Umjetna inteligencija u poslovanju

Flego, Ivor

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Economics and Business / Sveučilište u Zagrebu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:148:619398

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**



Repository / Repozitorij:

REPEFZG - Digital Repository - Faculty of Economcs & Business Zagreb







Ekonomski fakultet

Menadžerska informatika

UMJETNA INTELIGENCIJA U POSLOVANJU

Title: Artificial intelligence in business

Diplomski rad

Ime Prezime: Ivor Flego, 0067489212

Mentor: Prof. dr. sc. Mario Spremić

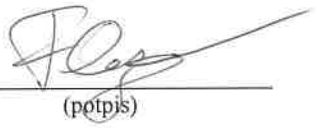
Zagreb, kolovoz 2019.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je završni/diplomski/specijalistički rad, odnosno doktorska disertacija isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Student/ica:

U Zagrebu, 9.9.2019.



(potpis)

Sadržaj

1. Uvod 3

1.1. Digitalna transformacija 3

1.2. Predmet i cilj rada 10

1.3. Metodologija i izvori podataka 10

1.4. Sadržaj i struktura rada 11

2. UMJETNA INTELIGENCIJA 12

2.1. Što je umjetna inteligencija 12

2.1.1. Strojno učenje (Machine learning) 16

2.1.2. Duboko učenje (Deep learning) 19

2.1.3. Umjetne neuronske mreže 21

2.2. Razvoj umjetne inteligencije kroz povijest 24

2.2.1. Slaba i jaka umjetna inteligencija 30

3. UMJETNA INTELIGENCIJA U POSLOVANJU 35

3.1. Integriranje umjetne inteligencije u poslovanje i primjeri korištenja 37

3.1.1. Etička pitanja korištenja umjetne inteligencije 44

3.1.2. Prednosti 49

3.1.3. Nedostaci 52

4. ISTRAŽIVANJE – LJUDSKO MIŠLJENJE O PRIMJENI UMJETNE INTELIGENCIJE U POSLOVANJU I ŽIVOTU 55

4.1. Sudionici, metoda i postupak provedbe istraživanja 55

4.2. Analiza rezultata istraživanja 56

5. ZAKLJUČAK 80

5.1. Što budućnost nosi? 85

6. LITERATURA 87

1. Uvod

1.1. Digitalna transformacija

„Idi digitalno ili nestani“, „Promjena je nova normala“, „Digitalna ekonomija“, „Sve je moguće“, „Digitalna transformacija i poslovanje“ samo su neki od pojmova s kojima se svakodnevno susrećemo u modernim poduzećima, korporacijama pa čak i lokalnim trgovinama u susjedstvu. Usporedno s ljudskim napretkom razvijala se i tehnologija, eksponencijalno bržim rastom od razvoja ljudi. Ekonomija i poslovanje su daleko dogurali od razmjene školjaka, krzna, stoke, dragog kamenja i plemenitih metala za raznorazna dobra i usluge. Svjedoci smo sve veće digitalizacije i robotizacije poslovanja, pružanja dobara i usluga, koji utječu ne samo na ekonomiju u globalnom pogledu već i na naš privatni život. Bilo to poslovanje banaka, odobravanje kredita, kupnja i dostava stvari preko interneta, pomoć virtualnih asistenata, financijske transakcije koje uopće ne uključuju fizički oblik novca ili sve veća prisutnost strojeva u poljoprivredi i drugim industrijama koji zamjenjuju ljudski rad i znoj. Predmet ovog diplomskog rada jest umjetna inteligencija, njezina integracija u poslovanje i sve što njezino korištenje donosi: poboljšanja, rizike, prednosti, nedostatke te kakva će budućnost izgledati jednoga dana kada ona bude neizostavni dio ekonomije i naših života.

U suvremenom razdoblju ekonomije poslovanje i poslovni procesi mijenjaju se iz korijena uvođenjem novih tehnoloških, komunikacijskih i informacijskih tehnologija te se transformira u tzv. digitalnu ekonomiju, koja obuhvaća sve sfere i područja poslovanja.

Pojam i filozofija digitalne transformacije javili su se još oko 50-ih godina prošloga stoljeća i nisu imali prevelik utjecaj na poslovanje zbog skromnih dobitaka i koristi koji su bili takvi zbog tehnoloških ograničenja toga vremena. Tijekom 70-ih i 80-ih godina prošloga stoljeća, kada je počela revolucija osobnih računala i sve više su se počele usvajati računalne tehnologije u poslovanje i druge sfere života, povećala se svijest o važnosti i mogućnostima računalnih tehnologija koje su promijenile upravljanje i donošenje odluka u upravljanju. Devedesete godine donijele su skladišta podataka, lokalne mreže, globalni internet, pohranu digitalnih podataka i digitalne telefone mogućnostima tehnologije koje su dostupne menadžerima.

U 2000-ima ostvarena je realizacija pristupačnih mobilnih telefona, bržih paralelnih procesora, distribuiranog računalstva i pohrane te digitalnih mobilnih mreža.[1] Početkom 2010. godine eksponencijalno su se povećale računalne mogućnosti i mogućnosti informacijske tehnologije koja je postala neizostavni dio svakog poduzeća i postala ključni resurs u modernom poslovanju. Medicina, prehrambena industrija, obrazovanje, proizvodnja, prodaja, promet, bankarstvo, poslovanje, sport, sve te industrije su se značajno promijenile pod utjecajem razvoja informacijskih tehnologija. Danas je najnormalnija stvar obaviti plaćanje računa na mobilnoj aplikaciji, ugovoriti kredit preko interneta, sve te stvari obaviti bez da se mora otići u fizičku poslovnicu banke. Naravno gdje postoje prednosti postoje i neki nedostaci.

U ovom svijetu brzih promjena, čovjek je zaboravio na svoje prirodno stanište, svoju okolinu. Tehnologija se neprestano razvija, ali ponekad su troškovi veliki, stoga je važno mjeriti utjecaj koji tehnološke promjene imaju na održivi razvoj, sinergijski razvoj gospodarstva, društva i okoliša.[2]

Još jedna od aktualnih tema, uz digitalnu transformaciju, jest korištenje umjetne inteligencije u poslovanju koja može uvelike povećati učinkovitost i efikasnost kako poslovanja tako i gospodarstva zemalja koje ju koriste. Uz postupak implementacije umjetne inteligencije u poslovanje, stručnjaci se slažu da bi ju mogli koristiti kao metodu izuma opće namjene koja ima sposobnost preoblikovanja prirode inovacijskog procesa i organizacije istraživanja i razvoja. Ukoliko se ta predviđanja ostvare, proces bi se znatno mogao skratiti i i poboljšati, odnosno povećati kvalitetu dobivenih rezultata i smanjiti prostor za eventualne pogreške.

Razlikujemo aplikacije usmjerene na automatizaciju kao što je robotika i potencijal u nedavnim razvojima u „deep learning“ aplikacijama koje bi služile kao metoda opće namjene izuma, pronalazeći čvrste dokaze o pomaku u važnosti istraživanja usmjerenih na primjenu od 2009. godine.[3]

[1] Heavin, C. i Power. D.J. (2018) Challenges for digital transformation – towards a conceptual decision support guide for managers. Journal of Decision System. Dostupno na: https://www.researchgate.net/publication/325027329_Challenges_for_digital_transformation_-_towards_a_conceptual_decision_support_guide_for_managers [25.05.2019.]

[2] Jovanović, M. Dlačić J. i Okanović M. (2018) Digitalization and society's sustainable development – Measures and implications. Zborni rad. Rijeka: Ekonomski fakultet u Rijeci

[3] Cockburn, I.M. i Henderson, R. i Stern, S. (2018) The impact of Artificial Intelligence on Innovation. National bureau of economic research, Cambridge

U razvijenim zemljama digitalna ekonomija je postala neka vrsta standarda koji, ukoliko nije zadovoljen, poduzeće teško da može prosperirati i razvijati se na tržištu. U zemljama u razvoju, pojam digitalne ekonomije je donekle nov, iako postoje njezini predvodnici u tim zemljama i sve veća osviještenost o prednostima digitalizacije poslovanja. Digitalna ekonomija odgovor je na sve veću osjetljivost i promjenjivost tržišta te agilnost potrošačkih preferencija.

Neosporna je činjenica da je razvoj informacijskih tehnologija dao golem doprinos povećanju poslovne učinkovitosti, povećanju produktivnosti, ali je neosporno i da je promijenio naše razumijevanje i pristup rješavanju svakodnevnih zadataka.[4] Otkada se dogodila eksplozija informacijske tehnologije i otkada je ona postala „must have" bilo kojeg poduzeća koje želi rasti, razvijati se i dominirati tržištem postalo je vrlo važno kako na pravi način iskoristiti dostupne tehnologije kao bismo odgovorili na nove trendove i izazove u ekonomiji i poslovanju.

U današnje vrijeme informacijska tehnologija i digitalizacija poslovanja više nisu recepti za dominaciju i monopol nad tržištem, već ključni resursi i filozofija poslovanja koja omogućuje preživljavanje na stalno rastućem tržištu i koja je odgovor na sveprisutnu promjenu, kako na tržištu, kod konkurenata, potrošača ili načina poslovanja. Samo investiranje u digitalizaciju poslovanja i informacijsku tehnologiju ne jamči pozitivne rezultate samo po sebi, potrebno je vrlo kvalitetno planiranje i implementacija, koje, ukoliko su kvalitetno napravljene, mogu donijeti puno pozitivnoga za poduzeće. Puno je primjera iz prakse gdje su poduzeća radila velike investicije u informatički sektor te umjesto rasta i pozitivnih rezultata, ostvarila su stagnaciju, u nekim slučajevima i pad te ozbiljne poslovne probleme. Uzrok tome je najčešće bila neadekvatna i slabo planirana provedba i implementacija rješenja u poslovne procese. Vrlo bitno je shvatiti da ulaganja i investicije u IT sektor nikada ne prestaju, pogotovo u današnje vrijeme gdje se svakim danom otkrivaju i implementiraju nova, poboljšana rješenja, koja su superiornija dosadašnjim načinima poslovanja i rješavanja poslovnih problema. Poduzeća koja shvate i prihvate takvu filozofiju poslovanja trenutno su lideri na svojim tržištima, a na tu poziciju su došli ne nužno pružajući revolucionarne proizvode i usluge, već pametnim i dobro planiranim investicijama i implementacijama u svoje poslovanje i poslovne procese. Informacijska tehnologija i digitalizacija poslovanja poduzeću može u isto vrijeme biti i najbolji prijatelj i najgori neprijatelj.

[4] Stojanović, S.D. (2017) Digitalna ekonomija i transformacija poslovnih procesa – izazovi i rizici. Stručni rad. Mjesto izdavanja: Novi Sad. Nakladnik: Fakultet za ekonomiju i inženjerski menadžment u Novom Sadu

Čitajući sve gore navedeno, može se zaključiti da je došlo vrijeme četvrte industrijske revolucije koja se može okarakterizirati kao digitalno povezivanje proizvoda, strojeva, alata, rada, ljudi i ostaloga. Glavni temelji četvrte industrijske revolucije su robotika i automatizacija koji omogućuju uštedu proizvodne energije, znatno smanjenje troškova te eksponencijalno povećanje kvalitete proizvoda i usluga.

Glavni subjekti digitalizacije poslovanja i nosioci uspješnosti informacijske tehnologije su ljudi i roboti. Ljudi su ti koji koriste emocije, iskustvo, maštu, sposobnost procjene i donošenja odluka pri kreativnom procesu transformacije poslovanja iz tradicionalnog u digitalno. Ljude možemo s pravom nazvati „mozgom" te operacije. Roboti su ti koji rade „fizički" posao, izgradnja informatičke konstrukcije i strukture, njihovo održavanje te prilagođavanje i unaprjeđivanje. To je fizički put koji diktira kako će poslovni procesi funkcionirati i kako će se nositi s problemima. Upravo su ti poslovni procesi, pravila i ograničenja ono što mislimo kada kažemo roboti, osmišljeni od strane ljudi kako bi si olakšali život. Vrlo važno je shvatiti da su ljudi i roboti partneri te su jednako važni u digitalnoj transformaciji poslovanja i zaslužni za uspjeh ili neuspjeh takvog pothvata.

Naravno, u slučaju da „mozak" funkcionira kako treba, pretpostavka je da postoji tehnološki obučena radna snaga. Razvojem tehnologije raste potražnja za ICT stručnjacima (eng. Information and Communications technology) koji svojim znanjem i vještinama, kreativnošću i inovacijama uspješno savladavaju postavljene probleme i pravovremeno donose odluke i zaključke.[5] Efikasno korištenje resursa poduzeća te umreženost i digitalna povezanost također su važni uvjeti za uspješnu provedbu digitalizacija poduzeća. Prva industrijska revolucija počela je izumom parnog stroja, druga je vezana uz otkrivanje i iskorištavanje električne energije dok treću industrijsku revoluciju obilježava promjena iz analogne elektronske tehnologije u digitalnu. U kojem obliku se zapravo manifestira četvrta industrijska revolucija? Radi se o modelu inteligentnih tvornica budućnosti u kojoj računalom upravljani sustavi nadziru fizičke procese, stvarajući virtualni kopiju fizičkog svijeta i donose decentralizirane odluke temeljene na mehanizmima samoorganizacije.[6]

[5] Basara, B.N. (2017) Digitalna transformacija kao temelj 4. industrijske revolucije. Završni rad. Pula: Politehnika Pula, Visoka tehničko-poslovna škola
[6] Basara, B.N. (2017) Digitalna transformacija kao temelj 4. industrijske revolucije. Završni rad. Pula: Politehnika Pula, Visoka tehničko-poslovna škola

Također stvaraju se tehnološki podržane platforme koje kombiniraju i spajaju ponudu i potražnju. Te platforme su jednostavne za pristupanje i korištenje preko pametnih telefona, one okupljaju ljude, imovinu i podatke čime stvaraju potpuno nove načine konzumiranja robe i usluga u tom procesu.[7] Takav način poslovanja i spajanja ponude i potražnje te kreiranja tržišta smanjuje prepreke stvaranja bogatstva. Ove nove tvrtke brzo se množe u mnogim novim uslugama, od praonice rublja do kupovanja namirnica, od kuće do parkirališta, od masaže do putovanja.[8]

Današnje vrijeme poslovanja karakteriziraju pojmovi poput: stalna promjena, agilno okruženje, brza prilagodba, svakodnevne inovacije itd. U takvom prevrtljivom digitalnom okruženju za pretpostaviti je da se generira velika količina podataka koja je uvjetovana tehnološkom napretku. U današnje moderno vrijeme takve informacije nazivamo Veliki Podaci (Big Data). Iz samog naziva već možemo razaznati što to je, iznimno velik broj strukturiranih, polu strukturiranih ili nestrukturiranih podataka kontinuirano generiranih iz raznolikih izvora, koji preplavljuju poslovanje u realnom vremenu i utječu na donošenje odluka putem rudarenja informacija iz velike hrpe podataka. Veliki podaci uključuju velike strukturirane skupove podataka i nestrukturirane podatke u obliku teksta (npr. Dokumenti, prirodni jezik), web-podatke (npr. Web-strukturu, korištenje weba, web-sadržaj), podatke društvenih medija (npr. Virtualnu mrežu), multimedijske podatke (npr. Sliku, audio, video) i mobilne podatke (npr. senzor, zemljopisni položaj, aplikacija).[9]

Kako se tehnologija razvijala, paralelno je rastao i broj generiranih podataka. Nekada nebitni i nevažni podaci koji su se skupljali i pohranjivali jedino ukoliko je tako bilo fiksno zadano, danas čine jedan od stupova poslovanja. Danas podatke prikuplja gotovo sve što nas okružuje, od mobitela, prijenosnih i uredskih računala do automobila, aplikacija, klima uređaja i medicinskih pomagala. Gotovo sve što radimo ostavlja digitalni trag koji se može koristiti za razne analize kasnije.[10]

[7] Schwab, K. (2016) The Fourth Industrial Revolution. Cologny, Switzerland:World Economic Forum
[8] Schwab, K. (2016) The Fourth Industrial Revolution. Cologny, Switzerland:World Economic Forum
[9] Sheng, J., Amankwah-Amoah, J., & Wang, X. (2017). A multidisciplinary perspective of big data in management research. International Journal of Production Economics, 191, 97-112. Dostupno na: https://doi.org/10.1016/j.ijpe.2017.06.006 [25.05.2019.]
[10] Šebalj, D. i Živković, A. i Hodak, K. (2016) Big data: changes in data management. SRCE, Ekonomski vjesnik. Dostupno na: https://hrcak.srce.hr/ojs/index.php/ekonomski-vjesnik/article/view/4208 [28.05.2019.]

U prilog tome ide i jednostavna matematika koja nam govori da je u samo posljednje dvije godine čovječanstvo generiralo 90% ukupnih podataka ikada. Također, Svake dvije godine generiramo 10 puta više podataka u odnosu na zadnje mjerenje.[11]

A taj odnos, tj. brojka će samo rasti kako se informacijska tehnologija razvija. Međutim, izvješće McKinseyja iz 2016.-te godine pokazuje da unatoč najvećem broju podataka koji se nalaze u proizvodnji, samo 20-30% tih podataka se zapravo koristi za poboljšanje sustava.[12] Ovi podaci dolaze odasvud; senzori za prikupljanje informacija o klimi, broju postova na društvenim mrežama, digitalne slike i videozapisi, evidencija transakcija, GPS signale mobitela i navigacijskih uređaja itd. Važno je spomenuti dva vrlo važna i relevantna zakona kada se priča o elektroničkom poslovanju te digitalnom poslovanju i transformaciji. Prvi je Moorov zakon koji glasi: snaga mikročipova se udvostručava svake godine. Osnivač ovog zakona je Gordon Moore, jedan od osnivača Intela. Prema vlastitom predviđanju, ovaj će se zakon primjenjivati do 2020. godine. Kao dokaz mnoge tvrtke najavljuju da će u bliskoj budućnosti više pozornosti posvetiti veličini čipova i njihovoj učinkovitosti nego sirovoj snazi. Drugi zakon jest Metcalfeov zakon: vrijednost mreže raste eksponencijalno s rastom broja njezinih korisnika. Robert Metcalfe uveo je ovaj zakon 1980-ih. Njegova prva zamisao zakona bila je više o broju uređaja nego o samim korisnicima, s obzirom da jedan korisnik može koristiti više uređaja, kao što su računala, telefoni, faksovi i drugi. Prema njegovom objašnjenju, kada imamo dva telefona, možemo uspostaviti samo jednu vezu, a ako taj broj naraste na 12 telefonskih uređaja, a vrijednost telefonske mreže će se povećati, jer sada možemo uspostaviti čak 66 međusobno povezanih telefonskih priključaka.[13] Što se tiče obrade Big Data podataka do sada su identificirane sljedeće metode obrade: deskriptivna analiza podataka i informacija kako bi se definiralo trenutno stanje poslovne situacije na način da razvoj, obrasci i iznimke postanu očigledni, u obliku izrade standardnih izvješća, ad hoc izvješća i upozorenja.[14]

[11] IMB Data Science Meetup (2015)
[12] McKinsey, (2016). The Age Of Analytics: Competing In AdataDriven World. Dostupno na: https://www.mckinsey.com/business-functions/ mckinsey-analytics/our-insights/the-age-of-analyticscompeting-in-a-data-driven-world [28.05.2019.]
[13] Nuculovic, N. (2016) Metcalfeov zakon. Dostupno na: https://nikolanuculovic.wordpress.com/2016/05/24/metcalfeov-zakon/ [08.06.2019].
[14] Sivarajah, U., Kamal, M. M., Irani, Z., & Weerakkody, V. (2017). Critical analysis of Big Data challenges and analytical methods. Journal of Business Research. Dostupno na: https://doi.org/10.1016/j.jbusres.2016.08.001 [02.06.2019.]

Kada pričamo o digitalnoj transformaciji neizbježna tema jest IoT ili Internet of Things. Osnovna ideja koncepta Interneta stvari (IoT) je sveprisutna prisutnost oko nas raznih stvari ili predmeta kao što su oznake radio-frekvencijske identifikacije (RFID), senzori, mobilni telefoni itd, koji mogu komunicirati i međusobno surađivati te surađivati sa svojim susjedima kako bi postigli zajedničke ciljeve.[15] Iako već postoji veliki broj međusobno povezanih uređaja, očekuje se da će taj broj samo rasti i to ubrzanim tempom. Takva velika mreža povezanih uređaja i sustava naravno predstavlja veliku opasnost zloupotrebe podataka i sigurnosne rizike pa je vrlo važno razviti jednostavan i učinkovit mehanizam primjene uređaja te podataka koje smiju koristiti.

Što sve gore navedeno znači za budućnost, kako će ona izgledati uslijed velikih tehnoloških promjena koje su već tu i koje tek dolaze? Danas oko 50% svjetske populacije živi u gradovima, no predviđanja su da će do 2040. godine ta brojka narasti do nekih 70%. Predviđanja su, unatoč povećanju gradskog stanovništva, da će tehnološki napredak suzbiti povećanje negativnih efekata te povećati prednosti i koristi. Kao neki od negativnih čimbenika navode se: problem u društvenoj i organizacijskoj sferi uslijed povećavanja broja stanovnika u gradovima, opterećenje infrastrukture, nedostatak resursa, otežavanje prometa te zdravstveni problemi stanovništva uslijed ugrožavanja okoliša.[16]

IoT rješenja mogu pridonijeti njihovom rješavanju. Kao jedno od mogućih rješenja spominje se Pametni grad – grad koji koristi ICT tehnologiju te, uz primjenu tehnoloških inovacija, doprinosi učinkovitijem i racionalnijem korištenju resursa, što znači uštedu energije i smanjenje negativnih utjecaja na okoliš. Razvoj pametnog grada često se povezuje s ostvarenjem sljedećih elemenata: pametna ekonomija, pametna populacija, pametno upravljanje, pametan promet, pametno okruženje i pametan život.[17] Iako takva definicija zvuči futuristički već danas imamo neke oblike primjene IoT pametnih aplikacija kao npr. kontrola sustava prometa, pametne aplikacije za parkiranje vozila, mjerenje razine onečišćenja zraka i alarmiranje nadležnih institucija.

[15] Atzori, L., Iera, A., Morabito, G. (2010) The internet of things: A survey, Computer Networks, vol. 54, no. 15, pp. 2787–2805

[16] Simon, J.; Covic, Z. and Petkovic, I.: Industrie 4.0 Based Customized Mass Production Overview. Conference MECHEDU, 2017, Subotica Tech – College of Applied Sciences, Subotica, 2017

[17] Zidek, K. (2016) Embedded vision equipment of industrial robot for inline detection of product errors by clustering-classification algorithms. International Journal of Advanced Robotic Systems. Dostupno na: http://dx.doi.org/10.1177/1729881416664901 [17.06.2019.]

Osnovna ideja provedbe IoT je pružanje pametne infrastrukture za područja kao što su promet, električna energija, opskrba vodom, stambena izgradnja i javne usluge.[18]

Možemo se složiti kako se, u današnje vrijeme, nalazimo u nekoj fazi tranzicije, informacijska tehnologija nam puno pomaže u svim sferama života, poslovanju, medicini, industriji, istraživanju i razvoju itd., no još nije postala centralni dio naših života, tek posjeduje taj potencijal, da postane neizostavni dio naših života i pomogne nam pri idućem koraku (r)evolucije.

1.2. Predmet i cilj rada

Ciljevi ovog rada biti će uz teoretsku obradu teme obraditi i studije slučaja korištenja umjetne inteligencije u poslovanju koje postoje danas, objektivno objasniti prednosti i nedostatke s tehnološke i ljudske strane te provesti istraživanje o mišljenju buduće radne snage o korištenju umjetne inteligencije na radnom mjestu i u poslovanju općenito. Također jedan od glavnih ciljeva ovog rada biti će objasniti etičke probleme i pitanja oko dizajniranja, implementacije i korištenja umjetne inteligencije u poslovanju. Istraživanje će se provesti anketnim upitnikom koji sadrži 30-ak pitanja i za čije rješavanje treba 5 do 10 minuta. Odgovori na pitanja će se sastojati od odgovora DA/NE, precizno definiranih odgovora na pitanja te će sudionik istraživanja na nekim pitanjima imati opciju iznijeti vlastito mišljenje ukoliko niti jedan od ponuđenih odgovora ne predstavlja njegovo mišljenje. Rezultati provedenog istraživanja usporedit će se s istraživanjem provedenim u Sjedinjenim Američkim Državama. Na kraju rada autor će navesti zaključak o svemu prethodno napisanom o temi koju obrađuje i koji odražava isključivo njegova osobna mišljenja.

1.3. Metodologija i izvori podataka

Metodologija i izvori podataka korišteni pri izradi ovog rada sastoje se od knjiga, časopisa, znanstvenih članaka te internetskih izvora renomiranih ekonomskih te informatičkih stručnjaka, ne samo na području umjetne inteligencije, već općenito na području digitalne transformacije i poslovanja. Misli i komentari cijenjenih autora i autorica izneseni u tim publikacijama biti će citirani, sukladno pravilima citiranja te čitav popis literature, koji je korišten pri izradi ovog rada, dostupan je u šestom (6.) poglavlju pod nazivom LITERATURA.

[18] Simon, J.; Trojanova, M.; Zbihlej, J. and Sarosi, J.(2018) Mass Customization Model in Food Industry Using Industry 4.0 Standard with Fuzzy Based Multi-criteria Decision Making Methodology. Advances in Mechanical Engineering 10(3), 1-18

1.4. Sadržaj i struktura rada

Na početku rada, autor će čitatelju objasniti što to točno znači pojam umjetne inteligencije, što taj pojam podrazumijeva i što se od njega očekuje u ovom radu, te predstaviti i uvesti ga u svijet poslovanja gdje postoje golemi potencijal i koristi za integraciju umjetne inteligencije. Čitatelj će zatim proći kroz povijesni razvoj do sada razvijenih iteracija umjetne inteligencije i to ne samo aplikacijski razvoj, već i razvoj ljudskog shvaćanja što umjetna inteligencija podrazumijeva.

Od Turingovog koncepta računala koje samo uči do primjene umjetne inteligencije u moderno doba, npr. u industriji proizvodnje ili u poslovnim informatičkim sustavima. Čitatelj će se obrazovati o podjeli umjetne inteligencije, koja je jaka, a koja slaba, naučiti će razlikovati usku, opću i super umjetnu inteligenciju.

Nakon čitanja povijesnog razvoja i učenja o umjetnoj inteligenciji u obliku mrtvog slova na papiru, čitatelj prelazi na iduće poglavlje, a to jest integracija i korištenje umjetne inteligencije u poslovanju i u stvarnim životnim situacijama. Cilj je prikazati na modernim primjerima načela i zakone integriranja i funkcioniranja umjetne inteligencije u poslovanju. Kao što se zaposlenik, između ostalog, ocjenjuje kroz rezultate svoga rada, jednako će se ocjenjivati i umjetna inteligencija, na temelju rezultata koje je postigla i koristi koja je proizašla iz njezine implementacije i korištenja. Stav je autora da je tako najlakše i najjednostavnije objektivno prikazati obje strane medalje zvane umjetna inteligencija, njezine prednosti s jedne i nedostatke s druge strane.

Prije zaključka prezentirati će se istraživanje i dobiveni rezultati o ljudskim mišljenjima i stavovima o umjetnoj inteligenciji te njezinom korištenju u poslovanju i na radnome mjestu, provedeno među studentima i mladom radnom snagom.

Ovakvu skupinu ispitanika možemo nazvati budućom radnom snagom te je, kao takva, namjerno izabrana za kandidata u sklopu istraživanja jer se pretpostavlja da će oni biti u središtu i da će biti najviše pogođeni tehnološkom eksplozijom koja se svakim danom sve više približava. Upravo zbog tih razloga zanimljivo je čuti njihova razmišljanja i stavove o umjetnoj inteligenciji, prije nego li ona u većoj mjeri postane dio njihovih života i karijera.

Nakon putovanja kroz svijet umjetne inteligencije čitatelj dolazi do posljednjeg poglavlja, zaključka. To poglavlje će obuhvatiti sve važnije misli prethodno navedene u radu kako bi se objektivno mogla prokomentirati tema na temelju navedenih činjenica i stavova.

2. UMJETNA INTELIGENCIJA

2.1. Što je umjetna inteligencija

Temeljni pokretači gospodarskog rasta oduvijek su bile tehnološke inovacije. One najvažnije, koje su imale najveći utjecaj na naš život, ekonomski stručnjaci zovu tehnologije opće namjene. Parni stroj, električna energija, motor s unutarnjim izgaranjem, iskorištavanje nuklearne lančane reakcije samo su neki od primjera kako bi lakše razlikovali tehnologije opće namjene od „običnih“ tehnoloških inovacija. Parni stroj omogućio je eksponencijalni razvoj industrije, električna energija zamijenila je fosilna goriva u velikoj mjeri te omogućila efikasnije iskorištavanje resursa, motor s unutarnjim izgaranjem stvorio je flote automobila, kamiona, zrakoplova, revolucionirao prijevoz ljudi i dobara, iskorištavanje nuklearne lančane reakcije donijelo je dobre i loše strane, opskrbljivanje električnom energijom te nuklearna oružja. Najvažnija tehnologija opće namjene naše ere jest umjetna inteligencija.

No, što je zapravo umjetna inteligencija? Da bismo odgovorili na to pitanje, treba prvo definirati što je to inteligencija uopće. Osoba može imati enciklopedijsko znanje o činjenicama i brojkama koje se odnose na zemlje svijeta ili posjeduje ogromnu količinu podataka te se može prisjetiti točno određene informacije u danom trenutku, no samo posjedovanje tog znanja samo po sebi neće tu osobu učiniti inteligentnom. Dakle, ako nečiji mozak posjeduje veliki broj informacija, to ne znači nužno da je ta osoba visoko inteligentna. Iako se svi slažemo da inteligencija ima neke veze sa znanjem i sposobnošću za rasuđivanje, čini se da ljudska inteligencija nadilazi tu svijest ili samosvijest, mudrost, emocije, simpatije, intuiciju i kreativnost. Nekima inteligencija uključuje i duhovnost - povezanost s većom silom ili bićem.[19] Također, dokazano je da inteligencija dolazi u mnogim oblicima, neki ljudi su visoko inteligentni u području matematike i primijenjene fizike, drugi u umjetnošću, glazbi ili politici.

[19] Rose, D. (2018). Artificial Intelligence for Business- What you need to know about Machine Learning and Neural Networks. Chicago Lakeshore Press

Neki ljudi diče se akademskim postignućima i izuzetno su cijenjeni u društvu, dok su drugi, bez ikakvog formalnog obrazovanja, razvili više milijunske biznise ili postavili i dokazali izuzetne matematičke teoreme. Općenito, inteligencija je sposobnost razumijevanja objektivnog svijeta i primjene znanja za rješavanje problema.

Inteligencija pojedinca sastoji se od širokih mogućnosti, kao što su: sposobnost uočavanja i razumijevanja objektivnih stvari, objektivnog svijeta i sebe; sposobnost stjecanja iskustva i znanja putem učenja; sposobnost razumijevanja znanja te primjene znanja i iskustva za analizu problema i rješavanje problema; sposobnosti udruživanja, rasuđivanja, odlučivanja i odlučivanja; sposobnost jezične apstrakcije i generalizacije; sposobnosti otkrivanja, pronalaska, kreativnosti i inovacije; sposobnost da se brzo, razumno i razumno nose sa složenim okruženjima; i sposobnost predviđanja i uvida u razvoj i promjene stvari.[20]

Ljudi su pokušali razviti jedinstveni standard za mjerenje inteligencije (IQ test) no takvo ispitivanje testira samo jedan dio inteligencije poput kratkoročne memorije, analitičkog razmišljanja i matematičke sposobnosti.

Kako bismo dokazali ovu tvrdnju dovoljno je uzeti jednu osobu, npr. Steve Jobs. Svi znaju tko je on, bez njega je nemoguće zamisliti ovaj eksponencijalni tehnološki rast posljednjih 50ak godina. Stevea su zvali genijalnim inženjerom, velikim inovatorom, talentiranim menadžerom. Među njegovim dostignućima su tehnologije, bez kojih danas ne možemo zamisliti svoj život. Možda odlazak jedne osobe iz IT sfere nije izazvao toliko žaljenja kako običnih ljudi, tako i njegovih kolega na tržištu. Osnivač najvrjednijeg poduzeća na svijetu Apple, pretvorio je Pixar u lidera među tvrtkama koje snimaju animirane filmove, Macintosh, iPhone, iPod, iPad, AppStore samo su neki od njegovih mnogobrojnih uspjeha. Zapamćen je kao kreativan genij, sjajan branitelj svojih ideja i ispred svoga vremena. Međutim, koliko god je bio visoko inovativan i kreativan, odnosi s ljudima mu nisu bili jača strana. Poznato je da bio jedan od glavnih izvora tenzija gdje god da je radio, upuštao se u glasne svađe s kolegama na radnom mjestu i ponekada se ponašao kao razmaženo derište. Rijetko je imao kontrolu nad svojim emocijama, posebice u ranoj karijeri. Psihološki profil stila vođenja Jobs-a pun je kontrasta od vizionarskog i genijalnog, gotovo proročanskog do tiranskog narcisoidnog stava o zlostavljanju zaposlenika i ignoriranju svih pogleda, osim njegovih.

[20] Akerkar, R. (2019). Artificial Intelligence for Business. Sogndal, Norway. Western Norway Research Institute.

Njegov nedostatak emocionalne inteligencije bio je jednako poznat kao vizionarski pogled na svijet koji je imao i uočavanja onoga što je moguće tamo gdje drugi to nisu bili u mogućnosti.

Vrlo je važno razlikovati razmišljanje od inteligencije. Razmišljanje je sposobnost analiziranja, rasuđivanja, procjenjivanja te formuliranja koncepata i ideja. Svako biće sposobno razmišljati ne znači da je i inteligentno. Mnogi ljudi pristrano pristupaju ovom problemu, govoreći: "Računala su napravljena od silikona i napajanja i stoga nisu sposobni za razmišljanje" ili, s druge strane, "Računala rade mnogo brže od ljudi i zato moraju biti inteligentnija od ljudi. "Istina je najvjerojatnije negdje između ove dvije krajnosti.[21] Što je onda inteligencija? Možemo reći da je inteligencija primjena stečenog znanja i iskustva kako bi se našla potencijalna rješenja nekog složenog problema ili pravodobno korištenje informacija kako bi se ostvarila nekakva korist. Inteligencija je kognitivna sposobnost pojedinca da uči iz iskustva, da dobro razmišlja, pamti važne informacije i nosi se sa zahtjevima svakodnevnog života.[22]

Bez točno definiranog načina mjerenja ili definicije ljudske inteligencije zaista je teško zaključiti ponašali se neko računalo, sustav ili proces inteligentno. Računalni sustavi neke stvari rade mnogo bolje od ljudi, određene zadatke jednako uspješno obavljaju puno brže, više nije novost da računala pobjeđuju najbolje ljudske igrače u šahu. IBM Watson pobijedio je neke od najboljih prvaka u igranoj emisiji Jeopardy. Googleov DeepMind pobijedio je najbolje igrače u 2500 godina staroj kineskoj igri zvanoj "Go" - igri koja je toliko složena da se smatra da postoji veća moguća konfiguracija ploče nego što ima atoma u svemiru. Ipak, nijedno od ovih računala ne razumije svrhu igre ili nema razloga za igru.[23] Iako su u nekim stvarima računala mnogo uspješnija od ljudi, čini li ih to inteligentnima? Prema svemu navedenome, odgovor je ne. Zaključili smo da postoji mnogo vrsta inteligencije, a ni sami ne znamo kako ju točno definirati ili mjeriti. Uz to, pobjede računala rezultat su usklađivanja obrazaca, vađenja podataka iz baze koje omogućavaju računalu da odgovori na protivnikov potez.

[21] Lucci, S. & Kopec, D. (2016). Artificial Intelligence in the 21st Century. Boston. Nakladnik: Boston - Mercury Learning and Information

[22] Sternberg, R. J. 1994. In search of the human mind. 395–396. New York, NY: Harcourt-Brace

[23] Rose, D. (2018). Artificial Intelligence for Business- What you need to know about Machine Learning and Neural Networks. Nakladnik: Chicago Lakeshore Press

Naravno prisutne su raznolike rasprave na tu temu no zanimljivo je kako, neki krugovi, inteligentno ponašanje u ovom slučaju pripisuju zato što je računalo bolje u izvršavanju tog određenog zadatka, a opet rijetko čujemo da su brodovi inteligentniji od ljudi jer se brže kreću vodom ili dizalice u automehaničarskoj radioni koje mogu lakše i više od ljudi podići automobil i druge teške stvari. Uski inteligentni programi mogu pobijediti ljude u određenim zadacima, ali oni to znanje ne mogu primijeniti na druge zadatke. Rješavanje zadataka izvan originalnih parametara programa zahtijeva izgradnju dodatnih programa koji su slično usko specijalizirani.[24]

Umjetna inteligencija je znanost građenja strojeva da rade ono što bi zahtijevalo inteligenciju ako bi to radio čovjek.[25] Ukoliko opis izvršenja zadatka odgovara navedenoj definiciji tada možemo pričati o inteligenciji u strojevima. U ovoj definiciji se misli na jaku umjetnu inteligenciju, podjelu o kojoj će biti više riječi u poglavlju nakon ovoga. Zasad pod pojmom umjetna inteligencija misli se na slabu umjetnu inteligenciju. Vrlo smo daleko od toga da imamo strojeve koji mogu naučiti najosnovnije stvari o svijetu na način na koji ljudi i životinje to mogu.[26]

Danas umjetna inteligencija je impresivna kada je u okruženju gdje su pravila jasna i mogućnosti ograničene. Organizacije kao Google imaju najviše koristi od implementacije umjetne inteligencije jer rade u dobro definiranom prostoru s jasno postavljenim pravilima. Iako većina ljudi nije toga svjesna, umjetna inteligencija nalazi se svuda oko nas, u telefonima, automobilima, bolnicama, bankama, medijima, društvenim mrežama itd. Zamislite slijedeću situaciju, dijete piše domaću zadaću u svojoj sobi, pita mamu, koja u kuhinji čita časopis, kako se zove glavni grad Nigerije. Mama razmišlja i prije nego li je uspjela išta izustiti Alexa kaže točan odgovor: Abuja.

Alexa je tzv. kućna pomoćnica, Amazonov sustav umjetne inteligencije koji pomaže u kućanstvu. U današnjem svijetu takvi sustavi, u očima djeteta, zamijenili su roditelje kao izvor informacija, što je prije par desetak godina zvučalo kao znanstvena fantastika.

[24] Yao, M., Zhou, A. & Jia, M. (2018). Applied Artificial Intelligence. A Handbook for Business Leaders. New York
[25] Raphael, B. 1976. The thinking computer. San Francisco, CA: W.H. Freeman.
[26] Vincent, J. (2017). Facebook's head of AI wants us to stop using the Terminator to talk about AI. Interview with The Verge. The Verge

2.1.1. Strojno učenje (Machine learning)

Najvažnija tehnologija opće namjene naše ere je umjetna inteligencija, posebno strojno učenje – sposobnost stroja da stalno poboljšava svoje performanse, a da ljudi ne moraju točno objasniti kako ispuniti sve zadatke koji su mu zadani. Strojno učenje pokreće promjene na tri razine: zadacima i zanimanjima, poslovnim procesima i poslovnim modelima.[27]

Posljednjih nekoliko godina strojno učenje postalo je puno učinkovitije i šire dostupno nego ikada do sada. Strojno učenje predstavlja potpuno drugačiji pristup kreiranju i razvoju softwarea. Stroj nije programiran za točno određeni ishod, već on uči iz primjera. Dosadašnja praksa bila je usredotočena na kodiranje postojećih znanja i postupaka u strojeve. Naučili smo izgraditi sustave koji uče kako samostalno izvršavati zadatke. Kako se umjetna inteligencija sve više razvijati te preuzima sve veću ulogu u poslovanju, javlja se potreba za redizajnom zadataka, poslovnih procesa te, na kraju, poslovnih modela. Strojno učenje spada u područje slabe umjetne inteligencije jer ono ne razumije što se govori nego samo povezuje simbole i značenje te identificira uzorke. Velika je razlika leži u tome što računalo samo prepoznaju uzorke u podacima, umjesto da to pruža programer, tj. računalo s vremenom postaje „pametnije“.

Strojno učenje danas predstavlja jedno od najbrže rastućih područja u informacijskoj tehnologiji i razvoja umjetne inteligencije. To je moguće zato jer su troškovi pohrane i obrade podataka znatno pali u posljednjih nekoliko godina. U području digitalne transformacije veliku ulogu imaju Veliki Podaci ili Big Data čija računalna obrada prepoznaje obrasce, trendove i povezanosti. Strojno učenje nadilazi ograničenja simboličkih sustava. Umjesto memoriranja simbola računalni sustav koristi algoritme strojnog učenja za stvaranje modela apstraktnih koncepata. Otkriva statističke obrasce pomoću algoritama strojnog učenja na ogromnim količinama podataka.[28]

Je li to stvarno toliko bitno i koliko je/će to biti stvarno korisno? Odgovor na prvi dio pitanja – jest, stvarno je toliko bitno. Jedan od razloga velikog razvoja u polju strojnog učenja umjetne inteligencije posljednjih godina leži u tom što smo naučili artikulirati vlastito znanje.

[27] Brynjolfsson E., Mcaffe A. (2017) The Business of Artificial Intelligence, How AI Fits into Your Science Team; What it can – and cannot – do for your organization. Dostupno na: https://hbr.org/cover-story/2017/07/the-business-of-artificial-intelligence [23.06.2019]

[28] Rose, D. (2018). Artificial Intelligence for Business- What you need to know about Machine Learning and Neural Networks. Nakladnik: Chicago Lakeshore Press

Možda zvuči glupo, no zapitajte se, kako bi drugoj osobi objasnili kako prepoznati lice nekog prijatelja ili pokušajte napisati upute koje će omogućiti nekome da nauči sam voziti bicikl (tzv. priča o profesoru mehanike i biciklista). Ako se od profesora traži da navodi principe mehanike dok pokušava voziti bicikl, a svoj uspjeh na biciklu temelji na poznavanju tih načela, osuđen je na neuspjeh. Isto tako, ako biciklist pokušava naučiti zakone mehanike i primijeniti ih dok obavlja svoj zanat, i on je predodređen za neuspjeh i možda tragičnu nesreću.[29]

Ovaj primjer savršeno oslikava razvijanje ljudskih vještina i znanja u mnogim područjima koji se pohranjuju u podsvijest i nije moguće jednostavno ih objasniti. Mnoga znanja koje imamo su prešutna, što znači da ih ne možemo u potpunosti objasniti.[30] Ta činjenica je poznata pod nazivom Polanyijev Paradoks, prema filozofu Michaelu Polanyiju. Ovaj paradoks ne samo da ograničava koje stvari možemo objasniti i što možemo reći jedni drugima, već ograničava našu sposobnost prenošenja misli, stavova i inteligencije strojevima. Nesposobnost artikuliranja vlastitog znanja značila je da ne možemo strojevima objasniti kako i zašto nešto napraviti, tj. nismo mogli automatizirati zadatke. Kao što znamo, dosadašnja praksa fokusirala se na kodiranje procesa i ishoda, upravo taj izraz „kodiranje“ znači transformaciju znanja iz ljudskih glava u oblik koji je razumljiv strojevima na taj način da to znanje oni mogu koristiti. Strojno učenje umjetne inteligencije nadilazi navedeni paradoks i ostala ograničenja jer strojevi uče sami od sebe iz viđenih primjera i korištenja povratnih informacija.

Odgovor na drugi dio pitanja, koliko će takvi sustavi biti korisni, možemo vidjeti već i danas. Neke medicinske ustanove koriste sustave strojnog vida za prepoznavanje potencijalnih stanica raka. Google je razvio upravo takav sustav umjetne inteligencije - nazvan LYNA, opisan je u radu pod naslovom "Otkrivanje metastaza karcinoma dojke na temelju umjetne inteligencije", objavljenom u Američkom časopisu za kiruršku patologiju. U testovima je postigao površinu ispod radne razine prijemnika (AUC) - mjera točnosti otkrivanja - od 99 posto.

[29] Michie, D. L. 1986. On Machine Intelligence, 2nd edition. Chichester, England: Ellis Horwood
[30] Brynjolfsson E., Mcaffe A. (2017) The Business of Artificial Intelligence, How AI Fits into Your Science Team; What it can – and cannot – do for your organization. Dostupno na: https://hbr.org/cover-story/2017/07/the-business-of-artificial-intelligence [23.06.2019]

To je superiorno ljudskim patolozima koji, prema procjeni, propuštaju male metastaze na pojedinim dijapozitivima čak 62% vremena kada su pod vremenskim ograničenjima.[31] Korištenjem takvog sustava oslobađa se radiologe i liječnike da se usredotoče na stvarno kritične slučajeve, komunikaciju s pacijentima i koordinaciju s drugim liječnicima i ustanovama. Znanstvenici su koristili umjetnu inteligenciju kako bi prepoznali obrasce karcinoma dojke - i otkrili su 5 novih vrsta bolesti za koje je svaka odgovarala različitim personaliziranim tretmanima.[32]

Da se zaključiti da su sustavi umjetne inteligencije izvrsni učenici, mogu postići nadljudske performanse u širokom rasponu aktivnosti. Takvi sustavi nalaze se u čitavoj ekonomiji, a njihov utjecaj biti će velik. Iako se umjetna inteligencija koristi u mnogim poduzećima širom svijeta, njezin utjecaj, zasad, nije toliko velik. Učinci umjetne inteligencije povećat će se u narednom desetljeću, jer proizvodnja, trgovina na malo, transport, financije, zdravstvena zaštita, pravo, oglašavanje, osiguranje, zabava, obrazovanje i gotovo svaka druga industrija transformiraju svoje temeljne procese i poslovne modele kako bi iskoristili prednosti strojno učenje.[33]

Gotovo svakoga dana mogu se naći senzacionalistički natpisi u raznim novinama, časopisima ili internetskim portalima kako umjetna inteligencija dolazi svim ljudima uzeti poslove. No istina je potpuno drugačija, umjetna inteligencija gotovo nikada ne zamjenjuje cijeli posao, proces ili poslovni model iz jednostavnog razloga, ne postoji toliko razvijen sustav koji ima tu mogućnost. Umjetna inteligencija najčešće nadopunjuje ljudski posao ili aktivnosti, tj. olakšava ga ili skraćuje. Ako neki uspješno završen posao se sastoji od 10 koraka, umjetna inteligencija odradi jedan ili dva koraka koji se automatiziraju, ubrzavajući time proces i omogućavajući više vremena ljudskom radniku za ostale korake.

Na primjer, sustav za podršku prodaje chat sobe u Udacityu nije pokušao izgraditi bot koji bi mogao preuzeti sve razgovore; Umjesto toga, savjetovala je ljudske prodavače kako poboljšati njihov učinak. Ljudi su ostali glavni, ali postali su znatno učinkovitiji i učinkovitiji.

[31] Wiggers K. (2018) Google AI claims 99% accuracy in metastatic breast cancer detection. Nakladnik: VentureBeat. Dostupno na: https://venturebeat.com/2018/10/12/google-ai-claims-99-accuracy-in-metastatic-breast-cancer-detection/ [25.06.2019]
[32] ScienceDaily, Institute of Cancer Research (2019). Dostupno na: https://www.sciencedaily.com/releases/2019/08/190802131354.htm [28.06.2019]
[33] Brynjolfsson E., Mcaffe A. (2017) The Business of Artificial Intelligence, How AI Fits into Your Science Team; What it can – and cannot – do for your organization. Dostupno na: https://hbr.org/cover-story/2017/07/the-business-of-artificial-intelligence [28.06.2019]

Ovaj je pristup obično mnogo izvodljiviji od pokušaja dizajniranja strojeva koji mogu učiniti sve što ljudi mogu. To često vodi boljem, zadovoljnijem poslu za ljude koji su uključeni i, na kraju, do boljih rezultata za kupce. JP Morgan Chase uveo je sustav za reviziju ugovora o zajmu (jedan od zadataka u poslovnom procesu), posao na koji se prije trošilo oko 350 000 ljudskih sati sada se obavi za nekoliko sekundi.

Zasada velika snaga umjetne inteligencije leži u potpornoj ulozi ljudskom radniku. Kreativnost, dizajn, implementacija i planiranje šire slike poslovanja nisu poslovi u kojima bi umjetna inteligencija bila dobra, zato dobar poslovni menadžer mora znati pravilno rasporediti resurse i zadatke između strojeva i zaposlenika.

Sve navedeno odnosi se na jednu kategoriju strojnog učenja umjetne inteligencije, a to su tzv. nadzirani sustavi učenja. Takvi sustavi oslanjaju se na puno primjera točnog odgovora ili postupka na određeni problem ili situaciju, što je veći broj podataka to je sustav uspješniji u predikciji točnog odgovora. Npr. kada se stroju daju tisuće slika pasa kako bi pronašao uzorke i razlike između njih, sustav se ne mora brinuti o isključivanju slika koje nisu psi, npr. mačke, krave, automobili, kuće itd. Sve te slike koje su dane sustavu nazivaju se „trening set“ tj. set podataka za treniranje. Koristeći set podataka za treniranje stroj se uči da su svi uzorci koje pronađe dio karakteristika određenog entiteta, u ovom slučaju, karakteristike psa. Takva je situacija danas.

Strojevi također mogu učiti sami od sebe, daju im se enormne količine podataka i pušta ih se da sami pronalaze obrazce u podacima. To se zove strojno učenje bez nadzora. Npr. stroju se daju sve slike neke osobe s njihovog profila društvene mreže, stroj neće znati koja od tih osoba je mama, tata, dečko, cura, brat, sestra, muž, žena, kćer ili sin te osobe, no može selektirati osobe prema frekvenciji njihovog pojavljivanja na slikama ili području gdje je slika napravljena. Strojno učenje bez nadzora je, trenutno, manje učinkovitije od nadziranog sustava strojnog učenja, no ono je korak k razvoju snažne umjetne inteligencije.

2.1.2. Duboko učenje (Deep learning)

Duboko učenje sastoji se od mnogih hijerarhijskih slojeva koji obrađuju informacije na nelinearni način, gdje neki koncept niže razine pomaže u definiranju koncepata više razine.

Duboko učenje definirano je kao klasa strojnog učenja koja koristi mnoge slojeve nelinearne obrade informacija za nadzirane i nenadzirane značajke ekstrakcije i transformacije, te za analizu uzoraka i klasifikaciju.[34] Uz duboko učenje, moguće je prepoznati, klasificirati i kategorizirati obrasce u podacima za stroj uz relativno manje napora.

Google je pionir u eksperimentu dubokog učenja, koji je pokrenuo Andrew Ng. Duboko učenje nudi višeslojnu obradu informacija sličnu ljudskom načinu obrade podataka. Osnovna ideja dubokog učenja je korištenje hijerarhijske obrade pomoću mnogih slojeva arhitekture. Dubinsko učenje slijedi distribuirani pristup upravljanju velikim podacima. Pristup pretpostavlja da se podaci generiraju uzimajući u obzir brojne čimbenike, različito vrijeme i različite razine. Duboko učenje olakšava slaganje i obradu podataka u različite slojeve prema vremenu pojavljivanja podataka, razini kompleksnosti ili prirodi.

Postoje tri kategorije arhitektura dubokog učenja. Arhitekture koje pripadaju generativnoj kategoriji se fokusiraju na pretragu slojeva na nekontrolirani način. Ovaj pristup uklanja poteškoće u konstruiranju arhitektura niže razine koje se prenose na prethodne slojeve. Svaki se sloj može pretražiti i kasnije uključiti u model za daljnje opće prilagođavanje i učenje. Na taj se način rješava problem osposobljavanja arhitekture neuronske mreže s više slojeva i omogućuje se duboko učenje.

Arhitektura neuronske mreže može imati diskriminatornu sposobnost obrade tako što slaže output svakog sloja s izvornim podacima ili različitim kombinacijama informacija i tako formira arhitekturu dubokog učenja. U opisnom modelu često se rezultati neuronske mreže smatraju uvjetnom raspodjelom nad svim mogućim nizovima oznaka za zadani ulazni niz koji će se dalje optimizirati pomoću objektivne funkcije. Hibridna arhitektura samim nazivom odaje svoje karakteristike, kombinira svojstva generativne i diskriminirajuće arhitekture.

Analitika velikih podataka potrebna je za učinkovito upravljanje ogromnim količinama podataka. Glavni aspekti koji se mogu uzeti u obzir pri radu s velikim podacima su optimizacija velikih razmjera, upravljanje velikim dimenzijama i dinamičko rukovanje podacima. Duboko učenje biti će korisno u upravljanju takvim podacima i pomoći u grupiranju, obradi i vizualizaciji takvih podataka.

[34] Akerkar, R. (2019). Artificial Intelligence for Business. Sogndal, Norway- Western Norway Research Institute.

Bio-informatika, prepoznavanje vida i govora polja su u kojima se mogu pronaći takvi podaci s više dimenzija. Osim obujma i strukture, vrijeme je još jedan glavni faktor koji povećava složenost podataka i time otežava posao upravljanja podacima. Metode dubokog učenja zahtijevaju tisuće zapisa podataka da bi modeli postali relativno dobri u klasifikacijski informacija i podataka, a u nekim slučajevima i milijune da ih izvedu na razini ljudi.

Prema jednoj procjeni, nadzirani algoritam dubokog učenja općenito će postići prihvatljive performanse s oko 5000 primjeraka označenih po kategoriji te će odgovarati ili premašiti performanse na ljudskoj razini kada se obuči s skupom podataka koji sadrži najmanje 10 milijuna primjeraka s oznakom.[35] Međutim, ako se ne dosegne prag obujma podataka, umjetna inteligencija neće dodati vrijednost tradicionalnim analitičkim tehnikama.

Ovakve enormne skupove podataka nije lagano nabaviti ili stvoriti za poslovne slučajeve. Ako to nije dovoljan izazov, ostaje problem njihovog označavanja za sustave umjetne inteligencije koji moraju riješiti ljudi, jer se sustavi umjetne inteligencije trenutno obučavaju i osposobljavaju kroz nadzirano učenje što znači da ljudi moraju označiti i kategorizirati skupove podataka. Izazov označavanja tih velikih skupova podataka trenutno predstavlja usko grlo u procesu klasifikacije podataka od strane sustava umjetne inteligencije. Strojno i duboko učenje predstavljaju stanje u kojem se umjetna inteligencija danas nalazi, ona pokušava pronaći svoj put, usporedno s njom, ljudi također pokušavaju pronaći put kako bolje i efikasnije graditi sustave umjetne inteligencije. Današnje stanje možemo usporediti s malim djetetom kada pokušava naučiti hodati, puzati znamo, umjetna inteligencija se koristi u nekim industrijama, međutim tek smo zagrebli površinu ovog enormnog potencijala i tražimo način kako ga iskoristiti u potpunosti.

2.1.3. Umjetne neuronske mreže

Umjetne neuronske mreže inspirirane su ljudskim mozgom, koji je sastavljen od tkiva, žila, sive i bijele moždane tvari te neurona. To su fizički elementi koji tvore ljudski mozak. Zadatak neurona je prihvaćanje, obrađivanje i odašiljanje podataka. Fizički elementi koji tvore umjetne neuronske mreže jest hardware računala, odnosno žice, cijevi, matične ploče, procesori, radna memorija itd.

[35] Chui M., Manyika J., Miremandi M., Henke N., Chung R., Nel P., Malhotra S. (2017) McKinsey Global Institute, Discussion paper. Dostupno na: https://www.mckinsey.com/featured-insights/artificial-intelligence/notes-from-the-ai-frontier-applications-and-value-of-deep-learning [12.07.2019.]

Također neuronska mreža sastoji se od tzv. računalnih čvorova (eng. nodes) koji su ekvivalent neuronima u ljudskom mozgu. Svaki čvor prihvaća i kombinira zadane ili poslane inpute, izvodi nekakvu funkciju nad tim podacima te proizvodi rezultat tj. output. Taj rezultat se može prenijeti na druge računalne čvorove radi dodatne obrade. Ovdje je vrlo bitno shvatiti značenje da su neuronske mreže inspirirane ljudskih mozgom, ključna riječ inspirirane tj. nadahnute.

Ono po čemu je ljudski mozak poseban i zbog čega je inspirirao cijelo znanstveno polje umjetne inteligencije jest njegova izuzetna sposobnost da klasificira podatke, čak i one nepotpune. Mozak brzo razlikuje vrste rukopisa, boju glasa, hranu, različite životinje, razumije riječi iako netko ima čudan naglasak ili mrmlja sebi u bradu, drugim riječima sposobnost pronalaženja obrazaca ondje gdje granice nisu čvrsto postavljene i neke karakteristike nisu jasno izražene. Ono što je nama ljudima jednostavno i prirodno, upravo to je izuzetno teško naučiti sustave umjetne inteligencije, a još teže tim sustavim to primijeniti. Oni fantastično funkcioniraju u sustavima gdje su pravila i razlike između objekata jasno naznačene, međutim u ovakvim sivim zonama ljudski mozak ima značajnu prednost. Smanjivanje te razlike u performansama upravo je cilj umjetnih neuronskih mreža.

Umjetne neuronske mreže poboljšavaju sposobnost stroja da uči slojevitim računalnim čvorovima slično kao i slojevi neurona u ljudskom mozgu, tako da se svaki čvor može povezati s mnogim drugim čvorovima u mreži.[36] U umjetnoj neuronskoj mreži čvorovi su raspoređeni u tri sloja: ulazni, skriveni i izlazni. Signali prolaze kroz cijelu mrežu od ulaznog, preko skrivenog, do izlaznog sloja. Skriveni sloj, koji u sebi može sadržavati jedan ili više slojeva, obavlja najteži zadatak, a to su složeni proračuni. Zove skriveni, jer se ne vidi da radi svoj posao. Sve što vidite su podaci koje unosite u sustav na ulaznom sloju i rezultati koje sustav isporučuje na izlaznom sloju. Veze između čvorova su ponderirane kako bi se ustanovile njihove relativne snage. S takvim ponderiranim vezama čvor koji prima inpute iz dva ili više ulaznih čvorova može sam odrediti na koje ulazne podatke treba obratiti više pažnje. Također može prihvatiti ili odbiti unos ili koristiti njihov ponderirani prosjek tijekom obavljanja svoje funkcije.

Nakon primanja i zbrajanja ponderiranih ulaznih inputa, računalni čvor može dodati pozitivnu ili negativnu vrijednost, u zbroj ulaznih podataka, koja može povećati ili smanjiti vrijednost izlaza.

[36] Rose, D. (2018). Artificial Intelligence for Business- What you need to know about Machine Learning and Neural Networks. Chicago Lakeshore Press

Kao što neuroni u našem mozgu jačaju veze kako učimo, čvorovi u neuronskoj mreži prilagođavaju snagu svojih veza kako bi poboljšali sposobnost mreže da proizvode točan izlaz. Npr. ako se koristi nadzirano učenje za treniranje umjetne neuronske mreže, unose se poznati unosi u nju kako bi se utvrdila veza između oznaka i objekata podataka. Taj odnos se uči minimiziranjem razlike između stvarnih i oznaka koje predviđa sustav umjetne inteligencije.

Kad se trening set podataka unosi u neuronsku mrežu, ona izračunava outpute, klasificirajući objekte, prema svojim mogućnostima. Ako su outputi neuronske mreže izvan stvarnih vrijednosti, greška (razlika između stvarne i izračunate vrijednosti) se vraća kroz neuronsku mrežu, tako da čvorovi mogu prilagoditi snagu svojih veza i pristranosti te pokušati ponovo. Taj se postupak povratne veze i prilagođavanja ponavlja, između i unutar čvorova, sve dok umjetna neuronska mreža ne stvori dovoljno točne outpute, tj. minimalizira razliku između stvarne i izračunate vrijednosti. Umjetna neuronska mreža najučinkovitije uči pomoću velikih setova podataka, sto su kvalitetniji podaci to su točnije prognoze rezultata. Učenje neuronske mreže provodi se slijedećim pristupima.

Nadzirano učenje – mreži se daje mali skup točno klasificiranih podataka kako bi neuronska mreža ustvrdila odnose između objekata, zatim mreži se daje veći broj neklasificiranih podataka kako bi se provjerila točnost pri klasifikaciji objekata, nakon toga, ukoliko je potrebno, mreža se podešava i konfigurira.

Polu nadzirano učenje – mreži se daje kombinacija označenih i neoznačenih podataka kako bi ona sama identificirala obrasce koji bi zatim koristila pri klasifikaciji podataka i previđanju rezultata.

Nenadzirano učenje – mreži se daje veliki skup ne klasificiranih podataka kako bi ona sama pokušala prepoznati uzorke u podacima i klasificirala ih. Rezultati se pregledavaju kako bi se ustvrdila (ne)točnost klasifikacije i predviđanja rezultata.

Učenje nagrađivanjem – neuronskoj mreži se daju razni zadaci, a poboljšanja u performansama se „nagrađuju“, najčešće se provodi pomoću nekog sustava bodovanja, kada sustav postigne neki rezultati, ostvari određen broj bodova.

Umjetnim neuronskim mrežama mogu se analizirati ogromne količine podataka s društvenih mreža kako bi se razvile nove ideje o proizvodima. Liječnici mogu pomoću računala analizirati nalaze napravljene rendgenskim zrakama kako bi prepoznali obrasce koji ukazuju na rane znakove određenih vrsta raka. Analiza podataka iz komunikacije s kupcima i identifikacija obrazaca mogu upućivati na nedostatke proizvoda ili službe za korisnike. Potencijalne koristi takve tehnologije su beskrajne. Današnje neuronske mreže čak imaju sposobnost da nadmaše naše vještine u obavljanju karakteristično ljudskih zadataka, poput prevođenja, pretvaranja audio zapisa u tekst pa čak i vožnje automobila.

2.2. Razvoj umjetne inteligencije kroz povijest

Izgradnja umjetnog inteligentnog stroja/sustava dugo je nedosanjani san čovječanstva koji datira još od vremena starih Egipćana koji su gradili kipove u kojima su se svećenici mogli sakriti kako bi običnom puku mogli propovijedati mudrost božanstava.

Naravno običan puk je imao dojam da im se obraćaju sami bogovi s nebesa. Ovakva vrsta prevare pojavljivala se dosta kroz povijest čovječanstva pa je tako pronašla svoj put i u dio informacijske tehnologije, polje koje je zamućeno takvim obmanama pokušavajući steći status prihvaćene znanstvene discipline pod nazivom – umjetna inteligencija. Najpoznatiji pokušaj razvoja strojeva za razmišljanje ili najbolji primjer takve prevare bio je The Turk, koji je 1790. godine razvio Baron von Kempelen, savjetnik za mehaniku Kraljevske komore u Beču. Ovaj stroj je putovao Europom dugi niz godina te je zavaravao ljude da misle kako igraju šah protiv stroja. U stvari, mali šahist ljudske razine bio je skriven unutar okvira.

Najjači temelji AI proizlaze iz logičkih premisa koje je uspostavio Aristotel (oko 350. pr. Kr.). Ovaj starogrčki filozof i prirodoslovac toliko je bio ispred svoga vremena da svoje „prste“ ima i u temelju stvaranja umjetne inteligencije. On je uspostavio modele znanstvenog i discipliniranog mišljenja koji su postali standard današnje znanstvene metode. Njegova razlika između materije i forme bila je prethodnica jednom od najvažnijih koncepata danas u računalnoj znanosti: apstrakciji podataka, koja razlikuje metode (oblike) od školjki u koje su upleteni, ili u razlikovanju oblika (forme) koncepta od njegova stvarnog predstavljanja.[37]

[37] Lucci, S. & Kopec, D. (2016). Artificial Intelligence in the 21st Century. Boston. Nakladnik: Boston - Mercury Learning and Information

Također stalno je naglašavao ljudsku sposobnost rasuđivanja, držeći se uvjerenja da nas ta sposobnost razlikuje od ostalih živih bića i stavlja na vrh hranidbenog lanca na ovome svijetu. Ta misao povlači premisu da svaki umjetno inteligentan sustav mora imati sposobnost rasuđivanja, odnosno ona je presudna za njegov razvoj.

Raymond Llull, španjolski pustinjak i učenjak iz trinaestog stoljeća, bio je prva osoba koja je pokušala mehanizirati ljudske misaone procese. Zanimljivo je da, iako je bio pobožni kršćanin, nije vidio problem u korištenju znanosti kako bi propitao i dokazao istinitosti načela kršćanstva. Gdje u današnjem modernom svijetu neke religije su čvrsto protiv znanstvenih metoda pokušaja objašnjavanja postojanja Boga ili nastanka svijeta, te neke čak i odbacuju dokazane znanstvene tvrdnje. Llull je razvio sustav zasnovan na logici u kojem je koristio geometrijske dijagrame i tadašnje logičke uređaje kako bi postigao svoj cilj. Taj sustav detaljno je objašnjen u njegovom djelu Ars Magna. Sustav je bio rani pokušaj korištenja logičkih sredstava za dobivanje znanja.

Llull se nadao da će pokazati da se kršćanske doktrine mogu umjetno dobiti iz fiksnog skupa preliminarnih ideja. Llullov rad nadahnuo je mnoge nadolazeće pionire korištenja logike kao sredstva za dobivanje znanja. Wilhelm Leibniz, matematičar i filozof, vjerovao je da se može stvoriti sustav logičkog računa, odnosno univerzalne algebre. Tim sustavom razriješili bi se svi logički argumenti i moglo bi se argumentirano raspravljati o gotovo svemu.

Veliki francuski filozof Rene Descartes, u svojim Meditacijama, bavio se pitanjem svoje fizičke stvarnosti kognitivnom introspekcijom. Opravdao je vlastito postojanje stvarnošću misli; koja je kulminirala njegovom čuvenom izjavom "Cogito ergo sum" ili "Mislim dakle jesam.[38] Na taj su način Descartes i filozofi koji su ga slijedili uspostavili neovisnost uma i fizičkog svijeta. Konačno, to je dovelo do preferiranog suvremenog mišljenja da um i tijelo nisu nimalo bitno različiti.[39]

Prvi logički stroj ugledao je svijetlo dana 1775. godine kada ga je sagradio Charles Stanhope. Ovaj izumitelj radio je na svojim logičkim strojevima preko 30 godina, napravivši nekoliko verzija.

[38] Descartes, R. 1680. Six metaphysical meditations. Wherein it is proved that there is a God and the man's mind is really distinct from his body. Translated by W. Moltneux. London: Printed for B. Tooke.
[39] Luger, G. F. 2002. Artificial Intelligence: Structures and strategies for complex problem solving. Reading, MA: Addison-Wesley.

Stanhopeov demonstrator, kako su ga zvali, je uređaj koji je u stanju mehanički riješiti tradicionalne silogizme, numeričke silogizme i elementarne probleme vjerojatnosti. Korištenjem stroja korisnik je mogao provjeriti valjanost jednostavnih deduktivnih argumenata koji uključuju dvije pretpostavke i jedan zaključak. Stroj je imao očita ograničenja. Nije se mogao proširiti na silogizme koji uključuju više od dvije pretpostavke ili na probleme vjerojatnosti s više od dva događaja (za koje se pretpostavlja da su međusobno neovisni). Bilo koji od problema s koje je rješavao, mogao je biti riješen lako i brzo bez stroja. Zapravo je Stanhope svoj stroj dizajnirao u demonstrativne svrhe, kao što se može vidjeti i po imenu Demonstrator, a ne za rješavanje stvarnih problema. Napisao je: "Kako je instrument tako konstruiran da nam pomaže u demonstracijama, nazvao sam ga Demonstratorom. To je tako osebujno zamišljeno da isto tako simbolično pokazuje one proporcije ili stupnjeve vjerojatnosti da je objekt Logike vjerojatnosti da otkriti". Unatoč svojim ograničenjima, demonstrant Stanhope bio je prvi korak ka mehanizaciji misaonih procesa.

Slijedeći u nizu inovatora i vizionara je Charles Babbage. On je imao mnogo velikih i ambicioznih planova za izgradnju strojeva opće namjene. Njegov prvi i najpoznatiji stroj je ujedno i prototip modernih računala, a zvao se Difference Engine, Stroj Razlike. Zvao se tako zbog matematičkih principa na kojima je zasnovan, u principu je bio prvi mehanički kalkulator. Koristio se za izračunavanje i tabeliranje polinomskih funkcija.

Drugi važan stroj jest Analytical Engine ili Analitički Stroj koji je mogao izvršavati različite zadatke koji su zahtijevali ljudsku misao, poput vještine igranja kartaških igra i šaha. On je bio zamišljen kao stroj koji je bilježio napredak mehanizirane aritmetike. Babbage je sa suradnicom Lady Ada Lovelace zamislio da će njihov Analitički Stroj razmatrati apstraktne koncepte i brojeve. Lady Lovelace smatra se prvom programerkom na svijetu. Bila je kći lorda Byrona i bila je osoba po kojoj je programski jezik nazvan (ADA). Dijeli mnogo bitnih karakteristika koje se nalaze u današnjem modernom računalu. Imao je zasebne prostore za operacije, tj. odrađivanje zadatka i pohranjivanje podataka tj. rezultata tih operacija.

Logička struktura Analitičkog Stroja bila je u osnovi jednaka onoj koja je dominantna računalnim dizajnom u današnjem vremenu - odvajanjem memorije od središnjeg procesora, serijski rad pomoću alata stroja i objekti za unošenje i izlaz podataka i uputa.

Charles Babbage je svojim idejama i izumima zaslužio nadimak „Prvi pionir računala“. Nažalost većina njegovih ideja i koncepata nije izgrađena, većinom zbog nestrpljenja i uskraćivanja financiranja. Međutim vlastitim novcem je uspio napraviti 1/7 Stroja Razlike, koji funkcionira besprijekorno do današnjeg dana i prvi je uspješan automatski proračunski uređaj koji je utjelovio matematičko pravilo u mehanizmu.

George Boole, britanski matematičar i filozof, bio je izuzetno važan za temelje umjetne inteligencije i matematičku formalizaciju zakona logike koji pružaju temelj računalnoj znanosti. Boolova algebra je od velikog značaja pri dizajniranju logičkih sklopova. Boolova algebra dio je matematičke logike - algebarske strukture koja sažima osnove operacija I, ILI i NE, kao i skup teorijskih operacija poput sjedinjenja, presjeka i komplementa.

Claude Shannon nadaleko je prepoznat kao otac informacijske znanosti. Njegov seminarski rad o primjeni simboličke logike na relejskim krugovima temelji se na njegovu magistarskom radu dok je studirao na MIT-u.

Demonstrirao je da električne primjene Boolove algebre mogu konstruirati bilo koji logički numerički odnos. Njegov rad je bio od velike važnosti za rad telefona i računala. Također cijeni se njegov veliki doprinos polju umjetne inteligencije kroz istraživanja koja je provodio o računalnom i igranju igara.

Njegov revolucionarni rad na temu računalnog šaha imao je veliki utjecaj na to polje i dan danas se drži kao kao jedan od najboljih radova napisanih na tu temu.[40] Nimotron, razvijen 1938. godine, bio je prvi stroj koji je mogao izraditi kompletnu igru vještina. Dizajnirali su ga i patentirali Edward Condon, Gerald Twoney i Willard Derr i igrali igru Nim – matematičku igru strategije. Izradili su algoritam za igranje najboljeg poteza bilo kojoj poziciji ove igre, to je bio prvi korak ka polju robotike.

Torres y Quevedo bio je ugledan španjolski izumitelj koji je izgradio prvi eskpertni sustav. Kreirao je sistem koji se temeljio na pravilima za igranje završnice šaha. Kralj i Top protiv Kralja. Pravila su se temeljila na relativnim položajima ove tri figure.

[40] Shannon, C. E. 1950. Programming a computer for playing chess. Philosophical Magazine 7th Ser., 41: 256–275.

Konrad Zuse bio je Nijemac koji je izumio prvo digitalno računalo koje pokreće električna energija. Zuse je radio samostalno, a u početku je svoj rad bio posvetio isključivo matematičkim operacijama s brojevima. On je prepoznao povezanost inženjerstva i matematičke logike i naučio je da su proračuni u Booleovoj algebri identični propozicijskoj računici matematike. Razvio je sustav koji odgovara Booleovoj algebri uvjetnih prijedloga za releje, a budući da se puno rada u funkcioniranju umjetne inteligencije temelji na važnosti mogućnosti manipuliranja uvjetnim propozicijama (AKO - TADA), možemo uvidjeti važnost Zuseovog rada. Njegov rad na logičkim sklopovima prethodio je Shannonovoj tezi nekoliko godina. Prepoznao je potrebu za učinkovitom i ogromnom memorijom te je razvio računala koja su se temeljila na vakuumskim cijevima i elektromehaničkoj memoriji. Nazvao ih je Z1, Z2 i Z3. Općenito je prihvaćeno da je Z3 (ugledao svijetlo dana 12.05.1941.) prvo pouzdano, slobodno programirajuće radno računalo na svijetu temeljeno na brojevima s pomičnim zarezom. Nažalost uništeno je bombaškim napadima u Drugom svjetskom ratu, ali je replika izložena u Deutsche muzeju u Minhenu.

Od Drugog svjetskog rata i pojave računala, napredak u računalnoj znanosti i poznavanje programskih tehnika postignut je izazovima pokušaja tjeranja računala da igraju i savladaju složene igre na pločama. Neki primjeri igara čija je računalna igra profitirala primjenom uvida u umjetnu inteligenciju i metodologija uključuju šah, dame, GO i Othello. Pokušaji učenja računala da uspješno zaigraju te igre potaknule su razvoj i interes za umjetnom inteligencijom. Arthur Samuel je 1959. godine izradio program koji je igrao dame.

Korišten je za igru protiv različitih verzija sebe, a program koji je izgubio usvojio bi heuristiku pobjedničkog programa. Iako je program pružao dobre igre, nikada nije u potpunosti savladao igru. Jonathan Schaeffer 1989. godine, na Sveučilištu Alberta u Edmontonu, započeo je svoj dugoročni cilj osvajanja igre dame svojim Chinook programom.[41] U meču s 40 utakmica 1992. godine protiv dugogodišnje svjetske prvakinje Marion Tinsley, Chinook je izgubio 4-2 uz 34 remija. Godine 1994. njihov je meč bio izjednačen nakon šest utakmica, kada se Tinsley zbog zdravstvenih razloga povukla iz meča.

Ljudi su stoljećima pokušavali naučiti strojeve da igraju dobar šah. Zaljubljenost i opsesija šahovskim stroj vjerojatno proizlazi iz opće prihvaćenog mišljenja da je potrebna inteligencija za igranje šaha.

[41] Schaeffer, J. (1997) One jump ahead. New York, NY: Springer-Verlag.

Alan Turing postiže rani uvid u metode rješavanja problema koristeći igru u šahu kao testno okruženje za umjetnu inteligenciju. Iako računala njegovog vremena nisu bila dovoljno moćna da razviju dovoljno jak šahovski program, Turing je shvatio izazove koje je šah posjedovao sa svojih 10^{120} legalnih poteza i rezultata. Njegov rad iz 1948., „Računalni strojevi i inteligencija“, postavio je temelje za sve kasnije šahovske programe, što je naposljetku dovelo do razvoja velemajstorskih programa koji su se mogli natjecati sa svjetskim šahovskim prvacima 1990-ih godina. Turing je zaslužan za pohranjeni programski koncept koji je temelj svih današnjih računala. Do 1935. opisao je apstraktni računalni stroj s neograničenom memorijom i skener koji se kreće naprijed i nazad kroz memoriju, simbole za čitanje i pisanje koje diktira program koji je također pohranjen u memoriji. Njegova se koncepcija naziva Univerzalni Turingov stroj.[42]

Računalni šahovski programi neprestano su se poboljšavali tokom 70-ih godina prošlog stoljeća, sve dok do kraja tog desetljeća nisu dostigli razinu stručnjaka, top 1% ljudskih igrača na svijetu. Godine 1983. program Belle, Kena Thompsona, bio je prvi program koji je službeno postigao Master razinu.[43] Nakon toga slijede Hitech kao prvi Senior Master program i Deep Thought koji je postao prvi program koji je redovito pobjeđivao Grandmastere (najbolje ljudske igrače).[44] Oba programa potekla su sa Sveučilišta Carnegie-Mellon iz Pittsburga. Kada je IBM 1990-ih preuzeo projekt nastao je Deep Blue program koji je evolucija Deep Thought-a. 1996. godine dogodio se veliki okršaj najboljeg ljudskog šahovskog mozga protiv najboljeg računalnog, Garry Kasparov protiv Deep Blue-a u Philadelphiji. Kasparov je pobijedio 4-2. Godinu dana poslije, Deeper Blue (evolucija Deep Blue-a) pobijedio je Kasparova 3.5-2.5. U slijedećih 6 mečeva protiv Kasparova, Kramnika i ostalih igrača koji igraju šah na razini Svjetskog prvenstva, programi su imali dobar omjer, ali to nisu bili susreti Svjetskog prvenstva.

Iako su programi ipak malo inferiorniji od ljudi, ako bi šah gledali kao Turingov test, računalni programi igrali bi šah tako dobro da ih ne bismo mogli razlikovati od najboljih ljudskih šahovskih majstora. U kratkoj povijesti razvoja umjetne inteligencije otkrivene metodologije su već postale standardne metode u računalnoj znanosti.

[42] Lucci, S. & Kopec, D. (2016). Artificial Intelligence in the 21st Century. Boston. Nakladnik: Boston - Mercury Learning and Information

[43] Berliner, H. J. and Ebeling, C. 1989. Pattern knowledge and search: The SUPREM architecture. Artificial Intelligence 38:161–196.

[44] Hsu, F-H., Anantharaman, T., Campbell, M., and Nowatzyk, A.1990. A grandmaster chess machine. Scientific American 2634.

2.2.1. Slaba i jaka umjetna inteligencija

Službeni početak umjetne inteligencije smatra se konferencija u Dartmouthu 1956. godine. Početkom 1950-ih postojala su različita imena za polje "strojeva za razmišljanje": kibernetike, teorije automatizacije i složene obrade informacija.[45] Raznolikost imena je zbog raznolikosti konceptualnih usmjerenja. 1955. godine mladi asistent na Darmouth koledžu odlučio je organizirati grupu koja će razviti i razjasniti ideju mislećih strojeva. Ime tog asistenta bio je John McCarthy. Odlučio je da ime te radne grupe bude Artificial Intelligence ili umjetna inteligencija. Postao je autor osnovnoga programskog jezika umjetne inteligencije LISP-a (1958), te ga se danas smatra začetnikom umjetne inteligencije.

O podjeli umjetne inteligencije na slabu i jaku nemoguće je pričati bez da se spomene čovjek koji je ovom polju pridonio i prije nego li je uopće postojao termin umjetna inteligencija – Alan Turing. On je bio britanski matematičar i izvanredna figura u povijesti računalnih znanosti. On je također razvijao svoj stroj za koji je bio uvjeren da može učiti sam od sebe, no bio je svjestan tehnoloških ograničenja svoga vremena. Turingov stroj je matematički model koji bilježi bit računanja. Osmišljen je da odgovori na pitanje: "Što to znači za funkciju, da je podložna računanju?" Turingov stroj zapravo uopće nije bio stroj, već ideja, model računalnog uređaja koji slijedi zadani skup pravila za obradu informacija i obavljanje radnji.

Alan Turing vodio je grupu matematičara u Bletchley Parku, izvan Londona, čiji je zadatak bio dešifrirati kod njemačkog stroja Enigma. Ovaj je uređaj kodirao sve vojne zapovijedi njemačkim brodovima i avionima kako njihovi neprijatelji ne bi znali njihovo značenje, čak i kada bi presreli šifrirane poruke. Na kraju su ga dešifrirali koristeći Enigma Machine. Uspjeh Turingove grupe zasigurno je igrao presudnu ulogu u savezničkoj pobjedi nad Njemačkom jer su Saveznici znali sve njemačke zapovijedi prije njihovog izvršenja. Napravljena je izvrsna filmska adaptacija pod imenom „Igra imitacije“ 2014. godine.

Njegov doprinos polju umjetne inteligencije dan danas stoji kao posljednji test kojim bi se dokazalo postojanje umjetne inteligencije. Riječ je naravno o Turingovu testu. Ovaj test je njegov pokušaj odgovora na vrlo jednostavno, a zapravo vrlo kompleksno i komplicirano pitanje, jesu li računala inteligentna?

[45] McCorduck, P. (2004) Machines Who Think, A.K. Peters, Ltd, Second Edition

U radu iz 1951. godine predložio je test koji se zove "igra imitacije". Temeljila se na viktorijanskoj salonskoj igri u kojoj su muškarac i žena sjedili u jednoj sobi, a njihov ispitivač postavljen u drugoj. Sobe su bile razdvojene pregradom tako da ispitivač nije mogao vidjeti ispitanike. Ispitivač bi muškarcu i ženi postavio pitanje. Tada bi muškarac i žena svoje odgovore proslijedili u obliku odgovora napisanog na listiću papira. Ispitivač je trebao odlučiti koji od napisanih odgovora dolazi od muškarca, a koji od žene. Turing je u ovoj igri uvidio izvrstan temelj za testiranje inteligencije stroja. U svojoj inačici igre, zamijenio je muškarca strojem. Ostala pravila su ista, ispitivač bi postavio pitanje stroju i ljudskoj osobi te putem listića papira dobio njihove odgovore. Tada bi trebao izabrati za koji odgovor smatra da je od ljudske osobe. Ako bi ispitivaču oba odgovora bila slična, odnosno svejedno bi mu bilo koji odgovor bi odabrao jer smatra da su oba odgovora od inteligentnog ljudskog bića, tada bi stroj prošao test te „dokazao“ svoju inteligenciju. Ova igra imitacije poznata je kao Turingov test. Važno je napomenuti da niti jedan sustav umjetne inteligencije nije prošao Turingov test...još.

No, mnogi stručnjaci se slažu da Turingov test nije nužno najbolji način za testiranje inteligencije kod strojeva jer puno toga ovisi o ispitivaču. Neke ljude lako je zavarati da pričaju sa stvarnom osobom. Također premisa je da će umjetna inteligencija moći voditi normalan razgovor prije nego što će moći raditi zahtjevne zadatke poput predviđanja kretanja poslovnog tržišta ili predlaganja lansiranja novog proizvoda, što, naravno, ne mora biti točno.

Mnoga poduzeća razvijaju tzv. Chat-botove, sustave zadužene za komunikaciju s ljudima preko interneta kako bi sami od sebe naučili razgovarati. RoboMatic.ai, OhWhatAChat, Fake Chat Generator - Two AI Bots having Weird Conversations, Evil Grandpa Joe, Ask Erin ,Honey Waffle, Message Wiz, Kweri, Rorschach Test samo su neki od primjera i iako se čini da će ti sustavi položiti Turingov test u skorije vrijeme, to neće značiti da su ti sustavi inteligentni.

Tokom godina razvoja umjetne inteligencije razvila su se dva različita pristupa ili smjera shvaćanju umjetne inteligencije. Prvi pristup povezan je s MIT-om (Massachusetts Institute of Technology) i zagovornici ovoga smjera kao umjetnu inteligenciju vide svaki sustav koji pokazuje karakteristike inteligentnog ponašanja. Nije važno izvršava li sustav neki zadatak na isti način kao što to rade ljudi, već jedini kriterij je da program ispravno radi, tj. da isporuči isti, točni, rezultat.

Rezultati projekata implementacije i primjene umjetne inteligencije u područjima elektrotehnike, robotike i srodnih područja primarno se tiču zadovoljavajućih performansi.[46]

Ovakva umjetna inteligencija smatra se slabom umjetnom inteligencijom jer iako može imati karakteristike ljudske inteligencije to i dalje ne znači da postoje neki kognitivni procesi unutar tog sustava, već se samo oponaša već viđeno ponašanje. Na kraju slabom umjetnom inteligencijom smatra se kada se nekom sustavu mogu pripisati tek neka inteligentna svojstva, npr. mogućnost prepoznavanja govora, rješavanja zadataka itd. Slaba umjetna inteligencija je usko specijalizirana što znači da koristi svoje resurse i znanje kako bi riješila točno određen problem, nema mogućnost generalne primjene tog znanja, odnosno bavljenja zadacima koji nisu u točnom određenom spektru njezinih sposobnosti. Ti sustavi su dizajnirani za jedan određeni zadatak i njihove mogućnosti nisu lako prenosive na druge sustave.

Drugi pristup shvaćanja umjetne inteligencije predstavlja sveučilište Carnegie – Mellon, isto ono sveučilište iz kojeg su proizašla dva šahovska programa Hitech i Deep Thought. Ovaj pristup prije svega bavi se biološkom uvjerljivošću. To znači da kada neki sustav pokazuje inteligentno ponašanje, njegovo izvođenje mora se temeljiti na istim metodologijama koje koriste ljudi.

U sustavu postoji mnogo dijelova od kojih svaki obavlja potrebne zadatke kako bi cijeli sustav mogao funkcionirati. Zagovornici slabe umjetne inteligencije uspjeh sustava mjere samo na osnovu performansi tog sustava, dok zagovornici ovog drugog smjera fokusiraju se, uz performanse, na strukturu sustava i kako dijelovi tog sustava međusobno komuniciraju. Jaka umjetna inteligencija u tolikoj mjeri je razvijena da može razmišljati na istoj razini kao čovjek te svoje znanje i vještine primjenjuje generalno na sve situacije.

U svojoj knjizi „Primijenjena umjetna inteligencija“ autori Mariya Yao, Marlene Jia i Adelyn Zhou dizajnirali su Kontinuum umjetne inteligencije kako bi predstavili različite vrste inteligencije na temelju složenosti njihovih mogućnosti. Razlike između nivoa nisu točno precizirane te postoje mnoga preklapanja.[47] Najniža razina Kontinuuma umjetne inteligencije su sustavi koji djeluju, to su sustavi koji funkcioniraju u skladu s unaprijed definiranim scenarijima, najčešće ručno programiranim AKO – TADA vrstama pravila.

[46] Lucci, S. & Kopec, D. (2016). Artificial Intelligence in the 21st Century. Boston. Nakladnik: Boston - Mercury Learning and Information
[47] Yao, M., Zhou, A. & Jia, M. (2018). Applied Artificial Intelligence. A Handbook for Business Leaders. New York

Primjeri takvih sustava vidimo svakodnevno u svom životu poput požarnih alarma u kućama ili uredima, odnosno zgradama i tempomati u automobilima koji održavaju brzinu vozila tokom vremena.

Sustavi koji predviđaju su sustavi koji su sposobni analizirati podatke i koristiti ih za izradu predviđanja vjerojatnih događaja. Vrlo je bitno shvatiti da pod pojmom "predviđanje" misli se na mapiranje poznatih s nepoznatim informacijama i rezultat ne mora nužno biti budući događaj. Andrew Pole, statističar tvrtke Target, objasnio je za New York Times da je uspio identificirati 25 proizvoda, uključujući losion bez mirisa i dodatke kalcija, koji se mogu upotrijebiti za predviđanje vjerojatnosti da će kupac biti trudnica, pa čak i u kojem je stadiju trudnoće.[48] Statistika je glavni pokretač ovakvih sustava, međutim predviđanja su jednako dobra kao i podaci koji se koriste. U poslovnoj analizi nedostatak integriteta podataka i metodološke pogreške izuzetno su česte i vode do pogrešnih zaključaka i predviđanja.

Sustavi koji uče također predviđaju događaje, no ne zahtijevaju puno ručnog inženjerstva već mogu sami naučiti izvoditi zadatke, a da nisu izričito programirani za to. Strojno i duboko učenje pokreće ove sustave i oni mogu funkcionirati na ljudskim razinama, a u nekim situacijama čak i bolje od ljudi, najčešće kada se radi o računskim zadacima. Na primjer, u prodaji, pristupi strojnom učenju mogu biti bolji od metoda zasnovanih na pravilima ili statističkih metoda. Nakon što stroj proizvede predviđanje kvalitete neke informacije, prodavač tada primjenjuje ljudsku prosudbu kako bi odlučio što i kako dalje.

Složeniji sustavi, kao što su automobili sa automatskim upravljanjem i industrijska robotika, upravljaju sa svime, od prikupljanja početnih podataka do izvršenja akcije koja je rezultat njegove analize. Sjajan primjer toga je autonomna vožnja, vozilo mora pretvoriti video i senzorske informacije u precizna predviđanja okolnog svijeta i prilagoditi vožnju u skladu s tim.

Nedavni pomaci u neuronskim mrežnim modelima potaknuli su ponovno pokretanje računske kreativnosti, s računalima koji su sada sposobni stvarati originalne zapise, slike, glazbu, industrijski dizajn, pa čak i AI softver.[49]

[48] Duhigg, C. (2012) How Companies Learn Your Secrets. The New York Times Magazine. Dostupno na: http://www.nytimes.com/2012/02/19/magazine/shopping-habits.html [25.07.2019.]
[49] Simonite, T. (2017) Google's AI software is learning to make AI software. MIT Technology Review. Dostupno na: http://www.technologyreview.com/s/603381/ai-software-learns-tomake-ai-software/ [25.07.2019.]

Inženjer i kreativni pripovjedač Sam obučio je neuronsku mrežu na 14 milijuna linija odlomaka iz romantičnih romana i zamolio model da generira originalne priče na temelju novih slika.[50] Flow Machines, divizija Sonyja, koristio je sustav umjetne inteligencije kojem su puštali Bachove skladbe. Sustav je zatim komponirao vlastitu skladbu te uspio prevariti ljudske procjenitelje koji su imali poteškoće u razlikovanju stvarnih Bachovih skladbi od generiranih imitacija sustava umjetne inteligencije.

Autodesk, vodeći proizvođač računalno potpomognutog dizajna (CAD, softver za industrijski dizajn), objavio je program Dreamcatcher koji generira tisuće mogućih permutacija dizajna na temelju početnih ograničenja koja su postavili inženjeri. Dreamcatcher je proizveo bizarne, a opet vrlo učinkovite dizajne koji osporavaju tradicionalne pretpostavke za proizvodnju i premašuju ono što ljudski dizajneri mogu zamisliti.

Kako ljudski zaposlenici sve više surađuju s alatima i sustavima umjetne inteligencije na poslu i digitalni asistenti poput Appleove Siri i Amazonove Alexe prožimaju naš osobni život, strojevima će trebati emocionalna inteligencija kako bi uspjeli u našem društvu. Poznavanje korisnikovog afektivnog stanja omogućava računalima da reagiraju empatično i dinamično, kao što to rade naši prijatelji. [51]Tvrtke poput Amazona već daju prioritet emocionalnom prepoznavanju za glasovnih naredbi i analize zvuka.

Emotivna svijest također može poboljšati međuljudske poslovne funkcije kao što su prodaja, marketing i komunikacije. Rana el Kaliouby, osnivač Affectiva, vodeće tvrtke koja se bavi razvojem emocionalne inteligencije, pomaže oglašivačima da poboljšaju učinkovitost robnog sadržaja procjenom i prilagođavanjem reakcijama potrošača. Mentalno i bihevioralno zdravlje također je područje zrelo za inovacije. Affectiva potječe iz akademskog istraživanja na MIT-u koje je osmišljeno kako bi pomoglo pacijentima s autizmom poboljšati prepoznavanje socijalnih i emocionalnih znakova.[52]

---

[50] Samim. (2015) Generating Stories about Images. Dostupno na: http://medium.com/@samim/generating-stories-about-imagesd163ba41e4ed [25.07.2019]

[51] Knight, W. (2016) Emotional intelligence might be a virtual assistant's secret weapon. MIT Technology Review. Dostupno na: http://www.technologyreview.com/s/601654/amazon-working-onmaking-alexarecognize-your-emotions/ [25.07.2019]

[52] Talbot, D. (2014) Apps for Autism. MIT Technology Review. Dostupno na: http://www.technologyreview.com/s/528191/digitalsummit-first-emotion-reading-apps-for-kids-withautism [25.07.2019.]

Zadnja kategorija odnosi na sustave koji pokazuju nadljudsku inteligenciju i sposobnosti, kao što su sposobnost dinamičkog mijenjanja vlastitog dizajna i arhitekture kako bi se prilagodili promjenjivim uvjetima u svom okruženju. Nas, kao ljudska bića, naši biološki mozgovi ograničavaju u inteligenciji. Nažalost nemamo sposobnost rekonstruiranja vlastite biološke infrastrukture tijekom života, nego se razvijamo genetskim mutacijama kroz generacije. Ne možemo mijenjati komponente našeg biološkog organizma kako bismo poboljšali performanse.

Što nije slučaj kod računala, njima možemo jednostavno umetnuti novu RAM memoriju, povećati kapacitet memorije ili instalirati novi procesor ako želimo da budu brži ili bolji. Jednom kada se pojavi takav sustav, Sustav koji evoluira, postići ćemo tehnološki singularitet, kada umjetna inteligencija nadmaši ljudsku.

Samo-razvijajući sustavi će biti u stanju sve brže ponavljati samo-poboljšanja, što će naposljetku dovesti do pojavljivanja super inteligencije. Kako gradimo današnje sustave koji uče, sustave koji stvaraju i sustave koji se odnose utječu na to kako gradimo sutra sisteme koji upravljaju i sustave koji se razvijaju. Iako nitko ne može predvidjeti kako će izgledati super inteligencija, danas možemo poduzeti mjere kako bismo povećali vjerojatnost da će inteligentni sustavi koje dizajniramo biti učinkoviti, etični i uzdići ljudske ciljeve i vrijednosti.[53]

3. UMJETNA INTELIGENCIJA U POSLOVANJU

Potencijal umjetne inteligencije seže daleko izvan sfere poslovanja i zgrtanja bogatstva ili pozicioniranja na tržištu. Nove tehnologije poput strojnog i dubokog učenja omogućuju nam mnogo više od pokretanja reklamnih klikova kod potencijalnih potrošača, pojednostavljenja prodaje i povećanja korporativnog profita. Umjetna inteligencija jednoga dana bi nam mogla pomoći kod borbe protiv kriminala, socijalne nepravde, zdravstvenih i humanitarnih kriza, pomoći nam kod rješavanja gorućih problema u svijetu i dramatično poboljšati kvalitetu života za cijeli planet. U ovome poglavlju ograničiti ćemo se na područje poslovanja, elektroničkog i tradicionalnog. Većina sustava umjetne inteligencije u poslovanjima danas stvara značenje iz prikupljenih podataka poduzeća u kojem su implementirana s ciljem korištenja tog značenja kako bi se usmjerile buduće poslovne odluke. Takvi sustavi poznati su pod nazivom poslovna inteligencija (Business Intelligence).

[53] Yao, M., Zhou, A. & Jia, M. (2018). Applied Artificial Intelligence. A Handbook for Business Leaders. New York

Najviše se koriste u prodaji i marketingu, npr. ako sustav prepozna da se određeni proizvodi dobro prodaju i popularni su kod neke demografske skupine, ta informacija će utjecati na cijenu i način plasiranja proizvoda kao i na njegov životni vijek. Takva primjena poslovne inteligencije fokusira se na vanjsko okruženje poduzeća, no što je s unutarnjim okruženjem?

Ukoliko poslovna inteligencija utvrdi da je produktivnost i zadovoljstvo zaposlenika nisko jer smatraju da se njihove vještine nedovoljno koriste ili smatraju da nisu dovoljno uključeni u poslovne odluke, odjel ljudskih potencijala može iskoristiti tu informaciju kako bi prilagodili postojeće planove napredovanja ili reorganizirali procese kako bi se zaposlenici osjećali više uključenima u rad poduzeća. Takvi potezi vode do povećanja zadovoljstva zaposlenika i povećanja produktivnosti.

Da bi stvorilo značenje, poslovna inteligencija prvo mora pretvoriti podatke u informacije, a zatim analizirati te podatke kako bi stvorio uvide koji se mogu pretvoriti u preporuke za djelovanje.[54] Važno je razlikovati podatke od informacija, svaki podatak nije informacija, ali svaka informacija jest podatak. Informacija je koristan i kvalitetan podatak čijim se raspolaganjem može postići neki utjecaj. Kvalitetna informacija je točna, pravovremena, razumljiva i pristupačna. Naravno to znači da svi ti podaci moraju biti čisti, odnosno pravilno zabilježeni, strukturirani, dosljedni i točni da se mogu analizirati i interpretirati. Prije su sav taj posao radili ljudski zaposlenici u čijem je radu postojala konstantna opasnost od grešaka. Tehnološki napredak omogućio je da se mnogi od ovih zadataka obavljaju automatski, s puno manjom mogućnošću pogreške. Mnoga poduzeća koriste sustave poslovne inteligencije koji sadrže algoritme i koriste strojno učenje kako bi pretvorili neobrađene unose podataka u dobro označene strukture podataka, spremne za upotrebu.

Postavlja se pitanje otkuda vući sve te podatke te kako ih kombinirati i spojiti? Većina poduzeća se sastoje od nekoliko odjela i svaki odjel, sam za sebe, generira određenu količinu podataka. Ti podaci su zatim spremljeni na server koji je u vlasništvu tog odjela, tzv. podatkovni silosi ili silosi podataka. Što je više odjela to je vise takvih servera. Tu se javlja problem dijeljenja tih podataka između odjela.

[54] Yao, M., Zhou, A. & Jia, M. (2018). Applied Artificial Intelligence. A Handbook for Business Leaders. New York

Različiti odjeli imaju različite ciljeve, u nekim poduzećima odjeli se međusobno natječu za resurse pa im nije u interesu dijeliti svoje podatke, dok u drugim poduzećima, odjeli na različite načine spremaju svoje podatke, u različitim formatima. Dok su takvi podatkovni silosi dobri za duboku, mikro analizu performansi pojedinog odjela, takvi uvidi ne postoje u kontekstu informacija koje generira ostatak poduzeća, što otežava donošenje holističkih odluka zasnovanih na podacima. Kako bi se riješili takvi problemi otvaraju se nova radna mjesta koja nisu postojala do prije par godina, poput CDO (Chief Data Officer) ili CDS (Chief Data Scientist).

3.1. Integriranje umjetne inteligencije u poslovanje i primjeri korištenja

Sustavi temeljeni na znanju bili su možda najuspješnija praktična grana umjetne inteligencije. Takvi su sustavi postigli dovoljnu veličinu i reputaciju da postanu neovisne discipline. Koncept znanja utemeljenog na pravilima, naglasak na rasuđivanje u situacijama nesigurnosti, pitanja verifikacije znanja o domeni, strojno učenje u pokretu automatskog stjecanja znanja, bila su neka od područja akademskog rasta.

Drugo područje napretka bila je obrada prirodnog jezika. Razumljivi prevoditeljski sustavi danas su dostupni za uporabu u ograničenom kontekstu, koji su uglavnom učinkoviti ako se sustavu može pružiti malo ljudskih uputa.[55] Semantička analiza web sadržaja, sadržaja i poveznica na web stranicama, vađenje teksta, vađenje određenih informacija iz dokumenata, automatska klasifikacija i personalizirani agenti koji traže informacije koje zanimaju određenu osobu danas su neka od aktivnih područja.

Obrada govora već je stvorila funkcionalno vrijedne alate. Danas su dostupni softverski alati koji vaš govorni tekst mogu pretvoriti u strojno obradiv tekst, kao što je Word dokument. Za njih je potrebna neka obuka i još nisu baš učinkovita u prilagodbi na više govornika. Takvi su alati pogodni za ljude koji nemaju dobru brzinu tipkanja, a još važnije onima koji imaju poteškoće u interakciji s računalima.

Robotika je također u velikom zamahu. U Japanu postoji inicijativa koja ima za cilj razviti humanoidne robote kako bi se građanima starije životne dobi pomoglo s njihovim dnevnim rutinama. Honda i Sony su izgradili robote koji mogu hodati, mahati, raditi neke osnovne plesne korake, itd.

[55] Akerkar, R. (2019). Artificial Intelligence for Business. Sogndal, Norway- Western Norway Research Institute.

Robotski kućni ljubimci postigli su komercijalni status kod nekoliko tvrtki koje prodaju sofisticirane pse za kućne ljubimce.

Iako je AI već neko vrijeme dio našeg svakodnevnog života, ova se tehnologija nalazi u prijelomnoj točki, ponajviše zbog nedavnog napretka u primjenama dubokog učenja. Duboko učenje koristi mreže koje su sposobne za nenadzirano učenje iz nestrukturiranih ili neoznačenih podataka. Neuronske mreže koje podupiru mogućnosti dubokog učenja postaju učinkovitije i preciznije zahvaljujući dva značajna nedavna tehnološka dostignuća: neviđenom pristupu velikim podacima i povećanju računalne snage.

Učinkovitost neuronskih mreža ovisi o količini dostupnih podataka. Uz implementaciju umjetne inteligencije u gotovo svakoj industriji, izgledno je da će značajno transformirati postojeće poslovne modele uz istodobno stvaranje novih. Npr., u financijskim uslugama postoje jasne i mjerljive koristi od poboljšane točnosti i brzine u sustavima otkrivanja prijevara koji su oplemenjeni umjetnom inteligencijom.[56]

Sve navedeno samo je dio uspjeha umjetne inteligencije u poslovanju. Od skromnog početka prije otprilike malo više od 50 godina ovo polje je naraslo u mnogim dimenzijama. Dok neki praktičari umjetne inteligencije teže izvornom cilju kreiranja i postizanja umjetne inteligencije u strojevima i računalnim sustavima, većina istraživanja danas je usmjerena na rješavanje složenih praktičnih problema.

Iako je u obećavajućoj fazi, očekuje se da tehnologija umjetne inteligencije uvesti novi standard za korporativnu produktivnost, konkurentsku prednost i, na kraju, ekonomski rast. Bez sumnje se može konstatirati kako će sve veći utjecaj umjetne inteligencije u poslovanju dovesti i do strateških promjena poslovnih modela. Niži troškovi uz veću kontrolu se nameću samo po sebi zbog Moorovog zakona, broj mikročipova se svake godine udvostručava, a time njihova cijena pada.

Još jedna od promjena strategije je sve manji postotak outsourcinga, tj. fokusiranja na jezgru poslovanja poduzeća, a za ostale funkcije unajmiti druga poduzeća ili agente specijalizirane točno za te zadatke, poput programiranja, proizvodnje, računovodstva pa čak financija i jednog dijela menadžmenta.

[56] McKinsey Global Institute (2017), "Artificial Intelligence the Next Digital Frontier?"

Već danas vidimo takvu strategiju poslovanja kod startup-ova i mladih poduzeća koja se bave stalnim inovacijama, posebno inovacijama koja uključuju učenje iz iskustva.[57] Zanimljivu usporedbu poslovanja s većim i manjim postotkom outsourcinga možemo vidjeti kod proizvođača automobila.

Veći dio industrije proizvodnje automobila je robotizirano, a neki proizvođači se fokusiraju na svoju jezgru poslovanja, odnosno razvijanje svojih konkurentskih prednosti, dok za proizvodnju različitih dijelova automobila unajmljuju druga poduzeća, pa čak i druge proizvođače automobila. Dok s druge strane imamo proizvođače automobila koji proizvode svoje dijelove, od početka do kraja sklapanja novog modela. Novi modeli automobila pojavljuju se na tržištu, u prosjeku, svakih 5 godina. Tijekom proizvodnje određenog modela, poduzeća ne znaju sa sigurnošću koliko će taj model biti uspješan, povratne informacije od kupaca, kao jedan od ključnih pokazatelja uspješnosti, mogu se prikupiti tek nakon plasiranja modela na tržište.

Ekonomisti Sharon Novak i Scott Stern u istraživanju 2008. godine otkrili su da proizvođači luksuznih automobila koji proizvode vlastite dijelove imaju veću stopu poboljšanja između izbacivanja novih modela.[58] Mjerili su stopu poboljšanja koristeći povratne informacije kupaca. Proizvođači koji su proizvodili svoje dijelove imali su veću kontrolu, što je značilo da su se mogli brže prilagoditi povratnim informacijama kupaca.

Proizvođači koji nisu proizvodili svoje dijelove nisu pokazali istu brzinu prilagodbe, no otkrila se jedna druga korist. Njihovi su početni modeli bili kvalitetniji od prvih modela proizvođača automobila koji su izrađivali vlastite dijelove. Stoga se proizvođači automobila suočavaju s izborom outsourcinga ili izrade samih dijelova kako bi postigli poboljšanja tijekom vremena, jer kontroliraju inovacije u životnom ciklusu svog modela proizvoda. Implementacija umjetne inteligencije u ovom području bila bi vrlo korisna. Iz kojeg razloga? Koju god strategiju poslovanja proizvođači automobila izabrali, postoji kompromis između kratkoročnih i dugoročnih performansi i rutinskih nasuprot izvanrednim događajima koji se rješava ključnim organizacijskim izborom: koliko se oslanjati na vanjske dobavljače.

[57] Agrawal, A., Gans, J. & Goldfarb, A. (2018). Prediction Machines- The Simple Economics of Artificial Intelligence. Boston~1

[58] Sharon Novak and Scott Stern (2008) "How Does Outsourcing Affect Performance Dynamics? Evidence from the Automobile Industry," Management Science 54, no. 12

Zastupljenost tog izbora je usko povezana s nesigurnošću. Međutim, kada bi umjetna inteligencija mogla predvidjeti potrebe potencijalnih kupaca i time smanjiti neizvjesnost, taj kompromis bi nestao, a samim time zasigurno bi se pojavila nova strategija poslovanja, bolja za proizvođače i kupce. Takav način stalnog inoviranja jest jedan od razloga zašto takvi modeli poslovanja imaju godišnja ažuriranja, koja ne uključuju velike promjene dizajna poslovnog modela, već poboljšanje postojećih komponenata koje poboljšavaju proizvod ili uslugu.

Razvoj softvera nije iznimka AI revolucije. Tehnike strojnog učenja ne samo da se mogu ubrzati tradicionalni životni ciklus razvoja softvera, već predstavljaju potpuno novu paradigmu za pronalazak tehnologije. U tradicionalnom razvoju mora se navesti točna funkcionalnost nekog računalnog programa prije nego što ga se ručno kodira. Tehnike umjetne inteligencije poput strojnog i dubokog učenja umjesto toga se oslanjaju na algoritme učenja koji se iterativno uvježbavaju i kontinuirano poboljšavaju na odabranim podacima za točno specificirane zadatke.[59]

Takav pristup sustavima umjetne inteligencije omogućava da nauče koje karakteristike i obrasci su važni bez da ih se to izričito podučava. Vodeći inženjeri iz Googla i Tesle smatraju da kroz nekih 10ak godina većina posla koja se tiče razvoja softwarea neće uključivati programiranje, već prikupljanje, označavanje i manipulaciju podataka kojima će se služiti neuronske mreže.

Tradicionalni razvoj softwarea počinje sa specifikacijom koja definira funkcionalne zahtjeve programa ili aplikacije, taj skup tehničkih podataka zatim ide na razvoj i dizajniranje održivih verzija. Verzije se zatim testiraju kako bi se ustanovilo koja od njih ide u produkcijsko okruženje gdje se mora neprestano održavati. Tijekom vremena proizvod može rasti u složenosti, što zahtjeva višestruke ovisnosti i integracije različitih sustava i korisničkih sučelja, kako bi se omogućila željena funkcionalnost. Svim ovim komponentama mora se ručno upravljati i ažurirati ih, što može dovesti do nedosljednosti i nerazrješivih pogrešaka.

Razvoj softwarea koji se temelji na strojnom učenju uči važne značajke i obrasce u podacima te gradi matematičke modele koji utječu na ove karakteristike. Prema Andrej Karpathyu, razvoj softwarea umjetne inteligencije (tzv. Software 2.0) je kod napisan metodama strojnog učenja poput stohastičkog uspona u gradijentu i povratnog širenja umjesto da ga generiraju ljudi.[60]

[59] Yao, M., Zhou, A. & Jia, M. (2018). Applied Artificial Intelligence. A Handbook for Business Leaders. New York
[60] Karpathy, A. (2017) Software 2.0 A Medium Corporation, Programming. Dostupno na: https://medium.com/@karpathy/software-2-0-a64152b37c35 [02.08.2019]

Razvoj programa temeljen na strojnom učenju nudi prednosti i nedostatke. Povećana homogenost, lakoća upravljanja, visok stupanj prenosivosti i bolje pouzdanost su neki od primjera prednosti. Međutim postoje i neki nedostatci poput složenosti ovakvih modela razvoja softwarea što otežava razumijevanja rada, pa ukoliko je program nestabilan ili ima neke kardinalne greške, teže će se otkriti zašto je to tako.

Strojno učenje neće zamijeniti tradicionalni razvoj softwarea jer, kao što je navedeno u prethodnom poglavlju, ono je jedan korak u procesu razvoja umjetne inteligencije. Trenutno veliki interes postoji za implementaciju umjetne inteligencije kod testiranja softwarea jer se radi o repetitivnom procesu koji pruža mogućnost automatizacije testiranja i detektiranja pogrešaka.

Brza izrada prototipa - pretvaranje poslovnih zahtjeva korisnika u opipljive proizvode traje mjesecima i godinama planiranja i dogovaranja. Iako su ljudi shvatili kako brže i bolje to raditi, npr. principi agilne metodologije i razvoj softwarea, umjetna inteligencija značajno je skratila taj proces omogućujući krajnjim korisnicima razvoj programa koristeći prirodni, svakodnevni jezik kroz vizualno sučelje.

Automatski refactoring računalnog koda – razumijevanje čistoga koda je kritična stavka za timsku suradnju i uspješno dugoročno održavanje softwarea. Refactoring kodova u velikim dimenzijama često je neizbježna potreba tijekom nadogradnje na nove tehnologije. Umjetna inteligencija može se koristiti za analizu koda i automatski ga optimizirati radi interpretacije i performansi.

Precizne procjene - razvoj softvera ima reputaciju za prekoračenje vremenskih i planiranih rokova. Pouzdane procjene zahtijevaju duboku stručnost, razumijevanje konteksta i poznavanje tima za implementaciju. Umjetna inteligencija se može se obučiti na podacima iz prošlih projekata, poput korisničkih priča, definicija značajki, procjena i stvarnih podataka, kako bi se preciznije predvidjelo potrebno ulaganje i proračun.

Inteligentni programski asistenti – kada se prijave greške u radu nekog programa programeri većinu vremena provode čitajući dokumentaciju ili kod kako bi shvatili gdje je greška. Pametni pomoćnici programiranja mogu smanjiti vrijeme provedeno na tim zadacima nudeći pravovremenu podršku i preporuke, poput relevantnih specifikacija, najboljih praksi i primjera koda. Primjeri takvih pomoćnika su Kite for Python i Codota za Java.

Automatska analitika i rukovanje pogreškama – programski asistenti mogu se učiti iz prošlih iskustava kako bi prepoznali uobičajene pogreške i automatski ih označili tijekom razvoja. Jednom kada je tehnologija uvedena, strojno se učenje može koristiti za analizu sustava za označavanje pogrešaka. Cilj je u budućnosti razviti sustave koji će se modificirati bez ljudske intervencije kao odgovor na pogreške (Sustavi koji evoluiraju, poglavlje 2.2.1 Slaba i jaka umjetna inteligencija).

Strateško odlučivanje - kojim proizvodima, uslugama i značajkama treba dati prednost, a koje treba minimalizirati. Umjetna inteligenciju se može obučiti o prošlim kretanjima na tržištu i prema trenutnim poslovnim prioritetima može procijeniti performanse postojećih aplikacija, pomažući inženjerskim timovima da identificiraju napore koji će maksimalizirati utjecaj i smanjiti rizik.

Nedavno istraživanje u Indiji pokazalo je da svake godine nekoliko tisuća seoskih poljoprivrednika počini samoubojstvo. Kada žetve ne uspiju, oni su prisiljeni posuđivati novac za mikro-financiranje kod lihvara, po velikim kamatama i nepovoljnim uvjetima. Kada ne mogu vratiti posuđene kredite okreću se samoubojstvu kako bi izbjegli osvetu vlasnika dugova. Koristeći se sustavima umjetne inteligencije s dubokim učenjem, FarmGuide analizira satelitske snimke kako bi predvidio prinose usjeva za pojedine farme. U SAD-u, istraživači sa Sveučilišta Stanford pokazali su strojno usmjerene metode za analizu prinosa usjeva usporedive s fizičkim istraživanjima koje je proveo Američki odjel za agrikulturu.[61] Koristeći ove prethodno nepristupačne informacije, FarmGuide ima mogućnost smisliti bolje predviđajuće modele pozajmljivanja i osiguranja, čime se smanjuje mogućnost zaduživanja poljoprivrednika po, za njih, nepovoljnim uvjetima.

UNICEF koristi sustav umjetne inteligencije pod imenom U-report, sistem koji omogućuje svim ljudima da prijave socijalne nepravde u svojim zajednicama SMS-om ili putem drugih platformi. Koristeći sučelje prirodnog jezika za prikupljanje uvida i statističku analizu nalaza, U-report koristi više od 4,2 milijuna korisnika širom svijeta za prepoznavanje i rješavanje zahtjevnih socijalnih pitanja poput zlostavljanja djece, javne zdravstvene politike i klimatskih promjena.

[61] You, J.X., Li, X.C., Low, M., Lobell, D.B., and Ermon, S. (2012) A combination of remote sensing and machine learning data for yield prediction. Dostupno na: http://sustain.stanford.edu/crop-yield-analysis [15.08.2019]

Putem U-reporta prijavljeno je mnogo slučajeva zloupotrebe vlasti, posebno velik utjecaj je imao u Liberiji gdje je izazvao toliko velik utjecaj da je prisilio UNICEF i ministricu obrazovanja Liberija da surađuju na planu zaustavljanja zloupotrebe položaja moći. U mnogim dijelovima svijeta građani nemaju povlasticu korištenja mobilnih aplikacija zbog ograničenja i represije. Zbog ograničenja na glasovne pozive i SMS poruke, tehnologije obrađivanja prirodnog jezika i botovi za razgovor su od presudne važnosti kako bi se utjecalo na socijalne nepravde.

Umjetna inteligencija ima ogroman utjecaj na medicinu i naše cjelokupno zdravlje. Polja patologije i radiologije, koja se uglavnom oslanjaju na istrenirane ljudske oči da bi uočili anomalije, revolucioniraju se razvojem sustava umjetne inteligencije koji su puno bolji od ljudi u uočavanju anomalija i otkrivanja karcinom u ranom stadiju.

Na odjelu radiologije se u Sjedinjenim Državama godišnje napravi 12,1 milijuna mamograma, ali gotovo polovica njih daje lažno pozitivne rezultate, što znači da jednoj u dvije zdrave žene može biti pogrešno dijagnosticiran rak.[62] U tom slučaju pacijentica mora ići na biopsiju, dosta invazivan zahvat kojim se otklanja dio sumnjivog tkiva kako bi se ono ispitalo i testiralo na bolest. Kako bi smanjili broj nepotrebnih kirurških intervencija, istraživači s MIT-a i Harvardske Medicinske Škole razvili su dijagnostički alat koji koristi strojno učenje kako bi ispravno identificirao 97% zloćudnih tumora. Od implementacije tehnologije, smanjen je broj operacija za 30%.[63]

Analiza potrošnje prikuplja, čisti i analizira podatke o izdacima kako bi poboljšala radnu učinkovitost i smanjila otpad. Velike tvrtke obično imaju višestruke sustave za prijavu koji su kompatibilni jedni s drugima, a prijetnja od gubljenja podataka je velika. Specijalizirane platforme poput Coupe-a omogućuju korištenjem strojnog učenja da se bolje identificiraju i kategoriziraju podaci o potrošnji, čak i popunjavanjem podataka kada nedostaju, kako bi se stvorio čist, standardizirani pregled načina poslovanja tvrtke.

Merantix, njemačko poduzeće, primjenjuje duboko učenje na medicinskim problemima. Nudi aplikaciju koja može otkriti nepravilne limfne čvorove u ljudskom tijelu na CT slikama. Da je pregled obavljen od strane ljudi, bio bi vrlo skup.

[62] Yao, M., Zhou, A. & Jia, M. (2018) Applied Artificial Intelligence. A Handbook for Business Leaders. New York
[63] Csail, A. C. (2017) Using artificial intelligence to improve early detection of breast cancer. MIT News. Dostupno na: http://news.mit.edu/2017/artificial-intelligence-early-breast-cancerdetection-1017 [15.08.2019]

U ovakvom scenariju duboko učenje osposobljava računala na skupovima podataka kako bi naučili što je nepravilno pojavljivanje u odnosu na limfni čvor normalnog izgleda. Nakon završetka, stručnjaci za radiološko snimanje primjenjuju to znanje na stvarnim pacijentima i identificiraju u kojoj mjeri nekome prijeti kancerogeni limfni čvor, uz znatno nižu cijenu.

LIDAR (light detection and ranging systems) su sustavi za otkrivanje svjetlosti i domete svjetla koji igraju ključnu ulogu u izbjegavanju sudara i u navigaciji. Ovaj sustav umjetne inteligencije pruža informacije koje pomažu da se vozila brze vožnje zadrže u njihovim predviđenim trakama, pomažući im da izbjegavaju ostala vozila i primjenjuju kočnice po potrebi itd., te time spašavaju ljudske živote smanjenjem broja prometnih nesreća.

3.1.1. Etička pitanja korištenja umjetne inteligencije

Iako je bitno razlikovati računalnu etiku od strojne, u ovom poglavlju dotaknuti ćemo se obje inačice etičkog ponašanja i problematike. Koja je razlika između računalne i strojne etike? Računalna etika bavi se etičkim pitanjima koja se tiču ljudske uporabe strojeva i sustava umjetne inteligencije, tj. kako ljudi programiraju i koriste te sisteme. Strojna etika je skup pravila kojima se osigurava da je ponašanje sustava umjetne inteligencije etički prihvatljivo prema ljudskim korisnicima i ostalim strojevima. Krajnji je cilj strojne etike, stvoriti stroj koji sam po sebi slijedi idealni etički princip ili skup principa; to jest, vodi se tim principom ili načelima u odlukama koje donosi o mogućim načinima djelovanja koje može poduzeti.[64] U ovom poglavlju fokusirati ćemo se najviše na same etičke odluke, kako ih integrirati u sustav umjetne inteligencije, a ne na to kako sustav prikuplja informacije potrebe za donošenje odluke i kako ih uključuje u svoje ponašanje.

Što znači biti etičan? Da bismo dobili odgovor na to, možemo povući paralelu s odgovorom na pitanje; što znači biti inteligentan, koje smo raspravljali u drugom poglavlju. Zaključili smo da ako nečiji mozak posjeduje veliki broj informacija, to ne znači nužno da je ta osoba visoko inteligentna, odnosno samo posjedovanje tog znanja samo po sebi neće tu osobu učiniti inteligentnom.

Isto vrijedi i za etično ponašanje, imati sve informacije i sadržaje u svijetu samo po sebi neće generirati etičko ponašanje ne samo u sustavu umjetne inteligencije, već i kod ljudi.

[64] Anderson M., Anderson S.L. (2007) Machine Etics: Creating an Ethical Intelligent Agent. AI Magzine, Vol 28 No

Opet dolazimo do problema Polanyijevoga paradoksa, tj. nemogućnosti izražavanja prešutnih znanja, u ovom slučaju stavova odnosno etičkog ponašanja.

Potrebno je razlikovati implicitni od eksplicitnog sustava umjetne inteligencije kada se priča o etičkom ponašanju. Implicitni sustavi su oni sustavi koji su programirani od strane ljudskih programera da se etički ponašaju ili da izbjegavaju neetička ponašanja, bez eksplicitne zastupljenosti etičkih načela. Ponašanje sustava ograničava njegov ljudski dizajner koji slijedi određene etičke principe. Također sami ne znamo kako postupiti u pojedinim situacijama pa zato ni ne možemo uspješno implementirati etiku u sustave umjetne inteligencije. Kako kodirati u sustav etički prihvatljivo ponašanje? Kako i koje primjere dati sustavu umjetne inteligencije kako bi sam mogao naučiti što je to etičko ponašanje i kako ga primijeniti?

Etička pitanja korištenja umjetne inteligencije je zapravo jedno jako zanimljivo i specifično interdisciplinarno polje. Zašto interdisciplinarno? Pa svi mi donosimo etičke odluke na dnevnoj bazi, ergo integriranje etičkih stajališta u sustav umjetne inteligencije zapravo bi trebao biti jednostavan posao. Ovo školski primjer pogrešnog pristupa aktualnoj problematici. Iako se svakodnevno susrećemo s etičkim dilemama i donosimo razne etičke odluke, to ne znači da smo svi stručnjaci za etiku. Gotovo svi svakodnevno koristimo razne elektroničke uređaje i uživamo u njihovim prednostima i pogodnostima, no to ne znači da smo stručnjaci za njih, da možemo brzo programirati neku aplikaciju koja bi nam trebala, popraviti mikrovalnu ili električni mikser kada se pokvari, ili ispraviti greške u nekom računalnom sustavu.

Tko zaslužuje pohvale kada sustav umjetne inteligencije na inovativan i efikasan način spasi živote ljudi na mostu koji se ruši ili kada inteligentan sustav upravljanja željezničkim prometom izbjegne nalet vlakova jedan na drugoga? Tko snosi odgovornost kada sustav umjetne inteligencije u automobilu u pokušaju da izbjegne nalet na pješake skrene u stranu i izazva frontalni sudar s drugim vozilom pritom dovodeći u opasnost putnike jednog i drugog vozila? Računalni stručnjak koji je dizajnirao taj sustav, ekspert etike koji je integrirao etično ponašanje u taj sustav, sam računalni sustav koji je „odlučio“ postupiti kako je?

Što dublje ulazimo u ovu problematiku, takva pitanja se sve više i više javljaju. Etičko ponašanje sustava umjetne inteligencije važno je iz nekoliko razloga. Postoje posljedice za ono što strojevi trenutno rade i za ono što se predviđa da će raditi u budućnosti.

Zanemarivanje ovog aspekta ponašanja stroja moglo bi imati ozbiljne posljedice. Od automobila koji autonomno voze i strojeva koji obavljaju naše svakodnevne poslove uz malu ili nikakvu ljudsku pomoć, do potpuno autonomnih robotskih entiteta koji će početi dovoditi u pitanje naša shvaćanja same prirode inteligencije, jasno je da će sustavi poput ovih biti sposobni nanijeti štetu ljudskim bićima, osim ako se to ne spriječi dodavanjem etičke komponente takvim sustavima.[65]

Velika većina ljudi ima crne prognoze kada je u pitanju budućnost gdje je umjetna inteligencija veliki dio ljudskih života. Te pesimistične prognoze proizlaze iz ljudskog straha da se autonomni inteligentni sustavi neće ponašati etično. Takve misli dodatno su pojačali popularni filmovi iz žanra znanstvene fantastike poput Odiseje 2001., Terminatora ili Matrix trilogije. Iako su radnje tih filmova izmišljene, zanimljivo je slušati argumente nekih ljudi koji upravo te filmove uzimaju kao nekakav dokaz da će umjetna inteligencija biti loša po nas. Hoće li čovječanstvo razviti nešto poput autonomnih inteligentnih sustava ovisiti će u velikoj mjeri o tome jesmo li sposobni ugraditi zaštitne mjere protiv neetičkog ponašanja u iste te sustave umjetne inteligencije. Mnogi stručnjaci u ovom području vjeruju da će istraživanje strojne etike unaprijediti proučavanja i razumijevanje etičke teorije. Etika je po prirodi najpraktičnija grana filozofije, odnosi se na to kako se subjekt u pitanju ponaša kada je suočen s etičkom dilemom. Iako je etika jedno od najčešćih tema razgovora današnjice, njezina teorija premalo vremena pridodaje stvarnosti. Kada se diskutira o primjerima etičkog ponašanja, oni najčešće nemaju prevelike veze sa stvarnim svijetom, pa se može diskutirati da su to umjetni primjeri. Istraživanje strojne etike već danas otkriva probleme s trenutnim teorijama etičko prihvatljivog ponašanja upravo iz razloga jer istraživači umjetne inteligencije veliki fokus stavljaju na detalje koji su uključeni u stvarnu primjenu etičkog ponašanja u stvarnom svijetu. Zasada kako stvari stoje, da bi sustav umjetne inteligencije naučili što je etički prihvatljivo ponašanje ono mora biti točno izračunato kako bi se jasno postavilo kako se sustav mora ponašati u određenim situacijama. Iako sadašnji sustavi umjetne inteligencije već danas zahtijevaju određena etička pravila koja nisu zastupljena u dizajniranim sustavima u automobilima ili elektranama, takav pristup pisanja algoritama umjetne inteligencije kako bi se sustavi približili ljudskom ponašanju vuče za sobom predvidljive komplikacije.[66]

[65] Anderson M., Anderson S.L. (2007) Machine Etics: Creating an Ethical Intelligent Agent. AI Magzine, Vol 28 No
[66] Uredili Franklin K., Ramsey W. M. (2014) The Cambrigde Handbook of Artificial Intelligence. Cambridge University Press

Većina ljudi je daleko od idealnih primjera etičkog ponašanja iako su svjesni etičkih principa. Najčešće postupaju za vlastiti interes, odnosno skloni su favoriziranju svojih želja i ambicija nad drugim, društveno korisnijim scenarijima. To je rezultat evolucije čime je neetičko ponašanje služilo kao mehanizam preživljavanja. Međutim, imamo priliku stvoriti sustave umjetne inteligencije kojima nedostaje ta predispozicija.

Dietrich je tvrdio da strojevi za koje smatramo da imaju dobre osobine ljudi i koji slijede principe ljudi koji su iznimka od općeg pravila o neetičkim ljudskim bićima mogu se smatrati "ljudima 2.0" - boljom verzijom ljudskih bića.[67]

Većina aplikacija AI zahtijeva ogromnu količinu podataka kako bi naučili i donijeli inteligentne odluke. U budućnosti ćemo se suočiti s nizom pravnih i etičkih dilema u traženju ravnoteže između značajnog društvenog napretka kojeg donosi umjetna inteligencija i temeljnih prava na privatnost. Podaci i algoritmi koje koriste sustavi umjetne inteligencije ne mogu biti samo točni i vrlo relevantni već moraju udovoljiti pitanjima privatnosti i udovoljiti regulatornim zahtjevima. Pitanja dostupnosti podataka mogu se izraziti u strogo reguliranim industrijama kao što je osiguranje, koje se kreće od povijesnog modela temeljenog na procjenjivanju rizika prema pristupu koji uključuje elemente koji predviđaju specifične rizike, npr. iako se faktori spola i religije mogu upotrijebiti za predviđanje nekih rizika, oni regulatornim tijelima u nekim aplikacijama i nadležnostima nisu prihvatljivi.[68]

Najveći problem je zapravo što pravoga rješenja nema, odnosno mi ljudi ga ne možemo pronaći. Pod pravo rješenje misli na rezultat koji zadovoljava sve strane i sva etička pitanja i situacije. Neke stvari zaista jesu crno bijele i lako se mogu razlikovati prihvatljiva od neprihvatljivih ponašanja, no za neke situacije je zaista teško procijeniti što je prihvatljivo, a što ne. Pogotovo u današnje vrijeme gdje se neka tradicionalno normalna i etična ponašanje dovode u pitanje te se vode tzv. moralne kampanje kako bi se ispravila neka izmišljena socijalna nepravda. Možda jednoga dana se razvije sustav koji će nam pomoći pri rješavanju tog problema.

[67] Dietrich E. (2006) Homo Sapiens 2.0: why should we build the better robots of our nature. Binghamton University
[68] Akerkar, R. (2019). Artificial Intelligence for Business. Sogndal, Norway- Western Norway Research Institute.

Da bismo bili učinkoviti, moramo razviti sofisticiranije politike koje idu mnogo dublje i šire od pojednostavljenih znanstvenofantastičnih rješenja poput Asimova tri zakona robotike.[69] IEEE, najveće svjetsko udruženje tehničkih stručnjaka, objavilo je Etički usklađen dizajn, skup standarda za etički dizajn umjetne inteligencije i autonomnih sustava.[70] U tom radu se navodi lanac odgovornosti za dizajn i rad takvih sustava. Također naglašava da takvi sustavi ne bi trebali narušavati ljudska prava kako bi ograničili mogući opseg rizika te bi njihovo djelovanje trebalo biti potpuno transparentno širem krugu interesnih strana.

Pod sve većim pritiskom glasina kako primjena umjetne inteligencije u poslovanju može po zlu i voditi k iskorištavanju zakonskih i etičkih rupa, u zajedničkoj suradnji Google DeepMind i Institut za Budućnost čovječanstva istražili su sigurnosne mehanizme kojima bi se ugasili otuđeni sustavi umjetne inteligencije.[71] U praksi, ove „velike crvene tipke“ zapravo su signali koji prevare sustav kako bi donio internu odluku o zaustavljanju i gašenju, bez da registrira ulaznu informaciju kao signal za isključivanje od strane vanjskog ljudskog operatera.

Iako u razvoju i primjeni umjetne inteligencije leži ogroman potencijal za poboljšanje ljudskog života, pogrešno bi bilo pretpostaviti da će takvi sustavi preuzeti sve zadatke na sebe i odrađivati sve umjesto ljudi. Dok su neki sustavi puno bolji u obavljanju svojih zadataka od ljudi, oni u prvom redu služe kao alat olakšanja života ljudskim radnicima, kako bi se oni mogli posvetiti važnijim i složenijim stvarima. Dakle, ne smijemo olako odbaciti mogućnost budućnosti gdje su sustavi umjetne inteligencije više u ulozi pomagača i sljedbenika, nego predvodnika. Ovu misao možda najbolje oslikava izjava Patricka Hebrona, autora knjige Strojno učenje za dizajnere; „Alati nisu namijenjeni da nam olakšaju život, oni nam trebaju dati prednost kako bismo mogli pomicati granice. Alati dižu kamenje, ljudi su ti koji grade katedrale.“[72]

[69] Do we need Asimov’s Laws? (2014) MIT Technology Review. Dostupno na: https://www.technologyreview.com/s/527336/do-we-need-asimovslaws/ [12.08.2019]
[70] IEEE Global Independent and Intelligent Systems Ethics Initiative. (2016) Ethically aligned design: a vision for prioritizing the well-being of humans with artificial intelligence and autonomous systems. Dostupno na: http://standards.ieee.org/develop/indconn/ec/autonomous_systems.html [12.08.2019]
[71] Gershgorn, D. (2016) Google Considers Creating "Big Red Button" Stop Dangerous A.I. In case of emergency. Popular science. Dostupno na: http://www.popsci.com/google-researches-big-redbutton-to-stopdangerous-ai [12.08.2019]
[72] Hebron, P. (2017) Thinking and design tools in the age of machine learning. Dostupno na: http://medium.com/artists-and-machineintelligence/rethinking-design-tools-in-the-age-of-machinelearning-369f3f07ab6c [12.08.2019]

3.1.2. Prednosti

Potencijalne koristi i prednosti sustava umjetne inteligencije gotovo da su beskonačni, no u ovom poglavlju govoriti ćemo o prednostima današnjih sustava koji su u primjeni u poslovanju. Trenutačna rješenja utemeljena na umjetnoj inteligenciji vrlo su dobra u pojednostavljivanju procesa i preuzimanju radnih zadataka poput pokretanja workflowa ili poslovnog procesa. Automatizacija oslobađa kognitivno opterećenje zaposlenika kako bi se oni mogli usredotočiti na važnije aspekte svog posla.

Administrativni zadaci u poduzeću dosta su monotoni i repetitivni te najčešće zahtijevaju ručni unos podataka, koji zahtjeva izuzetnu preciznost. Količina podataka eksponencijalno raste dok ljudska sposobnost da pazi na detalje s vremenom opada. Računalni sustavi umjetne inteligencije se ne umaraju i savršeni su za ponavljajuće zadatke gdje se ne smije dogoditi niti najmanji pad koncentracije. Uz to su puno brži i efikasniji od ljudi. Kao i kod ostalih općih i administrativnih funkcija, sustavi umjetne inteligencije najkorisniji su za automatiziranje zamornih ručnih procesa, omogućujući odvjetnicima, posebno onima koji rade u kući, da posvete više vremena vrijednom i strateškom radu. Takvi sustavi umjetne inteligencije ne zahtijevaju česte pauze i osvježenja kao ljudi. Mogu se programirati da rade vremenski puno duže od ljudi i neprekidno će obavljati posao bez umora, dosade ili ometanja. Dostupni su 24 sata na dan, 7 dana u tjednu, 365 dana u godini.

Primjenjujemo sustave umjetne inteligencije iz dana u dan korištenjem pametnih telefona. Uz odjeću, hranu i sklonište, mobitel je postao 4 najvažnija nužnost suvremenog čovjeka. Pametni telefon jedan je od svakodnevnih primjera kako koristimo snagu umjetne inteligencije kako bismo smanjili prepreke u svakodnevnom životu. Korištenjem društvenih medija, algoritam umjetne inteligencije identificira i detektira lice osobe i označava pojedince dok objavljujemo fotografije na web stranicama društvenih medija. Umjetna inteligencija široko se koristi u financijskim institucijama i bankarskim sektorima za organiziranje i upravljanje podacima. Odjeli za otkrivanje prevara koriste jednu od najboljih prednosti umjetne inteligencije koja se bavi sistemskim transakcijama na pametnoj kartici.

Sustavi umjetne inteligencije su rješenja koja koriste obradu prirodnog jezika i mogu djelovati kao spoter u pružanju potrebnih informacija o uvjetima ugovora, omogućujući odvjetnicima da usredotoče svoju pozornost na najvažnije segmente svakog ugovora i skrate cjelokupni postupak pravnog odobrenja.

Osim toga, pravni timovi moraju biti u tijeku s pravilima koja se neprestano mijenjaju. Agenti za dubinsku istragu već se koriste za preglede milijardi transakcija, kao i za izvlačenje i upravljanje višejezičnim podacima korporacije na više jezika.Pravna istraživanja sada se mogu nadopuniti s asistentima umjetne inteligencije koji mogu pregledati i kategorizirati velike dokumente. Novi proizvodi, uključujući i one koji koriste IBM Watson, sada mogu odgovoriti na pravna pitanja jednostavnim engleskim jezikom, čak i nadmašujući iskusne pravne stručnjake u točnosti, učinkovitosti i zadovoljstvu kupaca. Alati sada mogu predvidjeti kako će sudovi presuditi nove slučajeve, poput onih koji se bave poreznim pravom, sa stopom točnosti većom od 90 posto. Prema pravnicima IBM-a, upotreba sustava umjetne inteligencije smanjila je ukupno vrijeme potrebno za analizu rezultata pretraživanja za 50 posto. Ostale uporabe uključuju otkrivanje znakova upozorenja o rastućim pravnim problemima, što u konačnici može pomoći u očuvanju i poboljšanju vrijednosti portfelja neke marke ili branda.

Napredne organizacije već su implementirale sustave umjetne inteligencije kako bi komunicirali sa svojim kupcima koristeći 'avatare'. Digitalni pomoćnici ili replike pomoći će u smanjenju potreba za ljudskim resursima. To je tzv. digitalna asistencija. Automatizacija stručnosti, inteligentna automatizacija pravnih ekspertiza i procesa omogućava jednostavan način kreiranja koraka ili virtualnih pomoćnika za usklađivanje i regulatorna pitanja u određenom sektoru ili pravnom polju. Za razliku od ljudskih pravnika, softver za automatizaciju stručnosti nema određeno radno vrijeme, što olakšava pristup pravnom znanju za odgovor na uobičajena pitanja.

Sustavi umjetne inteligencije postali su izuzetno popularni u polju financijske revizije i računovodstva. Korištenjem sistema za prepoznavanje prirodnog jezika može se automatizirati upravljanje troškovima za računovođe i financijske kontrolore. Na taj se način smanjuje mogućnost pogreške i uklanjaju se najnaporniji dijelovi posla računovodstvenog stručnjaka.

Većina tvrtki ima mnogo digitalnih tokova koji se ponavljaju. Zaposlenici odgovorni za ove zadatke mogu lako postati dosadni i nepažljivi, omogućujući greške u poslovanju i podacima. Srećom, ovi zadaci dobro su prilagođeni za automatizaciju od strane robotske procesne automatizacije (RPA), koji su softverski roboti programirani za izvođenje određenog slijeda radnji. Što je još bolje, implementacija RPA relativno je brza i s malim rizikom, tako da se problematični roboti mogu brzo ukloniti bez štete za postojeće sustave.

Primjeri radnih tijekova u kojima RPA-i izvrsno funkcioniraju obuhvaćaju redovitu dijagnostiku softvera ili hardvera, stvaranje i ažuriranje računovodstvenih evidencija ili automatsko generiranje i dostavljanje periodičnih izvještaja relevantnim dioničarima.[73]

Umjetna inteligencija ima brojne prednosti poput otkrivanja smislenih i korisnih uzoraka u velikim količinama podataka bilo koje vrste, uključujući tekst, slike, video i druge nestrukturirane podatke. Modeli samo-učenja sustava umjetne inteligencije omogućuju poduzeću da se brzo prilagodi promjenama u obrascima svojih podataka i temeljnim uvjetima poslovanja. Donose se bolje i brže odluke maksimiziranjem vrijednosti svih podataka i prelaskom iz prediktivne analitike u propisivačku. Prepoznaje se arhitektura podataka koji omogućuju optimalnu segmentaciju i tretmane korisnika. Olakšava poslovnim korisnicima interpretaciju, reagiranje i korištenje podataka boljom vizualizacijom i transparentnošću. Nudi nove poslovne modele i stvaranje dodatne vrijednosti ubrzavanjem inovacija otkrivanja novih obrazaca podataka i potpunim korištenjem imovine znanja.

U prethodnom poglavlju naveli smo primjere kako sustavi umjetne inteligencije donose koristi i prednosti inovativnim ponašanjem u zdravstvu, transportu, poljoprivredi, poslovanju itd. Inteligentni sustavi za praćenje vremena i predviđanje vremenskih prognoza su također jedan od primjera. Postoji također sustav koji može predvidjeti, na osnovu simulacije tektonskih ploča zemlje, vremena erupcija vulkana. Postoje inteligentni sustavi koji prikupljaju podatke s telefona i šalju ih na analizu na temelju kojih se mogu dati uspješna predviđanja o pojavi potresa.

Aplikacije pametnih gradova često koriste umjetnu inteligenciju kako bi poboljšali planiranje okoliša, pružanje usluga, korištenje energije, upravljanje resursima i sprečavanje kriminala. Neke od najboljih aplikacija uključuju inteligentne prometne signale, aplikacije za e-upravljanje, pametne brojila za komunalije, Wi-Fi pokrivenost itd. Također u posljednje vrijeme jako su popularni pametni domovi – sposobni su osigurati bolju sigurnost i smanjiti potrošnju energije što u velikoj mjeri promovira koncept zelenog okruženja.

[73] Yao, M., Zhou, A. & Jia, M. (2018). Applied Artificial Intelligence. A Handbook for Business Leaders. New York

3.1.3. Nedostaci

Obzirom na potencijal koji sustavi umjetne inteligencije posjeduju, za očekivati je da će postojati neke poteškoće i nedostaci takvih sustava, jer, naposljetku, ništa na ovome svijetu nije savršeno i bez mana. Klasifikacija ili grupiranje, koji je najbolji način manipuliranja podacima, što je bolje, strojno učenje pod nadzorom ili bez, to su neka od pitanja na koje nije lagano dati odgovor, jer najčešće ne postoji jedan točan ili netočan odgovor. Za razliku od ljudi, današnjim sustavima umjetne inteligencije potrebni su ogromni klasteri podataka kako bi nešto naučili. Ljudima ne trebaju milijuni slika kako bi naučili prepoznati zebru, nilskog konja ili neku drugu životinju, dok sustavima umjetne inteligencije treba tolika količina podataka kako bi naučili razlikovati i segmentirati podatke. Sustavu umjetne inteligencije treba dati milijune slika i dodatno uskladiti parametre i ograničenja kako bi taj sustav uspješno prepoznao neku životinju. Također, moraju se koristiti slike iz nekoliko različitih perspektiva i kutova. Iz svega navedenog da se zaključiti da je potrebno dobavljanje velikih količina kvalitetnih podataka koji se daju sustavu, što je svakako nedostatak.

Kad je u pitanju učenje, strojevi mogu griješiti na isti način kao ljudi. Ako sustavu dajete trening podatke koji nisu reprezentativni za testne slučajeve, tada sustav umjetne inteligencije neće kvalitetno naučiti i klasificirati te podatke. Da bi umjetna neuronska mreža mogla učiti, morate joj pružiti dobre podatke i veliku količinu istih.

Samo parametriziranje podataka od strane ljudi zahtjeva ne malu količinu vremena dok ovakva osnovna obuka sustava umjetne inteligencije, također, iziskuje dosta vremena. Ovdje dolazimo do drugog nedostatka, a to je vrijeme koje je potrebno da se urede trening podaci te sam proces učenja. Dobra vijest je da kada se jednom mreža postavi, vrlo često radi puno bolji posao od ljudi.

Kod nadziranog strojnog učenja, sustavu se daje skup podataka koji sadrži oznake i objekte koje svaka pojedina oznaka predstavlja. Sustav umjetne inteligencije promatra primjere koje se oznake odnose na koje objekte. Ovo je tzv. trening set podataka. Nakon treninga, sustavu umjetne inteligencije daje se veći skup podataka, bez oznaka objekata, kako bi se utvrdilo koliko dobro sustav klasificira nepoznate objekte. Sustavu se ukaže na točnost i grešku klasifikacije, kako bi on mogao precizno prilagoditi daljnju segmentaciju. Ovaj set podataka se zove, set podataka za validaciju i on je dio većeg trening seta podataka.

Njegova jedina svrha jest precizno podešavanje postavki sustava neuronske mreže i koristi se samo za mjerenje konačnih performansi i rezultata obučenog sustava umjetne inteligencije. Vrlo je bitno ne miješati trening set s testnim podacima, jer onda se sustavu, pri učenju, daju neki odgovori, pa on nije u mogućnosti pravilno podesiti postavke. Iako je moguće poboljšanje rezultata, ovo zapravo smanjuje performanse. Isto kao kada student vara na ispitu, rezultat ispita može biti izvrstan, međutim to ne znači da je student nešto naučio, već upravo suprotno.

Iako se sustav nadziranog strojnog učenja može pouzdano koristiti za odgovore na točno određena pitanja i rješavanje određenih problema, nenadzirano učenje ima ogroman istraživački potencijal, npr. prepoznavanje obrazaca za koje najbolji ljudski analitičari čak ni ne znaju da postoje. To je veliki nedostatak jer se taj dio strojnog učenja ne primjenjuje toliko u poslovanju koliko bi trebao, a taj put je zapravo korak k razvoju umjetne inteligencije koja ima kognitivne mogućnosti u razini ljudi. Otkrivanje obrazaca u podacima kako bi se mogao utrti put inovativnim idejama i rješenjima problema za koje nismo ni znali da postoje.

Stvaranje umjetne inteligencije zahtijeva velike troškove jer su to vrlo složeni sustavi čiji popravci i održavanje zahtijevaju visoke troškove. Imaju softverske programe koji zahtijevaju učestale nadogradnje da bi udovoljili potrebama promjenjivog okruženja i da budu pametniji iz dana u dan. U slučaju ozbiljnih kvarova, postupak vraćanja izgubljenih kodova i podataka te ponovno postavljanje sustava može zahtijevati ogromne troškove.

Iako mnogi ljudi smatraju da jednoga dana kada se rodi prava umjetna inteligencija će doći do repliciranih ljudi, to nije točno. Smatra se da je inteligencija dar prirode, te se vodi etička polemika treba li taj dar kopirati u sustave umjetne inteligencije ili ne. Takvi sustavi nemaju samostalne emocije ili moralne vrijednosti, te varijable određene su sklonostima dizajnera takvih sustava. Izvode one zadatke za koje su programirani, te nemaju (još) kognitivni kapacitet donijeti odluku koja je ispravna ili pogrešna. Ukoliko se nađu u nepoznatoj situaciji, nisu u mogućnosti odlučiti što napraviti, ili naprave nešto pogrešno ili se pokvare u takvim situacijama. Za razliku od ljudi, umjetna inteligencija ne može se poboljšati iskustvom. Pohranjuje puno podataka i informacija, ali način na koji im se može pristupiti i koristiti bitno se razlikuje od ljudske inteligencije. Kao što smo naveli u prethodnom poglavlju, današnji sustavi umjetne inteligencije ne mogu primijeniti informacije i odgovore koje imaju u promjenjivom okruženju.

Upravo iz ovih spoznaja da se zaključiti kako strojevi neće zamijeniti ljude u skoroj budućnosti, pitanje je hoće li ikada. U sustavima umjetne inteligencije nema ničega sličnom kada čovjek radi strastveno te cijelo srce i dušu uloži u neki projekt ili posao. Zabrinutost problemima, čak i nakon kraja radnog vremena, ne postoji kod sustava umjetne inteligencije, također očiti je nedostatak osjećaja pripadnosti ili zajedništva.

Kreativnost ili mašta nisu stavke koje postoje u sustavima umjetne inteligencije, iako uvelike pomažu u dizajniranju i stvaranju zgrada, poslovnih modela i procesa, jednostavno nemaju snagu razmišljanja koju čovjek ima i originalnost kreativnog uma. Najveći nedostatak umjetne inteligencije je to što ne može iskusiti osjećaje, dok misli ljudi, s druge strane, su vođene osjećajima.

Zamjena ljudi sa strojevima može dovesti do velike nezaposlenosti. Iako smo u prethodnom poglavlju naveli da to otvara velike mogućnosti ljudima da se posvete drugim stvarima, to se možda neće dogoditi te ljude koji nemaju što raditi mogu dovesti do destruktivne uporabe svojih kreativnih umova.

Može nastati situacija u kojoj ljudi nepotrebno ovise o sustavima ukoliko se upotreba umjetne inteligencije pojača. Izgubiti će svoju kreativnu snagu i postat lijeni. Zanimljiv pogled takvog scenarija može se pronaći u animiranom filmu Wall-E. S druge strane, ukoliko ljudi razmišljaju na destruktivan način, mogu umjetnom inteligencijom ugroziti čovječanstvo te biti ozbiljna prijetnja.

Također, postoji stalan strah da će jednoga dana umjetna inteligencija nadvladati ljude, što samo po sebi nije neki problem, naći ćemo način za suživot, kako radimo već tisućama godina s drugim ljudima. Problem nastaje kada se ciljevi umjetne inteligencije i ljudi razlikuju.

Također jedan od većih nedostataka je rizik od cyber napada i hakiranje sustava umjetne inteligencije, čime bi došlo do gubitka velike količine podataka. Važno je minimalizirati takve prijetnje i razviti moguće scenarije kako bi se smanjila mogućnost štetnog djelovanja u slučaju takvih proboja sigurnosti.

PREDNOSTI	NEDOSTACI
Nema dosade, spavanja, odmora ili zabave – konstantno u pogonu	Uska specijalizacija - nema mogućnost generalne primjene naučenog znanja
Manja mogućnost pogreške, viša točnost i brzina	Visoka cijena i troškovi
Oslobađanje vremena ljudima za druge stvari	Etička pitanja – repliciranje inteligencije
Svakodnevna primjena	Dugotrajan proces učenja
Digitalni asistenti	Nema kreativnosti
Automatizacija ponavljajućih poslova	Uzima ljudima osjećaj koristi
Medicinska korisnost	Rizik od cyber napada i gubitka podataka
Dostupnost 24 sata dnevno/365 dana	Ne zamjenjuje ljude
Nedostatak osjećaja	Nedostatak osjećaja
Izvršavanje fizički opasnih zadataka	Prevelika ovisnost o autonomnim sustavima i gubljenje ljudskih mentalnih kapaciteta
Olakšava donošenje poslovnih odluka	Opasnost destruktivnog korištenja sustava

Tablica 1. Prednosti i nedostaci umjetne inteligencije

4. ISTRAŽIVANJE – LJUDSKO MIŠLJENJE O PRIMJENI UMJETNE INTELIGENCIJE U POSLOVANJU I ŽIVOTU

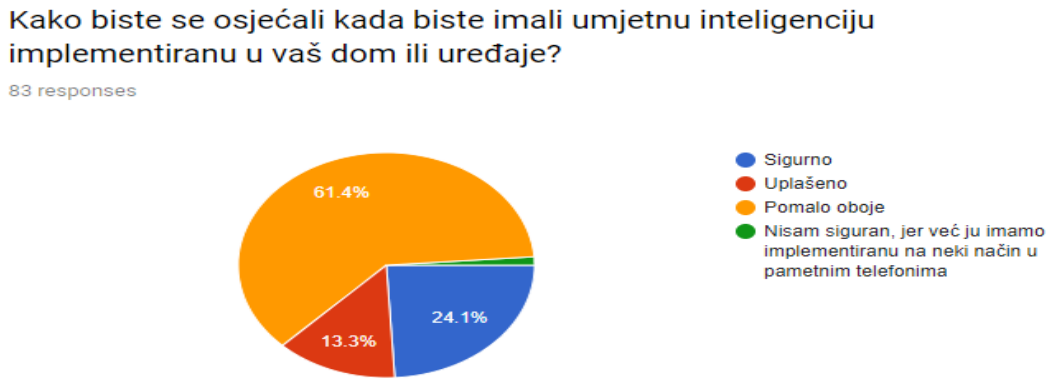
4.1. Sudionici, metoda i postupak provedbe istraživanja

Umjetna inteligencija je tehnologija o kojoj se govori desetljećima i koja sada ulazi u naše živote putem digitalnih asistenata, prototipova autonomnih automobila i robota koji zamjenjuju ljudski posao. Ono predstavlja jednu od najzanimljivijih i potencijalno najutjecajnijih tehnologija ikada razvijenih. Sudionici ovog istraživanja bili su studenti Ekonomskog fakulteta u Zagrebu i Studenti Hrvatskih studija sa Sveučilišta u Zagrebu jer će oni, kao buduća radna snaga, biti u središtu tehnološke eksplozije i morati će se naučiti suživotu s rastućim utjecajem informacijske tehnologije. Upravo zbog tih razloga zanimljivo je čuti njihova razmišljanja i stavove o umjetnoj inteligenciji, prije nego li ona u većoj mjeri postane dio njihovih života i karijera.

Istraživanje se provelo online anketnim upitnikom, kojem se pristupalo preko internetskog preglednika, i koji sadrži 30-ak pitanja, za čije rješavanje treba 5 do 10 minuta vremena. Odgovori na pitanja su se sastojali od odgovora DA/NE, precizno definiranih odgovora na pitanja te su sudionici istraživanja na nekim pitanjima imati opciju iznijeti vlastito mišljenje ukoliko niti jedan od ponuđenih odgovora nije predstavljao njihovo mišljenje. Temelj za anketni upitnik ovog istraživanja bilo je istraživanje globalne potrošačke ankete koje je proveo Northstar Research Partners Ltd u ime ARM-a, te je većina pitanja preuzeta iz tog upitnika s ciljem uspoređivanja rezultata globalne potrošačke ankete, tj. globalnog mišljenja o umjetnoj inteligenciji, te mišljenja i stavova buduće radne snage u Hrvatskoj.[74] Svi ispitanici koji su sudjelovali u istraživanju imaju barem osnovno razumijevanje pojma umjetna inteligencija i što je to.

4.2.Analiza rezultata istraživanja

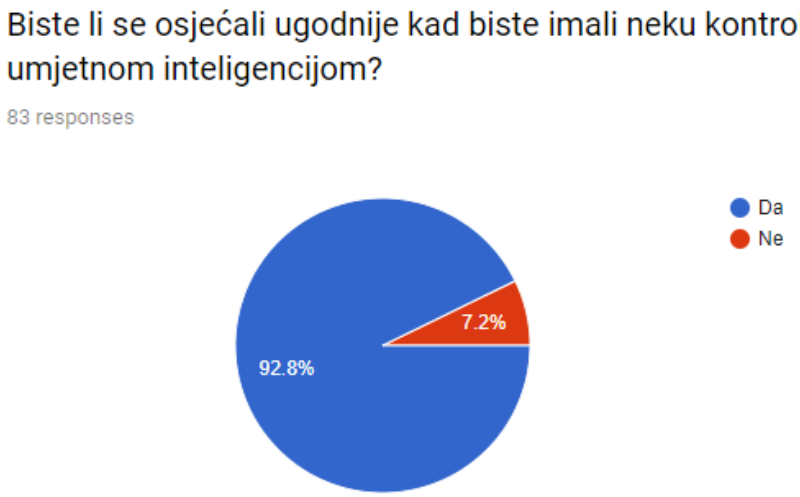
Od 83 ispitanika u istraživanju, kada im se postavilo pitanje o tome kako bi se osjećali kada bi sustav umjetne inteligencije imali implementirani u njihov dom ili uređaje, većina ili 61,4% je izjavila da bi se istovremeno osjećali sigurno i uplašeno. Kada gledamo razliku isključivo između ta dva osjećaja, prevladava osjećaj sigurnosti 24,1% naspram uplašenosti 13,3%. Samo jedan ispitanik je naveo da nije siguran kako bi se osjećao jer je umjetna inteligencija već implementirana u pametne telefone.



Slika 1. Upitnik o implementaciji umjetne inteligencije u dom ili uređaje

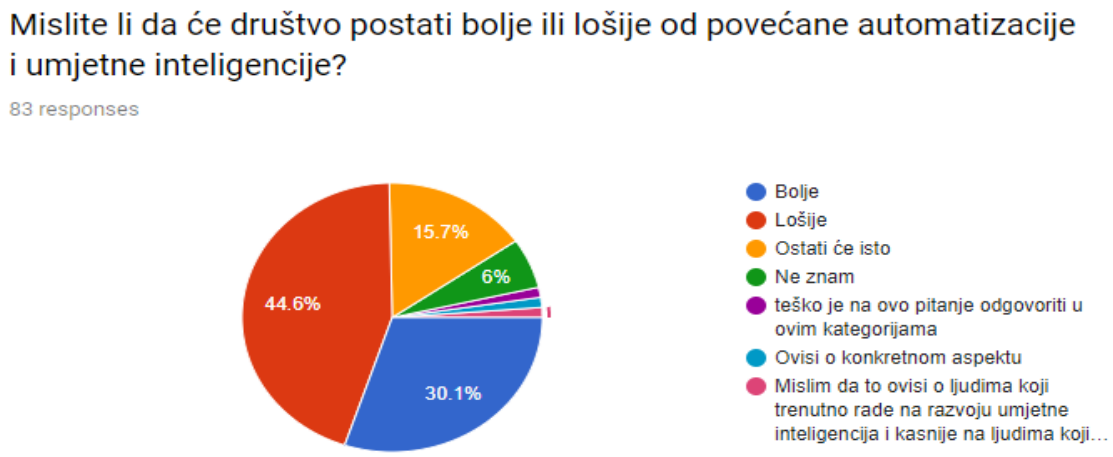
[74] Globalna potrošačka anketa, Northstar Research partners Ltd u ime ARM-a. Dostupno na: https://www.arm.com/solutions/artificial-intelligence/survey [20.04.2019.]

Posljedično pomiješanim osjećajima oko implementacije autonomnih sustava u domove ili uređaje, velika većina ispitanika, 92,8% osjećala bi se puno ugodnije kada bi imali nekakav oblik kontrole nad takvim sustavima u njihovom posjedu. Manjina, točnije 7,2% ispitanika, izjavila je da se, čak i kada bi imali kontrolu nad umjetnom inteligencijom, ne bi osjećali ugodnije.



Slika 2. Kontrola nad umjetnom inteligencijom

Vrlo je zanimljivo usporediti odgovore koje su ispitanici dali u ovom istraživanju s globalnom potrošačkom anketom koje je proveo Northstar Research Partners Ltd u ime ARM-a. Na pitanje misle li da će društvo postati bolje ili lošije od povećane automatizacije i umjetne inteligencije, većina ispitanika u ovom istraživanju iskazala je pesimističnu viziju društva u budućnosti i odgovorila da će društvo postati lošije, njih gotovo polovica, čak 44,6%. S druge strane, 30,1% ispitanika mišljenja je da će društvo profitirati i postati bolje zbog navedenih razloga. Ostali ispitanici ne znaju i ne usude se prognozirati ishod.



Slika 3. Mišljenje o stanju društva s povećanom automatizacijom i umjetnom inteligencijom

U globalnoj potrošačkoj anketi čak 61% ispitanika smatra da će društvo biti bolje kada se automatizacija poveća i umjetna inteligencija postane značajno važna u našim životima. Njih 22% misli da će društvo biti lošije, a 17% smatra da se ništa neće značajno promijeniti. Zanimljivo je primijetiti kako globalno gledajući, vlada pozitivno mišljenje kada se priča o stanju društva u budućnosti, dok kod nas, je obrnuto.



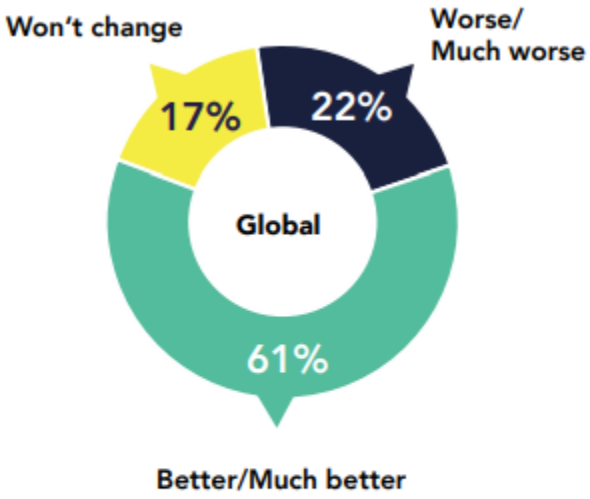
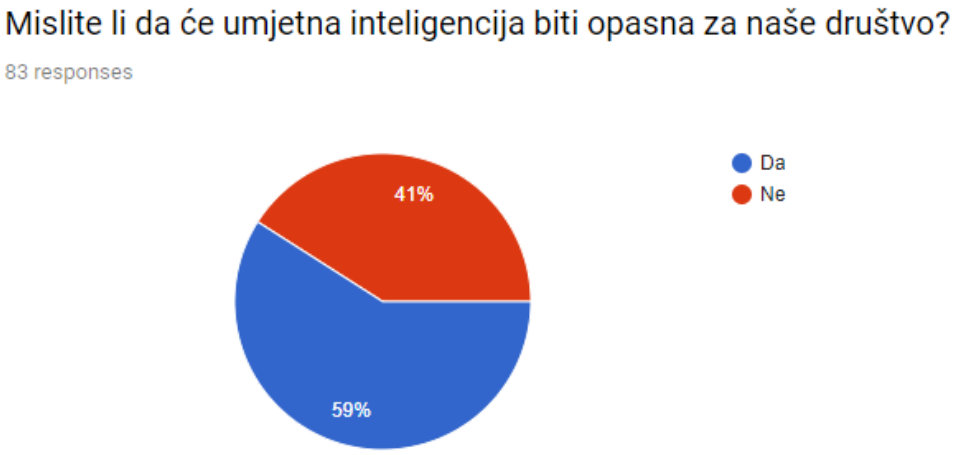


***Figure 4:** Do you think that society will become better or worse from increased automation and AI?*

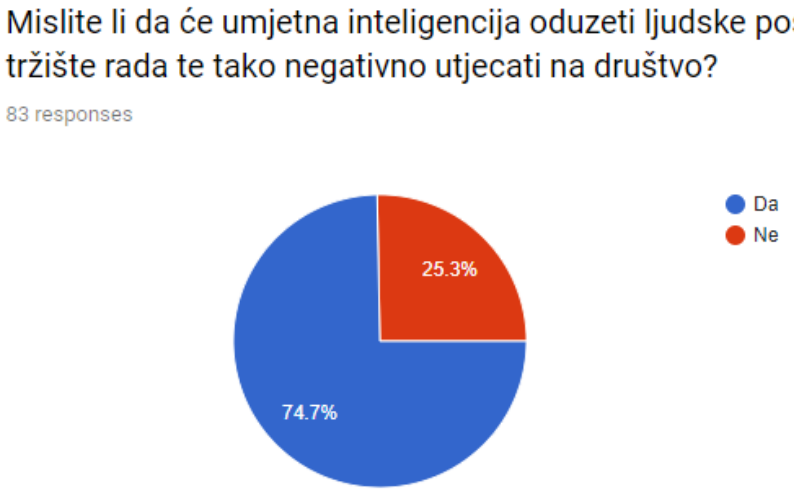
Slika 4 i 5. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a

Negativan pogled primjenu sustava umjetne inteligencije u poslovanju nastavlja se i u iduća dva pitanja, hoće li umjetna inteligencija biti opasna za naše društvo i hoće li oduzeti ljudske poslove i smanjiti tržište rada. Na prvo pitanje 59% ispitanika smatra da će razvoj umjetne inteligencije biti opasan po naše društvo, dok 41% smatra da neće.



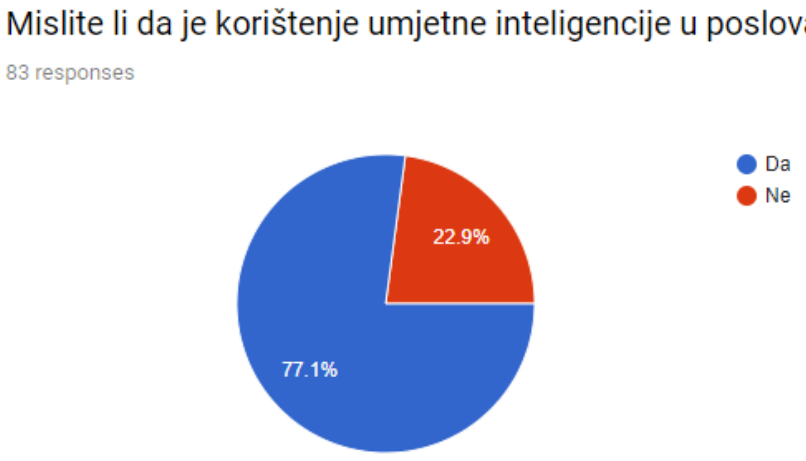
Slika 6. Opasnost umjetne inteligencije za naše društvo

Što se tiče ljudskog rada i tržišta kapitala, 74,7% smatra da će ljudi imati manje posla zbog implementacije umjetne inteligencije u poslovanje, a njih 25,3% smatra da se to neće dogoditi. Vrlo je izvjesno da će se to dogoditi, međutim važno je napomenuti da ispitanici tu pojavu vide kao negativnu, a ne pozitivnu.



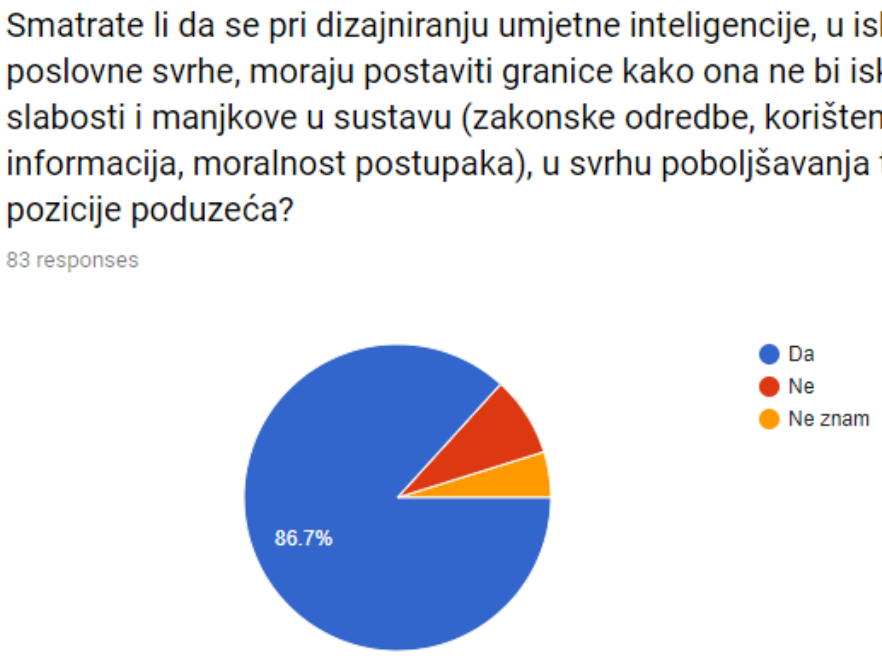
Slika 7. Utjecaj umjetne inteligencije na tržište rada

Iako većina ispitanika ima negativan stav prema autonomnim sustavima umjetne inteligencije, njihovo korištenje u poslovanju, pomalo kontradiktorno, vide kao pozitivnu pojavu. Čak 77,1% smatra da je implementacija takvih sustava u poslovanje dobra stvar, dok njih 22,9% misli da nije.



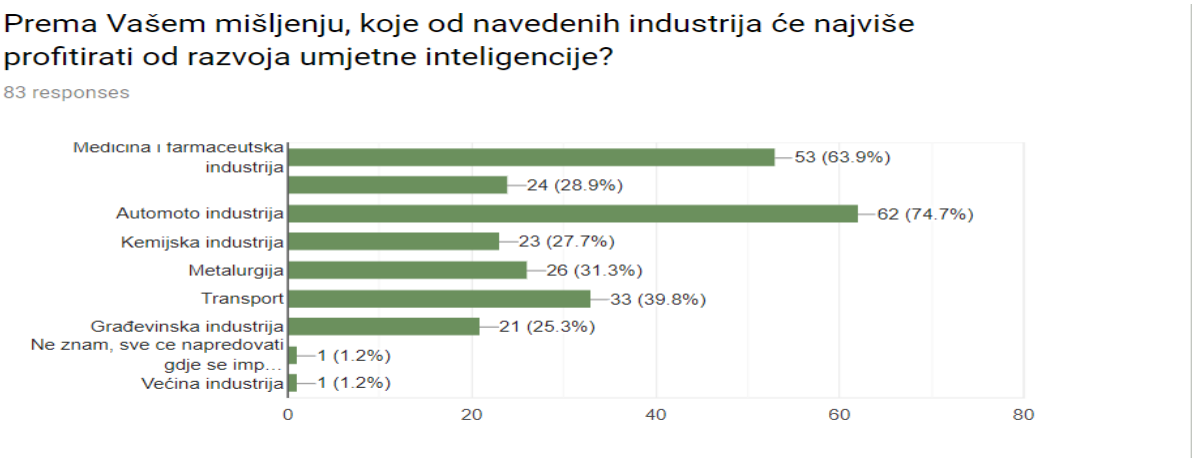
Slika 8. Korištenje umjetne inteligencije u poslovanju

Također većina ispitanika, njih 86,7%, smatra da je potrebno postaviti granice i ograničenja u autonomne sustave kako oni ne bi iskorištavali slabosti i manjkavosti u sustavu u svrhu poboljšavanja tržišne pozicije poduzeća, dok ostatak misli da to nije potrebno 8,4% ili ne zna 4%.



Slika 9. Ograničenja kod dizajniranja sustava umjetne inteligencije

Ispitanici smatraju da će auto-moto industrija najviše imati koristi od razvoja umjetne inteligencije, zatim slijede medicina i farmaceutska industrija, transport, metalurgija, poslovanje i gospodarstvo je tek na petom mjestu ispred, kemijske i građevinske industrije.



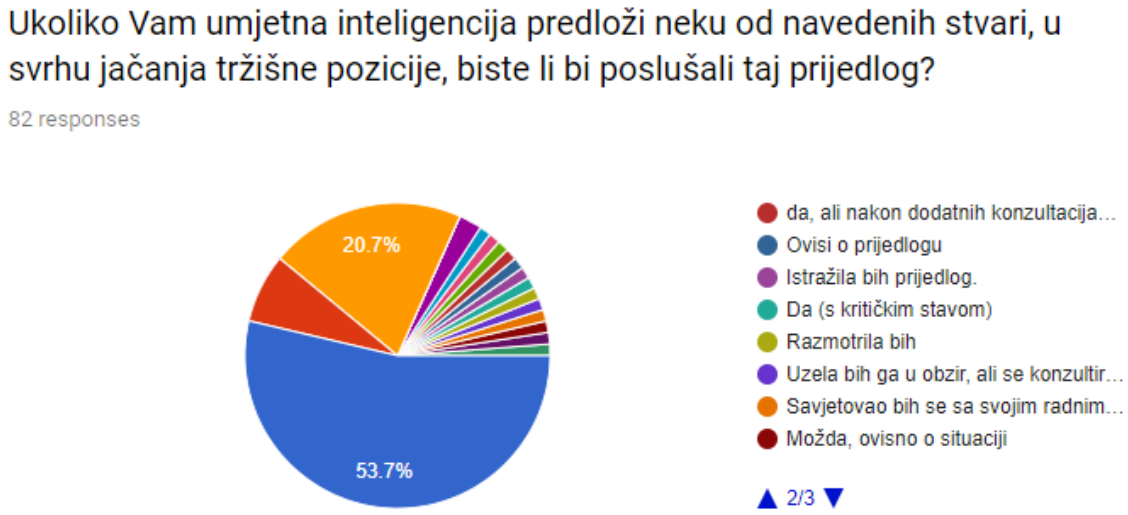
Slika 10. Utjecaj umjetne inteligencije na industrije

Većina ispitanika smatra da je umjetna inteligencija dobra u obradi i analizi velike količine podataka te da time pomaže organizaciji.



Slika 11. Korištenje umjetne inteligencije za obradu i analizu podataka

Isto tako kada bi im umjetna inteligencija predložila neku akciju u svrhu ostvarivanja poslovne koristi, većina ispitanika bi prihvatila prijedlog 53,7%, dok manjina ne bi 7,3%. Ostatak ispitanika, prije donošenja odluke, bi se konzultirao s ljudskim kolegama 37,5%.



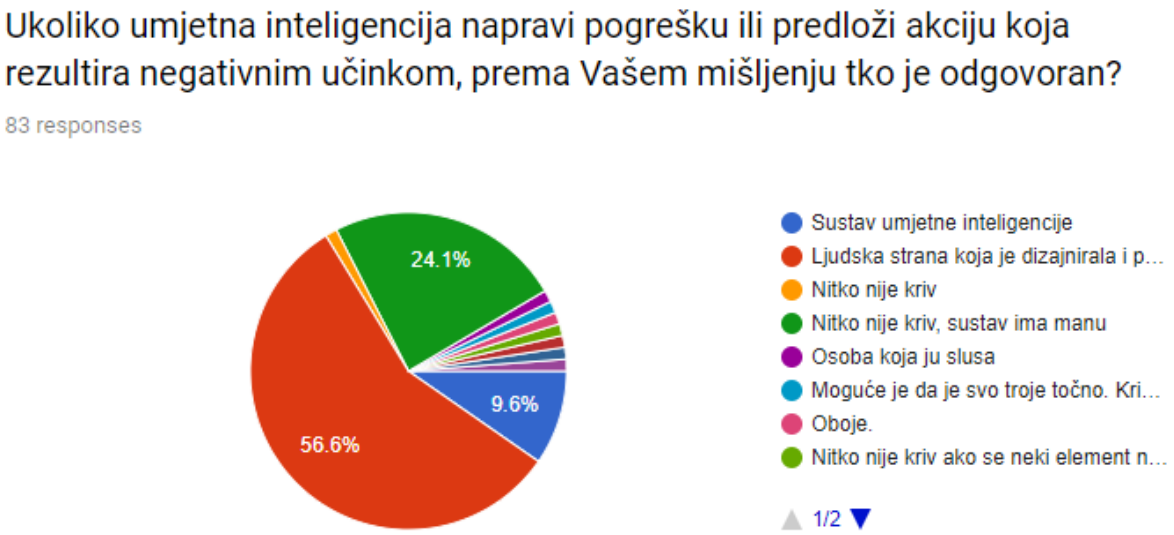
Slika 12. Prihvaćanje/neprihvaćanje prijedloga sustava umjetne inteligencije

Iduće pitanje je vrlo etički upitno, na svu sreću, većina ispitanika izabralo je ispravan odgovor 66,3%. Broj ispitanika koji bi poslušali prijedlog umjetne inteligencije koji donosi poslovnu korist ili prednost, ali etički i moralno nije dobar, jest točno 12%. Po 9,6% imaju ostali odgovori, „Ne znam“ i „Razmotrio/Razmotrila bih prijedlog s ljudskim kolegama“.

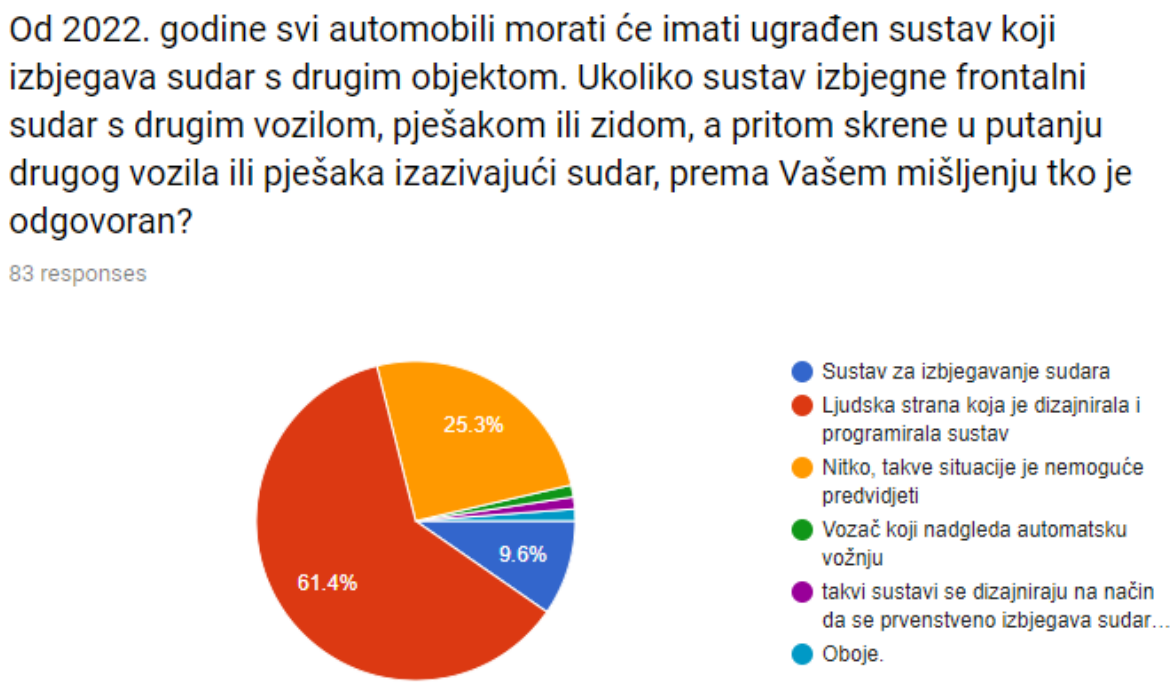


Slika 13. Prihvaćanje/neprihvaćanje prijedloga sustava umjetne inteligencije etično upitne prirode

Zanimljivo je vidjeti rezultate pitanja odgovornosti ukoliko sustav umjetne inteligencije napravi nekakvu pogrešku koja rezultira negativnim učinkom, u teoriji i na primjeru. U oba scenarija većina ispitanika smatra da je odgovornost na ljudskoj strani koja je dizajnirala sustav umjetne inteligencije, sljedeći odgovor s najviše odabira jest da nitko nije kriv, tj. da sustav ima manu ili da takve situacije nije moguće predvidjeti.

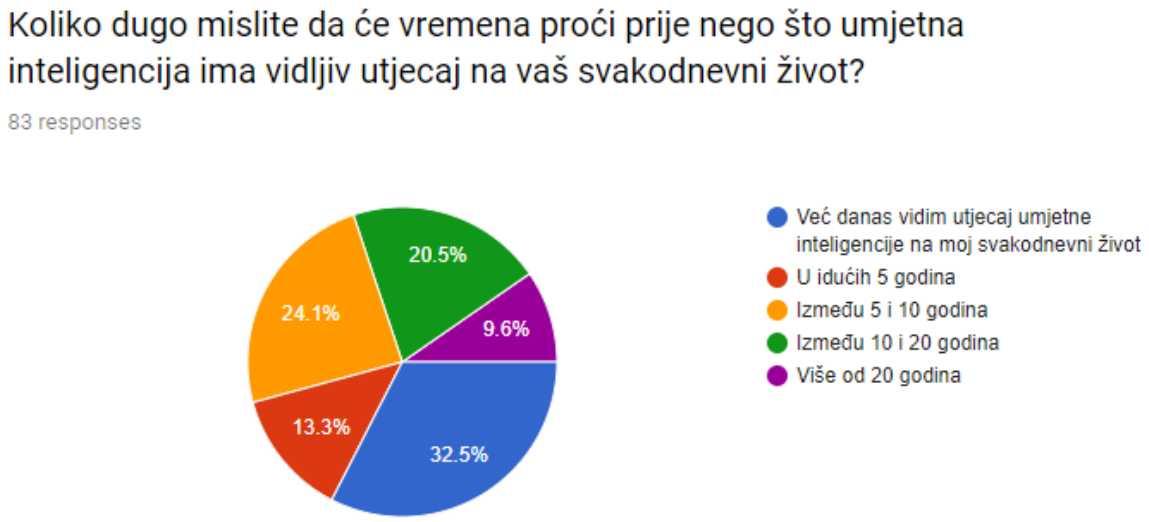


Slika 14. Odgovornost za negativni učinak umjetne inteligencije u teoriji



Slika 15. Odgovornost za negativni učinak umjetne inteligencije na praktičnom primjeru

Većina ispitanika misli da već danas osjećamo značajan utjecaj umjetne inteligencije u našim svakodnevnim životima 32,5%. Da na vidljiv utjecaj moramo čekati između 5 i 10 godina smatra 24,1% ispitanika, a odgovor 10 do 20 godina ima 20,5% odabira.



Slika 16. vidljiv utjecaj umjetne inteligencije na svakodnevni život

U izvješću globalne potrošačke ankete Northstar Research Partners Ltd može se vidjeti drugačiji trend razmišljanja.

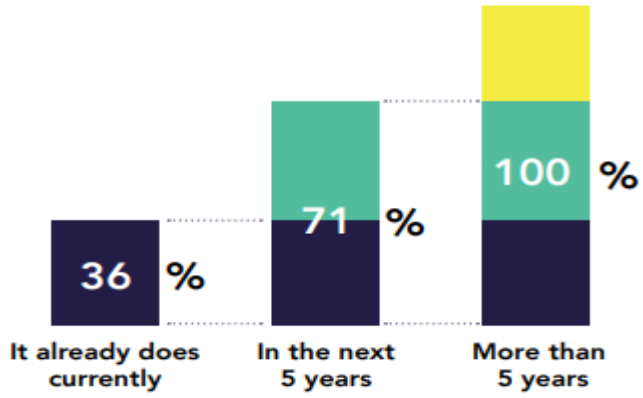
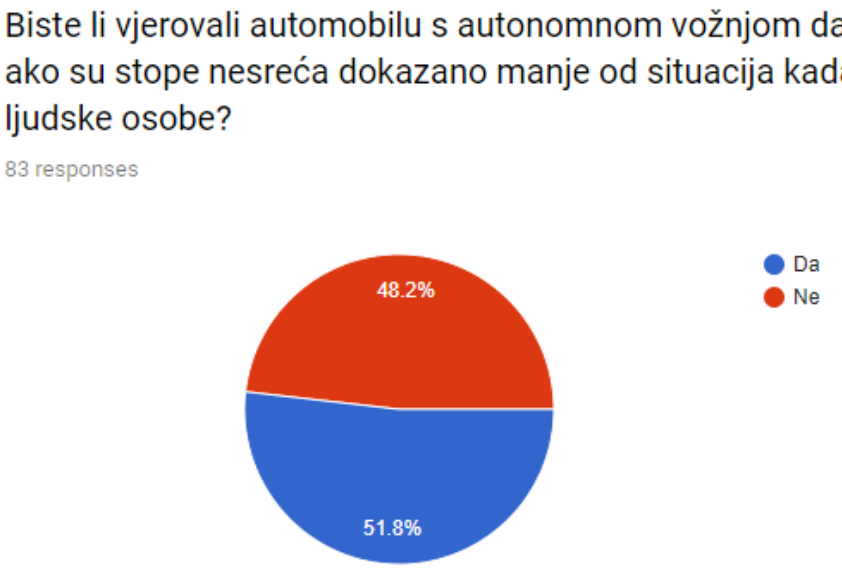


Figure 1: How long do you think it will be before AI has a noticeable impact on your daily life?

Slika 17. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a

U posljednjih nekoliko godina gotovo svi automobili imaju neki nivo autonomne vožnje, počevši od Tesle pa do gotovo svih automobilskih marki. U budućnosti ta tehnologija zasigurno će biti bolje razvijena i učinkovitija, pa se ispitanicima postavilo pitanje bi li vjerovali automobilu s autonomnom vožnjom da vozi njihovu obitelj ako su stope nesreća dokazano manje od stopa u situacijama kada su vozači ljudske osobe.



Slika 18. Povjerenje u automobile s autonomnom vožnjom

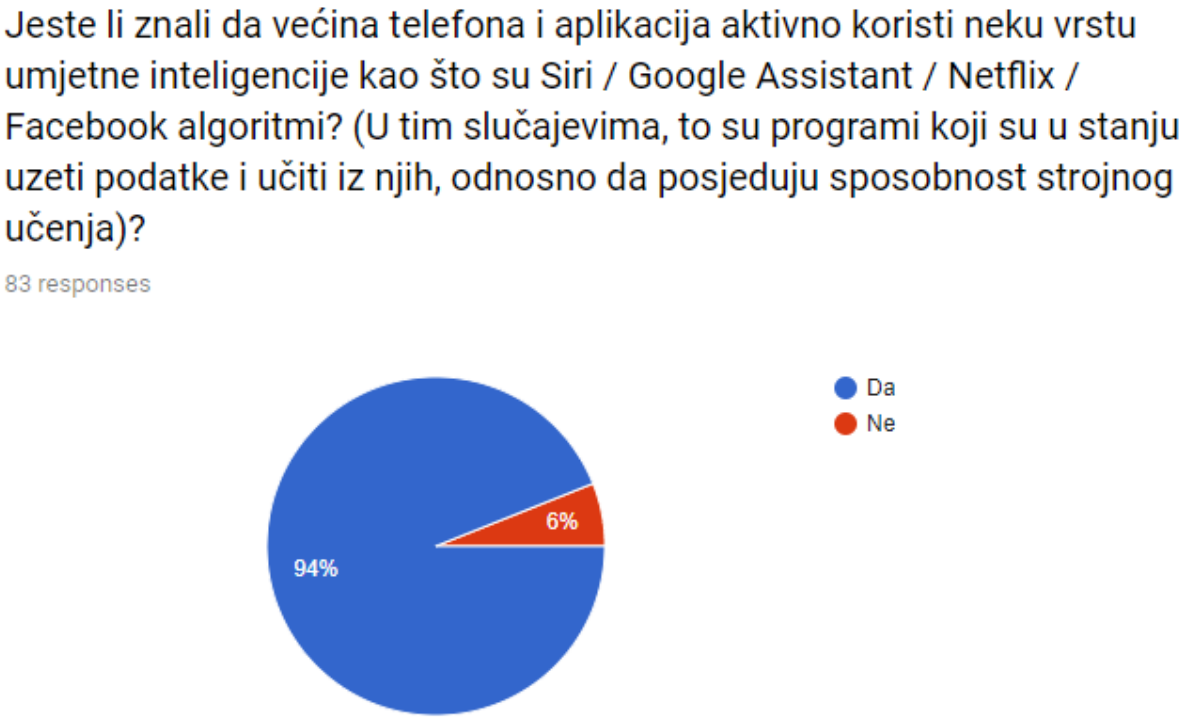
Iako su takvi sustavi dokazano učinkovitiji od ljudi, još uvijek postoji neka vrsta nepovjerenja prema njima, moguće zato jer je takva tehnologija na samim počecima razvoja, što se može vidjeti iz odgovora, malo više od pola ispitanika vjeruje automobilima s autonomnom vožnjom dovoljno da preveze njihovu obitelj.

U izvješću globalne potrošačke ankete Northstar Research Partners Ltd također malo više od pola ispitanika, točnije njih 55% vjeruje u sustave autonomne vožnje danas. Kada im se postavilo isto pitanje, ali za nekih 10ak godina, povećao se broj pozitivnih odgovora na 70% što pokazuje početni skepticizam prema takvim sustavima, no on se smanjuje s godinama razvoja i implementacije.

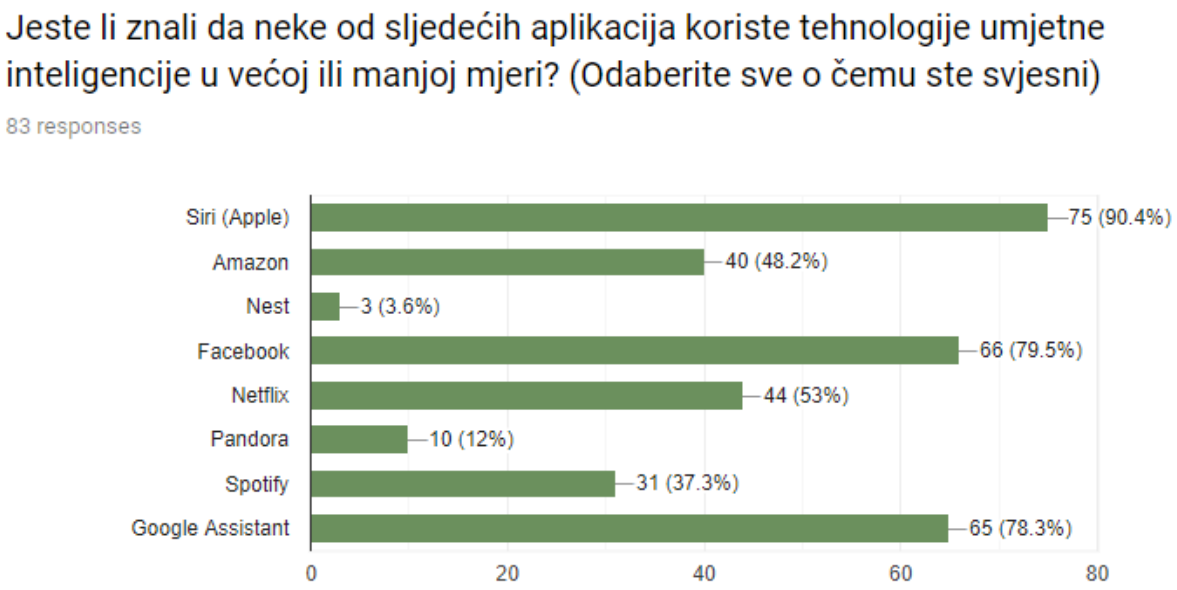


Slika 19. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a

Iako je većina ispitanika na prvo pitanje odgovorila da bi se osjećali i uplašeno i sigurno kada bi umjetna inteligencija bila implementirana u njihove uređaje, većina njih je ipak svjesna da se takva tehnologija već nalazi u njihovim pametnim telefonima i aplikacijama koje koriste.



Slika 20. Strojno učenje u telefonima i aplikacijama



Slika 21. Svjesnost o umjetnoj inteligenciji u aplikacijama

Očekivano najviše rezultate imaju Appleova digitalna asistentica Siri, Googleov Asistent i Facebook. Zanimljivo je da postoji visoka svijest u postojanju umjetne inteligencije u Netflixu i Spotifyu. Rezultati za Amazon su ispod očekivanja jer je su oni jedni od prvih poduzeća koja su implementirala umjetnu inteligenciju u svoje poslovanje i napravili su veliku marketinšku kampanju o tome.

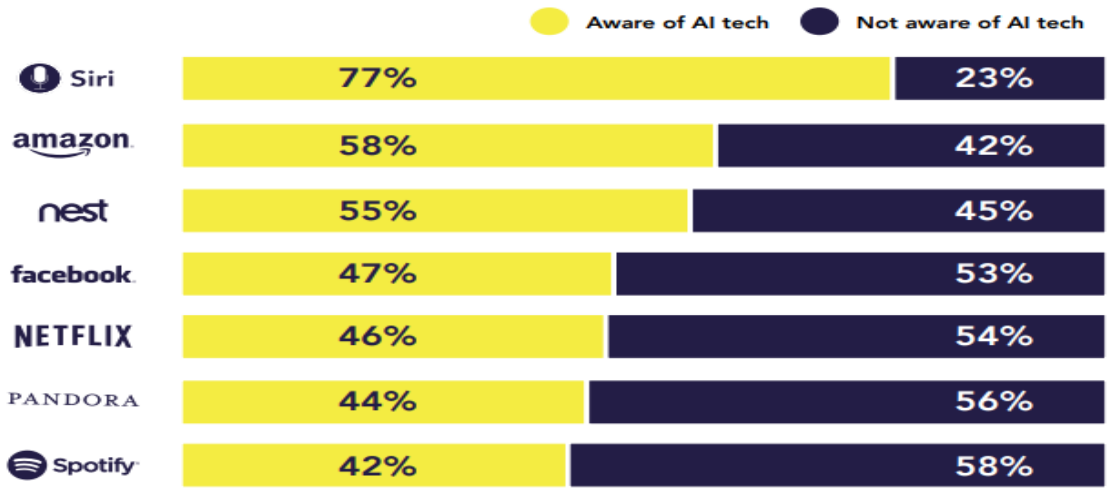
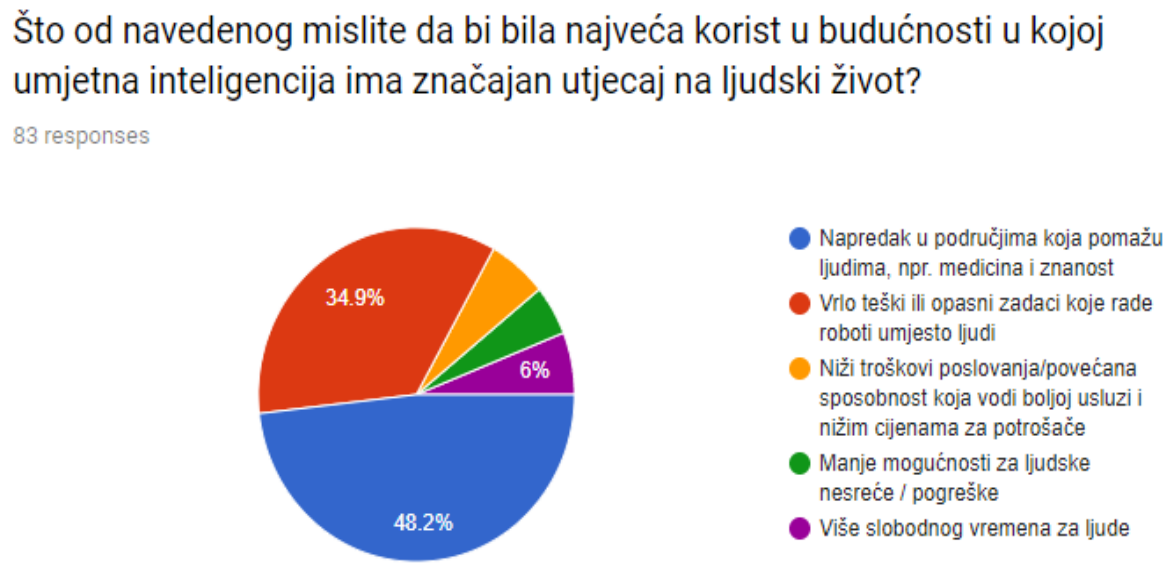


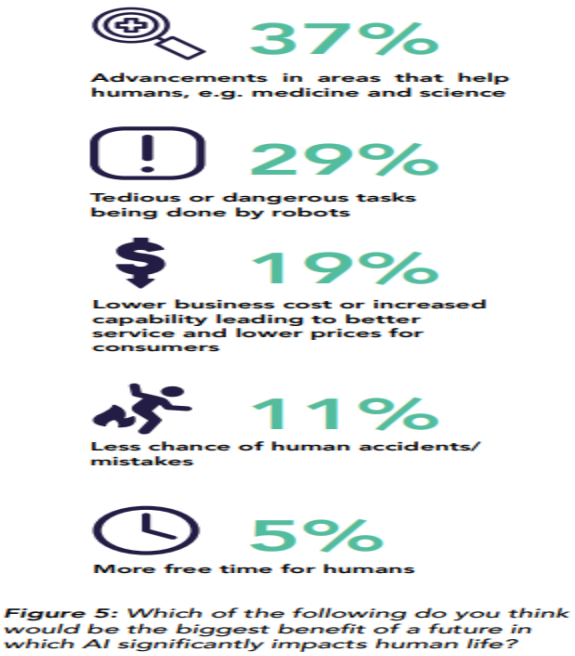
Figure 3: Were you aware that some/all of the following applications use AI-style technologies? (Choose all that you are aware of)

Slika 22. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a

Kada pričamo o koristima umjetne inteligencije za čovječanstvo, oba istraživanja daju približno identične rezultate. Većina smatra da će autonomni sustavi donijeti najviše koristi u medicini i znanosti te teškim i opasnim zadacima koji će takvi sustavi raditi umjesto ljudi.

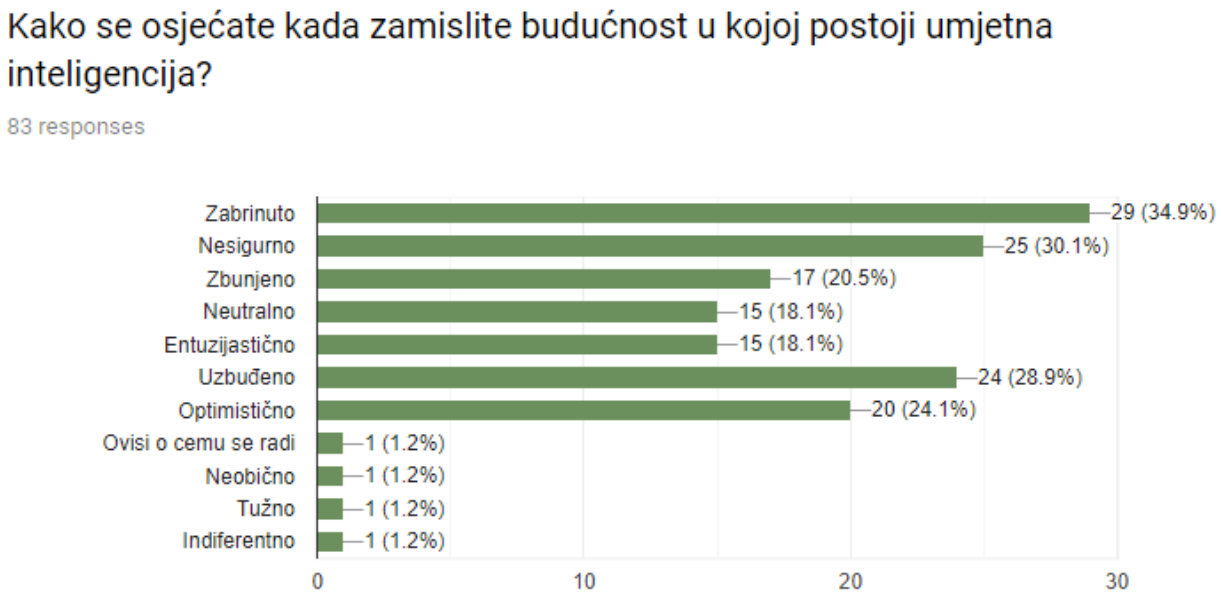


Slika 23. Polja najveće koristi od umjetne inteligencije



Slika 24. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a

Kada se priča o budućnosti i svijetu gdje umjetna inteligencija ima značajnu ulogu u našim životima, uspoređujući istraživanja, rezultati su potpuno suprotni. Kod nas prevladavaju negativni osjećaji poput zabrinutosti, nesigurnosti i zbunjenosti, dok u svijetu prevladavaju pozitivni kao što su optimističnost, uzbuđenost i entuzijastičnost. Broj ljudi koji su neutralni je približno jednak.



Slika 25. Osjećaji u vezi budućnosti s umjetnom inteligencijom

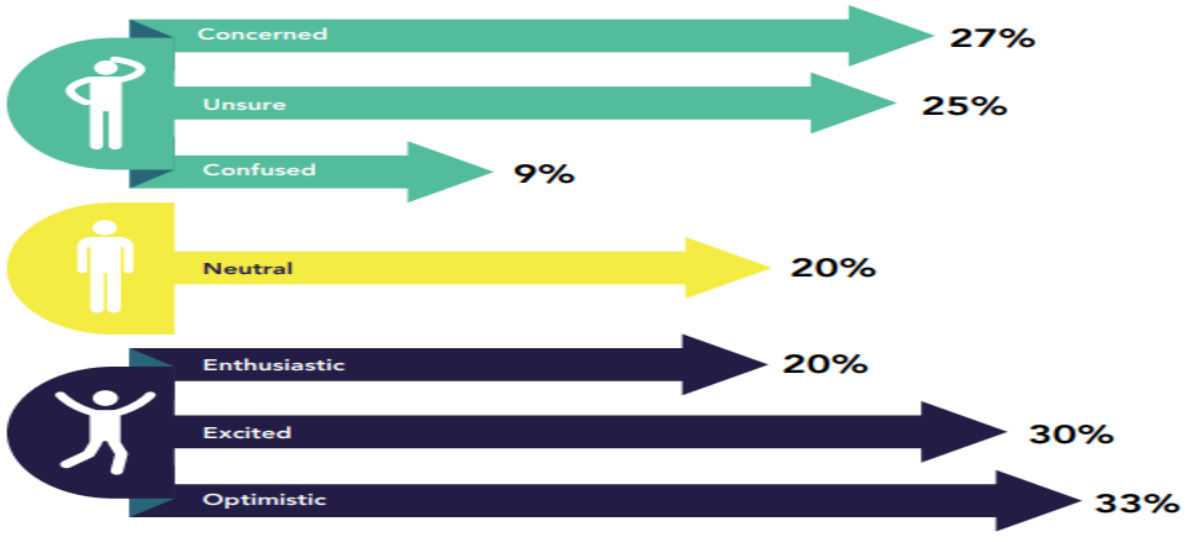
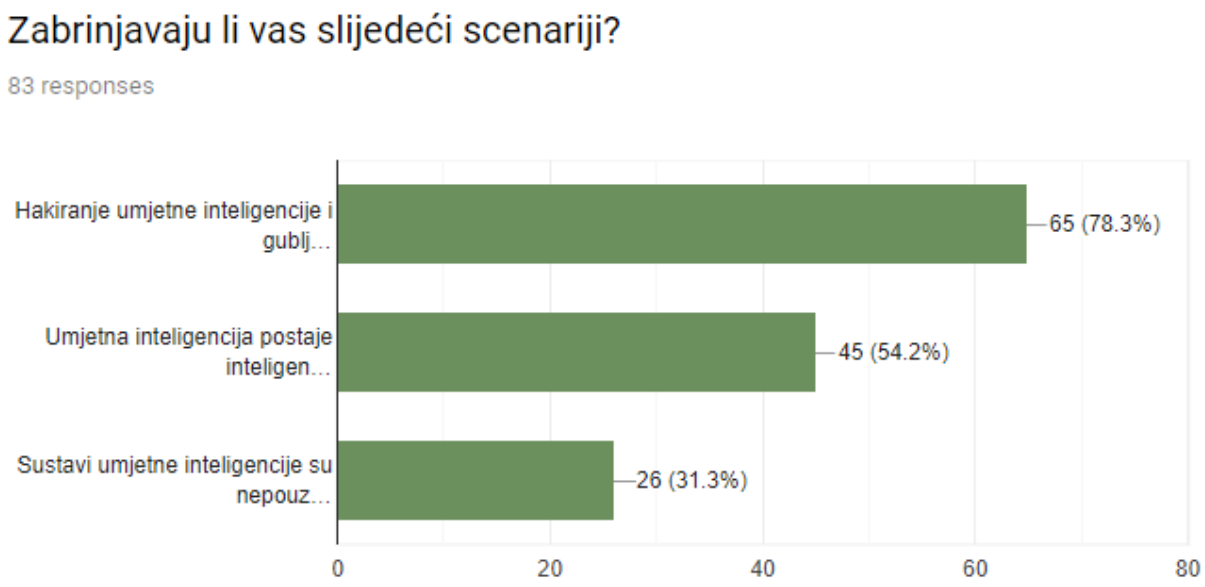


Figure 6: How does the prospect of an AI future make you feel? (Select all that apply)

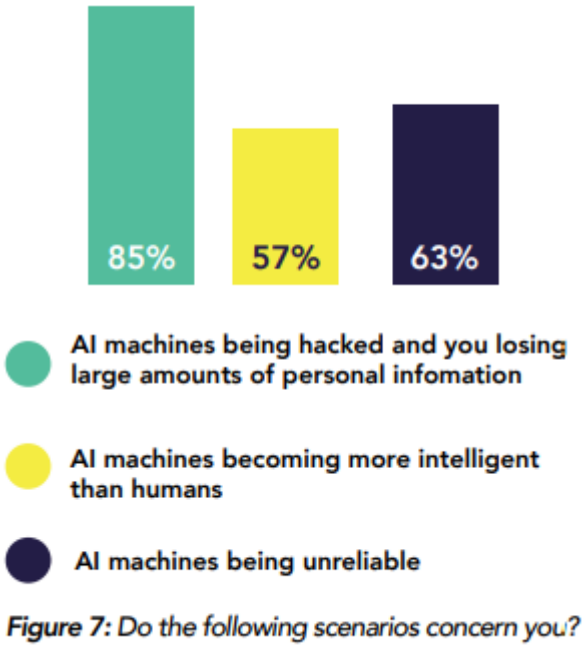
Slika 26. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a

Naravno, postoje brojni rizici i izazovi pri dizajniranju, implementiranju i korištenju umjetne inteligencije. Izdvojili smo tri najčešće spominjana te pitali ispitanike zabrinjavaju li ih navedeni scenariji. Hakiranje umjetne inteligencije i gubljenje velike količine osobnih podataka je na prvom mjestu, scenarij koji je izabralo 78,3% ispitanika. Zatim slijedi zabrinutost da će umjetna inteligencija postati inteligentnija od ljudi 54,2% te na kraju da će sustavi umjetne inteligencije postati nepouzdani 31,3%. Zanimljivo je vidjeti kako su ispitanici zabrinutiji zbog inteligentnijih sustava od ljudi, što ne treba nužno značiti da je to loše, od sustava koji su nepouzdani i ne isporučuju konzistentno točne rezultate.



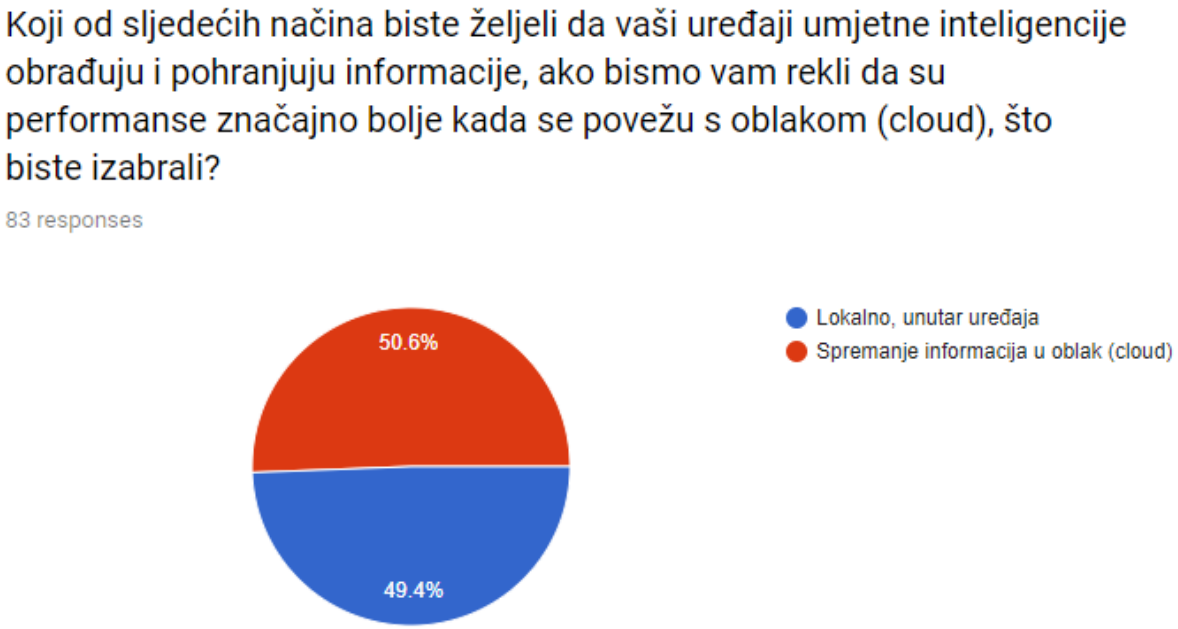
Slika 27. Zabrinutost o umjetnoj inteligenciji - scenariji

Uspoređujući rezultate dvaju istraživanja, zajednički rezultat je prvi scenarij za koji je glasalo najviše ispitanika u oba istraživanja, međutim u globalnoj potrošačkoj anketi Northstar Research Partners Ltd u ime ARM-a, na drugom mjestu su sustavi umjetne inteligencije koji su nepouzdani, dok veća inteligentnost autonomnih sustava je na trećem mjestu.



Slika 28. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a

Što se tiče načina i pohranjivanja podataka, cloud pohranjivanje pobjeđuje za 1 glas.



Slika 29. Obrađivanje i pohranjivanje osobnih podataka

Globalna mišljenja i stavovi hrvatskih studenata o nedostacima umjetne inteligencije se razlikuju.



Slika 30. Nedostaci umjetne inteligencije

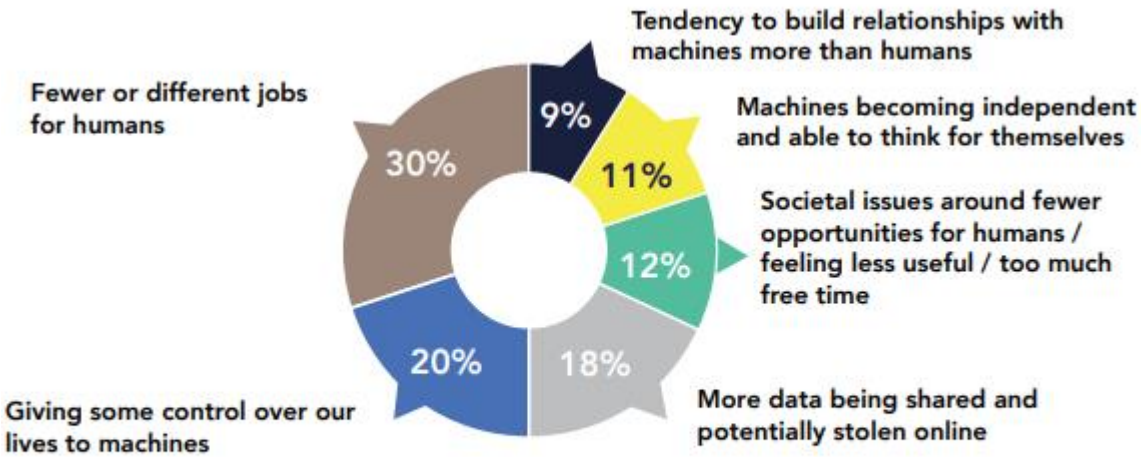
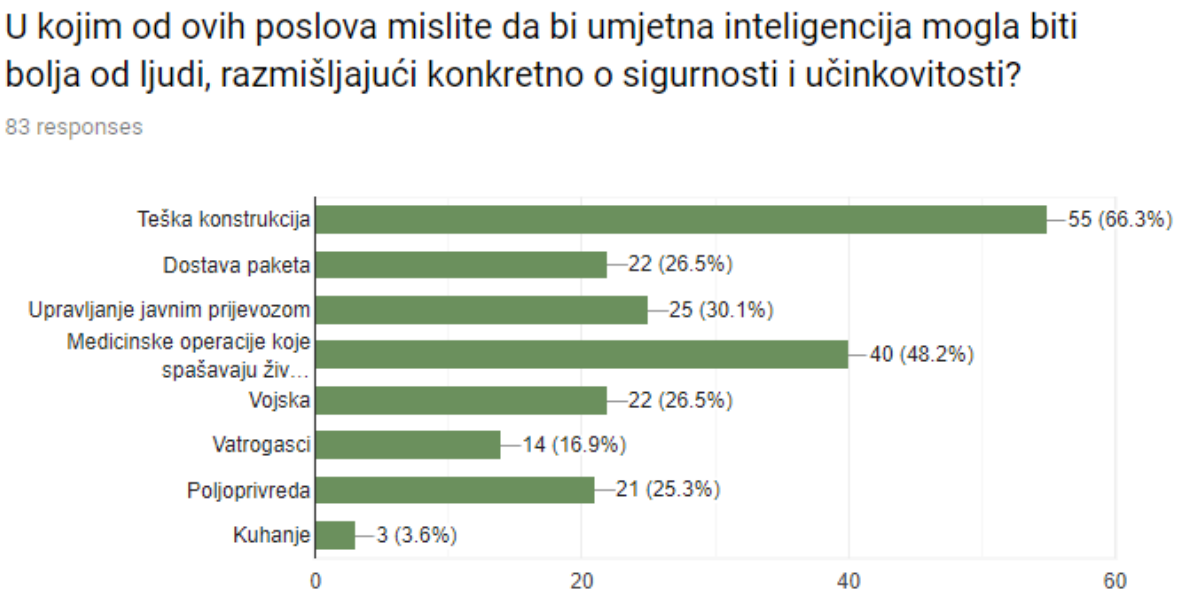


Figure 9: Which of the following do you think would be the biggest drawback of a future in which AI significantly impacts human life?

Slika 31. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a

Idućih nekoliko grafikona predstavljaju gotovo pa identične ostvarene rezultate u istraživanju provedenom za potrebe ovog diplomskog rada i globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a.



Slika 32. Poslovi bolje učinkovitosti umjetne inteligencije od ljudi

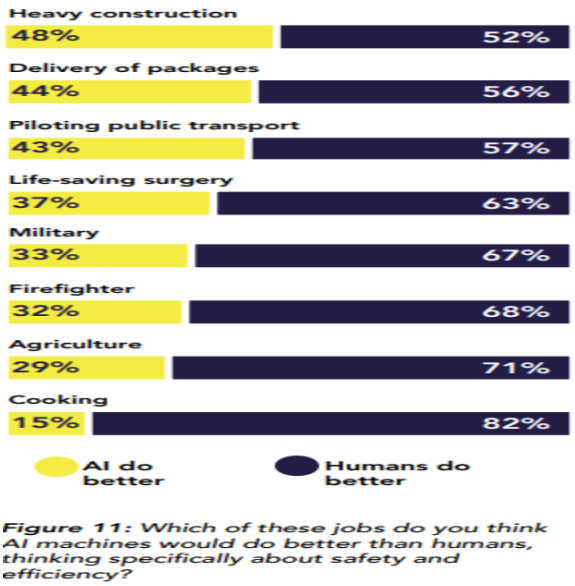
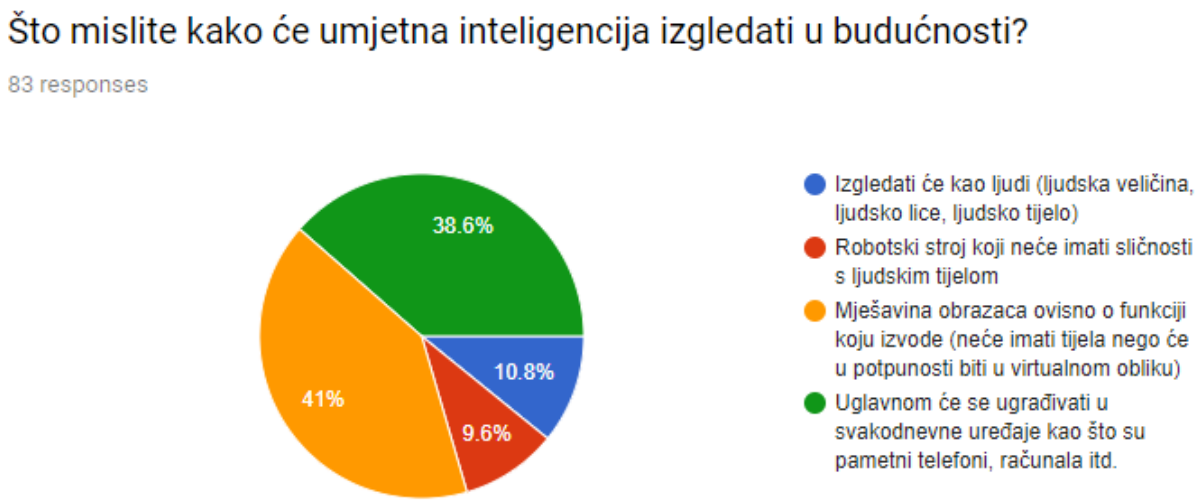


Figure 11: Which of these jobs do you think AI machines would do better than humans, thinking specifically about safety and efficiency?

Slika 33. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a



Slika 34. Izgled umjetne inteligencije u budućnosti

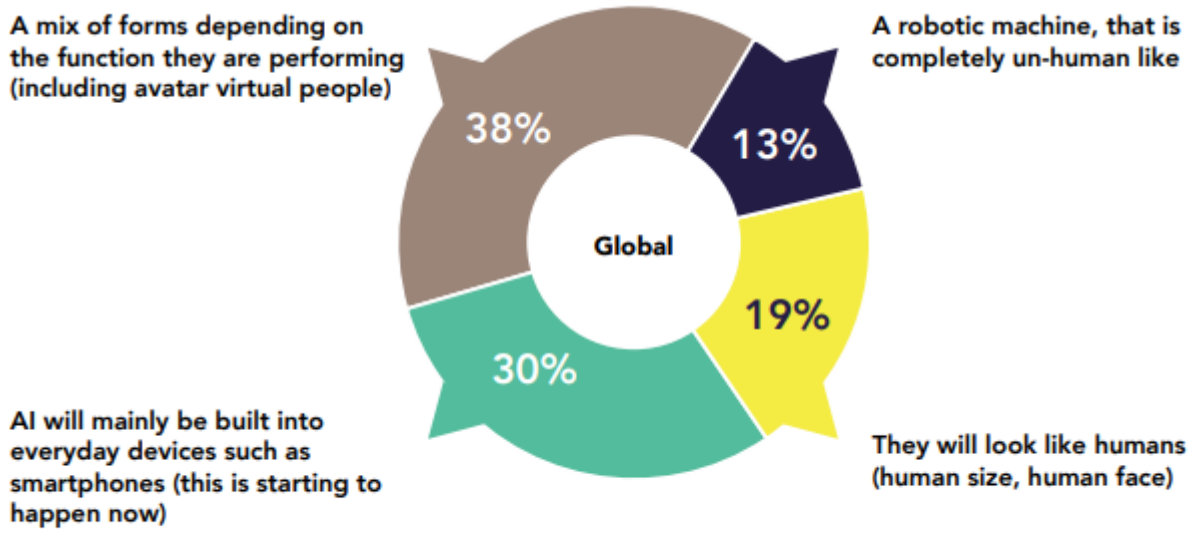


Figure 12: *What do you think future AI robots will look like?*

Slika 35. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a



Slika 36. Najprivlačniji načini korištenja umjetne inteligencije

Medicinske aplikacije koje će dijagnosticirati bolesti puno ranije 80,7%, kontrola prometa koja mijenja svjetla na semaforima i prati protok vozila u stvarnom vremenu, kako bi smanjila gužve 55,4%, osobni pratioci i asistenti, npr. sa sposobnošću da se brinu o starijim osobama 50,6%, potpuno autonomna vozila koja bi bila daleko sigurnija 42,2%, pozivni centri s razumijevanjem bilo kojeg jezika, u svrhu rješavanja problema ili pitanja 38,6%, kuće i uredi koji instinktivno reagiraju na potrebe korisnika 30,1%.

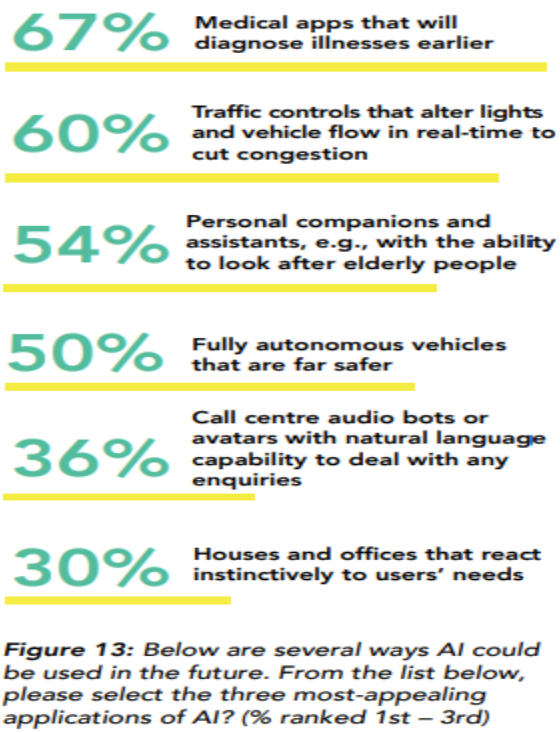
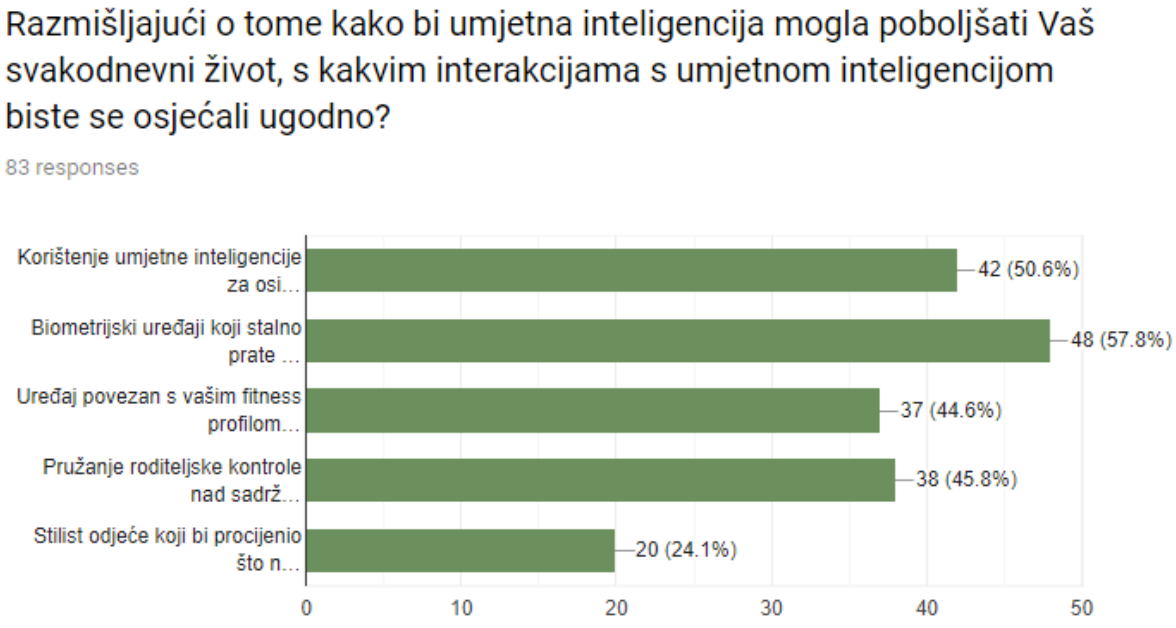


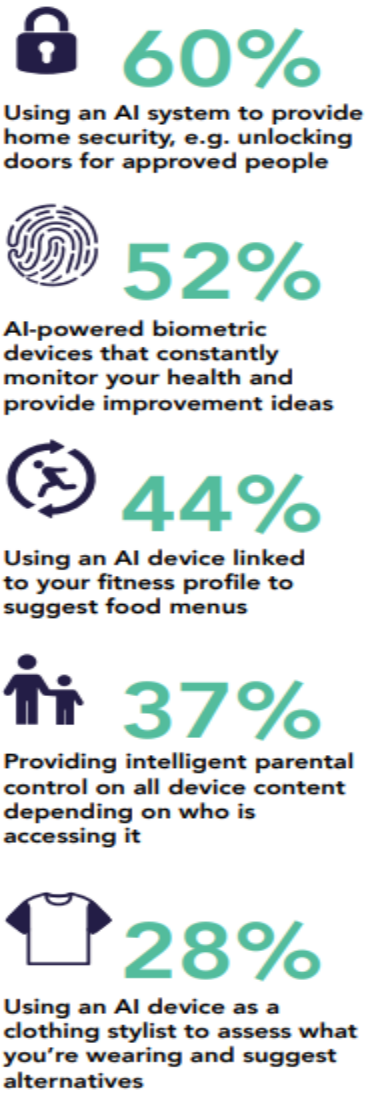
Figure 13: *Below are several ways AI could be used in the future. From the list below, please select the three most-appealing applications of AI? (% ranked 1st – 3rd)*

Slika 37. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a



Slika 38. Interakcije s umjetnom inteligencijom

Korištenje umjetne inteligencije za osiguranje sigurnosti doma, npr. otključavanje vrata za odobrene osobe 50,6%, biometrijski uređaji koji stalno prate vaše zdravlje i pružaju ideje za poboljšanje 57,8%, uređaj povezan s vašim fitness profilom kako bi predložio izbornike hrane 44,6%, pružanje roditeljske kontrole nad sadržajem koji se nalazi na uređajima, ovisno o tome tko pristupa tom uređaju 45,8%, stilist odjeće koji bi procijenio što nosite te predložio nove proizvode i alternative koje odgovaraju vašem profilu 24,1%.



Slika 39. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a

Iako umjetna inteligencija pruža neke bolje usluge od ljudi, sudionici i dalje preferiraju ljudsku stranu od umjetne, rezultati ovog istraživanja na to pitanje daju jednoznačni odgovor.



Slika 40. Odlazak ljudskom liječniku ili liječniku umjetne inteligencije

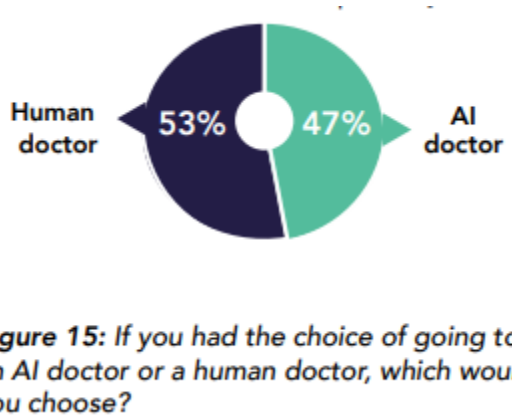
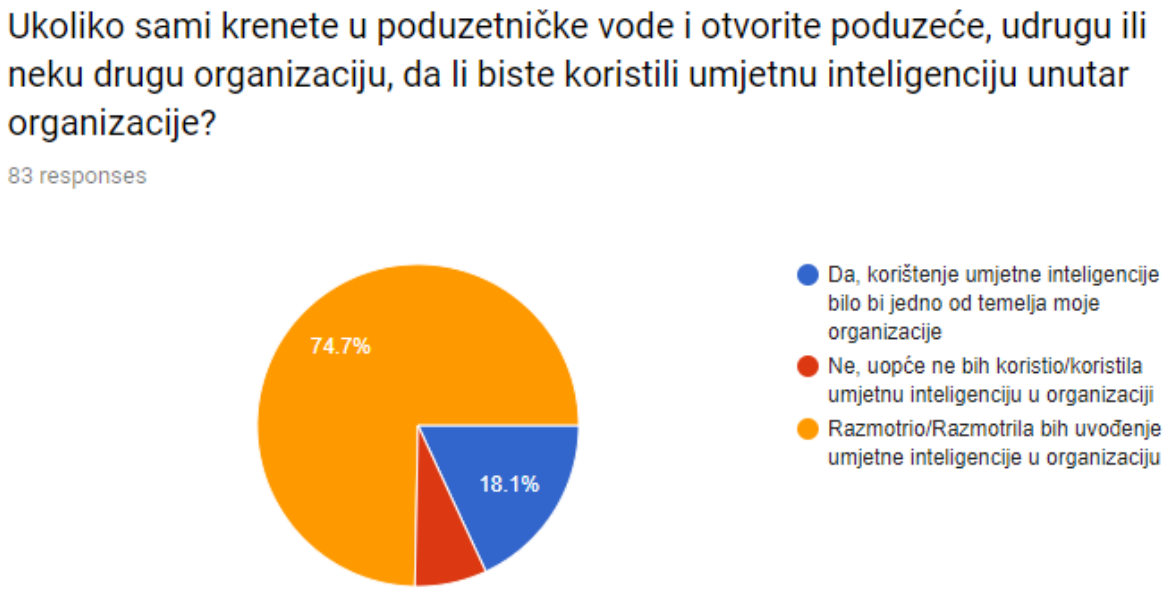


Figure 15: *If you had the choice of going to an AI doctor or a human doctor, which would you choose?*

Slika 41. Izvješće globalne potrošačke ankete Northstar Research Partners Ltd u ime ARM-a



Slika 42. Korištenje umjetne inteligencije unutar vlastite organizacije

Iako su sustavi umjetne inteligencije od velike koristi i posjeduju enorman potencijal za daljnji razvoj, ispitanici istraživanja provedenog u svrhu ovog diplomskog rada su veoma skeptični i nepovjerljivi prema njima, suprotno od nekakvog globalnog razmišljanja. Najviše se strahuje da će umjetna inteligencija zamijeniti ljude na poslovima, doseći viši stupanj inteligencije te izaći izvan naše kontrole. To sve, dakako, ne mora značiti loše vijesti za nas ljude, no rezultati ovog istraživanja pokazuju da tako većina ispitanika razmišlja.

5. ZAKLJUČAK

U suvremenom razdoblju ekonomije poslovanje i poslovni procesi mijenjaju se iz korijena uvođenjem novih tehnoloških, komunikacijskih i informacijskih tehnologija te se transformira u tzv. digitalnu ekonomiju, koja obuhvaća sve sfere i područja poslovanja. Usporedno s ljudskim napretkom razvijala se i tehnologija, eksponencijalno bržim rastom od razvoja ljudi. Ekonomija i poslovanje su daleko dogurali od razmjene školjaka, krzna, stoke, dragog kamenja i plemenitih metala za raznorazna dobra i usluge. Svjedoci smo sve veće digitalizacije i robotizacije poslovanja, pružanja dobara i usluga, koji utječu ne samo na ekonomiju u globalnom pogledu već i na naš privatni život.

Bilo to poslovanje banaka, odobravanje kredita, kupnja i dostava stvari preko interneta, pomoć virtualnih asistenata, financijske transakcije koje uopće ne uključuju fizički oblik novca ili sve veća prisutnost strojeva u poljoprivredi i drugim industrijama koji zamjenjuju ljudski rad i znoj.

Temeljni pokretači gospodarskog rasta oduvijek su bile tehnološke inovacije. One najvažnije, koje su imale najveći utjecaj na naš život, ekonomski stručnjaci zovu tehnologije opće namjene. Najvažnija tehnologija opće namjene naše ere jest umjetna inteligencija, koja je ujedino i kamen temeljac četvrte industrijske revolucije koja se vrti oko digitalizacije poslovanja i digitalne transformacije organizacija.

Kao što smo raspravili u drugom poglavlju, vrlo je teško definirati inteligenciju. Ako nečiji mozak ili sustav raspolaže velikim brojem informacija, to ne znači nužno da ta osoba ili sustav iskazuje inteligenciju. Iako se svi slažemo da inteligencija ima neke veze sa znanjem i sposobnošću za rasuđivanje, čini se da ljudska inteligencija nadilazi tu svijest ili samosvijest, mudrost, emocije, simpatije, intuiciju i kreativnost. Nekima inteligencija uključuje i duhovnost - povezanost s većom silom ili bićem.[75] Općenito, inteligencija je sposobnost razumijevanja objektivnog svijeta i primjene znanja za rješavanje problema.

Danas umjetna inteligencija je impresivna kada je u okruženju gdje su pravila jasna i mogućnosti ograničene. Organizacije kao Google imaju najviše koristi od implementacije umjetne inteligencije jer rade u dobro definiranom prostoru s jasno postavljenim pravilima. Iako većina ljudi nije toga svjesna, umjetna inteligencija nalazi se svuda oko nas, u telefonima, automobilima, bolnicama, bankama, medijima, društvenim mrežama itd.

Takvi sustavi umjetne inteligencije koriste strojno učenje – sposobnost stroja da stalno poboljšava svoje performanse, a da ljudi ne moraju točno objasniti kako ispuniti sve zadatke koji su mu zadani. Strojno učenje pokreće promjene na tri razine: zadacima i zanimanjima, poslovnim procesima i poslovnim modelima.[76]

[75] Rose, D. (2018). Artificial Intelligence for Business- What you need to know about Machine Learning and Neural Networks. Chicago Lakeshore Press

[76] Brynjolfsson E., Mcaffe A. (2017) The Business of Artificial Intelligence, How AI Fits into Your Science Team; What it can – and cannot – do for your organization. Dostupno na: https://hbr.org/cover-story/2017/07/the-business-of-artificial-intelligence [23.06.2019]

Umjetna inteligencija nije programirana za točno određeni ishod, već uči iz primjera. Dosadašnja praksa bila je usredotočena na kodiranje postojećih znanja i postupaka u strojeve. Strojno učenje spada u područje slabe umjetne inteligencije jer ono ne razumije što se govori nego samo povezuje simbole i značenje te identificira uzorke. Velika je razlika leži u tome što računalo samo prepoznaju uzorke u podacima, umjesto da to pruža programer, tj. računalo s vremenom postaje „pametnije“. Jedan od razloga velikog razvoja u ovom polju posljednjih godina leži u tom što smo naučili artikulirati vlastito znanje.

Uz strojno učenje, glavne uzdanice izvlačenja koristi iz sustava umjetne inteligencije su duboko učenje i neuronske mreže. Duboko učenje sastoji se od mnogih hijerarhijskih slojeva koji obrađuju informacije na nelinearni način, gdje neki koncept niže razine pomaže u definiranju koncepata više razine. Uz duboko učenje, moguće je prepoznati, klasificirati i kategorizirati obrasce u podacima za stroj uz relativno manje napora.

Umjetne neuronske mreže inspirirane su ljudskim mozgom, koji je sastavljen od tkiva, žila, sive i bijele moždane tvari te neurona. Zadatak neurona je prihvaćanje, obrađivanje i odašiljanje podataka. Fizički elementi koji tvore umjetne neuronske mreže jest hardware računala, odnosno žice, cijevi, matične ploče, procesori, radna memorija itd. Također neuronska mreža sastoji se od tzv. računalnih čvorova (eng. nodes) koji su ekvivalent neuronima u ljudskom mozgu. Svaki čvor prihvaća i kombinira zadane ili poslane inpute, izvodi nekakvu funkciju nad tim podacima te proizvodi rezultat tj. output. Taj rezultat se može prenijeti na druge računalne čvorove radi dodatne obrade.

Tokom godina razvoja umjetne inteligencije razvila su se dva različita pristupa ili smjera shvaćanju umjetne inteligencije. Prvi pristup povezan je s MIT-om i zagovornici ovoga smjera kao umjetnu inteligenciju vide svaki sustav koji pokazuje karakteristike inteligentnog ponašanja. Nije važno izvršava li sustav neki zadatak na isti način kao što to rade ljudi, već jedini kriterij je da program ispravno radi, tj. da isporuči isti, točni, rezultat. Ovakva umjetna inteligencija smatra se slabom umjetnom inteligencijom jer iako može imati karakteristike ljudske inteligencije to i dalje ne znači da postoje neki kognitivni procesi unutar tog sustava, već se samo oponaša već viđeno ponašanje.

Slaba umjetna inteligencija je usko specijalizirana što znači da koristi svoje resurse i znanje kako bi riješila točno određen problem, nema mogućnost generalne primjene tog znanja, odnosno bavljenja zadacima koji nisu u točnom određenom spektru njezinih sposobnosti. Ti sustavi su dizajnirani za jedan određeni zadatak i njihove mogućnosti nisu lako prenosive na druge sustave. Drugi pristup shvaćanja umjetne inteligencije predstavlja sveučilište Carnegie – Mellon, te ovaj pristup prije svega bavi se biološkom uvjerljivošću. To znači da kada neki sustav pokazuje inteligentno ponašanje, njegovo izvođenje mora se temeljiti na istim metodologijama koje koriste ljudi. Zagovornici ovog drugog smjera fokusiraju se, uz performanse, na strukturu sustava i kako dijelovi tog sustava međusobno komuniciraju. Jaka umjetna inteligencija, u teoriji, u tolikoj mjeri je razvijena da može razmišljati na istoj razini kao čovjek te svoje znanje i vještine primjenjuje generalno na sve situacije.

Većina sustava umjetne inteligencije u poslovanjima danas stvara značenje iz prikupljenih podataka poduzeća u kojem su implementirana s ciljem korištenja tog značenja kako bi se usmjerile buduće poslovne odluke. Takvi sustavi poznati su pod nazivom poslovna inteligencija (Business Intelligence). Prikupljene podatke poslovna inteligencija koristi kako bi poboljšala i učvrstila poziciju poduzeća na vanjskom tržištu ostvarujući pozitivne poslovne rezultate te istovremeno stabilizirala unutarnju organizacijsku kulturu i zadovoljstvo zaposlenika.

Trenutačna rješenja utemeljena na umjetnoj inteligenciji vrlo su dobra u pojednostavljivanju procesa i preuzimanju radnih zadataka poput pokretanja workflowa ili poslovnog procesa. Automatizacija oslobađa kognitivno opterećenje zaposlenika kako bi se oni mogli usredotočiti na važnije aspekte svog posla. Na taj se način smanjuje mogućnost pogreške i uklanjaju se najnaporniji dijelovi posla.

Automatizacija stručnosti, inteligentna automatizacija pravnih ekspertiza i procesa omogućava jednostavan način kreiranja koraka ili virtualnih pomoćnika za usklađivanje i regulatorna pitanja u određenom sektoru ili pravnom polju. Za razliku od ljudskih pravnika, softver za automatizaciju stručnosti nema određeno radno vrijeme, što olakšava pristup pravnom znanju za odgovor na uobičajena pitanja.

Većina tvrtki ima mnogo digitalnih tokova koji se ponavljaju. Zaposlenici odgovorni za ove zadatke mogu lako postati dosadni i nepažljivi, omogućujući greške u poslovanju i podacima.

Srećom, ovi zadaci dobro su prilagođeni za automatizaciju od strane robotske procesne automatizacije (RPA), koji su softverski roboti programirani za izvođenje određenog slijeda radnji. Što je još bolje, implementacija RPA relativno je brza i s malim rizikom, tako da se problematični roboti mogu brzo ukloniti bez štete za postojeće sustave.

Umjetna inteligencija ima brojne prednosti poput otkrivanja smislenih i korisnih uzoraka u velikim količinama podataka bilo koje vrste, uključujući tekst, slike, video i druge nestrukturirane podatke. Modeli samo-učenja sustava umjetne inteligencije omogućuju poduzeću da se brzo prilagodi promjenama u obrascima svojih podataka i temeljnim uvjetima poslovanja. Donose se bolje i brže odluke maksimiziranjem vrijednosti svih podataka i prelaskom iz prediktivne analitike u propisivačku.

Za razliku od ljudi, današnjim sustavima umjetne inteligencije potrebni su ogromni klasteri podataka kako bi nešto naučili, potrebno je dobavljanje velikih količina kvalitetnih podataka koji se daju sustavu, što je svakako nedostatak. Kad je u pitanju učenje, strojevi mogu griješiti na isti način kao ljudi. Da bi umjetna neuronska mreža mogla učiti, morate joj pružiti dobre podatke i veliku količinu istih. Samo parametriziranje podataka od strane ljudi zahtjeva ne malu količinu vremena dok ovakva osnovna obuka sustava umjetne inteligencije, također, iziskuje dosta vremena.

Stvaranje umjetne inteligencije zahtijeva velike troškove jer su to vrlo složeni sustavi čiji popravci i održavanje zahtijevaju visoke troškove. Imaju softverske programe koji zahtijevaju učestale nadogradnje da bi udovoljili potrebama promjenjivog okruženja i da budu pametniji iz dana u dan. U slučaju ozbiljnih kvarova, postupak vraćanja izgubljenih kodova i podataka te ponovno postavljanje sustava može zahtijevati ogromne troškove.

Također jedan od većih nedostataka je rizik od cyber napada i hakiranje sustava umjetne inteligencije, čime bi došlo do gubitka velike količine podataka. Važno je minimalizirati takve prijetnje i razviti moguće scenarije kako bi se smanjila mogućnost štetnog djelovanja u slučaju takvih proboja sigurnosti.

5.1. Što budućnost nosi?

Pretpostavimo da postoji umjetna inteligencija koja može predvidjeti nesigurnost na tržištu, u prvom redu potrebe i želje potencijalnih kupaca. Predviđanje je toliko jeftino da umanjuje neizvjesnost dovoljno da promijeni prirodu strateške dileme. U ovom slučaju, količinu posjedovanja vlastitog kapitala. Povećava se broj pouzdanih „ako“ scenarija, smanjujući tako potrebu poduzeća da posjeduje vlastitu kapitalnu opremu iz dva razloga.

Veća pouzdanost „ako“ scenarija za posljedicu bi imala većinu ugovora kojima se određuje što se treba učiniti ako nastupi neka neobična pojava. Uzmimo za primjer zrakoplovne kompanije. Umjetna inteligencija bi omogućavala predviđanje vremenskih (ne)prilika i generirala procedure kako se najbolje nositi s prekidima letova u stanju vremenskih neprilika i elemntarnih nepogoda. Ugovori bi postali specifičniji jer bi fokus bio na rješavanju izvanrednih situacija.

Umjesto kontroliranja zrakoplovnih ruta putem vlasništva kapitalne opreme (aviona, terminala, zaposlenika) zrakoplovne tvrtke bi potpisivale ugovore s neovisnim regionalnim prijevoznicima kako bi iskoristile niže troškove tih prijevoznika.[77] Također to povlači za sobom niže troškove poslovanja zbog manjeg udjela vlasničkog kapitala jer bi većina letova bila na leđima manjih regionalnih prijevoznika.

Pouzdanost predviđanja potreba i želja potrošača dalo bi samopouzdanje proizvođačima dobara i usluga da unaprijed dizajniraju proizvode i usluge koji će dovesti do velikog zadovoljstva među potrošačima. U auto industriji to bi značilo da bi prošlo manje vremena između pojedinih modela i ne bi bilo potrebe za prilagođavanjem pojedinog modela usred njegovog životnog vijeka. Slijedom toga, proizvođači automobila mogli bi od najboljih neovisnih dobavljača odabrati najbolje svjetske dijelove za svoje modele, uvjereni da predviđanje umjetne inteligencije unaprijed eliminira potrebu skupih pregovora. Smanjila bi se potreba za tvornicama i proizvodnjom vlastitih dijelova. Ovo cijelo predviđanje temelji se na pretpostavci da za većinu „ako“ scenarija jasno odredimo „tada“ ishode.

Ova procjena drži složenost zrakoplovnih mreža i automobilskih proizvoda fiksnom. Moglo bi se dogoditi da točna predviđanja umjetne inteligencije pruže prijevoznicima i proizvođačima automobila povjerenje da omoguće složenije dogovore, proizvode i usluge.

[77] Agrawal, A., Gans, J. & Goldfarb, A. (2018). Prediction Machines- The Simple Economics of Artificial Intelligence. Boston~1

Nije jasno kakav bi utjecaj na outsourcing umjetna inteligencija mogla imati budući da bolja predviđanja vode k više outsourcinga, dok veća razina složenosti isti taj outsourcing smanjuje. Jedan od ključnih izazova korištenja umjetne inteligencije u budućnosti svakako će biti otvorenost podataka koji su potrebni za njezinu obuku, te pristup odgovarajućim računalnim resursima. Također pravne i zakonske regulative igrati će veliku ulogu u razvoju i primjeni tih sustava kako bi se sačuvale građanske slobode i etički okviri za njihovo upravljanje. Ne smije se zaboraviti podjela odgovornosti za postignute rezultate autonomnih sustava, između programera i stroja i u kojoj mjeri?

Otkada se dogodila eksplozija informacijske tehnologije i otkada je ona postala „must have" bilo kojeg poduzeća koje želi rasti, razvijati se i dominirati tržištem postalo je vrlo važno kako na pravi način iskoristiti dostupne tehnologije kao bismo odgovorili na nove trendove i izazove u ekonomiji i poslovanju. U današnje vrijeme informacijska tehnologija i digitalizacija poslovanja više nisu recepti za dominaciju i monopol nad tržištem, već ključni resursi i filozofija poslovanja koja omogućuje preživljavanje na stalno rastućem tržištu i koja je odgovor na sveprisutnu promjenu, kako na tržištu, kod konkurenata, potrošača ili načina poslovanja. Samo investiranje u digitalizaciju poslovanja i informacijsku tehnologiju ne jamči pozitivne rezultate samo po sebi, potrebno je vrlo kvalitetno planiranje i implementacija, koje, ukoliko su kvalitetno napravljene, mogu donijeti puno pozitivnoga za poduzeće. Informacijska tehnologija i digitalizacija poslovanja poduzeću može u isto vrijeme biti i najbolji prijatelj i najgori neprijatelj pa je od kritične važnosti provesti pomno planiranje i opreznu implementaciju novih sustava kako bi poduzeće ostvarilo koristi, a ne probleme digitalizacije.

Sve što je stvoreno na ovom svijetu i u našim pojedinačnim društvima kontinuirani je rezultat inteligencije. Umjetna inteligencija povećava i osnažuje ljudsku inteligenciju i sve dok smo uspješni u održavanju korisne tehnologije, moći ćemo pomoći civilizaciji. Na samom kraju, nakon svih misli, stavova i predviđanja, autor ovog rada nudi jedan citat Alana Turinga koji zaista savršeno opisuje sadašnje i buduće stanje umjetne inteligencije te potencijal koji ona posjeduje.

„We can only see a short distance ahead, but we can see plenty there that needs to be done."[78]

(Iako vidimo kratku udaljenost u budućnost, vidimo puno toga tamo što se treba napraviti.)

[78] A. M. Turing (1950) Computing Machinery and Intelligence. Mind 49: 433-460.

6. LITERATURA

1. Agrawal, A., Gans, J. & Goldfarb, A. (2018). Prediction Machines- The Simple Economics of Artificial Intelligence. Boston~1
2. Anderson M., Anderson S.L. (2007) Machine Etics: Creating an Ethical Intelligent Agent. AI Magzine, Vol 28 No
3. Atzori, L., Iera, A., Morabito, G. (2010) The internet of things: A survey, Computer Networks, vol. 54, no. 15, pp. 2787–2805
4. Akerkar, R. (2019). Artificial Intelligence for Business. Sogndal, Norway. Western Norway Research Institute.
5. Basara, B.N. (2017) Digitalna transformacija kao temelj 4. industrijske revolucije. Završni rad. Pula: Politehnika Pula, Visoka tehničko-poslovna škola
6. Berliner, H. J. and Ebeling, C. 1989. Pattern knowledge and search: The SUPREM architecture. Artificial Intelligence 38:161–196.
7. Brynjolfsson E., Mcaffe A. (2017) The Business of Artificial Intelligence, How AI Fits into Your Science Team; What it can – and cannot – do for your organization. Dostupno na: https://hbr.org/cover-story/2017/07/the-business-of-artificial-intelligence [23.06.2019]
8. Chui M., Manyika J., Miremandi M., Henke N., Chung R., Nel P., Malhotra S. (2017) McKinsey Global Institute, Discussion paper. Dostupno na: https://www.mckinsey.com/featured-insights/artificial-intelligence/notes-from-the-ai-frontier-applications-and-value-of-deep-learning
9. Cockburn, I.M. i Henderson, R. i Stern, S. (2018) The impact of Artificial Intelligence on Innovation. National bureau of economic research, Cambridge
10. Csail, A. C. (2017) Using artificial intelligence to improve early detection of breast cancer. MIT News. Dostupno na: http://news.mit.edu/2017/artificial-intelligence-early-breast-cancerdetection-1017
11. Dietrich E. (2006) Homo Sapiens 2.0: why should we build the better robots of our nature. Binghamton University
12. Do we need Asimov's Laws? (2014) MIT Technology Review. Dostupno na: https://www.technologyreview.com/s/527336/do-we-need-asimovslaws/

13. Duhigg, C. (2012) How Companies Learn Your Secrets. The New York Times Magazine. Dostupno na: http://www.nytimes.com/2012/02/19/magazine/shopping-habits.html [25.07.2019.]
14. Gershgorn, D. (2016) Google Considers Creating "Big Red Button" Stop Dangerous A.I. In case of emergency. Popular science. Dostupno na: http://www.popsci.com/google-researches-big-redbutton-to-stopdangerous-ai
15. Globalna potrošačka anketa, Northstar Research partners Ltd u ime ARM-a. Dostupno na: https://www.arm.com/solutions/artificial-intelligence/survey
16. Heavin, C. i Power. D.J. (2018) Challenges for digital transformation – towards a conceptual decision support guide for managers. Journal of Decision System. Dostupno na: https://www.researchgate.net/publication/325027329_Challenges_for_digital_transformation_-_towards_a_conceptual_decision_support_guide_for_managers
17. Hebron, P. (2017) Thinking and design tools in the age of machine learning. Dostupno na: http://medium.com/artists-and-machineintelligence/rethinking-design-tools-in-the-age-of-machinelearning-369f3f07ab6c
18. Hsu, F-H., Anantharaman, T., Campbell, M., and Nowatzyk, A.1990. A grandmaster chess machine. Scientific American 2634.
19. IEEE Global Independent and Intelligent Systems Ethics Initiative. (2016) Ethically aligned design: a vision for prioritizing the well-being of humans with artificial intelligence and autonomous systems. Dostupno na: http://standards.ieee.org/develop/indconn/ec/autonomous_systems.html
20. IMB Data Science Meetup (2015)
21. Karpathy, A. (2017) Software 2.0 A Medium Corporation, Programming. Dostupno na: https://medium.com/@karpathy/software-2-0-a64152b37c35
22. Knight, W. (2016) Emotional intelligence might be a virtual assistant's secret weapon. MIT Technology Review. Dostupno na: http://www.technologyreview.com/s/601654/amazon-working-onmaking-alexarecognize-your-emotions/
23. Lucci, S. & Kopec, D. (2016). Artificial Intelligence in the 21st Century. Boston. Nakladnik: Boston - Mercury Learning and Information

24. Luger, G. F. 2002. Artificial Intelligence: Structures and strategies for complex problem solving. Reading, MA: Addison-Wesley.
25. Jovanović, M. Dlačić J. i Okanović M. (2018) Digitalization and society's sustainable development – Measures and implications. Zborni rad. Rijeka: Ekonomski fakultet u Rijeci
26. McCorduck, P. (2004) Machines Who Think, A.K. Peters, Ltd, Second Edition
27. McKinsey, (2016). The Age Of Analytics: Competing In AdataDriven World. Dostupno na: https://www.mckinsey.com/business-functions/ mckinsey-analytics/our-insights/the-age-of-analyticscompeting-in-a-data-driven-world
28. McKinsey Global Institute (2017), "Artificial Intelligence the Next Digital Frontier?"
29. Michie, D. L. 1986. On Machine Intelligence, 2nd edition. Chichester, England: Ellis Horwood
30. Nuculovic, N. (2016) Metcalfeov zakon. Dostupno na: https://nikolanuculovic.wordpress.com/2016/05/24/metcalfeov-zakon/
31. Raphael, B. 1976. The thinking computer. San Francisco, CA: W.H. Freeman.
32. Rose, D. (2018). Artificial Intelligence for Business- What you need to know about Machine Learning and Neural Networks. Chicago Lakeshore Press
33. Samim. (2015) Generating Stories about Images. Dostupno na: http://medium.com/@samim/generating-stories-about-imagesd163ba41e4ed
34. Schwab, K. (2016) The Fourth Industrial Revolution. Cologny, Switzerland:World Economic Forum
35. Schaeffer, J. (1997) One jump ahead. New York, NY: Springer-Verlag.
36. ScienceDaily, Institute of Cancer Research (2019). Dostupno na: https://www.sciencedaily.com/releases/2019/08/190802131354.htm
37. Shannon, C. E. 1950. Programming a computer for playing chess. Philosophical Magazine 7th Ser., 41: 256–275.
38. Sheng, J., Amankwah-Amoah, J., & Wang, X. (2017). A multidisciplinary perspective of big data in management research. International Journal of Production Economics, 191, 97-112. Dostupno na: https://doi.org/10.1016/j.ijpe.2017.06.006
39. Sharon Novak and Scott Stern (2008) "How Does Outsourcing Affect Performance Dynamics? Evidence from the Automobile Industry," Management Science 54, no. 12

40. Simon, J.; Covic, Z. and Petkovic, I.: Industrie 4.0 Based Customized Mass Production Overview. Conference MECHEDU, 2017, Subotica Tech – College of Applied Sciences, Subotica, 2017
41. Simon, J.; Trojanova, M.; Zbihlej, J. and Sarosi, J.(2018) Mass Customization Model in Food Industry Using Industry 4.0 Standard with Fuzzy Based Multi-criteria Decision Making Methodology. Advances in Mechanical Engineering 10(3), 1-18
42. Simonite, T. (2017) Google's AI software is learning to make AI software. MIT Technology Review. Dostupno na: http://www.technologyreview.com/s/603381/ai-software-learns-tomake-ai-software/
43. Sivarajah, U., Kamal, M. M., Irani, Z., & Weerakkody, V. (2017). Critical analysis of Big Data challenges and analytical methods. Journal of Business Research. Dostupno na: https://doi.org/10.1016/j.jbusres.2016.08.001
44. Sternberg, R. J. 1994. In search of the human mind. 395–396. New York, NY: Harcourt-Brace
45. Stojanović, S.D. (2017) Digitalna ekonomija i transformacija poslovnih procesa – izazovi i rizici. Stručni rad. Mjesto izdavanja: Novi Sad. Nakladnik: Fakultet za ekonomiju i inženjerski menadžment u Novom Sadu
46. Šebalj, D. i Živković, A. i Hodak, K. (2016) Big data: changes in data management. SRCE, Ekonomski vjesnik. Dostupno na: https://hrcak.srce.hr/ojs/index.php/ekonomski-vjesnik/article/view/4208
47. Talbot, D. (2014) Apps for Autism. MIT Technology Review. Dostupno na: http://www.technologyreview.com/s/528191/digitalsummit-first-emotion-reading-apps-for-kids-withautism
48. A. M. Turing (1950) Computing Machinery and Intelligence. Mind 49: 433-460.
49. Uredili Franklin K., Ramsey W. M. (2014) The Cambrigde Handbook of Artificial Intelligence. Cambridge University Press
50. Vincent, J. (2017). Facebook's head of AI wants us to stop using the Terminator to talk about AI. Interview with The Verge. The Verge
51. Zidek, K. (2016) Embedded vision equipment of industrial robot for inline detection of product errors by clustering-classification algorithms. International Journal of Advanced Robotic Systems. Dostupno na: http://dx.doi.org/10.1177/1729881416664901

52. Wiggers K. (2018) Google AI claims 99% accuracy in metastatic breast cancer detection. Nakladnik: VentureBeat. Dostupno na: https://venturebeat.com/2018/10/12/google-ai-claims-99-accuracy-in-metastatic-breast-cancer-detection/
53. Yao, M., Zhou, A. & Jia, M. (2018). Applied Artificial Intelligence. A Handbook for Business Leaders. New York
54. You, J.X., Li, X.C., Low, M., Lobell, D.B., and Ermon, S. (2012) A combination of remote sensing and machine learning data for yield prediction. Dostupno na: http://sustain.stanford.edu/crop-yield-analysis