

Uloga ljudi u interaktivnom strojnom učenju

Tomac, Toni

Undergraduate thesis / Završni rad

2021

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:137:200618>

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

Download date / Datum preuzimanja: **2024-04-27**



Repository / Repozitorij:

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



Sveučilište Jurja Dobrile u Puli

Fakultet Informatike u Puli

TONI TOMAC

ULOGA LJUDI U INTERAKTIVNOM STROJNOM UČENJU

Završni rad

Pula, rujan, 2021.

Sveučilište Jurja Dobrile u Puli

Fakultet Informatike u Puli

TONI TOMAC

ULOGA LJUDI U INTERAKTIVNOM STROJNOM UČENJU

Završni rad

JMBAG: 0303069622, redoviti student

Kolegij: Osnove IKT

Znanstveno područje: Društvene znanosti

Znanstveno polje: Informacijske i komunikacijske znanosti

Znanstvena grana: Informacijski sustavi i Informatologija

Studijski smjer: Sveučilišni preddiplomski studij Informatika

Mentor: doc.dr.sc. Snježana Babić

Pula, rujan, 2021.



IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani Toni Tomac, kandidat za prvostupnika informatike 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 nedozvoljeni 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

Toni Tomac

U Puli, 14.01.2021.



IZJAVA O KORIŠTENJU AUTORSKOG DJELA

Ja, Toni Tomac dajem odobrenje Sveučilištu Jurja Dobrile u Puli, kao nositelju prava iskorištavanja, da moj Završni rad pod nazivom Uloga ljudi u interaktivnom strojnom učenju

koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, rujan, 2021.

Potpis

Toni Tomac

Sadržaj

1. Uvod	1
2. Strojno učenje	2
2.1. Povijest	4
2.2. Metode strojnog učenja	5
2.2.1. Nadzirano učenje	5
2.2.2. Nenadzirano učenje	7
3. Interaktivno strojno učenje	11
3.1. Okvir za interaktivno strojno učenje	15
4. Uloga ljudi u strojnom učenju	19
4.1. Primjeri uloge ljudi u interaktivnom strojnom učenju	21
5. Zaključak	31
6. Literatura	32
SAŽETAK	38

1. Uvod

U današnje doba interneta strojno učenje postaje sve popularnije i prisutnije. Pojavom Interneta strojno učenje je doživjelo ogroman porast korištenja i rasprostranjenosti, te su se pojavili potpuno novi resursi i mogućnosti. Strojno učenje je zaživjelo u svim ljudskim djelatnostima, a interakcija između korisnika i stroja je postala svakodnevna.

Potencijal strojnog učenja u olakšavanju svakodnevnih radnji je brzo prepoznat od strane ljudi bez kojih to sve ne bi bilo moguće, a u ovom radu će se objasniti na koje načine. Sustavi koji mogu interaktivno učiti od svojih krajnjih korisnika postaju rašireniji. Sve više istraživača shvaća važnost proučavanja korisnika ovih sustava. Taj napredak je donedavno uglavnom bio potaknut napretkom strojnog učenja. interaktivno komuniciranje korisnika i sustava rezultira i boljim korisničkim iskustvom.

U ovom radu cilj je predložiti na koje to sve načine ljudi mogu interaktivno komunicirati sa strojem. Završni rad je podijeljen u šest poglavlja. U uvodnom se pojašnjava korištenje strojnog učenja. Nakon toga slijedi poglavlje gdje se objašnjava strojno učenje i njegova povijest. Tu su još objašnjene metode strojnog učenja i unutar tih podjela će se objasniti njihova primjena te metode i postupke uz koje se mogu koristiti. Zatim, slijedi cjelina o interaktivnom strojnom učenju u kojoj se opisuje što je zapravo interaktivno strojno učenje i koja je njegova uloga. Unutar interaktivnog strojnog učenja objašnjen je okvir za interaktivno strojno učenje koji koristi transparentno stablo za povećanje snage. U četvrtom poglavlju se uz primjere prikazuje uloga ljudi u interaktivnom strojnom učenju. Primjeri koji su objašnjeni su glazba temeljena na gestama, videoigra temeljena na pokretima tijela i segmentacija slike s interaktivnim strojnim učenjem. U petom poglavlju se nalazi zaključak o ulozi ljudi u interaktivnom strojnom učenju. Zadnja, odnosno šesta cjelina prikazuje literaturu koja je korištena prilikom izrade završnog rada.

2. Strojno učenje

Definicija strojnog učenja je računalni program uči ako se performanse izvršavanja zadatka T , mjerene pomoću mjere uspješnosti P , poboljšavaju s iskustvom E (Mitchell, 1997).

Strojno učenje je programiranje računala tako da optimiziraju neki kriterij uspješnosti temeljem podatkovnih primjera ili na temelju prethodnog iskustva. Glavni cilj im je izgraditi računalni sustav koji automatski kroz iskustvo poboljšava svoje performanse. U prošlosti su računala mogla raditi samo ono za što su programirana, pomoću strojnog učenja omogućeno im je da pomoću algoritama strojnog učenja uče na sličan način kao i ljudi gdje stroj prikuplja znanje bazirano na prošlom iskustvu. Kako bi se spriječilo stalno ažuriranje softverskog koda on tijekom vremena postane sposoban samostalno poboljšavati svoj rad što je s aspekta financijske strane jedna velika prednost. Kod strojnog učenja program ne dobije odmah najbolje rješenje nego od više mogućih rješenja izabere najbolje.

Osnova strojnog učenja je računalni program koji nema tipičnu algoritamsku strukturu nego iz prikupljenih podataka ili drugačije definiranih iskustava odabire najprikladniji, a kada se govori o algoritmu u računalnom smislu podrazumijeva se niz instrukcija koje se moraju slijediti kako bi se ulaz pretvorio u traženi izlaz (Alpaydin, 2019).

Kako bi mogli koristiti strojno učenje potrebno je biti upoznat s podacima koji se koriste. Podatak je formalizirani zapis pogodan za komuniciranje, interpretaciju i obradu pomoću ljudi ili strojeva. Nad podacima se vrši niz postupaka kako bi se dobila ispravna rješenja, a to se naziva obrada podataka koja se obavlja putem programa, a onaj rezultat koji se dobije od obrade podataka naziva se informacija (Wikipedija, 2020).

Strojno učenje je nastalo na temelju raznih disciplina i njihovih metoda. Neke od disciplina su statistika, rudarenje podacima (eng. Data Mining), umjetna inteligencija. Statistika je skup alata pomoću kojih možete dobiti odgovore na pitanja o podacima. Statistika i strojno učenje su usko povezana područja, toliko da i statističari strojno učenje nazivaju „statističkim učenjem“ i statistika se smatra preduvjetom za strojno učenje. Potrebna je statistika koja će pomoći da se promatranja pretvore u informacije i dobiju odgovori na pitanja o uzrocima opažanja.

Pomoću statistike koja se u svrhu strojnog učenja koristi za razumijevanje i usporedbu podataka kao i za validaciju modela. Statistika je ključna za adekvatnu pripremu podataka i koristi se kao dio procesa modeliranja. Statistika ima glavnu ulogu u istraživanju podataka koje obavljaju analitičari s podacima te nakon toga donose odluke koje zavise o poslovnim potrebama, to je ujedno i prvi korak strojnog učenja. Statistički podaci se koriste kada iz velikog skupa podataka želimo stvoriti znanstveno pouzdane uzorke i iz toga proizlazi izraz „statistički značajan“ uzorak što znači da želimo dobiti reprezentativni skup podataka prave veličine koji se tada može koristiti za strojno učenje. Algoritmi strojnog učenja su obično kompleksniji od statističkih i zahtijevaju donošenje odluka o dizajnu prije nego što počne proces izrade (Brownlee, 2019).

Strojno učenje je usko povezano i s Bayesov-im metodama koje u globalu pružaju način izračuna vjerojatnosti hipoteze na temelju njene prethodne vjerojatnosti te Bayesov-a statistika pruža mogućnost za ažuriranje znanja na postojeće (Brownlee, 2020).

U današnje vrijeme organizacije sakupljaju ogromne količine podataka na temelju kojih moraju donositi poslovne odluke. Iz navedenog razloga počelo se koristiti rudarenje podacima.

Rudarenje podacima (eng. Data Mining) je sve što obuhvaća sortiranje, grupiranje ili organiziranje velikog broja podataka i izvlačenje informacija koje su relevantne za upotrebu (Wikipedija, 2021). Poznato je još kao i otkrivanje znanja u dostupnim bazama podataka. Za rudarenje podataka postoji čitav niz faktora koji mogu utjecati na konačni rezultat događaja. Ideja je izgraditi računalne programe koji automatski pregledavaju baze podataka, a strojno učenje pruža tehničku osnovu za rudarenje podataka. U pripremi podataka i analizi potreban je ekspert koji razumije značenje ulaznih podataka i da može dati tumačenje dobivenih rezultata koji se pomoću ljudskog znanja mogu razumjeti (Witten, 2011).

Razlika između strojnog učenja i rudarenja podacima je da strojno učenje iz prethodno postojećih podataka i događaja predviđa budući rezultat na temelju trenutnih podataka, a rudarenje podacima uzima obrasce koji već postoje u podacima.

U početku procesa rudarenja podacima obrasci su nepoznati, a kod strojnog učenja računalu se daju neka pravila ili varijable za lakše razumijevanje i učenje. Kao što je i navedeno veliku ulogu u rudarenju podacima imaju ljudi, dok kod strojnog učenja nakon što se uspostave početna pravila i varijable stroj postaje inteligentniji sam po sebi (Marr, 2021).

2.1. Povijest

Razvijanje strojnog učenja je započelo 50-tih godina prošlog stoljeća, a njihova upotreba je zahtijevala puno vremena i bila je ograničena na specifične domene. Nastalo je od sustava koji su se temeljili na obradi različitih vrsta informacija, a kako je vrijeme prolazilo ulagalo se sve više u sustave i postajali su sve razvijeniji. Najpoznatiji sustav 90-tih godina je bio umjetni živčani sustav (eng. Artificial Neural Network). Uz pomoć matematičkih modela bilo je moguće simulirati kognitivne funkcije ljudskog mozga (Alpaydin, 2004).

Kako je napredovala tehnika tako su se sve više razvijali i alati gdje je strojno učenje bilo u mogućnosti brže i efikasnije obrađivati podatke koji su rješavali probleme bez pretpostavki. Tako je danas u računalnim sustavima postalo nemoguće pronaći nešto što ne koristi algoritme strojnog učenja.

2.2. Metode strojnog učenja

Podjela strojnog učenja se dijeli na više kategorija. Prva se dijeli na nadzirano učenje (eng. Supervised) koje može biti pomoću klasifikacije i regresije i nenadzirano (eng. Unsupervised) učenje koje se izvršava grupiranjem, procjenom gustoće i smanjenjem dimenzionalnosti. Ova podjela se pita je li klasificiranje sustava trenirano s ljudskim nadzorom ili ne i po tome odluči o kojoj se podjeli radi. Metoda koja će se još detaljnije obraditi zove se podržano učenje (eng. Reinforcement learning).

2.2.1. Nadzirano učenje (eng. Supervised learning)

Prema Hoffman-u (2019) nadzirano učenje ima sposobnost da predvidi budućnost na temelju prošlosti, a zbog toga se još naziva i model prediktivne analize. Može koristiti povijesne informacije o tržištu dionica kako bi predvidio buduće fluktuacije. Nadzirano učenje pronalazi vezu između skupova podataka i ciljne varijable te ga program mora naučiti dajući primjere iz prošlosti koji su pokazani kao točni. Primjer nadziranog učenja je prepoznavanje lica na slikama gdje na temelju prošlih slika pretpostavi koja je osoba na slici.

Podaci su u obliku x i y , gdje je x ulazna vrijednost, a y predstavlja ciljanu vrijednost. To se može prikazati pomoću $y=f(x)$ funkcije gdje se uz ulazne podatke (x) mogu predvidjeti izlazne varijable (y) za te podatke. Cilj je napraviti model koji će raditi predikcije na novim primjerima (Hoffman, 2019).

Model nadgledanog učenja služi i za razumijevanje koji faktor utječe na ishod i na koji način. Nadzirano učenje pruža nam moćan alat za klasifikaciju i obradu podataka koji u tu svrhu koristi označene podatke, odnosno skup podataka koji je klasificiran. Skup podataka koristi se kao osnova za predviđanje klasifikacije ostalih neobilježenih podataka upotrebom algoritama strojnog učenja, a to se sve postiže uz pomoć tehnika učenja pod nadzorom (Ryan, 2014). Dvije najvažnije tehnike su klasifikacija i regresija.

2.2.1.1. Regresija (eng. Regression)

Regresija je postupak strojnog učenja koji generira izlaznu numeričku vrijednost temeljem atributa čije su vrijednosti isključivo numeričke pa se zbog toga postupak često naziva numerička predikcija. Regresija zahtijeva da vaše podatkovne točke imaju kontinuirane vrijednosti. Prvo se pronalaze neovisne varijable, a zatim se izračunavaju koeficijenti prema neovisnim varijablama koji minimiziraju razlike između stvarnih i predviđenih vrijednosti. Predviđene vrijednosti su kontinuirane, a samim time i regresijski rezultati su kontinuirani (Malik, 2018).

Regresija je jedna od najranija tehnika strojnog učenja koja se još uvijek često upotrebljava. Na osnovnoj razini regresija se koristi za ispitivanje odnosa između jedne ovisne i jedne neovisne varijable.

Regresijski problem je problem kojem je izlaz broj kao na primjer cijena, te su u regresijskom slučaju izlazi kontinuirani, a ne diskretni. Najjednostavnija metoda je linearna regresija gdje se pokušava modelirati odnos između ulazne i izlazne varijable koristeći linearnu ili vektorsku funkciju (Shukla, 2021).

Linearna regresija se smatra analitičkom tehnikom koja se koristi za modeliranje između više ulaznih varijabli i kontinuirane izlazne varijable, a ključna pretpostavka je da odnos između ulazne i izlazne varijable je linearan. Linearna regresija se najčešće koristi u poslovnom svijetu, politici i medicini. Također postoji skup linearnih algoritama koji se mogu koristiti za regresiju, ali i klasifikaciju i procjenu gustoće vrijednosti, a nazivaju se SVM (eng. Support Vector Machines) algoritmi. Još valja napomenuti i logističku regresiju koja je linearna metoda, ali predviđanja se izvršavaju pomoću logističke funkcije, te modelira vjerojatnost zadane klase. Ključna razlika između logističke i linearne regresije je što je kod logističke regresije izlazna vrijednost binarna u obliku 0 i 1, a ne numerička kao kod linearne (Brownlee, 2016).

2.2.1.2. Klasifikacija (eng. Classification)

Dok je kod regresije izlazna varijabla kontinuirana vrijednost, zadatak klasifikacije je procjena klase. Uz ovaj model pokušavamo predvidjeti kategorije odgovora što znači da odgovor na traženo pitanje ima konkretan broj kao odgovor. Primjer klasifikacije je jesu li neki papiri povjerljivi ili dostupni svima, stupnjevi stadija raka, e-mailovi se dijele na spam ili siguran mail. Uz pomoć klasifikacije podaci se spremaju u već prethodno definirane kategorije ili klase s obzirom na svojstvo tih podataka (Brownlee, 2020).

Klasifikacijski model pokušava izvući neki zaključak iz promatranih vrijednosti s obzirom na jedan ili više ulaznih podataka te će klasifikacijski model pokušati predvidjeti vrijednost jednog ili više ishoda.

Najjednostavnija metoda klasifikacije je logistička regresija. Zvuči kao dio regresije, ali nije. Uz pomoć logističke regresije procjenjuje se vjerojatnost pojave događaja na temelju jednog ili više podataka. Koristi se za modeliranje vjerojatnosti konačnog broja ishoda, a to su obično dva ishoda. Logistička jednadžba je stvorena na takav način da izlazne vrijednosti mogu biti samo 0 i 1 (Brownlee, 2016).

2.2.2. Nenadzirano učenje (eng. Unsupervised learning)

U nenadziranom učenju računalu se prepušta nalaženje skrivenih uzoraka u gomili podataka. Tada nema unaprijed određenog odgovora nego se pokrene algoritam koji izvodi strojno učenje i onda se dobije ishod te se zbog toga nenadzirano učenje smatra više kao rudarenje podataka nego strojno učenje. Ovakav način učenja je teško promatrati u svakodnevnom životu zbog toga što se događa intuitivno. Cilj nenadziranog učenja je grupirati podatke prema sličnostima i predstaviti taj skup podataka u odgovarajućem formatu (Johnson, 2021).

Problem s nenadziranim učenjem je taj što ga je teže provesti nego nadzirano učenje, ali unatoč tome je potreban i koristi se učestalo. Neki od razloga zašto se koristi nenadzirano učenje (Mishra, 2017):

- Bilježenje velikih skupova podataka je vrlo skupo i zbog toga ručno se može označiti samo nekoliko primjera, a primjer toga je prepoznavanje govora.
- Postoje slučajevi kada ne znamo na koliko i na koje klase su podaci podijeljeni, a primjer toga je rudarenje podataka.
- Možda ćemo htjeti koristiti klasteriranje da bismo stekli uvid u strukturu podataka prije dizajniranja klasifikatora.

Nenadzirano učenje se primjenjuje na dvije osnovne vrste problema, a to su grupiranje i asocijacija (Mishra, 2017).

2.2.2.1. Grupiranje (eng. Clustering)

Grupiranje je najčešći problem kada je u pitanju nenadzirano učenje, a uglavnom se bavi pronalaženjem uzoraka u grupi nekategoriziranih podataka. Jednostavno rečeno grupiranje je postupak organiziranja objekata u skupine čiji su članovi na neki način slični. Algoritmi grupiranja obrađuju podatke i pronalaze prirodne grupe ako one postoje u podacima. Moguće je promijeniti koliko grupa algoritmi trebaju prepoznati radi lakše podijele podataka (Johnson, 2021).

Postoje različiti načini grupiranja koji se mogu koristiti (Johnson, 2021):

- **Ekskluzivno grupiranje** (eng. Exclusive clustering)

U ovoj metodi grupiranja podaci su grupirani tako da jedan podatak može pripadati samo jednoj grupi.

- **Grupiranje preklapanjem** (eng. Overlapping clustering)

U ovoj se metodi za grupiranje podataka koriste nejasni skupovi podataka. Svaki podatak može pripadati dvjema ili više grupa. Ovdje su podaci povezani odgovarajućom vrijednošću.

- **Vjerojatna grupiranja** (eng. Probabilistic clustering)

Ova metoda koristi distribuciju vjerojatnosti za stvaranje grupa.

- Muška cipela
- Ženska cipela
- Muška rukavica
- Ženska rukavica

Ovi podaci mogu biti podijeljeni na dvije kategorije, „cipela“ i „rukavica“ ili „muška“ i „ženska“.

2.2.3. Podržano učenje (eng. Reinforcement learning)

Vrsta strojnog učenja gdje algoritam poduzima neku akciju kako bi maksimizirao sumu nagrada. Razlika između podržanog učenja i nadziranog učenja je ta da kod nadziranog učenja podaci već sadrže određenu kategoriju pa se po tome prilagođavaju, a kod podržanog učenja je suprotno, te zbog toga mora učiti iz svog iskustva.

Podržano učenje opisuje skup problema u kojima agent djeluje u okolini i mora naučiti djelovati koristeći povratne informacije. Postoje samo ciljevi koje je agent dužan postići, te radnje koje može izvesti i povratne informacije o učinku prema cilju. Podržano učenje ne govori unaprijed što raditi nego daje odgovarajuće nagrade ili kazne na kraju niza akcija ovisno o rezultatu. S vremenom agent uči na ishodima kako bi dodatno ojačao svoje postupke i buduće radnje, te je s toga podržano učenje temeljeno na povratnim informacijama (Johnson, 2021).

Prednosti podržanog učenja (Johnson, 2021):

- Pomaže pronaći koja situacija treba akciju
- Pomaže otkriti koja akcija donosi najveću nagradu tijekom duljeg perioda
- Podržano učenje agentu pruža vrijednosnu funkciju
- Omogućuje mu pronalaženje najbolje metode za dobivanje velikih nagrada

Podržano učenje se koristi za aplikacije i igrice kao što su (Johnson, 2021):

- Robotika za industrijsku automatizaciju
- Planiranje poslovne strategije
- Strojno učenje i obrada podataka
- Igre za samostalno učenje kao što je šah
- Sustavi za pomoć s pitanjima
- Simulatori za upravljanje zrakoplovima.

3. Interaktivno strojno učenje

Interaktivno strojno učenje je dizajn i implementacija algoritma i inteligentnih okvira korisničkog sučelja koji olakšavaju strojno učenje uz pomoć ljudske interakcije. Želimo da računala uče od ljudi u interakciji s njima na prirodnom jeziku i promatranjem. Ljudi također mogu i podučavati računala. Sustavi koji mogu interaktivno učiti od njihovih krajnjih korisnika postaju sve rašireniji. Postupak razvijanja aplikacije strojnog učenja započinje podacima koje su posebno prikupili stručnjaci za ciljanu aplikaciju. Zatim, stručnjaci eksperimentiraju s različitim algoritmima za strojno učenje, iterativno podešavajući parametre, a ponekad i prikupljanje više podataka za poboljšanje ciljnog proizvoda. Rezultate dodatno ispituju stručnjaci za traženo područje (Amershi, 2014). Interaktivno strojno učenje često se odnosi na bilo koji oblik pristupa strojnog učenja koji je usmjeren prema korisnicima (Holzinger, 2018).


Tipičan tijek rada interaktivnog strojnog učenja se sastoji od dva koraka u svakoj iteraciji. Prvo se rezultati prezentiraju korisniku nakon čega korisnik istražuje rezultate i zatim unosi povratne informacije u model. Drugo je da se model postupno ažurira uz pomoć ljudskog doprinosa. Omogućuje ljudima interaktivno upravljanje modelima i podacima te je povoljniji za zadatke gdje je potrebno ljudsko znanje u procesu analize (Jiang, 2019).

Interaktivno strojno učenje predviđa odgovarajuće reakcije na interakcije. To jest, čovjek daje ulaz, a sustav daje odgovor. Čovjek je u interakciji s očekivanjem da će sustav moći prevesti naše ulaze u smislene izlaze. Sustavi interaktivnog strojnog učenja projektiraju se pomoću okvira (eng. Framework) za interakciju s ljudima. Pristupe interaktivnog strojnog učenja definiramo kao algoritme koji mogu stupiti u interakciju s računalima i ljudima i putem te interakcije mogu optimizirati svoje ponašanje u učenju (Wallace, 2019).

Kvaliteta završnog modela ovisi o tome koliko je dobra kvaliteta podataka, ako kvaliteta podataka nije dobra (Varangaonkar, 2018):


- Potrebno mu je više vremena za učenje, ali daje točna predviđanja
- Kvaliteta predviđanja je loša

Taj se problem može riješiti uključivanjem ljudi u proces strojnog učenja. Uz pomoć povratnih informacija ljudi u testiranju modela može se brže i učinkovitije doći do točnijih predviđanja (Varangaonkar, 2018).



Slika 1. Osnovni dijagram toga koji prikazuje procese interaktivnog strojnog učenja (Varangaonkar, 2018).

U široko prihvaćenim pristupima strojnog učenja nema načina da se u proces obuke uključe povratne informacije ljudi kako bi se poboljšala točnost predviđanja, te zbog tog razloga stručnjaci interaktivno strojno učenje vide kao rješenje tog problema. Vidljivo je na slici (1) nakon što model (eng. Machine Learning Model) primi neki ulaz (eng. Input) on stvara predviđanja (eng. Prediction) za izlaz, a čovjek (eng. Human) nakon analize daje povratnu informaciju (eng. Feedback) na temelju koje model strojnog učenja ponovno stvara predviđanja (Varangaonkar, 2018).




Slika 2. Primjena interaktivnog strojnog učenja (Amershi, 2014).

Na slici (2) je prikazano kako u strojnom učenju ljudi iterativno (eng. Iteration cycles) isporučuju informacije sustavu za učenje (eng. Inputs), a zatim promatraju (eng. Testing) i tumače rezultate sustava za obavještanje o sljedećim ponavljanjima.

U interaktivnom strojnom učenju te su iteracije učestalije od tradicionalnog učenja. Da bi interakcija između korisnika i sustava bila bolja zahtijeva se povećani fokus na proučavanje uključenosti korisnika u proces.

Najpoznatiji primjeri interaktivnog strojnog učenja u aplikacijama su sustavi za preporuke kao što su preporuke proizvoda Amazona i preporuke filmova Netflix. Korisnicima sustava se često postavljaju ciljana pitanja o njihovim sklonostima prema pojedinim stavkama (koje pružaju tako što im se sviđaju ili ne sviđaju), a te se postavke zatim uključuju u sustave za naknadne preporuke. Ako sustav počne preporučivati neželjene stavke nakon uključivanja preferencija, korisnik može ispraviti sustav pružajući drugačije informacije u budućnosti (Amershi, 2014).

Implementacija interaktivnog strojnog učenja se vrši uz pomoć algoritama, a ti algoritmi moraju biti u mogućnosti omogućiti desetke do stotina tisuća podataka i učiti vrlo brzo iz prošlih iskustava i interakcija (Fails, 2003). Interaktivno strojno učenje razlikuje se od klasičnog strojnog učenja po tome što se ljudska inteligencija primjenjuje u usavršavanju modela interaktivnog strojnog učenja. Drugim riječima čovjek daje sustavu dodatne informacije za ažuriranje modela, a promjena u modelu se provjerava u skladu s ljudskim ciljevima (Dudley, 2018).




Slika 3. Prikaz strukture interaktivnog strojnog učenja (Dudley, 2018).

Na slici (3) je prikazana strukturna perspektiva sustava interaktivnog strojnog učenje koji se sastoji od četiri ključne komponente (Dudley, 2018):

- **Korisnik (eng. User)** je glavni pokretač procesa interaktivnog strojnog učenja i on upravlja procesom pružajući povratne informacije i upravlja modelom za testiranje
- **Model** je komponenta koja se testira. Uzima ulazne podatke i daje odgovarajuće rezultate na temelju trenutnog razumijevanja procesa.
- Uz pomoć **podataka (eng. Data)** se testira model, a podatke odabire korisnik
- **Sučelje (eng. Interface)** omogućuje interakciju između korisnika, modela i podataka

3.1. Okvir za interaktivno strojno učenje (eng. Framework)

Strojno učenje je učinkovit alat za izgradnju pouzdanog modela predviđanja i izdvajanja korisnih podataka iz skupa. Međutim kritiziran je zbog poteškoća u tumačenju i kompliciranog podešavanja parametara. Iako postoje neke statističke metode za rješavanje tog problema ispostavilo se da ljudska inteligencija na temelju znanja o ciljanom području djeluje bolje i pouzdanije u vezi s tim problemima. Tada se koristi vizualizacija koja je popularan i moćan alat za istraživanje podataka koncentrirajući se na ljudsku inteligenciju (Lee, 2016).




Slika 4. Prikaz interaktivne petlje između strojnog učenja i vizualizacije pomoću strojne i ljudske inteligencije (Lee, 2016).

Na slici (4) je vidljivo da u svakoj iteraciji petlje algoritam strojnog učenja ažurira model predviđanja prema zadanim podacima i povratnim informacijama korisnika. Zatim vizualizacija (eng. Visualization) pruža vizualni prikaz kodiranja i rezultate predviđanja na temelju podataka. U sučelju za vizualizaciju korisnik može promijeniti podatke na temelju znanja o ciljanom području. Te korisničke operacije bit će ulaz za sljedeće pokretanje iteracije. U ovoj iteraciji korisnik je zadužen za naknadne izmjene (Lee, 2016).

Za uključivanje ljudskih doprinosa za poboljšanje performansi strojnog učenja koristi se algoritam nazvan transparentno stablo za povećanje snage (eng. Transparent Boosting Tree).

Transparentno stablo je algoritam koji korisniku vizualizira model i pojedinih predviđanja svakog koraka u procesu strojnog učenja, nakon toga uzme njegove povratne informacije i uključuje ih u proces učenja. Model strojnog učenja je zadužen za filtriranje podataka koji će biti prikazani korisniku kako bi povratne informacije bile što korisnije (Varangaonkar, 2018).



Slika 5. Prikaz interakcije korisnika i sučelja za vizualizaciju transparentnog stabla za povećanje snage (Lee, 2016).

Vidljivo je iz slike (5) da transparentno stablo za povećanje snage omogućuje korisničke operacije na modelu i može prihvatiti povratne informacije korisnika kao ulaz za sljedeće ažuriranje modela. Mogu ukloniti ili dodati broj stabala u model (eng. Remove/Add Tree).

Osim toga u bilo kojoj fazi procesa učenja korisnik može definirati podskup podataka prema dopusti ili blokiraj značajke (eng. Allow/ Block Features).

Na stablu korisnik može ukloniti bilo koji čvor (eng. Remove Node) ili dodati čvor po potrebi (eng. Expand Node). Na vremenskoj skali gumb poništi (eng. Restore) omogućuje korisniku da se vrati na prethodni model koji je koristio u povijesti. Ovo je poželjno jer korisnici mogu opravdati jesu li ljudske operacije bile od pomoći i uz pomoć gumba „Restore“ korisnik može poništiti operacije koje nisu bile od pomoći pa ne mora započinjati proces ispočetka (Lee, 2016).

4. Uloga ljudi u strojnom učenju

S rastućom popularnošću i primjenama strojnog učenja i umjetne inteligencije u svim industrijskim domenama, ljudi imaju ključnu ulogu u strojnom učenju, te osim što ga kodiraju dodjeljuju mu odgovarajuće algoritme. Dok promatraju vlastite rezultate ili procjene algoritama u obliku vizualizacije, ljudi mogu predložiti način za poboljšanje tog predviđanja davanjem povratnih informacija u obliku ulaza poput ispravaka ili rangiranja, a to pomaže modelima na dva načina (Varangaonkar, 2018):

- Povećava točnost predviđanja
- Vrijeme za učenje algoritma se znatno skraćuje

Obje prednosti mogu biti od velike važnosti za tvrtke jer nastoje uključiti strojno učenje u svoje procese te traže brže i točnije predviđanje. Podešavanje parametara i određivanje složenosti modela dva su problema koji su kritični za izvedbu algoritama strojnog učenja. Pokazalo se da ljudska inteligencija uvijek djeluje bolje i pouzdanije u tim problemima s odlučivanjem. Osim toga ljudska inteligencija često nudi bolje tumačenje od strojne inteligencije (Zhou, 2014).

Trenutni algoritmi strojnog učenja rade asinkrono s ljudskim stručnjakom od kojeg se očekuje da pomogne u interpretaciji podataka. Ljudski stručnjak bi trebao biti svjestan konteksta problema i ispravno procijeniti koji skupovi podataka se trebaju koristiti. Glavna razlika ljudi i strojeva što osoba može učiti uz puno manju količinu podataka. Dijete od dvije godine može razlikovati je li se radi o mački ili psu, a da mu nisi potrebne ogromne količine primjera (Holzinger, 2018).

Strojevi stječu znanje kroz iskustvo podijeljeno u obliku prošlih podataka, dok ljudi stječu znanje kroz iskustvo i najveća prednost u tome je što mogu i na tuđim primjerima učiti i nije im potrebna ogromna količina informacija za to. Strojevi mogu riješiti nove probleme samo ako je njihova inteligencija ažurirana podacima prikupljenih iz prošlih događaja (Janardhanan, 2020).

Uloga ljudi u strojnom učenju se uglavnom odnosi na podatke. Priprema podataka je vremenski najzahtjevniji dio i veći dio posla zahtjeva ljudsko znanje unatoč nužnoj primjeni računala. Računala uče one podatke koje im ljudi daju na raspolaganje i tako ljudi upravljaju s računalima. Strojno učenje ne bi bilo moguće bez programera koji stvaraju strojno učenje i svakodnevno održavaju sustave i baza podataka (Holzinger, 2018).

Interaktivno strojno učenje ne bi bilo moguće izvršavati bez ljudi koji podučavaju strojeve i robote novim pojmovima pružajući pozitivne i negativne primjere. Ljudi imaju tendenciju davati više pozitivnih informacija nego negativnih. Uče strojeve tako da kada stroj izvrši traženu radnju povratna informacija bude pozitivna i stroj na temelju prošlih povratnih informacija odlučuje kako će tu istu ponovljenu radnju izvršiti.

Proučavanjem interakcije korisnika s interaktivnim strojnim učenjem zapažena je da povećana interakcija između korisnika i sustava za učenje u interaktivnom strojnom učenju zahtijeva bolje razumijevanje kakvu ulogu imaju krajnji korisnici u procesu učenja. U nastavku je objašnjeno kako takvo razumijevanje može dovesti do bolje informiranih sustava (Amershi, 2014).



Slika 6. Prikaz kako čovjek podučava robota (Amershi, 2014).

Na slici (6) možemo vidjeti kako čovjek podučava robota novim pojmovima pružajući pozitivne i negativne primjere. Na lijevoj slici možemo vidjeti pasivno učenje gdje primjere bira i prezentira čovjek, a desno aktivno učenje gdje učenici, a u ovom slučaju robot traži primjere koje je zatražio čovjek. Aktivno učenje je paradigma strojnog učenja u kojoj korisnik bira primjere koje će naučiti. Iako aktivno učenje dovodi do bržeg dolaska do ciljanog rezultata, korisnici postaju frustrirani jer moraju odgovarati na dugačak niz pitanja učenika i nemaju kontrolu nad interakcijama (Amershi, 2014).


Razumijevanje načina na koji ljudi zapravo komuniciraju sa strojnim učenjem ključni su za projektiranje sustava koje ljudi mogu učinkovito koristiti. Ti sustavi postaju sve prisutniji u svakodnevnom životu i u budućnosti će samo rasti njihova popularnost. Postoje razni primjeri interakcije ljudi sa strojnim učenjem, a u nastavku će se objasniti neki od njih.

4.1. Primjeri uloge ljudi u interaktivnom strojnom učenju

Interaktivno strojno učenje može poboljšati performanse uz pomoć ljudskog znanja kroz bogate interakcije. Koristi se za rješavanje širokog spektra problema u stvarnom svijetu. U nastavku pregledavamo na koje sve načine se može koristiti interaktivno strojno učenje.

4.1.1. Glazba temeljena na gestama

Wekinator je softverska aplikacija otvorenog koda izgrađena u popularnoj Weka. Koristi se za projektiranje sučelja temeljenih na pokretima i gestama. Uz pomoć Wekinatora stvara se glazba temeljena na gestama (Gillies, 2019).




Slika 7. Primjer petlje koju primjenjuje Wekinator (Gillies, 2019).

Na slici (7) se prikazuje model petlje koji koristi Wekinator. Dizajn petlje je relativno jednostavan i sastoji se od korisnika (eng. Designer) koji daje primjere (eng. Example movement/sound mappings), a zatim softver (eng. Software) testira (eng. Test) rezultate. Cilj Wekinatora je pokušati razumjeti što korisnik namjerava (Gillies, 2019).

Ovo područje je prirodno interaktivno, to znači da su glazbenici navikli primati povratne informacije pri interakciji s instrumentom. U nastavku su opisane glavne komponente sustava za interakciju gesta-zvuk (Amershi, 2014).

Iz slike (8) je vidljivo kako program Wekinator funkcionira. Korisnik namjesti program i kada pritisne „Start Recording“ napravi neku gestu ili pokret kao što je palac gore. Kada je korisnik gotov pritisne „Stop Recording“ i nakon toga „Train“. Kada je korisnik obavio te korake pritisne „Run“ i nakon toga kada podigne palac prema gore program će proizvoditi određeni zvuk.




Slika 8. Prikaz programa Wekinator (Magalhaes, 2020).

4.1.2. Videoigra temeljena na pokretima tijela


Prilagođavanje likova videoigara korisnicima uz pomoć ljudskog kretanja i gesta zadnjih godina postaje sve izraženije. Upravo se u videoigrama interakcija pokreta prvi put se pojavila. To su senzorske tehnologije koje mogu detaljno pratiti ljudsko kretanje, a njihova spremnost je pokrenula veliki interes za razvoj novih oblika interakcije koje koriste ljudi uz pomoć kretanja tijela.

Postoji softverska aplikacija koja korisnicima omogućuje da vlastitim pokretima osmisle ponašanje lika kojeg kontroliraju. Korisnici osmišljavaju pokrete snimajući vlastite pokrete tijela tijekom igranja, a zatim uz pomoć stabla odlučivanja testiraju modele na temelju tih pokreta.

Slika (9) prikazuje kako videoigre temeljene na pokretima funkcioniraju. Lik u igri reagira na postupke igrača koji komunicira s likom uz pomoć vlastitih pokreta. Svrha ljudi je da osmisle skup radnji koje lik mora prepoznati i znati reagirati na svaku od njih. Korisnik može vidjeti virtualni lik na ekranu i s pokretima svoga tijela izvodi radnje koje lik prati (Gillies, 2019).



Slika 9. Interakcija korisnika s virtualnim likom (Gillies, 2019).



Slika 10. Prikaz Pong igre. Igrač je predstavljen kao štap (Gillies, 2019).

Na slici (10) je prikazana 3D verzija klasične video igre Pong. Ovo je prikaz igre stolnog tenisa u kojoj igrači upravljaju reketima predstavljenima kao linije. Uz pomoć tih reketa oni mogu pogoditi lopticu, a igrač je predstavljen kao avatar u obliku štapića.

Nakon svakog poena avatar izvodi animaciju ovisno o trenutnom stanju igre. Cilj je stvoriti sustav koji na odgovarajući način određuje koju će animaciju izvesti s obzirom na trenutno stanje igre, a stanje je predstavljeno s nizom numeričkih varijabli (Gillies, 2019):

- Zadnji promašaj (eng. Last Miss): 1 ili -1 ovisno o tome koji je igrač promašio lopticu
- Rezultat (eng. Score): trenutni rezultat igrača
- Relativni rezultat (eng. Relative Score): trenutni rezultat igrača minus rezultat drugog igrača
- Udaljenost (eng. Distance): udaljenost lopte od igrača kada je promašena
- Broj dodavanja (eng. Number of pass): koliko je puta lopta prešla između igrača prije nego što je bod završio

Ove su varijable odabrane kako bi se dobio širok raspon informacija. Tijekom igre se snimaju pokreti igrača i bilježe se kretanja između kraja jednog poena i početka sljedećeg zajedno s varijablama s vrijednostima stanja. Odluke su prikazane kao stablo odlučivanja gdje unutarnji čvor stabla predstavlja odluku zasnovanu na jednoj varijabli. Vrijednost varijable se uspoređuje s i ovisno o ishodu podaci se prosljeđuju na jedan od čvorova dvoje djece. Na primjer trenutni rezultat mogao bi se prenijeti lijevom djetetu ako je manji od 10 ili desnom ako je veći od 10. Podređeni čvor donosi odluku na temelju svoje varijable i vrijednosti. Čvorovi listova su označeni klasama, a kada se dosegne određeni list stavka se onda može dodijeliti klasi. Zatim se ta klasa koristi da odabere isječak koji želi, a primjer toga je da igrač slavi kada osvoji bod ili bude razočaran kada ga izgubi (Gillies, 2019).



Slika 11. Prikaz stabla odlučivanja na temelju varijabli zadnji promašaj i relativni rezultat (Gillies, 2019).

Na slici (11) je prikazano kada je igrač blizu pobjede ili blizu poraza cijele igre, te stoga postoje klase pobjeda (eng. Win), dobra pobjeda (eng. Good Win), gubitak (eng. Lose) i loš gubitak (eng. Bad Lose). Gornji čvor relativni rezultat i donosi odluku na temelju posljednje varijable zadnji promašaj (eng. Last Miss) i sljedeći čvorovi zatim dolje dodjeljuju klasu na temelju relativnog rezultata (eng. Relative Score) (Gillies, 2019).



Slika 12. Prikaz sučelja za osmišljavanje odgovora avatara koje definira korisnik (Gillies, 2019).

Slika (12) prikazuje varijable (eng. Variables) koje predstavljaju svaki poen u igri, a klase (eng. Classes) su kategorije koje definira korisnik. Isječke (eng. Motion Clips) koje stvara osoba odgovaraju pokretu tijela zabilježenom u svakom trenutku igre. Stablo odlučivanja (eng. Decision Tree) je interaktivna vizualizacija koju korisnik koristi za uređivanje. Nakon odigrane igre i snimanja pokreta igrača podaci se skupljaju i korisnici mogu koristiti sučelje za stvaranje odluka koje će kontrolirati avatar. Korisnici komuniciraju sa sučeljem tako da isječke označe s klasama, a to radi tako da odabere željeni isječak, a zatim klikom (eng. Buttons) na odgovarajuću klasu (Gillies, 2019).

4.1.3. Segmentacija slike s interaktivnim strojnim učenjem

Segmentacija slike vrši se uz pomoć Crayons sustava koji korisnicima dopušta testiranje piksel klasifikatora iterativnim označavanjem piksela kao pozadina (eng. Background) ili prednji plan (eng. Foreground) i daje potpuno segmentiranu sliku kao izlaz. Korisnički unos usmjeren je na područja u kojima klasifikator nije uspio u prethodnom razdoblju iteracije i nakon svake interakcije korisnika sustav odgovara ažuriranom segmentacijom slike radi daljnjeg pregleda i korektivnog unosa (Amershi, 2014).

Postoje dva primarna cilja sustava Crayons (Fails, 2003):


- Omogućiti korisniku brzo stvaranje piksel klasifikatora
- Omogućiti korisniku da se usredotoči na problem klasifikacije, a ne na obradu slike ili algoritme

Crayons sustav se smatra uspješnim ako za stvaranje učinkovitog klasifikatora nije bilo potrebno više od par minuta.




Slika 13. Prikaz procesa projektiranja Crayons-a (Fails, 2003).

Slika (13) prikazuje proces projektiranja Crayons sustava gdje vidimo da se slike (eng. Images) unose u sustav Crayons koji zatim može izvesti generirani klasifikator (eng. Classifier). Pretpostavlja se da je korisnik već digitalizirao slike i spremio ih za unos u sustav. Implementacija je napisana na Javi pa se klasifikator obradi i pomoću standardnih Java mehanizama se šalje u datoteku (Fails, 2003).



Slika 14. Prikaz klasifikacijske petlje (Fails, 2003).

Na slici (14) možemo vidjeti da Crayons prima slike (eng. Images) na kojima korisnik radi neku ručnu klasifikaciju (eng. Manually Classify) i tada se stvara klasifikator (eng. Generate Classifier) i ispituje se povratna informacija. Korisnik tada može precizirati klasifikator dodavanjem još ručnih klasifikacija (Fails, 2003).



Slika 15. Prikaz interakcije Crayons-a (Fails, 2003).

Evaluacija Crayons-a putem korisničkih studija je otkrila da neposredni ishod koji pruža sustav je omogućio korisnicima brži pregled i ispravljanje klasifikacija dodavanjem novih podataka o testiranju u najproblematičnijim područjima.

Na slici (15) vidimo poteze kistom koji označavaju dijelove koje korisnik želi segmentirati. Na prvom paru slika (eng. Iteration 1) klasifikator može generirati samo mali broj podataka koje uči o pozadini i koži. U drugom paru slika (eng. Iteration 2) korisnik daje više podataka o dijelovima kože, ali i pozadine i to radi tako da kistom detaljnije označuje pozadinu, ali i dijelove kože. Nakon tog ispravka klasificirano je većina kože na ruci, ali i dio pozadine je klasificiran kao ruka, te nakon trećeg ispravka (eng. Iteration 3) se stvara ispravni klasifikator kože. Kao što je prikazano na slici u ovom slučaju je u potpunosti prikazan utjecaj i uloga ljudi gdje su oni u interakciji sa strojem i određuju koje dijelove treba klasificirati (Fails, 2003).

5. Zaključak

Smatra se da će u budućnosti strojno učenje postati glavni čimbenik u razvoju aplikacija i očekuje se još veća njegova rasprostranjenost. Na početku ovoga rada je ukratko objašnjeno što je strojno učenje i njegove početke u povijesti. U sljedećoj cjelini je objašnjeno interaktivno strojno učenje i koja je uloga ljudi u svemu tome. Interaktivno strojno učenje je objašnjeno i prikazano na primjerima.

Strojno učenje je relativno mlada znanstvena disciplina čiji je razvoj posljednjih godina uzrokovan jednako porastom ulaganja znatnih novčanih sredstava u istraživanja i razvijanja novih i praktičnijih metoda i zbog toga ga možemo sve češće primijetiti u korištenju svakodnevnih aplikacija kao što su društvene mreže koje su u današnje vrijeme glavni izvor informacija. Na temelju strojnog učenja mogu se izgraditi moćni interaktivni sustavi strojnog učenja koji daju više kontrole krajnjim korisnicima.

Možemo zaključiti da interaktivno strojno učenje je budućnost i način na koji će strojevi i ljudi komunicirati. Uloga ljudi u interaktivnom strojnom učenju može biti da kontrolira sustave i daje povratne informacije stroju iz kojih on uči, ali može i uz pomoć pokreta učiti stroj koje radnje da izvršava. Interaktivno strojno učenje ne bi bilo moguće izvršavati bez ljudi koji podučavaju strojeve.

6. Literatura

Knjige:

1. Alpaydin, E., (2009) Introduction to Machine Learning [online] Dostupno na: https://kkpatel7.files.wordpress.com/2015/04/alppaydin_machinelearning_2010.pdf (Pristupljeno 10.06.2021.)
2. Brownlee, J., (2019) Statistical Methods for Machine Learning [online] Dostupno na: [file:///D:/Toni/Downloads/dokumen.pub_statistical-methods-for-machine-learning%20\(1\).pdf](file:///D:/Toni/Downloads/dokumen.pub_statistical-methods-for-machine-learning%20(1).pdf) (Pristupljeno 10.06.2021.)
3. Brownlee, J., (2020) Probability for Machine Learning [online] Dostupno na: [file:///D:/Toni/Downloads/dokumen.pub_probability-for-machine-learning-discover-how-to-harness-uncertainty-with-python-v19nbsped%20\(2\).pdf](file:///D:/Toni/Downloads/dokumen.pub_probability-for-machine-learning-discover-how-to-harness-uncertainty-with-python-v19nbsped%20(2).pdf) (Pristupljeno 10.06.2021.)
4. Witten, I.H., Frank, E., Hall, M.A., (2011) Data Mining: Practical Machine Learning Tools and Techniques [online] Dostupno na: <https://www.wi-hs-wismar.de/~cleve/vorl/projects/dm/ss13/HierarClustern/Literatur/WittenFrank-DM-3rd.pdf> (Pristupljeno 10.06.2021.)
5. Brownlee, J., (2016) Master Machine Learning Algorithms [online] Dostupno na: https://datageneralist.files.wordpress.com/2018/03/master_machine_learning_algo_from_scratch.pdf (Pristupljeno 10.06.2021.)
6. Brownlee, J., (2020) Data Preparation for Machine Learning [online] Dostupno na: file:///D:/Toni/Downloads/dokumen.pub_data-preparation-for-machine-learning-data-cleaning-feature-selection-and-data.pdf (Pristupljeno 12.06.2021.)
7. Murphy, K.P., (2012) Machine Learning: A Probabilistic Perspective [online] Dostupno na: http://noiselab.ucsd.edu/ECE228/Murphy_Machine_Learning.pdf (Pristupljeno 13.07.2021.)
8. Jiang, L., Liu, S., Chen, C., (2019) Recenet research advances on interactive machine learning [online] Dostupno na: [1811.04548v1.pdf \(arxiv.org\)](https://arxiv.org/abs/1811.04548v1) (Pristupljeno 24.07.2021.)

9. Gillies, M., (2019) Understanding the role of Interactive Machine Learning in Movement Interaction Design [online] Dostupno na: https://research.gold.ac.uk/id/eprint/24757/7/Understanding_the_role_of_Interactive_Machine_Learning_in_Movement_Interaction_Design.pdf (Pristupljeno 24.07.2021.)
10. Ghahramani, Z., (2004) Unsupervised Learning [online] Dostupno na: [https://datajobs.com/data-science-repo/Unsupervised-Learning-Guide-\[Zoubin-Ghahramani\].pdf](https://datajobs.com/data-science-repo/Unsupervised-Learning-Guide-[Zoubin-Ghahramani].pdf) (Pristupljeno 18.06.2021.)
11. Sutton, R.S., Barto, A.G., (2014) Reinforcement Learning: An Introduction [online] Dostupno na: <https://web.stanford.edu/class/psych209/Readings/SuttonBartoPRLBook2ndEd.pdf> (Pristupljeno 16.06.2021.)
12. Wallace Mathewson, K., (2019) Humour in the loop: Improvised Theatre with Interactive Machine Learning Systems. Dostupno na: https://sites.ualberta.ca/~pilarski/docs/theses/Mathewson_Kory_W_201905_PhD.pdf (Pristupljeno 14.07.2021.)

Internet izvori:

13. Bhatti, B., (2019) How is Machine Learning Different from Statistics and Why it Matters, Towards data science. Dostupno na: <https://towardsdatascience.com/how-is-machine-learning-different-from-statistics-and-why-it-matters-5a8ed539976> (Pristupljeno 20.06.2021.)
14. Fails, J., (2003) Interactive Machine Learning. Dostupno na: [file:///D:/Toni/Downloads/download%20\(2\).pdf](file:///D:/Toni/Downloads/download%20(2).pdf) (Pristupljeno 10.07.2021.)
15. Lee, T., Johnson, J., Cheng, S., (2016) An Interactive Machine Learning Framework. Dostupno na: <https://arxiv.org/pdf/1610.05463.pdf> (Pristupljeno 10.07.2021.)
16. Podatak (2020.) Dostupno na: <https://hr.wikipedia.org/wiki/Podatak> (zadnja izmjena: 23.04.2020.), (Pristupljeno 20.06.2021.)
17. Rudarenje podataka (2021) Dostupno na: https://hr.wikipedia.org/wiki/Rudarenje_podataka (zadnja izmjena: 12.08.2021.), (Pristupljeno 20.06.2021.)

18. Marr, B., (2021) What is The difference between Data Mining and Machine Learning.
Dostupno na: <https://bernardmarr.com/what-is-the-difference-between-data-mining-and-machine-learning/> (Pristupljeno 20.06.2021.)
19. Zhou, T., Chen, T., He, L., (2014) Transparent Boosting Tree: An interactive Machine Learning Framework. Dostupno na: [file:///D:/Toni/Downloads/paper-tianyizh-tqchen-luheng%20\(1\).pdf](file:///D:/Toni/Downloads/paper-tianyizh-tqchen-luheng%20(1).pdf) (Pristupljeno 15.07.2021.)
20. Varangaonkar, A., (2018) What is interactive machine learning
Dostupno na: <https://hub.packtpub.com/what-is-interactive-machine-learning/>
(Pristupljeno 10.08.2021.)
21. Holzinger, A., Plass, M., Kickmeier-Rust, M., Holzinger, K., Cerasela Crisan, Camelia-M.Pintea, G., Palade, V., (2018) Interactive machine learning: experimental evidence for the human in the algorithmic loop. Dostupno na: [Interactive machine learning: experimental evidence for the human in the algorithmic loop \(springer.com\)](https://www.springer.com/interactive-machine-learning-experimental-evidence-for-the-human-in-the-algorithmic-loop)
(Pristupljeno: 10.08.2021.)
22. Janardhanan P., (2020) Human Learning and Machine Learning- How they differ?
Dostupno na: <https://www.datasciencecentral.com/profiles/blogs/human-learning-and-machine-learning-how-they-differ> (Pristupljeno 04.07.2021.)
23. Hoffman, K., (2021) Types of Machine Learning Algorithms. Dostupno na: <https://medium.com/analytics-vidhya/types-of-machine-learning-algorithms-8ac09d58f7f2> (Pristupljeno 04.07.2021.)
24. Ryan, M., Talabis, M., Kaye, D., McPherson, R., Jason L. Martin (2014) Information Security Analytics.
Dostupno na: https://minio1.123dok.com/dt03pdf/123dok/pdf/2019/03_13/hxqehk1593407988.pdf?X-Amz-Content-Sha256=UNSIGNED-PAYLOAD&X-Amz-Algorithm=AWS4-HMAC-SHA256&X-Amz-Credential=HBT28R878GBP52A279VA%2F20210918%2F%2Fs3%2Faws4_request&X-Amz-Date=20210918T124012Z&X-Amz-SignedHeaders=host&X-Amz-Expires=600&X-Amz-

[Signature=c456a0e59d25866fe91fe29c70c457936454a314b0c736c24186c83fd9c3fc11](#)

(Pristupljeno 04.07.2021.)

25. Malik F. (2018) Supervised Machine Learning Regression Vs Classification. Dostupno na: <https://medium.com/fintechexplained/supervised-machine-learning-regression-vs-classification-18b2f97708de> (Pristupljeno 13.06.2021.)
26. Shukla, S., (2021) Regression and Classification. Dostupno na: <https://www.geeksforgeeks.org/regression-classification-supervised-machine-learning/> (Pristupljeno 13.06.2021.)
27. Brownlee, J., (2020) 4 Types of Classification Tasks in Machine Learning Dostupno na: <https://machinelearningmastery.com/types-of-classification-in-machine-learning/> (Pristupljeno 13.06.2021.)
28. Daniel Johnson (2021) Supervised Machine Learning: What is, Algorithms with Examples Dostupno na: <https://www.guru99.com/supervised-machine-learning.html> (Pristupljeno 18.06.2021.)
29. Leonel, J., (2018) Supervised Learning Dostupno na: <https://medium.com/@jorgesleonel/supervised-learning-c16823b00c13> (Pristupljeno 01.07.2021.)
30. Knocklein, O., (2019) Classification Using Neural Network Dostupno na: <https://towardsdatascience.com/classification-using-neural-networks-b8e98f3a904f> (Pristupljeno 12.06.2021.)
31. Kotsiantis, S. (2007) Supervised Machine Learning: A Review of Classification Techniques. Dostupno na: [https://datajobs.com/data-science-repo/Supervised-Learning-\[SB-Kotsiantis\].pdf](https://datajobs.com/data-science-repo/Supervised-Learning-[SB-Kotsiantis].pdf) (Pristupljeno 11.06.2021.)
32. Johnson, D., (2021) Unsupervised Machine Learning: What is, Algorithms, Example Dostupno na: <https://www.guru99.com/unsupervised-machine-learning.html> (Pristupljeno 18.06.2021.)
33. Grupiranje (2020) Dostupno na: <https://hr.wikipedia.org/wiki/Grupiranje> (zadnja izmjena: 24.11.2020)

34. Reinforcement Learning (2021) Reinforcement Learning: What is, Algorithms, Applications, Example Dostupno na: <https://www.guru99.com/reinforcement-learning-tutorial.html> (Pristupljeno 16.06.2021.)
35. Jiang, L., Liu, S., Chen, C., (2019) Recenet research advances on interactive machine learning. Dostupno na: <https://link.springer.com/content/pdf/10.1007/s12650-018-0531-1.pdf> (Pristupljeno 14.07.2021.)
36. Dudley, J.J., Kristensson, P., (2018) A review of User Interface Design for Interactive Machine Learning. Dostupno na: https://www.repository.cam.ac.uk/bitstream/handle/1810/274032/TIIS_Special_Issue_I_ML_Survey.pdf?sequence=1 (Pristupljeno 14.07.2021.)
37. Magalhaes, D., (2020) Improving the interaction in Zoom using Machine Learning. Dostupno na: <https://uxdesign.cc/improving-the-interaction-in-zoom-using-machine-learning-3e96107da661> (Pristupljeno 14.08.2021.)

POPIS SLIKA

Slika 1: Osnovni dijagram toga koji prikazuje procese interaktivnog strojnog učenja

Slika 2: Primjena interaktivnog strojnog učenja

Slika 3: Prikaz strukture interaktivnog strojnog učenja

Slika 4: Prikaz interaktivne petlje između strojnog učenja i vizualizacije pomoću strojne i ljudske inteligencije

Slika 5: Prikaz interakcije korisnika i sučelja za vizualizaciju transparentnog stabla za povećanje snage

Slika 6: Prikaz kako čovjek podučava robota

Slika 7: Primjer petlje koju primjenjuje Wekinator

Slika 8: Prikaz programa Wekinator

Slika 9: Interakcija korisnika s virtualnim likom

Slika 10: Prikaz Pong igre

Slika 11: Prikaz stabla odlučivanja na temelju varijabli zadnji promašaj i relativni rezultat

Slika 12: Prikaz sučelja za osmišljavanje odgovora avatara koje definira korisnik

Slika 13: Prikaz procesa projektiranja Crayons-a

Slika 14: Prikaz klasifikacijske petlje

Slika 15: Prikaz interakcije Crayons-a

SAŽETAK

U današnje vrijeme strojno učenje je postalo važan segment u razvoju aplikacija i sustava. Strojno učenje nastoji izgraditi računalni sustav koji kroz iskustvo poboljšava svoje performanse. Ključnu ulogu u razvoju tih sustava imaju ljudi gdje im je prioritet razvijati računala od kojih žele da uče od ljudi. Cilj ovoga rada je bio objasniti ulogu i značaj ljudi u interaktivnom strojnom učenju. Omogućeno je interaktivno upravljanje podacima te je pogodno za zadatke gdje je potrebno ljudsko znanje u procesu razvoja. Unutar rada teorijski se razrađuje strojno učenje i metode strojnog učenja. Naveden je okvir koji se koristi za poboljšanje performansi strojnog učenja. Kroz odabrane primjere primjene interaktivnog strojnog učenja, nastojalo se objasniti ulogu ljudi. Rezultati ovog rada pomažu u boljem razumijevanju i korištenju strojnog učenja.

Ključne riječi: strojno učenje, interaktivno strojno učenje, uloga ljudi

ABSTRACT

Nowadays Machine Learning has become a major segment in application and system development. Machine learning seeks to build a computer system that improves its performance through experience. A key role in the development of these systems is played by people where their priority is to develop computer form which they want to learn from people. The aim of this paper was to explain the role and importance of humans in interactive machine learning. Interactive data management is enabled and is suitable for tasks where human knowledge is required in the development process. Within the paper, machine learning and its methods are theoretically elaborated. The framework used to improve machine learning performance is listed. Through selected examples, interactive machine learning is applied, an attempt was made to explain the role of people. The results of this work help to better understand and use machine learning.

Keywords: machine learning, interactive machine learning, the role of humans