimo preveriti, kje je prišlo do napake.

Za zabavo dodamo v naše testne podatke v podmapo “Ekostka” pasmo, katere še nismo uporabili, na primer kratkodlako britanko. Ponovno moramo naložiti spremembe, tako, da odpremo gradnik kjer nalagamo testne podatke, in kliknemo “reload”. Naš CA se je sedaj zmanjšal na 80 %, ogledamo pa si lahko tudi, pod katero pasmo je bila britanka uvrščena. Mreža je mislila, da je mačka na sliki pasme devon rex.



Slika 42: Prikaz napačno predvidevane slike.

5 ANALIZA

5.1 Dijaki


Anketo je rešilo 40 dijakov programa računalniški tehnik.

Najprej sva jih prosila, da s svojimi besedami opišejo pojem umetne inteligence. Dijaki so izbirali krajše odgovore, kot so računalniški možgani, inteligenca strojev, robot, ki razmišlja itd. Podajali pa niso le definicij umetne inteligence, pojavili so se tudi odgovori, kot so nevarnost, prihodnost, neverjetna in zanimiva ter razne asociacije računalniških igrice.

Nato sva jih vprašala, če vedo, kaj so nevronske mreže. 72,5 % dijakov je za nevronske mreže že slišalo.

Ste že kdaj slišali za nevronske mreže?

40 responses




Graf 3: Poznavanje nevronskih mrež med dijaki.

Pri vprašanju, če se umetna inteligenca razvija hitro, je 97,5 % dijakov potrdilo, da se. Kar je zanimivo glede na to, da jih 28 % sploh ne ve, kaj so nevronske mreže, ki so tesno povezane z umetno inteligenco. Domnevava, da je tako, zato ker so za umetno inteligenco slišali iz nestrokovnih virov.

Ali mislite, da se umetna inteligenca razvija hitro?

40 responses




Graf 4: Mnenje dijakov glede hitrosti razvijanja umetne intelligence.

V naslednjem vprašanju naju je zanimalo, če bo zaradi umetne inteligence veliko ljudi izgubilo službo. Le 22,5 % dijakov verjame, da se to ne bo zgodilo.

Bo zaradi nje v prihodnosti izgubljenih veliko služb?

40 responses




Graf 5: Mnenja dijakov o izgubi služb zaradi umetne inteligence.

Zanimivo je bilo tudi vprašanje, če nas bo umetna inteligenca kdaj presegla. Le 30 % dijakov misli, da nas bo.

Mislite, da nas bo umetna inteligenca kdaj presegla?

40 responses




Graf 6: Mnenje dijakov da nas bo umetna inteligenca presegla

Večina dijakov se je pri vprašanju glede poučevanje te teme v šoli strinjala, da dobi premalo informacij.

Imate občutek, da v šoli dobite dovolj informacij o nečem, kar nam kroji prihodnost?

40 responses




Graf 7: Občutek dijakov glede količine snovi, ki jo o umetni inteligenci dobijo v šoli.

To je potrjeno tudi z naslednjim odgovorom, saj je le 17,5 % dijakov že bilo v stiku z umetno inteligenco.

Ali ste že kdaj ustvarjali kaj, kar se navezuje na umetno inteligenco (programirali v pythonu v tensor flowu, delali z orange...)?

40 responses




Graf 8: Predhodno delo dijakov na področju umetne inteligence.

Zadnje vprašanje, ki je bilo za najino nalogo najbolj ključno, se je nanašalo na željo dijakov po boljšem poznavanju umetne inteligence in nevronske mreže. Ugotovila sva, da si jih več kot 90 % želi svoje znanje izboljšati.

Bi se radi naučili ali pa vsaj umetno inteligenco/nevronske mreže bolje spoznali?

40 responses



Graf 9: Želje dijakov po dodatnem znanju.

5.2 Profesorji


Pri profesorjih naju je najbolj zanimalo njihovo že obstoječe znanje, še bolj pa njihova želja po poučevanju umetne inteligence.

Na najino anketo je odgovorilo 93 profesorjev naše šole. Potrebno je poudariti, da vsi ne poučujejo stroke.

Pri raziskavi že obstoječega znanja profesorjev sva ugotovila, da bi sami svoje znanje v veliki večini ocenili z 2 ali 3. Zanimivo je, da nihče od anketiranih profesorjev svojega znanja ni ocenil s 5.

Kako bi ocenili svoje znanje o umetni inteligenci

93 responses




Graf 10: Predhodno znanje profesorjev.

Pri vprašanju o svojem zanimanju za umetno inteligenco so pretežno odgovorili s 3 ali 4. Iz tega je razvidno, da zanimanje med profesorji za umetno inteligenco obstaja. To je dober znak za dijake, ki si želijo, da bi o tej temi več slišali v šoli. Prav tako je spodbuden pokazatelj prilagajanja profesorjev na prihodnost.

Kako bi ocenili svoje zanimanje za to področje?

93 responses




Graf 11: Zanimanje profesorjev za umetno inteligenco.

Ugotovila sva, da si velika večina (74 %) profesorjev želi, da bi lahko v razredu kaj povedali o umetni inteligenci. To je presenetljivo, saj jih večina ni iz računalniške stroke.

Kakšno je vaše stališče do poučevanja umetne inteligence v razredu?

93 responses




Graf 12: Stališče profesorjev do poučevanja umetne inteligence.

Pri vprašanju, koliko, mislijo je zanimanja med dijaki, so pretežno odgovorili s 3 in 4, kar se sklada z odgovori dijakov iz prve ankete, ki so večinsko potrdili, da jih področje zanima.

Koliko zanimanja mislite, da je med dijaki za učenje o umetni inteligenci?

93 responses




Graf 13: Miselnost profesorjev, da dijake umetna inteligenca zanima.

Največ različnih mnenj sva zaznala pri vprašanju ali se profesorjem zdi, da je na internetu dovolj snovi za dijake. Tretjina jih verjame, da je snovi sicer dovolj, vendar je prezapletena. 28 % jih misli, da je snovi dovolj, vendar pa je primanjkuje v slovenščini. Še nadaljnjih 23 % jih misli, da je snovi dovolj, medtem ko jih je 12 % prepričanih, da snovi na splošno primanjkuje.

Mislite, da lahko dijaki na to temo na internetu najdejo dovolj snovi?

93 responses



Graf 14: Trenutna dostopnost snovi o umetni inteligenci.

Zadnje vprašanje je bilo odprtega tipa. Vprašala sva jih, kje vidijo uporabo umetne inteligence v šolstvu, odgovori so si bili, razen avtomatičnega ocenjevanja, zelo različni. Ugotovila sva, da profesorji vidijo uporabo na vseh področjih šolanja. Zanimivo je, da sta se v grobem oblikovala dva pogleda. Nekateri profesorji vidijo umetno inteligenco kot del dodatnega pouka. Ti so predlagali organizacijo krožka kot dodaten izziv boljšim dijakom pri rednem pouku ali pa povezovanje umetne inteligence s predmeti, ki že imajo sorodno snov. Drugi pa jo vidijo v uporabi za izboljšanje delovanja šole, ti na primer pri sestavljanju urnikov. Predlagali so tudi odpravo birokracije za učitelje, vodenje tehnične službe, razporejanje dijakov pri maturi in optimizacijo ogledov na informativnih dnevih.

5.3 Potrjevanje hipotez

Na začetku naloge sva si postavila hipoteze o rezultatih ankete. Potrdiva lahko naslednje hipoteze:

- hipotezo 1: dijaki želijo spoznati umetno inteligenco in nevronske mreže,
- hipotezo 4: profesorje področje umetne inteligence zanima,
- hipotezo 5: zaradi zanimanja bi profesorji v veliki večini predavali o tej temi,
- hipotezo 6: v večini profesorji mislijo, da tudi dijake to področje zanima.

Prvo hipotezo lahko potrdiva, ker je večina dijakov na najini anketi odgovorila, da si umetno inteligenco in nevronske mreže želi bolje spoznati. Pri četrti hipotezi sva predvidevala pravilno, ker bi več kot polovica profesorjev svoje zanimanje za to področje ocenila s 3 ali več. Velika večina profesorjev si želi o tem področju tudi kaj povedati, zato lahko potrdiva peto hipotezo. Pravilno sva ocenila tudi šesto hipotezo, saj je več kot polovica profesorjev željo za učenje umetne inteligence pri dijakih ocenila s 4 ali več.

Nekatera predvidevanja sva ocenila napačno, hipotezi pri katerih sva se zmotila, sta:

- hipoteza 2: večina dijakov je že bila v stiku z umetno inteligenco in nevronskimi mrežami,
- hipoteza 3: dijaki v večini menijo, da bo umetna inteligenca presegla človeško inteligenco.

Drugo hipotezo morava ovreči, ker so nama rezultati ankete pokazali, da večina dijakov še ni sestavljala nevronskih mrež ali pa počela karkoli na temo umetne inteligence. Prav tako lahko ovrečeva tretjo hipotezo, saj večina dijakov ne verjame, da nas bo umetna inteligenca presegla.

6 ZAKLJUČEK

Umetna inteligenca napreduje vse hitreje, zato bo v prihodnosti izobrazba na tem področju še pomembnejša, kot je danes. Ugotovila sva, da je želja po znanju o tej temi zelo velika, kar je spodbudno. Na žalost pa na tem področju, še posebej v Sloveniji, primanjkuje učnih vsebin, ki bi bile dostopne dijakom in profesorjem ter preprosto razumljive. Pojavlja se veliko novih strokovnih izrazov, za katere še nimamo prevoda v slovenščino. Primanjkuje veliko strokovnih in preprostih virov za učenje tega področja v slovenščini. Eden največjih absurdov je, da so dijaki in profesorji v istem razredu, z istimi željami, a jih ne morejo uresničiti, vsaj ne tako, kot bi si želeli. To dokazuje anketa, ki kaže, da si dijaki, kljub volji profesorjev, ki si to smer želijo poučevati, še vedno želijo več znanja.

Rešitev vidiva v spodbujanju profesorjev in šolskega sistema, da se hitreje prilagaja razvoju tehnologije. Dijaki so pripravljeni pridobivati znanja, a jih privlačijo predvsem nove in moderne vsebine, ne pa toliko sedanje, ki so že zastarele in manj uporabne.

Prav tako se nama zdi pomembno, da bi vsi sledili najinemu cilju: deliti pridobljeno znanje. Vse kar sva se naučila, sva dala na najino spletno stran – od učnih vsebin do projektov, ki sva se jih lotila. Delala sva v TensorFlowu, v katerem sva mrežo učila prepoznavanja števil in v Orangu, v katerem sva sestavila mrežo, ki je prepoznala vrsto rože na podlagi njenih meritev ter mrežo, ki je prepoznala pasmo mačke na sliki. Na spletno stran sva objavila tudi video posnetke s postopki sestavljanja teh mrež.

Najine dosežke bi lahko še nadgradila: na spletno stran bi dodala še igre, ki bi dijake naučile teorijo na bolj zabaven način, dodala bi lahko tudi kvize, pri katerih bi uporabniki spletne strani preverili svoje znanje. Z razvijanjem spletne strani bi lahko dodajala stopnje težavnosti, s čimer bi ponudila zapletene teme in praktične primere. Uporabniki bi svoje znanje tako lahko postopoma nadgrajevali.

“Ne pustite, da vas učenje vodi le v znanje,

naj vas vodi v dejanja.” - Jim Rohn

7 VIRI

Boyatzis, R. E., 2008. Competencies in the 21st century. *Journal of Management Development*, januar.

Brownlee, J., 2018. *When to use mlp cnn and rnn neural networks*. [Elektronski]
Dostopno na: <https://machinelearningmastery.com/when-to-use-mlp-cnn-and-rnn-neural-networks/>
[Poskus dostopa 26. februar 2019].

Cellan-Jones, R., 2014. *Stephen Hawking warns artificial intelligence could end mankind*. [Elektronski]
Dostopno na: <https://www.bbc.com/news/technology-30290540>
[Poskus dostopa 26. februar 2019].

Computerphile, 2016. *AI safety*. [Elektronski]
Dostopno na: <https://www.youtube.com/watch?v=IB1OvoCNnWY>
[Poskus dostopa 27. februar 2019].

Computerphile, 2017. *AI "Stop Button" Problem*. [Elektronski]
Dostopno na: <https://www.youtube.com/watch?v=3TYT1QdfdsM>
[Poskus dostopa 27. februar 2019].

Computerphile, 2018. *AI Gridworlds*. [Elektronski]
Dostopno na: https://www.youtube.com/watch?v=eElfR_BnL5k
[Poskus dostopa 27. februar 2019].

Deepmind Technologies Limited, 2017. *Specifying AI safety problems in simple environments*. [Elektronski]
Dostopno na: <https://deepmind.com/blog/specifying-ai-safety-problems/>
[Poskus dostopa 26. februar 2019].

E. Perez, C., 2017. *Exploration, Exploitation and Imperfect Representation in Deep Learning*. [Elektronski]
Dostopno na: <https://medium.com/intuitionmachine/exploration-exploitation-and-imperfect-representation-in-deep-learning-9472b67fdecd>
[Poskus dostopa 26. februar 2019].

Kaplan, A. & Haenlein, M., 2019. Buisness Horizons. *Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence*, Januar-Februar, pp. 15-25.

- Kohonen, T. & Honkela, T., 2012. *Kohonen network*. [Elektronski]
Dostopno na: http://www.scholarpedia.org/article/Kohonen_network
[Poskus dostopa 26. februar 2019].
- Labs, M., 2017. *Everything you need to know about Neural Networks*. [Elektronski]
Dostopno na: <https://hackernoon.com/everything-you-need-to-know-about-neural-networks-8988c3ee4491>
[Poskus dostopa 5. marec 2019].
- Maupeou, S. d., brez datuma *Introduction to Hopfield neural networks*. [Elektronski]
Dostopno na: <https://www.doc.ic.ac.uk/~sd4215/hopfield.html>
[Poskus dostopa 26. februar 2019].
- McCormick, C., 2013. *Radial Basis Function Network (RBFN) Tutorial*. [Elektronski]
Dostopno na: <http://mccormickml.com/2013/08/15/radial-basis-function-network-rbfn-tutorial/>
[Poskus dostopa 26. februar 2019].
- Mramor, K., 2007. *Nevronske mreže*. [Elektronski]
Dostopno na: http://mafija.fmf.uni-lj.si/seminar/files/2007_2008/seminar.pdf
[Poskus dostopa 5. marec 2019].
- Nunes da Silva, I. in drugi, 2017. *Artificial Neural Networks*. prva ured. s.l.:Springer International Publishing.
- Organge Data Mining, 2018. *Getting Started with Orange*. [Elektronski]
Dostopno na: <https://www.youtube.com/playlist?list=PLmNPvQr9Tf-ZSDLwOzxpvY-HrE0yv-8Fy>
[Poskus dostopa 27. februar 2019].
- Stergiou, C. & Siganos, D., brez datuma *Neural Networks*. [Elektronski]
Dostopno na: https://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html
[Poskus dostopa 26. februar 2019].
- Sternberg, R. J., 2017. *Human Intelligence*. [Elektronski]
Dostopno na: <https://www.britannica.com/science/human-intelligence-psychology>
[Poskus dostopa 9. marec 2019].
- Tch, A., 2017. *The mostly complete chart of Neural Networks, explained*. [Elektronski]
Dostopno na: <https://towardsdatascience.com/the-mostly-complete-chart-of-neural-networks-explained-3fb6f2367464>
[Poskus dostopa 26. februar 2019].

The TensorFlow Authors, brez datuma *Get started with tensorflow*. [Elektronski]

Dostopno na:

<https://colab.research.google.com/github/tensorflow/docs/blob/master/site/en/tutorials/index.ipynb>

[Poskus dostopa 26. februar 2019].

Tutorials point, brez datuma *AI - Agents & Environments*. [Elektronski]

Dostopno na:

https://www.tutorialspoint.com/artificial_intelligence/artificial_intelligence_agents_and_environments.htm

[Poskus dostopa 26. februar 2019].

Tutorials point, brez datuma *Unsupervised learning*. [Elektronski]

Dostopno na:

https://www.tutorialspoint.com/artificial_neural_network/artificial_neural_network_unsupervised_learning.htm

[Poskus dostopa 5. marec 2019].

Varga, M., 2017. *Zašifrirajmo vse! | Monitor*. [Elektronski]

Dostopno na: <https://www.monitor.si/clanek/zasifrirajmo-vse/181609/>

[Poskus dostopa 9. marec 2019].

Wikipedia, 2015. *Trije zakoni robotike*. [Elektronski]

Dostopno na: https://sl.wikipedia.org/wiki/Trije_zakoni_robotike

[Poskus dostopa 26. februar 2019].

Wikipedia, 2018. *Turingov test*. [Elektronski]

Dostopno na: https://sl.wikipedia.org/wiki/Turingov_test

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Applications of artificial intelligence*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Applications_of_artificial_intelligence

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Artificial Intelligence*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Artificial_intelligence

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Cognition*. [Elektronski]

Dostopno na: <https://en.wikipedia.org/wiki/Cognition>

[Poskus dostopa 27. februar 2019].

Wikipedia, 2019. *Emotional intelligence*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Emotional_intelligence

[Poskus dostopa 27. februar 2019].

Wikipedia, 2019. *Intelligence*. [Elektronski]

Dostopno na: <https://en.wikipedia.org/wiki/Intelligence>

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Iris flower data set*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Iris_flower_data_set

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Multilayer perceptron*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Multilayer_perceptron

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Natural language processing*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Natural_language_processing

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Natural-language generation*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Natural-language_generation

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Natural-language understanding*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Natural-language_understanding

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Pattern recognition*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Pattern_recognition

[Poskus dostopa 5. marec 2019].

Wikipedia, 2019. *Social intelligence*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Social_intelligence

[Poskus dostopa 27. februar 2019].

Wikipedia, 2019. *Speech recognition*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Speech_recognition

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Speech synthesis*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Speech_synthesis

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Supervised learning*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Supervised_learning

[Poskus dostopa 5. marec 2019].

Wikipedia, 2019. *Technological singularity*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Technological_singularity

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Turing test*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Turing_test

[Poskus dostopa 26. februar 2019].

Wikipedia, 2019. *Unsupervised learning*. [Elektronski]

Dostopno na: https://en.wikipedia.org/wiki/Unsupervised_learning

[Poskus dostopa 5. marec 2019].

PRILOGE

Anketa dijakov

Umetna inteligenca

Sva Matija in Ivana ter za najino maturitetno nalogo preiskujeva umetno inteligenco in nevronske mreže. S hitrostjo, ki se ta razvija, naju zanima, kako dobro so učenci z umetno inteligenco seznanjeni. Prosila bi, da si vzamete nekaj kratkih minut, da odgovorite na vprašanja, ki sva jih pripravila. Za vaš čas se iskreno zahvaljujema.

- Ivana in Matija

* Required

Kako bi s svojimi besedami opisali umetno inteligenco? *

Your answer

Ste že kdaj slišali za nevronske mreže? *

☐ Da.

☐ Ne.

Ali mislite, da se umetna inteligenca razvija hitro? *

☐ Da.

☐ Ne.

Bo zaradi nje v prihodnosti izgubljenih veliko služb? *

☐ Da.

☐ Ne.

Mislite, da nas bo umetna inteligenca kdaj presegla? *

☐ Da.

☐ Ne.

Imate občutek, da v šoli dobite dovolj informacij o nečem, kar nam kroji prihodnost? *

☐ Da.

☐ Ne.

Ali ste že kdaj ustvarjali kaj, kar se navezuje na umetno inteligenco (programirali v pythonu v tensor flowu, delali z orange...)? *

☐ Da.

☐ Ne.

Bi se radi naučili ali pa vsaj umetno inteligenco/nevronske mreže bolje spoznali? *

☐ Da.

☐ Ne.

Anketa profesorjev

Umetna inteligenca

Sva Matija in Ivana ter za najino maturitetno nalogo preiskujeva umetno inteligenco in nevronske mreže. S hitrostjo, ki se ta razvija, naju zanima, kako dobro so ste profesorji seznanjeni s tem področjem ter koliko vas to področje dejansko zanima. Prosila bi, da si vzamete nekaj kratkih minut, da odgovorite na vprašanja, ki sva jih pripravila. Za vaš čas se iskreno zahvaljujema.
- Ivana in Matija

* Required

Kako bi ocenili svoje znanje o umetni inteligenci *

	1	2	3	4	5	
nezadostno	☐	☐	☐	☐	☐	odlično

Kako bi ocenili svoje zanimanje za to področje? *

	1	2	3	4	5	
me ne zanima	☐	☐	☐	☐	☐	izjemno navdušen

Kakšno je vaše stališče do poučevanja umetne inteligence v razredu? *

- ☐ Že učim in sem z količino snovi za dijake zadovoljen
- ☐ Že učim in bi si želel več snovi za dijake
- ☐ Imam željo, da bi nekaj o tej temi lahko povedal v razredu
- ☐ Mislim, da je to še pretežka tema za srednjo šolo
- ☐ Other:

Koliko zanimanja mislite, da je med dijaki za učenje o umetni inteligenci? *

	1	2	3	4	5	
nikakršnega	☐	☐	☐	☐	☐	izjemno veliko

Mislite, da lahko dijaki na to temo na internetu najdejo dovolj snovi? *

- ☐ Da
- ☐ Ne
- ☐ Snovi je dovolj, vendar je prezapletena
- ☐ Snovi je dovolj, manjka je v slovenščini
- ☐ Other:

Imate kakšno idejo kjer bi se takšna tehnologija v prihodnosti lahko uporabila v šolstvu? (Kot na primer optimiziranje urnikov)

Your answer

IZJAVA*

Mentor Boštjan Resinovič v skladu z 2. in 17. členom Pravilnika raziskovalne dejavnosti »Mladi za Celje« Mestne občine Celje, zagotavljam, da je v raziskovalni nalogi z naslovom Interaktivno učenje o umetni inteligenci, katere avtorja sta Matija Podbreznik in Ivana Lavrič:

- besedilo v tiskani in elektronski obliki istovetno,
- pri raziskovanju uporabljeno gradivo navedeno v seznamu uporabljene literature,
- da je za objavo fotografij v nalogi pridobljeno avtorjevo dovoljenje in je hranjeno v šolskem arhivu,
- da sme Osrednja knjižnica Celje objaviti raziskovalno nalogo v polnem besedilu na knjižničnih portalih z navedbo, da je raziskovalna naloga nastala v okviru projekta Mladi za Celje,
- da je raziskovalno nalogo dovoljeno uporabiti za izobraževalne in raziskovalne namene s povzemanjem misli, idej, konceptov oziroma besedil iz naloge ob upoštevanju avtorstva in korektnem citiranju,
- da smo seznanjeni z razpisni pogoji projekta Mladi za Celje.

Celje, 8.3.2019



Podpis mentorja

Podpis odgovorne osebe

*

POJASNILO

V skladu z 2. in 17. členom Pravilnika raziskovalne dejavnosti »Mladi za Celje« Mestne občine Celje je potrebno podpisano izjavo mentorja (-ice) in odgovorne osebe šole vključiti v izvod za knjižnico, dovoljenje za objavo avtorja (-ice) fotografskega gradiva, katerega ni avtor (-ica) raziskovalne naloge, pa hrani šola v svojem arhivu.