

Umjetna inteligencija u poslovanju

Šeparović, Marko

Undergraduate thesis / Završni rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:137:816136>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-11-23**



Repository / Repozitorij:

[Digital Repository Juraj Dobrila University of Pula](#)



Sveučilište Jurja Dobrile u Puli
Fakultet ekonomije i turizma
„Dr. Mijo Mirković“

MARKO ŠEPAROVIĆ

UMJETNA INTELIGENCIJA U POSLOVANJU

Završni rad

Pula, rujan 2020.

Sveučilište Jurja Dobrile u Puli

Fakultet ekonomije i turizma

„Dr. Mijo Mirković“

MARKO ŠEPAROVIĆ

UMJETNA INTELIGENCIJA U POSLOVANJU

Završni rad

JMBAG: 0303077993, redoviti student

Studijski smjer: Informatički menadžment

Kolegij: Ekonomska Informatika

Mentorica: prof. dr. sc. Vanja Bevanda

Pula, rujan 2020.



IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani Šeparović Marko, kandidat za prvostupnika ekonomije/poslovne ekonomije, smjera Informatički menadžment ovime izjavljujem da je ovaj Završni rad rezultat isključivo mogega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Završnog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

Marko Šeparović

U Puli, rujan, 2020 godine

Sadržaj

Uvod/umjetna inteligencija.....	1,2
1. Machine learning/strojno učenje.....	2,3
2. Umjetna inteligencija i strojno učenje u poslovanju.....	4
3. Neuronske mreže.....	5
4. Supervised learning/nadzirano učenje.....	6-16
4.1. Regresijski problemi.....	6-10
4.2. Klasifikacijski problemi.....	10-16
5. Unsupervised learning/nenadzirano učenje.....	16-22
5.1. Cluster analysis/clustering.....	18-21
5.2. Neuronske mreže.....	21
5.3. Razlike između nadziranog i nenadziranog učenja.....	22
6. Prepoznavanje glasa.....	22-29
6.1. Primjer programa koji koristi prepoznavanje glasa.....	24-28
6.2. Primjena ovog programa u poslovanju.....	28-29
7. Umjetna inteligencija i poslovanje danas.....	29-30
Zaključak.....	31
Sažetak na hrvatskom jeziku.....	32
Sažetak na engleskom jeziku.....	33
Popis literature	34
Popis grafikona, tablica i slika	35

Uvod/umjetna inteligencija

Ovaj rad će obuhvatiti i objasniti umjetnu inteligenciju, strojno učenje, strojne algoritme i ostale slične teme i prikazat će njihovu uporabu u poslovanju. Početi ćemo definiranjem umjetne inteligencije.

Umjetna inteligencija je polje računarstva čiji je cilj razvoj računalnih sustava koji mogu izvršavati zadatke za koje je obično potrebna ljudska inteligencija.

Neki od tih zadataka su: vizualna percepcija, prepoznavanje govora, odlučivanje, prevođenje jezika...

Ukratko, umjetna inteligencija je inteligencija demonstrirana od strane računala, za razliku od prirodne inteligencije koju koriste životinje (ljudi i ostali inteligentni organizmi).

Kolokvijalno, termin „umjetna inteligencija“ se često koristi da se opišu mašine koje oponašaju kognitivne funkcije koje asociramo s ljudskim umom, kao „učenje“ i „rješavanje problema“.¹

Jedna od brojnih uporaba umjetne inteligencije je poboljšavanje korisničkog sučelja.

Korisničko sučelje je mjesto gdje se dešavaju interakcije između ljudi i mašina. Cilj ove interakcije je olakšavanje i omogućavanje efektivnog rada i kontrole nad mašinom s ljudskog gledišta, sve dok mašina istovremeno šalje natrag informacije koje pomažu korisniku da pravi odluke.

Ovaj rad će govoriti o nekima od najvažnijih grana umjetne inteligencije i strojnog učenja kao neuronske mreže i prepoznavanje govora. Ove grane ćemo u radu detaljno razraditi i objasniti, navesti ćemo njihove uporabe, slabosti i snage. Rad će se fokusirati na glavne aspekte strojnog učenja, nadzirano učenje i nenadzirano učenje, te na veoma važan dio nenadziranog učenja, prepoznavanje glasa.

Osim uvoda i zaključka, ovaj rad se sastoji od sedam zaokruženih cjelina. U prvoj se govori o strojnom učenju, njegovoj definiciji, uporabi, razvoju itd. Nabrajaju se i glavni aspekti strojnog učenja te se spominje i njegova povijest.

¹https://en.wikipedia.org/wiki/Artificial_intelligence, (pristupljeno 26. kolovoza 2020.).

U drugoj cjelini se govori o umjetnoj inteligenciji u poslovanju, utjecaju umjetne inteligencije na poslovni svijet i potencijale umjetne inteligencije u poslovnom svijetu. U trećoj cjelini, rad govori o neuronskim mrežama, poređenju vještačkih neuronskih mreža i bioloških neuronskih mreža i vrstama neuronskih mreža. U četvrtoj cjelini, rad govori o nadziranom učenju, vrstama nadziranog učenja, uporabama, i primjerima nadziranog učenja. Govorimo isto o regresijskim i klasifikacijskim problemima nadziranog učenja. U petoj cjelini govorimo o nenadziranom učenju, klaster analizi, vrstama nenadziranog učenja, nastavljamo analizu neuronskih mreža, govorimo i o razlikama između nadziranog i nenadziranog učenja, itd... U šestoj cjelini se govori o prepoznavanju glasa, biti će definirano i biti će demonstriran primjer programa koji koristi prepoznavanje glasa. U posljednjoj, sedmoj cjelini, rad će govoriti o utjecaju umjetne inteligencije u poslovanju u današnjem dobu, govorit ćemo o mogućim trenutnim i budućim uporabama umjetne inteligencije u poslovnom svijetu.

1. Machine learning/Strojno učenje

Machine learning ili strojno učenje je grana umjetne inteligencije koja se bavi računalnim algoritmima koji se poboljšavaju kroz iskustvo. Ovaj rad će se baviti pretežno strojnim učenjem jer se najpreciznije može aplicirati u poslovanju.

Biti će dano više primjera poslovnih aplikacija strojnog učenja i računalnih algoritama koji se mogu primijeniti u poslovanju.

Algoritmi strojnog učenja prave matematički model baziran na uzorcima podataka koje još zovemo i „podaci vježbanja“ da bi pravili predikcije ili odluke bez da su eksplicitno programirani da to urade. ²

Neke od poznatijih uporaba strojnog učenja su algoritmi koji google koristi da bi filtrirao i rangirao rezultate pretrage na browseru, automatsko filtriranje „spam“ email-a , prepoznavanje glasa itd...

²https://en.wikipedia.org/wiki/Machine_learning, (pristupljeno 26. kolovoza 2020.).

U ovim zadacima je veoma teško ili nemoguće razviti „obične“ algoritme da urade te zadatke i zato se koristi strojno učenje.³

Arthur Samuel je 1959. godine definirao strojno učenje kao znanstveno polje koje daje računarima mogućnost da uče bez da su za to eksplicitno programirani.

Jedno od njegovih velikih postignuća je to da je razvio program koji igra igru „checkers“ ili dama bolje od njega. To je uspio tako što je razvio AI algoritme koje je aplicirao na svoj program i kroz tisuće testnih igra, program je kroz iskustvo naučio da igra checkers bolje od njega.

Modernija definicija strojnog učenja je od Tom Mitchella koji je 1998. godine opisao ovo polje ovako:

Možemo reći da je program naučio iz iskustva E gledajući na zadatak T i neku mjeru izvođenja P, ako performansa na T, izmjerena sa P se poboljša sa iskustvom E.

Ovu definiciju možemo aplicirati na Arthurov program tako što ćemo iskustvo E povezati s iskustvom programa igrajući igru tisuće puta protiv sebe, zadatak T je zadatak igranja igre i mjera izvođenja ili performansa P je vjerojatnost da će program pobijediti sljedeću igru protiv nekog novog protivnika. Ako se P povećava ili poboljšava onda smatramo da je to strojno učenje i da je program funkcionalan.

Ovaj model možemo primijeniti na još primjera strojnog učenja kao filtriranje „spam“ email-ova gdje će T biti klasificiranje email-ova na „spam“ i „nije spam“ , iskustvo E će biti „gledanje“ programa kako mi sortiramo email-ove i P ili performansa će biti broj ili postotak email-ova koje je program sortirao točno kao „spam“ ili „nije spam“.⁴

³https://en.wikipedia.org/wiki/Machine_learning, (pristupljeno 27. kolovoza 2020.).

⁴<https://www.coursera.org/learn/machine-learning/home/welcome>, (pristupljeno 27. kolovoza 2020.).

2. Umjetna inteligencija i strojno učenje u poslovanju

U poslovanju, umjetna inteligencija ima široku uporabu. Mi koristimo umjetnu inteligenciju u više formi svakodnevno a većinom ni ne primijetimo.

U svakoj industriji umjetna inteligencija je sve više i više prominentna, od najjednostavnijih procesa do veoma kompleksnih i specifičnih specijalizacija za koje je neophodna komponenta.

Razvojem umjetne inteligencije vidimo da ta praksa postaje imperativ za poslovanja i kompanije da održe svoju poziciju na tržištu i da zadrže ili dobiju prednost nad drugim poslovnim organizacijama.

Strojno učenje je najčešći tip umjetne inteligencije koji se koristi u poslovne svrhe ali i općenito. Koristi se primarno u svrhu procesiranja velikih količina podataka brzo.

U poslovanju je veoma korisno jer uzima ogromne količine podataka (kao internet) i iz njih izvlači specifične podatke i informacije koje ljudi mogu razumjeti i lakše „probaviti“.

Jedan primjer ovakve uporabe je da zamislimo da posjedujemo poduzeće koje se bavi proizvodnjom automobila. Sve mašine koje proizvode specifične dijelove automobila su spojene za centralnu mrežu jer nam to omogućuje najefikasnije upravljanje i kontrolu njima. Svi ovi uređaji i mašine šalju konstantan niz podataka o njihovoj funkcionalnosti, produkciji, efikasnosti itd. na glavni server ili na glavnu lokaciju tog poduzeća. Veoma je nepraktično ako uopće moguće za ljude da dešifriraju sve te podatke i da ih sve provjeravaju, a i da mogu, najvjerojatnije bi propustili neke paterne koje se ponavljaju i indiciraju kvar uređaja ili neku drugu važnu informaciju. Strojno učenje nam je u ovoj situaciji optimalno jer može brzo i učinkovito analizirati sve te podatke i prepoznati paterne i anomalije koje dešavaju. Ako naprimjer mašina u našoj kompaniji radi sporije nego što treba, naš algoritam će to primijetiti i poslati notifikaciju našem timu za održavanje uređaja. Onda će oni uraditi svoj dio posla i popraviti mašinu ili postaviti preventivne mjere koje će spriječiti kvar mašine. ⁵

⁵ <https://www.businessnewsdaily.com/9402-artificial-intelligence-business-trends.html>, (pristupljeno 27. kolovoza 2020.).

3. Neuronske mreže

Duboko učenje je potpolje strojnog učenja bazirano na umjetnim neuronskim mrežama, to su računalni sistemi inspirirani biološkim nervnim mrežama koje čine životinjski mozak.

Inspirirani su i načinom procesiranja informacija i distribuiranim komunikacijskim čvorovima u biološkim sistemima.

Umjetne neuronske mreže i životinjski mozgovi imaju dosta razlika, neuronske mreže su sklone da budu statične i simbolične dok je biološki mozak većine živih bića dinamičan i analogan.

Svaka konekcija neuronskih čvorova (kao sinapse u biološkom mozgu) može prenositi signal drugim neuronima. Umjetni neuron koji primi signal ga onda procesira i može nastaviti signalizirati ostale neurone povezane s njim.

Taj „signal“ je zapravo realni broj i output svakog neurona je izračunat koristeći neku nelinearnu funkciju zbroja njegovih inputa. Konekcije između neurona se zovu ivice.

Neuronske mreže uče ili „bivaju trenirane“ tako što procesiraju primjere, svaki od kojih ima poznat input i rezultat. Onda prave asocijacije između inputa i rezultata koje su bazirane na vjerojatnosti, koje se spremaju u podatkovnoj strukturi same mreže. One omogućavaju računarima da „uče“ iz opservacijskih podataka.

Ovakvi sistemi „uče“ da rade zadatke razmatrajući primjere, uglavnom bez da su isprogramirana pravila specifična za taj zadatak. ⁶

Neke od vrsta neuronskih mreža su: Feedforward Neural Networks, Radial basis function Neural Network, Kohonen Self Organizing Neural Network, Recurrent Neural Network(RNN), Convolutional Neural Network, Modular Neural Network, itd...

U nastavku rada ćemo daljnje razraditi neuronske mreže. (str. 20.)

⁶ https://en.wikipedia.org/wiki/Artificial_neural_network, (pristupljeno 27. kolovoza 2020.).

4. Supervised learning/nadzirano učenje

Nadzirano učenje je dio strojnog učenja koji ima za zadatak da nauči funkciju koja će mapirati input na output koristeći input-output parove. Termin „supervised learning“ odnosi se na činjenicu da dajemo algoritmu grupu podataka koji zovemo „ispravni odgovori“ i pomoću tih odgovora algoritam nam treba dati ispravnu predikciju i prenijeti je u output. U nadziranom učenju, svaki primjer je par koji se sastoji od unosnog objekta (obično vektora) i poželjne vrijednosti outputa. Algoritmi ove metode analiziraju podatke „treniranja“ i prave funkcije koje se onda mogu koristiti za mapiranje novih primjera.⁷

Problemi nadziranog učenja su kategorizirani u regresijske i klasifikacijske probleme.

4.1. Regresijski problemi

U regresijskim problemima, mi pokušavamo predvidjeti rezultate neprekidnog outputa, što znači da pokušavamo mapirati varijable na neku neprekidnu funkciju. Regresijski problem nastaje kada je output neka realna ili neprekidna vrijednost kao „plaća“ ili „težina“. Mnogo se modela može koristiti za ove probleme ali najjednostavniji je linearna regresija. Ovaj model pokušava uklopiti podatke sa najboljim „hyper-plane-om“ koji prolazi kroz točke.


Neki od regresijskih primjera zadataka su: Predviđanje starosti osobe, predviđanje cijena kuća gledajući na okolinu u kojoj je kuća, predviđanje broja prodanih glazbenih albuma za sljedeći mjesec, predviđanje cijene dionica neke kompanije za sljedećih nekoliko dana, predviđanje plaće gledajući na prihod kompanije, predviđanja cijena automobila gledajući na kilometražu.

Ovdje će biti prikazan i objašnjen primjer regresijskog problema u nadziranom učenju koji će biti apliciran na realnu situaciju u poslovnom svijetu.

Pretpostavimo da posjedujemo kompaniju koja se bavi nekretninama i želimo da predvidimo za koliko novaca naši klijenti mogu prodati svoje kuće bazirano na površini kuće. Naravno, za regresijske probleme možemo imati i više varijabli ali za ovaj primjer ćemo koristiti samo površinu kuće.

⁷ https://en.wikipedia.org/wiki/Supervised_learning, (pristupljeno 27. kolovoza 2020.).

Grafikon 1. Prikaz skupa podataka o prodanim kućama iz grada Portland, Oregon.




Izvor: Osobno istraživanje i podaci iz ispod navedene literature „(11)“

Na ovom prikazu je prikazan skup podataka iz grada Portland, Oregon. Plave točke obilježavaju prodane kuće u jednom periodu, prikazana je njihova cijena u tisućama dolara i površina u stopama kvadratnim.

Pretpostavimo da se našoj kompaniji javi klijent iz Portlanda i želi da proda kuću koja ima površinu 750 kvadratnih stopa. Naša kompanija ima zadatak da odredi cijenu za koju klijent može kuću prodati koristeći ove parametre i regresijske algoritme nadziranog strojnog učenja. Jedna od stvari što algoritam može uraditi je provući pravu liniju kroz ove podatke i tako odrediti za koliko bi se tisuća dolara mogla klijentova kuća od 750 kvadratnih stopa prodati. Za sljedeće demonstracije biti će korištene približne vrijednosti radi svrhe demonstracije naspram svrhe točnosti. ⁸

⁸ <https://www.coursera.org/learn/machine-learning/home/welcome>, (pristupljeno 28. kolovoza 2020.).

Grafikon 2. Prikaz primjera linearne regresije koristeći podatke o prodaji kuća iz Oregona.



Izvor: Osobno istraživanje i podaci iz ispod navedene literature „(12)“


Koristeći ovu metodu možemo vidjeti da klijent može prodati kuću za otprilike 190 tisuća dolara. Ali ovo nije jedini algoritam koji možemo koristiti za ovu situaciju. Postoji zapravo bolji algoritam koji možemo koristiti. Naprimjer, umjesto da provučemo ravnu liniju kroz podatke, bolje bi bilo da koristimo kvadratnu funkciju s kojom ćemo dobiti parabolu koja će prolaziti kroz podatke. ⁹

¹⁰ Kvadratna formula: $y = c + bx + ax^2$

⁹ <https://www.coursera.org/learn/machine-learning/home/welcome>, (pristupljeno 28. kolovoza 2020.).

¹⁰ <http://www.pmean.com/06/QuadraticRegression.html>, (pristupljeno 28. kolovoza 2020.).

Grafikon 3. Prikaz primjera kvadratne regresije koristeći podatke o prodaji kuća iz Oregona.



Izvor: Osobno istraživanje i podaci iz ispod navedene literature „(11)“

Sa ovim algoritmom primijetimo da klijent može prodati kuću za 210 tisuća dolara. Algoritam koji provuče ravnu liniju kroz podatke se zove linearni regresijski model i najjednostavniji je od regresijskih modela ali je zato i najmanje precizan.

Algoritam koji provuče parabolu kroz podatke se zove kvadratni regresijski model i dosta je kompleksniji od linearnog ali je zato i precizniji. ¹²

Kod linearne regresije, jedna varijabla se smatra obrazložavajućom a druga se smatra zavisnom. Ovaj regresijski model minimalizira distancu između ravne linije i svake točke podataka da bi se optimalno uklopila.

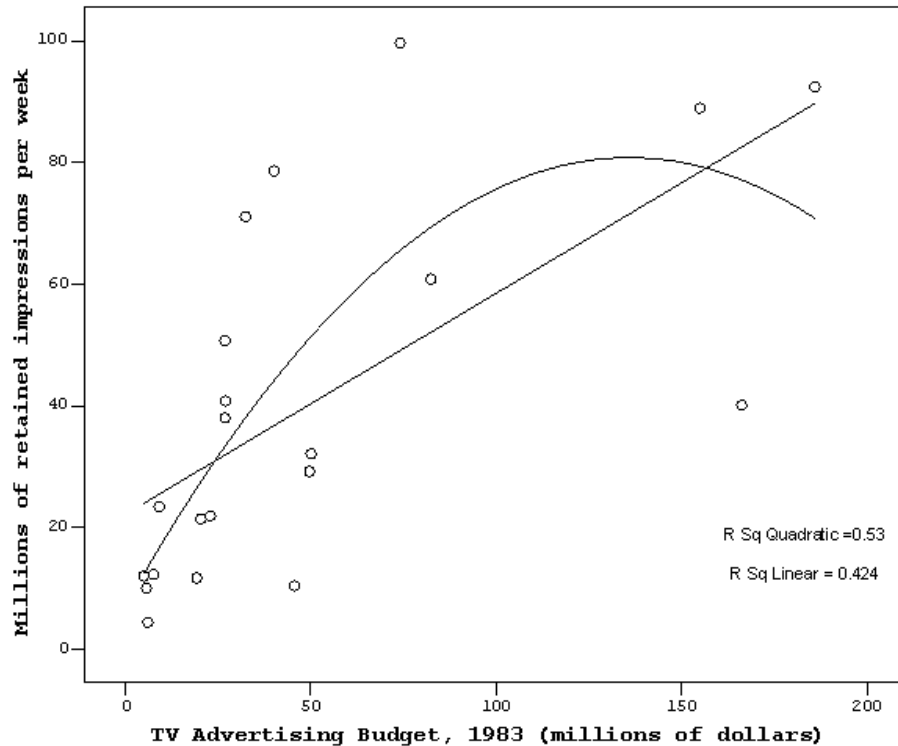
Kvadratni ili polinomni modeli se mogu savijati. Mogu biti konstruirani do n-tog stupnja. Što je veći n-ti stupanj, više se puta može saviti krivulja i tako predstaviti precizniji rezultat. Kvadratna funkcija je kvadrirana i zato se može saviti samo jednom, to čini parabolu, a polinomna funkcija koja je naprimjer kubirana se može saviti 2 puta i tako dalje. ¹³

¹¹ <https://www.coursera.org/learn/machine-learning/home/welcome>, (pristupljeno 29. kolovoza 2020.).

¹² <http://www.pmean.com/06/QuadraticRegression.html>, (pristupljeno 29. kolovoza 2020.).

¹³ <https://towardsdatascience.com/linear-vs-polynomial-regression-walk-through-83ca4f2363a3>, (pristupljeno 29. kolovoza 2020.).

Grafikon 4. Primjer linearne i kvadratne regresije.



Izvor: <http://www.pmean.com/06/QuadraticRegression.html> (pristupljeno 23. rujna 2020.).

Ovdje vidimo prikaz i linearne i kvadratne regresije korištene na istim podacima na istom grafu. Ovo su podaci iz istraživanja koje je usporedilo budžet televizijskih reklama i impresioniranost gledatelja. Vidimo da su se reklame koje su imale veći budžet više sviđale gledateljima nego reklame s manjim budžetom. ¹⁴

4.2. Klasifikacijski problemi

Klasifikacijski nadzirani problemi su ti koji koriste algoritme da nauče kako da daju „klasu“ ili „etiketu“ primjerima iz problema. Jedan od najosnovnijih primjera ovog modela je klasificiranje email-ova na „spam“ ili „nije spam“. U ovom primjeru cilj algoritma je da „gleda“ nas kako klasificiramo email-ove i da koristi ostale indikatore kao frekvencija otvaranja specifičnih email-ova, vrijeme čitanja, brisanje email-ova itd. da bi odredio ¹⁵

¹⁴ <http://www.pmean.com/06/QuadraticRegression.html>, (pristupljeno 29. kolovoza 2020.).

¹⁵ <https://machinelearningmastery.com/types-of-classification-in-machine-learning/>, (pristupljeno 29. kolovoza 2020.).

ili pokušao predvidjeti koje od budućih email-ova treba klasificirati kao „spam“ a koje kao „nije spam“. ¹⁶

Klasifikacijski nadzirani algoritmi se bave problemima koje mogu imati 2 outputa „0 ili 1“ naprimjer kada pomoću njih pokušamo predvidjeti da li je neki tumor malignan ili benignan gledajući na njegovu veličinu, starost pacijenta, debljinu nakupine, ravnomjernost veličine ćelija, ravnomjernost oblika ćelija itd. Veličina, starost pacijenta i ostalo navedeno su parametri testiranja i njih algoritam koristi da bi predvidio da li je tumor 0 = benignan ili 1 = malignan.

Klasifikacijski algoritmi se bave i problemima koji nemaju binaran output. Algoritam može koristiti prije navedene parametre da predvidi da li je tumor 0 = benignan, 1 = prvi stadij raka, 2 = drugi stadij raka, 3 = treći stadij raka i 4 = četvrti stadij raka.

Klasifikacijski algoritmi mogu imati beskonačno mnogo outputa i beskonačno mnogo inputa ili parametara ali moraju moći svoje outpute staviti u neku „klasu“ kao naprimjer nacionalnost osobe, da li osoba ima vozačku dozvolu ili nema, rasa osobe, da li će kompanija bankrotirati u roku od 30 dana ili ne. Činjenica da se njihovi outputi mogu staviti u različite klase ih diferencira od regresijskih algoritama čiji je output neka neprekidna vrijednost ili neki realni broj koji ne možemo klasificirati.

Ovdje je navedeno nekoliko problema za koje možemo koristiti klasifikacijske algoritme:

Predviđanje nacionalnosti osobe, predviđanje da li će se cijena dionica neke kompanije povećati ili smanjiti sutra, predviđanje da li je neki dokument povezan s nekom specifičnom temom ili nije, pogađanje spola neke osobe na osnovi njihove slike ili stila pisanja, klasificiranje email-ova na „spam“ i „nije spam“, klasificiranje knjiga po žanrovima na osnovi riječi korištenih u knjizi, pogađanje da li će kiša padati za sedmicu dana ili ne.¹⁷

¹⁶ <https://machinelearningmastery.com/types-of-classification-in-machine-learning/>, (pristupljeno 29. kolovoza 2020.).

¹⁷ <https://www.geeksforgeeks.org/regression-classification-supervised-machine-learning/>, (pristupljeno 30. kolovoza 2020.).

Neki od najpopularnijih algoritama koji se koriste za klasifikaciju su:


Logistic Regression (za binarnu klasifikaciju), k-Nearest Neighbors (za binarnu klasifikaciju i višeklasnu klasifikaciju), decision Trees (za binarnu klasifikaciju i višeklasnu klasifikaciju), support Vector Machine (za binarnu klasifikaciju), naive Bayes (za binarnu i višeklasnu klasifikaciju), random forest (za višeklasnu klasifikaciju), gradient Boosting (za višeklasnu klasifikaciju).¹⁸

Primjer uporabe klasifikacijskog algoritma u poslovnom okruženju:

Sada će biti postavljena hipotetska poslovna situacija i prikazan graf outputa algoritma da bi detaljnije bili demonstrirani klasifikacijski algoritmi. Pretpostavimo da posjedujemo poduzeće koje proizvodi i prodaje medicinske maske usred globalne epidemiološke situacije. Naše poduzeće se nalazi u metropoli u kojoj ima još 10 poduzeća koji rade istu stvar. Mi želimo da saznamo da li će naše poduzeće, u području u kojem se nalazi uspjeti ispuniti tjednu prodajnu kvotu od 10000 maski. Glavni pokazatelj u prvom primjeru (parametar u našem algoritmu) je broj stanovnika koji žive u krugu s poluprečnikom od 2 kilometra oko našeg poduzeća (naše poduzeće je u centru kruga). Naravno, u stvarnom svijetu, mnogo više varijabli bi bilo potrebno za ovakvu predikciju kao broj zaraženih u tom području, geografska blizina konkurencije, cijena maski itd. ali za prvu demonstraciju će biti korišten samo broj stanovnika kao testnu varijablu. Algoritam će koristiti podatke koji nam govore tko je od ostalih 10 poduzeća uspio preći kvotu i koliko stanovnika živi u krugu s poluprečnikom od 2 kilometra oko njihovih poslovnica. Koristeći te podatke, pomoću klasifikacijskih algoritama nadziranog učenja, predvidjet ćemo da li će naše poduzeće preći tjednu kvotu ili ne.

¹⁸ <https://machinelearningmastery.com/types-of-classification-in-machine-learning/>, (pristupljeno 30. kolovoza 2020.).

Grafikon 5. Jednodimenzionalni primjer problema binarne klasifikacije.




Poduzeća koja su ispunila tjednu kvotu od 10000 prodanih maski.

Poduzeća koja nisu ispunila tjednu kvotu od 10000 prodanih maski.

Izvor: Osobno istraživanje.

Sada ćemo mapirati skupinu podataka koju imamo u grafu iznad na jednodimenzionalnu ravnu. Poduzeća koja su ispunila kvotu ćemo označiti plavom bojom a poduzeća koja nisu ćemo označiti crvenom bojom.


Grafikon 6. Jednodimenzionalni primjer problema binarne klasifikacije.



Izvor: Osobno istraživanje.

Sada ćemo dodati naše poduzeće na ovaj linijski prikaz. Reći ćemo da se naše poduzeće nalazi na području unutar kruga koji ima 6000 stanovnika. Naše poduzeće ćemo označiti zelenom bojom.

Grafikon 7. Jednodimenzionalni primjer problema binarne klasifikacije sa dodatkom našeg poduzeća.



Izvor: Osobno istraživanje.

Ovaj jednodimenzionalni prikaz nam pokazuje da naše poduzeće ima veću šansu da ispuni kvotu nego da je ne ispuni jer je grupiran s ostalim poduzećima koji su uspjeli ispuniti kvotu ali nam ne prikazuje točan presjek koji je algoritam uradio koristeći podatke ostalih poduzeća.

Postoji bolji način prikazivanja rada ovog algoritma ali će nam za to trebati drugi parametar ili drugo „svojstvo“ koje će nam omogućiti da napravimo dvodimenzionalni graf. Drugi parametar će nam biti postotak zaraženih ljudi u krugu. Koristiti ćemo linearnu klasifikaciju da prikazemo distinkciju između poduzeća koji su ispunili kvotu i poduzeća koji nisu.

Linearna funkcija inputa se može napisati ovako:

$$w_1 x_1 + \dots + w_d x_d + b = w^T x + b$$

w = težinski vektor

x = input

b = skalarna pristranost

Izračun predikcije se piše ovako:

$$z = w^T x + b$$

$$y = \begin{cases} 1 & \text{if } z \geq r \\ 0 & \text{if } z < r \end{cases}$$

r = threshold (prag) ¹⁹

Biti će prikazana i nelinearna klasifikacija istog problema. Kao i kod regresijskih problema, nelinearna metoda kod klasifikacijskih problema ili „nelinearna klasifikacija“ je mnogo preciznija od linearne ali je zato i kompliciranija.


Formula za nelinearnu (polinomnu) homogenu klasifikaciju je:

$$k(\vec{x}_i, \vec{x}_j) = (\vec{x}_i \cdot \vec{x}_j)^d$$

Formula za nelinearnu (polinomnu) nehomogenu klasifikaciju je:

$$k(\vec{x}_i, \vec{x}_j) = (\vec{x}_i \cdot \vec{x}_j + 1)^d$$

Grafikon 8. Dvodimenzionalni prikaz linearne binarne klasifikacije prijašnjeg problema:



Izvor: Osobno istraživanje.

Na ordinati su nam prikazani postoci zaraženosti dok nam je na apscisi prikazan broj stanovnika. Uvođenje drugog parametra nam je omogućilo dvodimenzionalni prikaz i linearnu klasifikaciju. Na grafu nam je vizualna reprezentacija linearnog algoritma koji je grupirao podatke u dvije kategorije. Isto kao i u demonstraciji regresijskih algoritama, podaci nisu 100% precizni jer ih u ovim primjerima služim za svrhu demonstracije i simplifikacije a ne preciznosti.


¹⁹http://www.cs.toronto.edu/~rgrosse/courses/csc321_2017/readings/L03%20Linear%20Classifiers.pdf (pristupljeno 31. kol. 2020.).

Na ovom prikazu vidimo linearni separator i primjetimo da je naše poduzeće grupirano sa poduzećima koji su ispunili tjednu kvotu te možemo predvidjeti da naše poduzeće ima veliku šansu da ispuni tjednu kvotu od 10000 prodanih maski.

Slijedeći graf će pokazati dvodimenzionalni prikaz nelinearne binarne klasifikacije. Isto kao i na nelinearnom primjeru regresije, ovdje primijetimo da je nelinearnost preciznija od linearnosti i primijetimo da povećanjem eksponenta u formuli povećavamo broj krivulja koje separator može napraviti što rezultira preciznijom klasifikacijom.

Dvodimenzionalni prikaz nelinearne binarne klasifikacije prijašnjeg problema:

Grafikon 9. Dvodimenzionalni prikaz nelinearne binarne klasifikacije prijašnjeg problema:



Izvor: Osobno istraživanje.

I na ovom, preciznijem prikazu, vidimo da naše poduzeće ima dosta veću šansu da uspije prijeći tjednu kvotu nego da ne uspije.

5. Unsupervised learning/nenadzirano učenje

Nenadzirano učenje je tip mašinskog učenja koji u skupini podataka traži prethodno neprimijećene paterne koje nemaju prethodne klasifikacije ili oznake, ovaj model strojnog učenja se radi sa što manje ljudskog nadziranja. Za razliku od nadziranog učenja, koje

obično koristi podatke koje ljudi označe, nenadzirano učenje, još poznato kao „samo-organizacija“ omogućava modeliranje gustoća vjerojatnosti od inputa.

Dvije od glavnih metoda koje se koriste u nenadziranom učenju su cluster analysis (klaster analiza) i principal component (glavna komponenta).²⁰ Nenadzirano učenje nam omogućava da pristupimo problemima s malo ili bez mogućnosti predviđanja izgleda rezultata. Možemo izvući strukturu iz podataka u kojima ne znamo učinke varijabli.²¹

Neke od namjena i primjera uporabe nenadziranog učenja su:

Podjela podataka u grupe na osnovi njihovih sličnosti.

Detekcija anomalija ili pronalaženje nepravilnosti/neuobičajenih točaka u podacima. Ovo je korisno za pronalaženje lažnih transakcija ili promjena u malware-u od strane napadača.

„Association mining“ koje nam omogućava da identificiramo grupe stavki u našoj grupi podataka.

Online vijesti kao „Google News“ koriste nenadzirano učenje da bi grupirali podatke i vijesti koje su tematski povezane.

Biolozzi grupiraju gene iz mnogo različitih ljudi na osnovi sličnosti koristeći nenadzirano strojno učenje.

Segmentiranje tržišta i ciljano oglašavanje.

Analiza društvenih mreža. Koristeći „znanje“ o prijateljima sa društvenih mreža, algoritmi nenadziranog učenja saznaju tko su novi ljudi koje bi mogli poznavati i koje grupe prijatelja bi se mogle međusobno poznavati.

Analiza astronomskih podataka.

²⁰ https://en.wikipedia.org/wiki/Unsupervised_learning, (pristupljeno 31. kolovoza 2020.).

²¹ <https://www.coursera.org/learn/machine-learning/home/welcome>, (pristupljeno 31. kolovoza 2020.).

Većina ovih uporaba se realizira pomoću „clustering“ algoritama. Algoritmi nenadziranog učenja omogućavaju korisnicima da izvršavaju više kompleksne zadatke u usporedbi s algoritmima nadziranog učenja. Ovi algoritmi su obično više nepredvidivi nego ostale metode mašinskog učenja. Neki od ovih algoritama su: clustering (klasteriranje), detekcija anomalija, neuronske mreže, itd.

Neki od razloga zašto koristiti nenadzirano učenje su:

Pomaže nam da pronađemo veliki broj nepoznatih paterna u podacima koje možemo koristiti u svakakve svrhe uključujući poslovne.

Pomaže nam da pronađemo značajke koji nam mogu biti korisne za kategorizaciju.²²

Ova metoda se dešava u stvarnom vremenu, što znači da možemo promatrati rad algoritama i učiti iz njih.

Lakše je dobiti neoznačene podatke iz računara nego označene podatke, koji trebaju ručnu intervenciju.

Najveći nedostatak nenadziranog učenja je činjenica da ne možemo dobiti precizne informacije glede sortiranja podataka.

5.1. Cluster analysis/clustering

Klasteriranje ili klaster analiza se koristi u nenadziranom učenju da bi se grupirali ili segmentirali podaci sa sličnim atributima s ciljem ekstrapolacije algoritmičnih povezanosti. To je grupa algoritama strojnog učenja koja grupira podatke koji nisu obilježeni, klasificirani ili kategorizirani. Umjesto da reagira na povratne informacije, klaster analiza identificira sličnosti u podacima i reagira na osnovi prisutnosti ili odsutnosti tih sličnosti u svakoj novoj instanci ili dijelu podataka. Ovaj pristup pomaže pri detekciji anomalija ili neuobičajenosti u dijelovima podataka koji ne pripadaju niti u jednu grupu.²³

²² <https://www.guru99.com/unsupervised-machine-learning.html> (pristupljeno 1. rujna 2020.)

²³ https://en.wikipedia.org/wiki/Unsupervised_learning (pristupljeno 1. rujna 2020.)

Algoritmi klasteriranja procesiraju podatke da bi pronašli prirodne „klastere“ ili grupe ako one postoje u tim podacima. Mi možemo modificirati broj klastera koje naš algoritam treba identificirati što nam omogućava da podešavamo „zrnatost“ ovih grupa.

Postoje različite metode klasteriranja:

Ekskluzivni (partitioning): ova klastering metoda grupira podatke na način da oni mogu pripadati samo jednom klasteru. Primjer algoritma ove metode je K-means.

Overlapping (preklapajući): u ovoj metodi, „fuzzy“ grupe se koriste da se klasteriraju podaci. Svaka točka može pripadati u dva ili više klastera sa različitim stupnjevima pripadnosti. Ovdje, podaci su asocirani sa prikladnom vrijednošću pripadnosti. Primjer algoritma je Fuzzy C-means.²⁴

Agglomerative clustering: u ovoj tehnici svaki podatak je klaster. Iterativne unije između dva najbliža klastera smanjuju broj klastera. Primjer algoritma je hijerarhijsko klasteriranje.

Probabilistic clustering: ova tehnika koristi distribuciju vjerojatnosti da stvori klastere. Primjer: Sljedeće ključne riječi: „man's shoe“, „women's shoe“, „women's glove“, „man's glove“ se mogu klasterirati u dvije kategorije. „shoe“ i „glove“ ili „man“ i „woman“.²⁵

Principal component analysis (PCA): je nenadzirana tehnika koja se koristi da bi se preprocesirala i smanjila dimenzionalnost visoko-dimenzionalnih skupina podataka. U ovoj tehnici važno je sačuvati originalnu strukturu i veze koje su ključne u originalnom skupu podataka tako da bi modeli strojnog učenja još uvijek mogli učiti od njih i koristiti ih da bi napravili precizna predviđanja. Ovu metodu možemo aplicirati na klastere da bi smanjili njihovu dimenzionalnost.²⁵

To su bile neke od metoda klasteriranja, sada će biti nabrojani algoritme koje se koriste u klaster analizama.

²⁴ https://en.wikipedia.org/wiki/Unsupervised_learning (pristupljeno 1. rujna 2020.)

²⁵ <https://hackernoon.com/principal-component-analysis-unsupervised-learning-model-8f18c7683262> (pristupljeno 1. rujna 2020.)


Hijerarhijsko klasteriranje: to je algoritam koji pravi hijerarhiju klastera. Strategije za ovu metodu su „agglomerative“ i „divisive“ strategije. Algoritam završava kad ostane samo jedan klaster.

K-means klasteriranje: ovo je iterativni clustering algoritam koji nam pomaže da nađemo najveću vrijednost za svaku iteraciju. Na početku, izabran je željeni broj klastera. U ovoj metodi podatke moramo klasterirati u k-grupe. Što je veći „k“, to su manje grupe sa više zrnatosti. Isto tako što je manji „k“, to su veće grupa sa manje zrnatosti. Output ovog algoritma je grupa „oznaka“. Svaka grupa u ovom algoritmu je definirana kreacijom „centroida“. Centroidi su kao srca klastera, oni „hvataju“ točke najbliže njima i dodaju ih u klaster. K-means klasteriranje definira dvije podgrupe: dendogram i agglomerative clustering.²⁶

DBSCAN: Density-based spatial clustering of applications with noise algoritam.

OPTICS: Ordering points to identify the clustering structure algoritam.

Grafikon 10. Prikaz razlike između klasteriranja i klasifikacije.



Izvor: <https://towardsdatascience.com/clustering-clearly-explained-5561642ec20c>, (pristupljeno 1. rujna 2020.).

²⁶ https://en.wikipedia.org/wiki/Unsupervised_learning (pristupljeno 1. rujna 2020.)

Ovdje vidimo razliku između klasteriranja i klasifikacije. Vidimo da kod klasteriranja podaci nisu označeni i da se grupiraju po točkama koje su blizu jedne drugima, kod klasifikacije podaci su označeni i treba nam „pravilo“ ili hyperplane da bi dodijelili oznake na nove točke.

5.2. Neuronske mreže

Neuronske mreže su već bile objašnjene u ovom radu (stranica 5). Ovdje će biti daljnje razrađene i govoriti ćemo o njima u kontekstu nenadziranog učenja. Klasični primjer nenadziranog učenja u proučavanju neuronskih mreža je Donald Hebbov princip. On tvrdi da neuroni koji se zajedno aktiviraju se i vežu zajedno. U Hebbijevskom učenju, veza se uspostavlja bez obzira na pogrešku ali je isključivo funkcija slučajne podudarnosti između akcijskih potencijala dva neurona. Pretpostavlja se da se Hebbijevsko učenje temelji na nizu kognitivnih funkcija poput prepoznavanja paterni i učenja iz iskustva. Među modelima neuronskih mreža, samoorganizirajuće mape (self-organizing maps (SOM)) i teorija adaptivne rezonancije (adaptive resonance theory(ART)) se obično koriste u algoritmima nenadziranog učenja.

SOM je topografska organizacija u kojoj obližnje lokacije na mapi prikazuju inpute sa sličnim svojstvima.

ART model omogućava broj klastera da varira sa veličinom problema i dopušta korisniku da kontrolira stupanj sličnosti između članova istog klastera pomoću korisnički definirane konstante zvane „the vigilance parameter“. ART mreže se koriste za mnogo „pattern recognition“ zadataka kao „automatsko prepoznavanje mete“ i „obrada seizmičkih signala“. ²⁷

²⁷ https://en.wikipedia.org/wiki/Unsupervised_learning, (pristupljeno 2. rujna 2020.).

5.3. Razlike između nadziranog i nenadziranog učenja:

Tablica 1. Tablica razlika između nadziranog i nenadziranog učenja.

Parametri	Nadzirano učenje	Nenadzirano učenje
Unosni podaci:	Algoritmi su trenirani koristeći označene podatke.	Algoritmi su trenirani koristeći podatke koji nisu označeni.
Složenost računanja:	Nadzirano učenje je jednostavnija metoda.	Nenadzirano učenje je računalno složenija metoda.
Preciznost:	Visoka preciznost i pouzdana metoda.	Manja preciznost i pouzdanost.

Izvor: <https://www.guru99.com/unsupervised-machine-learning.html>, (pristupljeno 2. rujna 2020.).

6. Prepoznavanje glasa

Prepoznavanje glasa je interdisciplinarno potpolje informatike, računalnih znanosti i računalne lingvistike koje razvija metodologije i tehnike koje omogućavaju prepoznavanje i prevođenje govornog jezika u tekst pomoću računala. Poznato je još i kao automatsko prepoznavanje glasa (ASR), računalno prepoznavanje glasa i speech to text (STT). Uključuje znanja i istraživanja s polja računalne znanosti, lingvistike, strojnog učenja i računalnog inženjerstva. „Speaker dependent“ sistemi su ti koji koriste „treening“ ili „enrollment“ u kojima individualni govornik čita tekst ili izolirani vokabular u sistem. Sistem onda analizira glas od tog govornika koristeći strojno učenje i koristi te podatke da „naštima“ prepoznavanje glasa kako bi bilo optimalno za glas tog govornika što rezultira mnogo većom preciznošću. Sistemi koji ne koriste trening se zovu „speaker independent“ sistemi. Iz tehnološke perspektive, prepoznavanje glasa ima dugu povijest sa nekoliko valova velikih inovacija. Najnovije inovacije koje su unaprijedile prepoznavanje glasa su deep learning (duboko učenje) i big data. Ova unapređenja se ne primjete samo u mnoštvu akademskih radova koji su objavljeni u tom području nego i u globalnoj ²⁸

²⁸ https://en.wikipedia.org/wiki/Speech_recognition, (pristupljeno 2. rujna 2020.).

primjeni različitih „deep learning“ metoda pomoću kojih se dizajniraju i raspoređuju sistemi prepoznavanja govora. ²⁹

Moderni sistemi za prepoznavanje glasa koriste neuronske mreže kako bi učili iz iskustva i optimizirali sistem. Sistemi automatske transkripcije koje razvijaju poduzeća kao „Rev“ su pogonjeni sa automatskim prepoznavanjem glasa (ASR) i prirodnim procesiranjem glasa (NLP). ASR je pretvorba izgovorene riječi u tekst a NLP je procesiranje teksta s ciljem izvlačenja njegovog značenja. Gledajući da ljudi često pričaju koristeći kolokvijalni/neformalni govor, skraćenice i akronime, potrebna je velika računalna analiza prirodnog jezika kako bi se proizvela precizna transkripcija. Poteškoće prepoznavanja govora su mnogobrojne ali se smanjuju. Neke od ovih poteškoća uključuju prevladavanje loše opreme za snimanje zvuka, mnogo pozadinskih zvukova, teški naglasci i dijalekti, varirajuća visina ljudskih glasova, itd. Još uvijek nismo usavršili podučavanje mašine da čita govorni jezik kao što ljudi mogu. Slušanje i razumijevanje toga što ljudi pričaju je puno vrijednije nego samo slušanje riječi.

Mašine „uče“ da „slušaju“ naglaske, emocije i infleksije, ali još uvijek smo daleko od savršenstva. Kako tehnologija postaje sve više sofisticirana i više podataka se koristi u specifičnim algoritmima, ove poteškoće se sve brže prevazilaze. Tehnologija koja podržava sučelja koja koriste glasovno prepoznavanje je veoma snažna. S naprecima u umjetnoj inteligenciji i ogromnim količinama govornih podataka koji se mogu „kopati“ za svrhe strojnog učenja, ne bi bilo iznenađujuće da glasovno prepoznavanje postane sljedeće dominantno korisničko sučelje. ³⁰

²⁹ https://en.wikipedia.org/wiki/Speech_recognition, (pristupljeno 2. rujna 2020.).

³⁰ <https://www.rev.com/blog/artificial-intelligence-machine-learning-speech-recognition>, (pristupljeno 2. rujna 2020.).

6.1. Primjer programa koji koristi prepoznavanje glasa

Sad kad je definirano šta je prepoznavanje glasa, biti će demonstriran program koji je kodiran u Javascript-u koristeći HTML i CSS za vizualne elemente. Ovaj program koristi integrirani (u windows 10) API za prepoznavanje glasa. Isti API koristi „Cortana“, microsoft-ov AI assistant. Isto će biti korišten i „ResponsiveVoice“ „text to speech“ API koji pretvara tekst u govor. Prvo će biti pojašnjeno šta ovaj program radi i onda će biti pokazane potencijalne uporabe ovog programa u poslovne svrhe.

HTML:

```
<!DOCTYPE html>

<html lang="en">

  <head>
    <meta charset="UTF-8">
    <meta name="viewport" content="width=device-width, initial-scale=1.0">
    <title>Voice Recognition API v2</title>

    <link rel="stylesheet" href="main.css">
  </head>

  <body>
    <div class="words" contenteditable="true"> </div>

    <script src="https://code.responsivevoice.org/responsivevoice.js?key=*****
*****"></script>
    <script src="script.js"></script>
  </body>

</html>
```

Ovdje imamo kod za jednostavnu HTML web stranicu. U „body“ smo instancirali „ResponsiveVoice“ „Text to speech“ API.

U „head“ smo se povezali sa CSS kodom koristeći „<link>“ tag.

U „body“ smo se povezali s Javascript kodom koristeći „<script>“ tag.

CSS:

```
html {
  font-size: 10px;
}

body {
  background-color: rgb(120,120,144);
  font-family: "Lucida Sans Unicode";
  font-weight: 200;
  font-size: 20px;
}

.words {
  max-width: 500px;
  margin: 50px auto;
  background: rgb(208,168,176);
  color: black;
  border-radius: 5px;
}
```

Ovdje imamo jednostavan CSS kod za vizualno uređivanje naše web stranice.

Javascript:

```
window.SpeechRecognition = window.SpeechRecognition || window.webkitSpeechRecogni  
tion;
```

Ovom linijom koda instanciramo API prepoznavanja govora.

```
const recognition = new SpeechRecognition();  
recognition.interimResults = false;
```

Ovdje kažemo API-u da ne želimo da nam vraća rezultate prepoznavanja govora dok ne završimo rečenicu, to jeste dok rezultati ne budu finalni. Ako bi ovdje stavili „true“ umjesto „false“ API bi nam vraćao rezultate nakon svake prepoznate riječi/sloga.

```
let p = document.createElement('p');  
const words = document.querySelector(".words");  
words.appendChild(p);
```

Govorimo programu da svaki put kad dobijemo rezultat, napravimo novi paragraf u koji ćemo kasnije ispisati taj rezultat.

```

var gog;
var yt;
var fb;
var wapp;
var net;
var hist;
var ig;
var cr;

```

Instanciramo varijable koje ćemo kasnije koristiti.

```

recognition.addEventListener("result", e => {
  const transcript = Array.from(e.results)
    .map(result => result[0])
    .map(result => result.transcript)
    .join("")
  p.textContent = transcript;
  if(e.results[0].isFinal) {
    p = document.createElement('p');
    words.appendChild(p);
  }
})

```

Ovdje nam je najvažniji dio našeg Javascript koda. Algoritmu za prepoznavanje glasa dodajemo „event listener“. To nam je procedura koje će čekati da se neki događaj („event“) desi, u ovom slučaju to je povratak rezultata glasovnog prepoznavanja.

Kada dobije rezultat ili kad se desi „event“, ova će procedura odraditi zadanu funkciju. Prva funkcija koju smo zadali nam stavlja rezultate glasovnog prepoznavanja u „transcript“. Nakon toga „transcript“ formatiramo tako da na kraju imamo običan tekst. Onda, naša funkcija stavlja dobiveni tekst u prije spomenute paragrafe.

U ovom dijelu već imamo stranicu koja koristi glasovno prepoznavanje da ispisuje ono što mi govorimo na ekran. Sljedeće što trebamo uraditi je dodavati različite funkcije koje će se izvršiti kada mi kažemo neku specifičnu riječ ili rečenicu.

```

var a = ["blue", "red", "green", "Green", "thistle", "olive", "turquoise", "Peru", "violet", "teal", "purple", "pink", "orange", "Orange", "silver", "yellow", "cyan", "magenta", "black", "white", "gray", "brown", "Brown", "grey", "maroon", "Grey", "lime", "aquamarine", "chocolate", "lavender", "Navy", "fuchsia"];
for(var i=0; i <= a.length; i++) {
  if(transcript.includes(a[i])) {
    document.body.style.backgroundColor = a[i];
  }
}

```

Ovo je funkcija koja će promijeniti boju pozadine u boju koju kažemo.


```
if(transcript.includes("repeat after me")) {
    var b = transcript;
    b = b.replace("repeat after me", "");
    responsiveVoice.speak(b);
}
```

Ova funkcija će nakon izgovaranja fraze „repeat after me“, koristeći „ResponsiveVoice“ „text to speech“ API, ponoviti za nama ono što kažemo.

Napomena: Koristim terminologiju „funkcija“ za prije spomenute i buduće skupine koda jer su dio veće funkcije koja se izvrši kada „event listener“ dobije rezultat od algoritma za prepoznavanje govora. Smatram to prikladnim nazivom za ove „for loops“, „if statements“, itd. jer su dio glavne funkcije i u većini slučajeva su jedina stvar koja se izvrši u jednom pozivu glavne funkcije te se mogu smatrati „podfunkcijama“.

```
if(transcript.includes("Google")) {
    gog = window.open('http://google.com')
}
if(transcript.includes("exit")) {
    gog.close()
};
```

Ovo je funkcija koja kad kažemo „Google“, nam u browseru otvori novi prozorčić i ode na adresu <http://google.com>. Kad kažemo „exit“, program će nam zatvoriti prije otvoreni prozorčić.

```
if(transcript.includes("Corona")) {
    cr = window.open('https://www.worldometers.info/coronavirus/')
};
if(transcript.includes("virus")) {
    cr.close()
};
```

Ako kažemo „Corona“, otvoriti će nam se novi prozorčić koji će otići na adresu stranice koja nam pokazuje globalne statistike korona virusa u stvarnom vremenu. Ako kažemo „virus“, taj prozorčić će se zatvoriti.

```
if(transcript.includes("reload")) {
    location.reload();
};
```

Ako kažemo „reload“, ponovno će nam se učitati web stranica u kojem je naše sučelje za prepoznavanje glasa.

Slika 1. Prikaz sučelja programa koji koristi prepoznavanje glasa.



Izvor: Osobno istraživanje.

Ovako izgleda naše sučelje u kojem se ispisuju riječi koje izgovaramo.

```
recognition.addEventListener("end", recognition.start);  
recognition.start();
```

Prva linija koda nam dodaje novi „event listener“ koji čeka da se prvi završi, nakon što se završi, ovaj „event listener“ govori API-u za prepoznavanje glasa da opet počne „slušati“.

Druga linija koda govori API-u za prepoznavanje glasa da prvi put počne „slušati“ i s tim započinje cijeli program.

6.2. Primjena ovog programa u poslovanju:

Mi ovaj program možemo primijeniti u poslovne svrhe na mnogo načina. Jedna od stvari koje možemo uraditi je napraviti funkciju koja će raditi specifične stvari koje su nam korisne u nekom poslovanju. Zamislimo da smo neko poduzeće koje se bavi proizvodnjom brze hrane, zamislimo da imamo „take-out lane“, to jest stazu za automobile da prođu i ponesu hranu kući. Mi možemo automatizirati proces narudžbe hrane koristeći algoritme prepoznavanja glasa tako što će naši klijenti u mikrofon reći ili broj narudžbe koju žele ili naziv narudžbe i tako izvršiti narudžbu eliminirajući potrebu za ljudskom intervencijom.

Još jedan primjer korištenja ovakvog programa u poslovne svrhe bi bio sljedeći. Pretpostavimo da posjedujemo poduzeće koje proizvodi i prodaje software za specifične medicinske svrhe. Klijent koji je slijep nam zatraži da za njega iskodiramo program koji će mu pomoći u navigaciji i orijentaciji. Za ovo možemo koristiti prepoznavanje glasa, strojno učenje i električno inženjerstvo. Mogli bi koristiti prije demonstrirani program koji bi registrirao glas klijenta i izvršavao njegove upute. Koristili bi neki „single board“ računar kao „Raspberry Pi“ i spojili ga na kameru koja je instalirana na servo motor. Koristili bi strojno učenje i stotine tisuća iteracija „treeninga“ razaznavanja predmeta. Pomoću algoritama strojnog učenja za razaznavanje predmeta naučili bi naš sistem da „označi“ predmete u stvarnom svijetu kao „automobil“, „pješački prelaz“, „semafor“, itd. Kamera bi omogućila programu da „vidi“ predmete i mogla bi sama sebe podešavati koristeći servo motor. Kamera bi bila pozicionirana na odjevnom predmetu klijenta. Korisnik bi davao glasovne komande sistemu koji bi onda pokretao funkcije. Primjer ovoga je da korisnik pita program „gdje se trenutno nalazim?“ i program mu odgovori, (koristeći „text to speech“) „nalazite se (trenutna lokacija korisnika prikupljena pomoću mikro gps prijemnika priključenog na raspberry pi)“. Korisnik isto može pitati „šta se nalazi ispred mene“, kamera će poslati podatke algoritmu za razaznavanje predmeta i algoritam će vratiti tekstualni podatak koji će „text to speech“ algoritam pročitati korisniku i tako mu reći šta se nalazi ispred njega.

7. Umjetna inteligencija i poslovanje danas

Umjetnu inteligenciju ne smatramo zamjenom za ljudsku inteligenciju i domišljatost nego je smatramo kao pomoćni alat. Iako umjetna inteligencija trenutno ima poteškoće u rješavanju nekih od jednostavnijih zadataka u stvarnom svijetu, vješta je u procesiranju i analiziranju hrpa podataka puno brže nego što ljudski mozak može. Softveri umjetne inteligencije onda mogu vratiti sintetizirane „planove akcije“ koje su dobili od analize velikih količina podataka i predstaviti ih korisnicima. Na ovaj način, ljudi mogu koristiti umjetnu inteligenciju da mapiraju moguće posljedice svake radnje i ³¹

³¹ <https://www.businessnewsdaily.com/9402-artificial-intelligence-business-trends.html>, (pristupljeno 3. rujna 2020.).

ubrzaju proces pravljenja odluka. „Umjetna inteligencija je kao drugi dolazak software-a“ rekao je Amir Husain, osnivač i direktor tvrtke za strojno učenje „SparkCognition“. „To je forma software-a koja samostalno pravi odluke i može da djeluje u situacijama koje nisu predviđene ni od strane programera. Umjetna inteligencija ima veći opseg sposobnosti za pravljenje odluka od tradicionalnog software-a“. Ove odlike čine umjetnu inteligenciju veoma vrijednom među mnogim industrijskim granama, bilo da je to jednostavno pomaganje posjetiteljima i osoblju da učinkovito pronalaze put oko kampusa ili da obavlja složene zadatke poput nadzora vjetroagregata kako bi predvidjeli kada će se trebati popravljati. Strojno učenje se često koristi u sistemima koji se bave velikom veličinom podataka. Na primjer, sistemi pametnog menadžmenta energije sakupljaju podatke od senzora koji su spojeni na razne dijelove. Ta hrpa podataka je onda kontekstualizirana pomoću strojnog učenja i algoritama i dostavljena ljudima koji prave odluke da bi lakše razumjeli potrošnju energije i potrebe održavanja.

Umjetna inteligencija je čak i nezamjenjiv saveznik u borbi protiv rupa u obranbenim sustavima računalnih mreža. Nikad ne možemo imati dovoljno stručnjaka za kibernetičku sigurnost koji bi pregledali sve ove probleme. To nije moguće zbog njihovog exponencijalnog rasta u složenosti i zato nam je potrebna umjetna inteligencija da bi nam olakšala nošenje s ovakvim problemima.

Umjetna inteligencija također mijenja sustave upravljanja odnosima s kupcima (CRM). Softveri poput „Salesforce“ ili „Zoho“ zahtijevaju snažnu ljudsku intervenciju kako bi ostali ažurni i točni, ali kada primijenimo umjetnu inteligenciju na ove platforme, normalan CRM sustav se pretvara u sustav koji se automatski ažurira i ispravlja te koji stoji na vrhu sektora upravljanja odnosa.

Još jedan primjer korisnosti i raznovrsnosti umjetne inteligencije se nalazi u financijskom sektoru. Korištenjem ove tehnologije, ako imamo hipoteku u banci i treba je obnoviti za 90 dana ili manje, ako šetamo pored neke podružnice banke, dobit ćemo personaliziranu poruku koja će nas obavijestiti da trebamo otići u tu podružnicu i obnoviti kupnju. ³²

³² <https://www.businessnewsdaily.com/9402-artificial-intelligence-business-trends.html>, (pristupljeno 3. rujna 2020.).

Zaključak

Ljudi u modernom svijetu koriste umjetnu inteligenciju sve više i više, u mnogo slučajeva je koristimo a i da ne primijetimo. Sa ovim masovnim korištenjem postavlja se pitanje „da li će mašine učiniti ljude bespotrebnim“. Neki stručnjaci misle da nikada nećemo stići do trenutka u budućnosti u kojem mašine preuzmu sve ljudske poslove i ljudi ostanu bez načina prihoda, dok drugi misle da je to velika mogućnost i problem koji treba razmatrati. Struktura poslovanja se mijenja ali to ne mora značiti da će umjetna inteligencija nužno zamijeniti poslove. Dopustit će nam da napravimo ekonomiju baziranu na znanju i napraviti će bolju automatizaciju svakodnevnog života. Ne trebamo se brinuti da će umjetna inteligencija i roboti zamijeniti sve ljudske poslove, algoritmi će najvjerojatnije zamijeniti „white-collar“ poslove kao poslovne analitičare, računovođe, itd. Ali to nam omogućava da se fokusiramo na ostale specijalizacije i da automatiziramo ono što možemo. Pomak prema sustavima temeljenim na umjetnoj inteligenciji vjerojatno će uzrokovati da gospodarstvo dodaje radna mjesta koja olakšavaju tranziciju. Umjetna inteligencija će uzrokovati više zarade nego što će uništiti, ali prvobitno, ta zarada neće biti jednako raspoređena. Budućnost brzo dolazi i umjetna inteligencija će sigurno biti veliki dio nje. Kako se ova tehnologija razvija, svijet će vidjeti nove startape, mnogobrojne poslovne aplikacije i načine uporabe za korisnike. Neki će poslovi biti zamijenjeni ali će se mnogo novih poslova stvoriti. Umjetna inteligencija ima potencijal da dramatično preuredi ekonomiju i gospodarstvo ali točan utjecaj umjetne inteligencije tek trebamo vidjeti.

Sažetak rada na hrvatskom jeziku:

Cilj ovog završnog rada je educiranje čitatelja na temu „umjetna inteligencija u poslovanju“. Čitatelji će naučiti o važnim aspektima umjetne inteligencije i njenoj uporabi u poslovnom svijetu. Naučiti će o strojnom učenju, njegovim algoritmima i njegovoj podjeli na nadzirano i nenadzirano strojno učenje. Obje podjele će se detaljno opisati i pojednostavniti s primjerima. Strojno učenje će biti definirano i biti će nabrojani algoritmi i metode istog. Ovaj rad će opisati regresijske i klasifikacijske probleme nadziranog strojnog učenja i opisati će aspekte nenadziranog učenja kao prepoznavanje glasa i neuronske mreže. Prepoznavanje glasa će biti detaljno razrađeno koristeći primjer programa koji ga koristi. Rad je pun grafova i tablica koje dodatno objašnjavaju temu koju opisuju. Čitatelji će naučiti o mnogo trenutnih i budućih mogućih primjena umjetne inteligencije u poslovnom svijetu te će im biti pokazani primjeri istih. Usporedba nadziranog i nenadziranog učenja će biti pokrivena te će isto tako biti pokrivena i usporedba klasifikacijskih i regresijskih problema i algoritama. Čitatelji će dobiti znanje o razlikama između umjetnih neuronskih mreža i bioloških neuronskih mreža. Rezultat rada je pojednostavljen izvor informacija glede umjetne inteligencije u poslovanju, strojnog učenja, neuronskih mreža, itd. Rad doprinosi znanstvenoj i edukacijskoj zajednici tako što omogućava dodatni način pristupa informacijama te grupiran skup podataka na datu temu.

The summary of the final work:

The goal of this final work is the education of the readers on the subject of “artificial intelligence in a business sense”. The readers will learn about the important aspects of artificial intelligence and its use in the business world. They will learn about machine learning, its algorithms and its classification into supervised and unsupervised machine learning. Both of these classifications will be thoroughly described and simplified using examples. Machine learning will be defined and its algorithms and methods will be listed. This work will describe the regression and classification problems of supervised learning and will describe the aspects of unsupervised learning such as vocal recognition and neural networks. Voice recognition will be thoroughly worked through using an example of a program that uses it. The work is filled with graphs and tables that additionally explain the subject at matter. The readers will learn about lots of possible current and future uses of artificial intelligence in the business world and will be shown examples of the aforementioned uses. The comparison between supervised and unsupervised learning will be covered and so will the differences between classification and regression problems and algorithms. The readers will also gain knowledge of the differences between artificial and biological neural networks. The result of this work is a simplified source of information regarding artificial intelligence in the business world, machine learning, neural networks and so on... The work contributes to the scientific and educational communities by providing an additional way to access information and an aggregated data set on the subject at hand.

Popis literature po redosljedu u radu:

- ¹https://en.wikipedia.org/wiki/Artificial_intelligence, (pristupljeno 26. kolovoza 2020.).
- ²https://en.wikipedia.org/wiki/Machine_learning, (pristupljeno 26. kolovoza 2020.).
- ³https://en.wikipedia.org/wiki/Machine_learning, (pristupljeno 27. kolovoza 2020.).
- ⁴ <https://www.coursera.org/learn/machine-learning/home/welcome>, (pristupljeno 27. kolovoza 2020.).
- ⁵ <https://www.businessnewsdaily.com/9402-artificial-intelligence-business-trends.html>, (pristupljeno 27. kolovoza 2020.).
- ⁶ https://en.wikipedia.org/wiki/Artificial_neural_network, (pristupljeno 27. kolovoza 2020.).
- ⁷ https://en.wikipedia.org/wiki/Supervised_learning, (pristupljeno 27. kolovoza 2020.).
- ⁸ <https://www.coursera.org/learn/machine-learning/home/welcome>, (pristupljeno 28. kolovoza 2020.).
- ⁹ <https://www.coursera.org/learn/machine-learning/home/welcome>, (pristupljeno 28. kolovoza 2020.).
- ¹⁰ <http://www.pmean.com/06/QuadraticRegression.html>, (pristupljeno 28. kolovoza 2020.).
- ¹¹ <https://www.coursera.org/learn/machine-learning/home/welcome>, (pristupljeno 29. kolovoza 2020.).
- ¹² <http://www.pmean.com/06/QuadraticRegression.html>, (pristupljeno 29. kolovoza 2020.).
- ¹³ <https://towardsdatascience.com/linear-vs-polynomial-regression-walk-through-83ca4f2363a3>, (pristupljeno 29. kolovoza 2020.).
- ¹⁴ <http://www.pmean.com/06/QuadraticRegression.html>, (pristupljeno 29. kolovoza 2020.).
- ¹⁵ <https://machinelearningmastery.com/types-of-classification-in-machine-learning/>, (pristupljeno 29. kolovoza 2020.).
- ¹⁶ <https://machinelearningmastery.com/types-of-classification-in-machine-learning/>, (pristupljeno 29. kolovoza 2020.).
- ¹⁷ <https://www.geeksforgeeks.org/regression-classification-supervised-machine-learning/>, (pristupljeno 30. kolovoza 2020.).
- ¹⁸ <https://machinelearningmastery.com/types-of-classification-in-machine-learning/>, (pristupljeno 30. kolovoza 2020.).
- ¹⁹ http://www.cs.toronto.edu/~rgrosse/courses/csc321_2017/readings/L03%20Linear%20Classifiers.pdf, (pristupljeno 31. kol. 2020.).
- ²⁰ https://en.wikipedia.org/wiki/Unsupervised_learning, (pristupljeno 31. kolovoza 2020.).
- ²¹ <https://www.coursera.org/learn/machine-learning/home/welcome>, (pristupljeno 31. kolovoza 2020.).
- ²² <https://www.guru99.com/unsupervised-machine-learning.html> (pristupljeno 1. rujna 2020.)
- ²³ https://en.wikipedia.org/wiki/Unsupervised_learning (pristupljeno 1. rujna 2020.)
- ²⁴ https://en.wikipedia.org/wiki/Unsupervised_learning (pristupljeno 1. rujna 2020.)
- ²⁵ <https://hackernoon.com/principal-component-analysis-unsupervised-learning-model-8f18c7683262> (pristupljeno 1. rujna 2020.)
- ²⁶ https://en.wikipedia.org/wiki/Unsupervised_learning (pristupljeno 1. rujna 2020.)
- ²⁷ https://en.wikipedia.org/wiki/Unsupervised_learning, (pristupljeno 2. rujna 2020.).
- ²⁸ https://en.wikipedia.org/wiki/Speech_recognition, (pristupljeno 2. rujna 2020.).
- ²⁹ https://en.wikipedia.org/wiki/Speech_recognition, (pristupljeno 2. rujna 2020.).
- ³⁰ <https://www.rev.com/blog/artificial-intelligence-machine-learning-speech-recognition>, (pristupljeno 2. rujna 2020.).
- ³¹ <https://www.businessnewsdaily.com/9402-artificial-intelligence-business-trends.html>, (pristupljeno 3. rujna 2020.).
- ³² <https://www.businessnewsdaily.com/9402-artificial-intelligence-business-trends.html>, (pristupljeno 3. rujna 2020.).

Popis tablica i grafikona:

Grafikon 1 Prikaz skupa podataka o prodanim kućama iz grada Portland, Oregon. (str. 7)

Grafikon 2 Prikaz primjera linearne regresije koristeći podatke o prodaji kuća iz Oregona. (str. 8)

Grafikon 3 Prikaz primjera kvadratne regresije koristeći podatke o prodaji kuća iz Oregona. (str. 9)

Grafikon 4 Primjer linearne i kvadratne regresije. (str. 10)

Grafikon 5. Jednodimenzionalni primjer problema binarne klasifikacije. (str. 13)

Grafikon 6. Jednodimenzionalni primjer problema binarne klasifikacije. (str. 13)

Grafikon 7. Jednodimenzionalni primjer problema binarne klasifikacije sa dodatkom našeg poduzeća. (str. 14)

Grafikon 8. Dvodimenzionalni prikaz linearne binarne klasifikacije prijašnjeg problema. (str. 15)

Grafikon 9. Dvodimenzionalni prikaz nelinearne binarne klasifikacije priješnjeg problema. (str. 16)

Grafikon 10. Prikaz razlike između klasteriranja i klasifikacije. (str. 20)

Tablica 1. Tablica razlika između nadziranog i nenadziranog učenja. (str. 22)

Slika 1. Prikaz sučelja programa koji koristi prepoznavanje glasa. (str. 28)