Umjetna inteligencija u visokom obrazovanju

Šikić, Lovro

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Humanities and Social Sciences / Sveučilište u Zagrebu, Filozofski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:131:096741

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Filozofski fakultet
Sveučilišta u Zagrebu

Repository / Repozitorij:

ODRAZ - open repository of the University of Zagreb
Faculty of Humanities and Social Sciences

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU
FILOZOFSKI FAKULTET
ODSJEK ZA INFORMACIJSKE I KOMUNIKACIJSKE ZNANOSTI
SMJER INFORMATIKA (nastavnički)
Akademska godina 2020./ 2021.

Lovro Šikić

Umjetna inteligencija u visokom obrazovanju

Diplomski rad

Mentor: dr.sc. Vedran Juričić, doc.

Zagreb, svibanj 2021.

Izjava o akademskoj čestitosti

Izjavljujem da je ovaj rad rezultat mog vlastitog rada koji se temelji na istraživanjima te objavljenoj i citiranoj literaturi. 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. Također izjavljujem da nijedan dio rada nije korišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Sadržaj

Sadržaj i
1. Uvod 1
2. Umjetna inteligencija 2
2.1. Razvoj umjetne inteligencije 4
2.2. Investicijski i razvojni trendovi 5
3. Umjetna inteligencija u edukaciji 10
3.1. Revolucije edukacije 11
3.2. Utjecaj umjetne inteligencije na studente 14
3.3. Utjecaj umjetne inteligencije na nastavnike 16
4. Inteligentni sustavi za poučavanje 19
4.1. Primjeri inteligentnih sustava za poučavanje 22
4.2. Problemi koje rješava umjetna inteligencija 26
5. Istraživanje studentskog stava u vezi umjetne inteligencije 29
5.1. Opći podaci 32
5.2. Razvoj umjetne inteligencije 34
5.3. Rasprava 45
6. Zaključak 49
7. Literatura 50
Popis slika 55
Popis grafova 56
Sažetak 57
Summary 58

1. Uvod

Umjetna inteligencija je na nezaustavljivom razvojnom putu. Svake godine izlaze novi članci, knjige, časopisi i drugi oblici literature koji opisuju napretke i nova otkrića u polju umjetne inteligencije. Počevši od 50-ih godina prošloga stoljeća, ubrzanim širenjem i razvitkom tehnologija, pa sve do 80-ih godina kada započinje prva digitalna revolucija.

Ti počeci, zajedno s kasnijom pojavom Interneta, mobilnih uređaja, velikih podataka, društvenih stranica i sl., donijeli su napredak u svim segmentima društva. Svjedoci smo da je u 21. stoljeću tehnološki napredak izuzetno brz, iz čega je vidljivo da se razvoj društva u cjelini, ali ni tehnologija ne planiraju zaustaviti u skorije vrijeme.

Rad u 2. poglavlju razmatra kakav utjecaj umjetna inteligencija ima na nastavnike i studente. Korištenje umjetne inteligencije u obrazovnom sustavu i oko obrazovnog sustava je ponekad na granici etike, ali doprinosi njegovom razvitku. Društvene stranice, poput Facebooka i drugih, prikupljaju osobne podatke, podatke pretraživanja svojih korisnika i preko algoritama priazuju personalizirane oglase. Takvo korištenje umjetne inteligencije nije sasvim etično, ali se pokazalo efikasnim jer studenti koji se prijavljuju na određena sveučilišta pokazuju veću razinu angažiranosti prema studentskim obvezama (Belkin, D., 2019).

S obzirom na novi trend, koji podarazumijeva da se u slobodno vrijeme često koristi s digitalnim tehnologijama, i s obzirom na činjenicu da se dosta svakodnevnih aktivnosti odvija putem društvenih stranica i općenito na internetu, velika poduzeća su to prepoznala kao priliku za investiranje i počeli su ulagati velike svote novaca kako bi doprinijele razvoju umjetne inteligencije, a popratno tome i povećanju svog prihoda.

Razvoj investicijskih trendova obrađen je u 3. poglavlju te pokazuje koje su to korporacije investiranjem najviše doprinijele razvoju i korištenju kako umjetne inteligencije tako i svih popratnih tehnologija, a posebno u njihovom svakodnevnom poslovanju.

Na kraju rada analizira se utjecaj umjetne inteligencije na studente i u kojoj su oni mjeri upoznati s tom tehnologijom, te se analizira njihovo stajalište o inteligentnim sustavima za poučavanje.

2. Umjetna inteligencija

Prema McCarthyju (2004), koji je između ostalog i definirao pojam umjetne inteligencije, umjetna inteligencija je znanost i istraživanje u cilju izrade inteligentnih strojeva, posebno inteligentnih računalnih programa. Upitan je li umjetna inteligencija zapravo njezina imitacija, McCarthy kao odgovor navodi da može biti ali da nije uvijek.

Definicija umjetne inteligencije Johna McCarthyja je zapravo samo jedna od mnogih, ali ta je najprihvaćenija. Wang (2019) u svom radu „O definiranju umjetne inteligencije[1]“ analizira problem definiranja umjetne inteligencije te navodi kako ne postoji konsenzus oko definicije. Problem zbog kojeg se umjetna inteligencija ne može u potpunosti definirati je zapravo sama inteligencija. Inteligencija je vrlo kompleksna i teška za shvatiti, te se zbog puno različitih shvaćanja inteligencije javlja isti problem i kod definicije umjetne inteligencije. Zbog toga će veliki broj stručnjaka umjesto rasprave o definiciji odabrati opciju nastavljanja svojih istraživanja neovisno o tome spadaju li ona u područje umjetne inteligencije ili ne.

Danas je umjetna inteligencija jedno od područja u koje se investira najviše resursa i koje se najbrže razvija pa su se zbog velikih investicija počele razvijati i sporedne grane ove znanstvene discipline, kao što su robotika, podatkovna znanost, duboko učenje i sl.

Najpoznatija ličnost u području umjetne inteligencije je Alan Turing. Turing je u svom radu, izdanom 1950. godine pod nazivom „Computing Machinery and Intelligence[2]“, prvi upitao „mogu li strojevi misliti[3]“ .Tim radom daje uvid u to kako treba sastaviti strojeve koji su inteligentni i na koji način testirati njihovu inteligenciju. Turing je doista bio pionir u području umjetne inteligencije, ali generalno i u znanosti, godinama ispred drugih, samim time što je uspio predvidjeti da će računala uspjeti zavarati ljudske ispitivače u više od 30% slučajeva. Nadalje, neizostavni dio opusa Alana Turinga je „igra oponašanja“, kasnije poznata i kao Turingov test. Turingov test je test sposobnosti stroja da pokaže inteligentno ponašanje koje je ekvivalentno ili nerazlučivo od ljudskog (Turing, 1950). Prema profesoru Collinsu (2019), Turingov test je i dan danas bitan jer nam daje uvid u stupanj razvoja umjetne inteligencije.

Godinu dana nakon izdavanja Turingova rada „Computing Machinery and Intelligence, Christopher Stracheya[4] je uspješno napisao prvi program koji koristi umjetnu inteligenciju. Do 1952. godine stroj je bio sposoban odigrati cijelu partiju dame razumnom brzinom (Copeland

[1] Eng. On Defining Artificial Intelligence
[2] Hrv. Računalni strojevi i inteligencija
[3] Eng. Can machines think?
[4] Britanski informatičar

2000). Također, bio je sposoban ispitati svaki mogući potez dok ne pronađe odgovor, no budući da je trebalo preoispitati puno poteza, program je bio znantno sporiji od čovjeka.

Par godina kasnije, 1956.godine, dogodio se još jedan veliki pomak u području umjetne inteligencije. Arthur Lee Samuel uspio je napraviti program koji je sposoban samostalno učiti igru dama. Program je igrom protiv pravog protivnika učio pohranjujući podatke o odigranim potezima. S obzirom na to da je kapacitet pohranjivanja tadašnjih računala bio vrlo ograničen, tako je i samo učenje programa bilo vrlo ograničeno. Takva poteškoća nije spriječila Samuela da razvije prvi samoučeći program. Samuel je svoj program iste godine predstavio na televiziji gdje su ljudi mogli vidjeti kako igra igru dama sa strojem. Stroj je razvijen u IBM-ovom labaratoriju, a predsjednik i osnivač IBM-a Thomas J. Watson je predvidio da će cijena dionica IBM-a porasti i do 15%, što se i dogodilo (McCarthy, Wiederhold 1992). Nagli porast cijena dionica, nakon demonstracije fundamentalnog koncepta umjetne inteligencije, bio je dobar pokazatelj u kojem će se smjeru financiranje i zainteresiranost u budućnosti kretati.

Tijekom 1964. godine, došlo je do još jednog velikog pomaka u razvoju umjetne inteligencije. Dr. Bobrow je te godine dokazao da računalo ima sposobnost razumijeti prirodni jezik i rješavati tekstualne matematičke zadatke (Brendza 2017). Godinu dana kasnije, Joseph Weizenbaum je predstavio ELIZU, prvi chatbot na svijetu. ELIZA je bila sposobna voditi razgovor na engleskom jeziku o bilo kojoj temi (Brendza 2017). Program nije shvaćao što sugovornik želi reći, već je samo davao odgovore po „skripti“, ali ljudi su i dalje bili mišljenja da program daje iluziju ljudskih osjećaja.

Gotovo dva puna desetljeća kasnije, ponovno se dogodio veliki pomak u području umjetne inteligencije i to pojavom „dubokog učenja[5]“, metode koja omogućava računalima da uče tako da obavljaju aktivnosti i prikupljaju iskustvo (McKinsey Global Institute 2018). Metodu su popularizirali John Hopfield i David Rumelhard.

Sve do danas takvi pomaci nisu stali, a kako je računalna snaga rasla, tako su i ti pomaci postajali sve češći i veći. U 21. stoljeću, došlo je do brojnih pomaka. Google je 2009. počeo raditi na samovozećem automobilu, 2011. superračunalo Watson pobijedilo je Jeopardy[6] pobjednike, iste godine su SIRI, Google Now i Cortana[7] postali dio mainstream sadašnjice. Par

[5] Eng. deep learning
[6] Popularna televizijska natjecateljska emisija gdje se sudionici natječu u tome tko ima bolje opće znanje.
[7] Virtualni asistenti, koji omogućavaju korisnicima da brzo dobiju informacije, obave zadatke, pošalju poruke itd.

godina kasnije, 2015., Elon Musk i ostali su donirali preko milijardu dolara u područje umjetne inteligencije (BootstrapLabs 2017).

2.1. Razvoj umjetne inteligencije

Umjetna inteligencija doživjela je velike napretke u posljednjih par desetljeća. Uz sav napredak, javljaju se novi načini na koje se umjetna inteligencija koristi te ona, u određenom udjelu, postaje zastupljena u svim granama znanosti. Osim što se koristi u akademskim ustanovama, koristi se i u pametnim telefonima, automobilima, televizijama, igraćim konzolama, popularnim mrežnim uslugama poput YouTuba[8], Twittera, Facebooka itd.

Razvoj umjetne inteligencije može se u grubo podijeliti u tri faze (COE, 2017):

1. Umjetna inteligencija prije 20. stoljeća
2. Umjetna inteligencija 20. stoljeća
3. Umjetna inteligencija 21. stoljeća.

U antičkim vremenima, umjetna inteligencija se spominje u kontekstu grčkih mitova o Hefestu i Pigmalionu koji su uključivali ideju o inteligentnim robotima i umjetnim bićima. Tisućama godina kasnije Samuel Butler[9] predstavio je ideju da se teorija evolucije Charlesa Darwina[10] odnosi i na strojeve te da će se oni jednoga dana i osvijestiti te na samom kraju i zamijeniti tj. istisnuti čovječanstvo (COE, 2017).

U 20. stoljeću su se pojavili veliki pomaci u razumijevanju i razvitku umjetne inteligencije. Umjetna inteligencija doživjela je veliki skok iz nečega što bi se moglo smatrati znanstvenom fantastikom u nešto što doista postoji u stvarnom svijetu. Edward Condon[11] 1940. godine predstavio je svoj stroj Nimatron, digitalno računalo koje je savršeno igralo igru Nim.

U pedesetim godinama 20. stoljeća došlo je do vjerojatno najpoznatijih evolucijskih koraka u razvoju umjetne inteligencije. U radu je već spomenut Alan Turing[12] i njegov test, čija je svrha

[8] Američka mrežna platforma za dijeljenje video zapisa, osnovana od strane 3 bivša zaposlenika PayPala – Chad H., Steve C., Jawed K.
[9] Samuel Butler bio je ikonoklastični engleski autor.
[10] Charles Darwin bio je engleski znanstvenik i prirodoslovac, te je autor teorije evolucije živih bića koja je i po njemu dobila naziv, darvinizam.
[11] Edward Condon bio je američki nuklearni fizičar, pionir u kvantnoj mehanici te je sudjelovao u izradi radara i nuklearnog oružja tokom Drugog svjetskog rata.
[12] Alan Turing britanski je logičar, kriptoanalitičar i matematičar, te ga se često smatra i ocem računarstva modernog doba. Izumitelj je Turingove mašine, matematičkog modela za stvaranje klase od predvidljivih funkcija.

bila da testira sposobnosti stroja da pokaže inteligentno ponašanje, odnosno ponašanje koje se ne bi moglo razaznati od ljudskog (Turing, 1950).

Promatrajući razliku između razine razvoja umjetne inteligencije od 20. do 21. stoljeća može se dobiti dobar uvid u to koliko je vremena, resursa i znanja bilo uloženo kako bi se umjetna inteligencija razvila, od svojih skromnih početaka do onoga što je danas. Od pametnih mobitela do automobila i uređaja za video igre, umjetna inteligencija je zahvatila cijeli svijet i svaku disciplinu. Danas je gotovo neizbježan dio svakodnevice.

Bez obzira na brojna dostignuća, umjetna inteligencija je mlada disciplina, stara otprilike šezdeset godina. Od prošloga desetljeća ovog stoljeća, umjetna inteligencija doživjela je novi napredak, zato što je moć računala napredovala zajedno s interesom i potrebama. Nova računala imaju jaču računarsku snagu te su sposobna pristupiti velikom broju informacija u vrlo kratkom vremenu. Kako ljudske potrebe za znanjem, napretkom i brzinom postaju sve zahtjevnije, tako postaje veći interes za jačanje i poboljšanje umjetne inteligencije jer ona uspješno rješava neke od njih. Veći interes je uzrokovao razvoj poduzeća koja se bave umjetnom inteligencijom, bilo kroz investiranje, vlastito istraživanje i razvijanje programa ili kroz otkup poduzeća koja su već etablirana u kontekstu razvoja umjetne inteligencije.

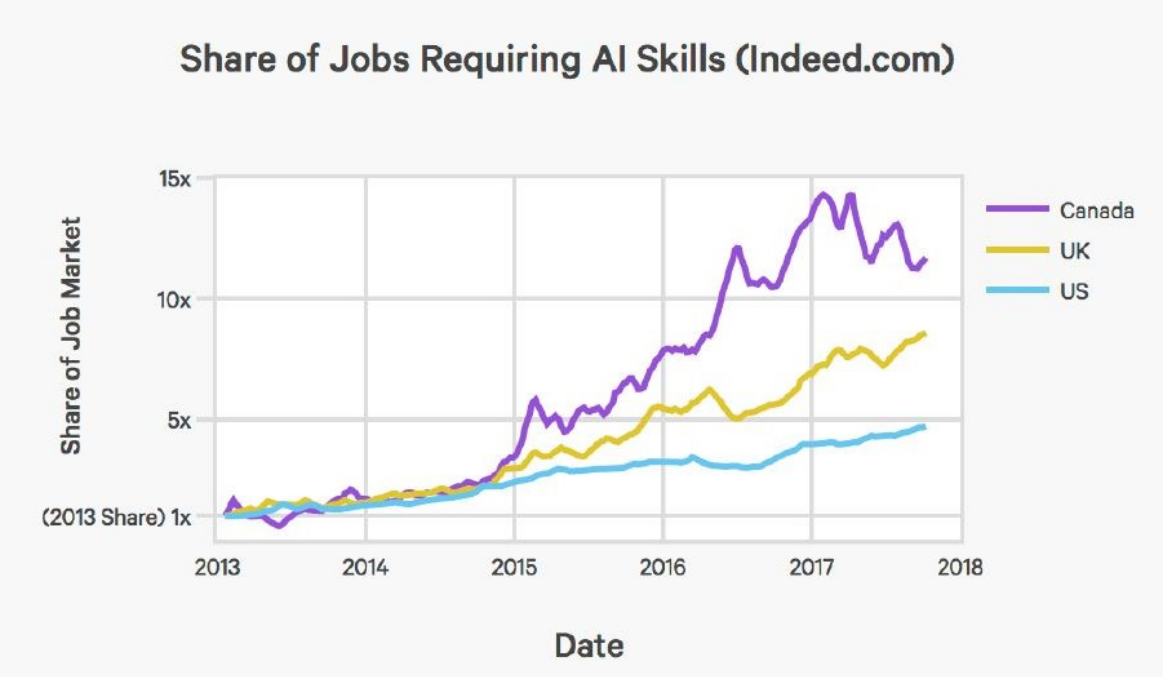
2.2. Investicijski i razvojni trendovi

S obzirom na to da postoji ulaganje po trendovima (engl. *Trend investing*), dalo se naslutiti kako će investicije u polju umjetne inteligencije porasti veoma brzo i da će se početi investirati puno više. Analizom trendova (engl. *Trend analysis*) može se dobiti okviran uvid u što se isplati investirati, a velika poduzeća su takvom analizom ustanovila kako će se ulaganje u umjetnu inteligenciju isplatiti, zbog čega su investiranje i razvoj uzeli maha. Sama zarada nije jedini poticaj investicija, već i činjenica da se javlja veći interes za proučavanje i rad u tom znanstvenom području. Prema World Economic Forumu (WEF) i istraživanjima koje je proveo Indeed [13] 2017. vidi se očito jačanje polja umjetne inteligencije.

Slika 1. pokazuje kretanje poslova u razdoblju od 2013. do 2018., koji su zahtijevali vještine u polju umjetne inteligencije. Slika prikazuje trend vezan za Kanadu, Ujedinjeno Kraljevstvo i Sjedinjene Američke Države. U promatranom razdoblju vidi se porast od 1500% za poslove koji zahtijevaju vještine vezane za umjetnu inteligenciju. U samo 5 godina je udio poslova koji

[13] Američko internetska stranica za zapošljavanje sa sjedištem u Texasu. Stranica je pokrenuta u studenom 2004. od strane Paul Forstera i Rony Kahana.

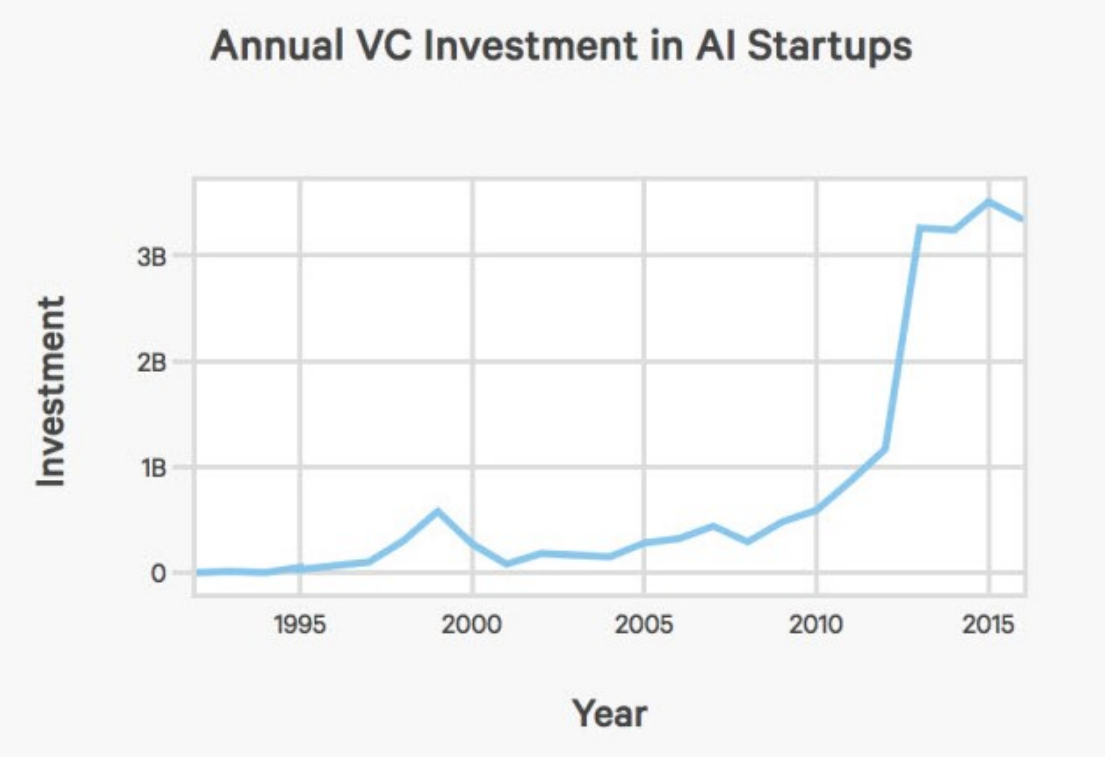
zahtijevaju znanje o umjetnoj inteligenciji i rad u tom području porastao s manje od 1% na 15%. Ovo je vrlo dobar indikator trenda, odnosno smjera u kojem ide poslovni sektor.



Slika 1. Vremenski prikaz porasta udjela poslova koji zahtjevaju vještine u području UI
Izvor: Artificial Intelligence Index, 2017 Annual Report, p 19

Značajan broj poslova stvara se u razvojnim tvrtkama (engl. *start-up*), a takva novonastala poduzeća doživljavaju brzu ekspanziju i razvoj zahvaljujući velikoj količini novca koja se u njih ulaže.

Slika 2. pokazuje porast investicija u razvojne tvrtke koje se bave umjetnom inteligencijom. Od 1995. su investicije s početnih 0 dolara porasle na preko 3 milijarde dolara godišnje. Porast broja investicija je popraćen bržim razvojem tvrtki i, naravno, većeg broja zaposlenika u navedenom području.



Slika 2. Prikaz porasta investicija ulagača u razvojne tvrtke koje se bave umjetnom inteligencijom

Izvor: Columbus L. (2018)

Iz slike 2 je vidljivo koliko su zapravo investicije porasle. Jedna od važnijih tvrtki je SenseTime, koja je od svog osnutka 2014. godine uspjela sakupiti preko 2.6 milijardi dolara u investicijama te ih to čini UI tvrtkom u koju se investiralo najviše novca. Iduća tvrtka na listi je UBTech Robotics koja je zaprimili preko 940 milijuna dolara. Usporedbom podataka iz slike 1 i slike 2 vidi se da trend investiranja ne usporava već da je brži nego ikada.

Iz navedenog se može izvući zaključak da se puno novaca i ostalih nemonetarnih dobara ulaže u područje umjetne inteligencije. S obzirom na to da se ovaj rad bavi umjetnom inteligencijom u obrazovanju, prethodno napisani dio će poslužiti kao dobar primjer za usporedbu. Naime, ulaganja u područje obrazovanja u kontekstu ulaganja u umjetnu inteligenciju puno su manje no što su ulaganja u općeniti razvoj umjetne inteligencije i u njene ostale primjene, poput autonomiziranja proizvodnje, vozila i sličnih stvari.

Dobar primjer investicije je Ujedinjeno Kraljevstvo koje je investiralo 18.5 milijuna funti u umjetnu inteligenciju, odnosno u obrazovanje ljudi koji bi se trebali obučiti i dobiti doktorat u

području umjetne inteligencije (Rogers C., 2019). Prema Sellick[14], nove tehnologije i tehnološki napredak često se doživljavaju kao opasnost, no njena istraživanja su pokazala kako se tehnologija može iskoristiti da bi se radnike informiralo o novim vještinama koje bi morali usvojiti kako bi se mogli uspješno natjecati na promijenjivom tržištu rada. Odjel za obrazovanje u umjetnoj inteligenciji došao je do zaključka da umjetna inteligencija može imati znatan utjecaj na kvalitetu poučavanja.

Kada je riječ o investitorima, prema Yin (2019), mogu se podijeliti u Velikih četiri u UI obrazovanju (engl. *The Big Four of AI Education*):

1. Tehnički divovi
2. Obrazovni divovi
3. Razvojna poduzeća edukacijskih tehnologija
4. Istraživački instituti visokog obrazovanja

Tehnički divovi su tehnološka poduzeća poput Googlea, Microsofta, Applea i Baidua. Takva poduzeća nisu usmjerena u potpunosti prema razvitku umjetne inteligencije, u kontekstu obrazovanja, ali sa svojom gotovo beskrajnom investicijskom moći i kvalitetnom radnom snagom u mogućnosti su razvijati nove tehnologije (Beylo, B., 2020). Isti ti tehnološki divovi nude svoje resurse i mogućnost učenja umjetne inteligencije u sklopu njih samih.

Obrazovni divovi dominiraju u području obrazovanja. Poduzeća poput Cengage, McGraw Hill i Pearson su vodeći u tom području. S obzirom na to da ova poduzeća raspolažu s najviše podataka, u mogućnosti su razvijati najkvalitetnije inteligentne sustave.

Razvojna poduzeća edukacijskih tehnologija susreću se s puno prepreka kao što su manjak financiranja, neetabliranost u industriji i neraspolaganje s velikim brojem talentiranih ljudi koji bi razvijali tehnologiju (Beylo, B., 2020). Ono što ih odvaja od drugih i što im daje malu prednost u nekim aspektima je da su oni isključivo fokusirani na razvoj najboljih UI proizvoda za edukaciju. Razvojna poduzeće Cognii je tako vodeći pružatelj usluga tehnologija za obrazovanje temeljenih na umjetnoj inteligenciji, kao što su virtualno učenje i asistenti u nastavi (Cognii, 2020). Alef, kao još jedno razvojno poduzeće, nudi uslugu studentima da na njihovoj platformi, Alef Platform, uče svojim tempom gdje je njihov napredak i rad moderiran i nadgledan od strane umjetne inteligencije kojom ta platforma raspolaže (Alkhalisi Z., 2019). Njihov napredak a općenito i napredak tehnologije, zainteresiranih, resursa, broja korisnika itd.

[14] Vicki Sellick – izvršna direktorica programa u Nesti, poduzeće koje se bavi inovacijama kako bi doprinijeli boljem funkcioniranju društva.

se može vidjeti kroz brojke. 2016. godine započeli su svoj rad sa 8 studenata na platformi, 2020. brojka studenata na platformi porasla je na 121,000, što je povećanje od 15,124 puta (Beylo, B., 2020). S obzirom na rast od preko 15000 puta, vidljiv je smjer u kojem ide poduzeće, ali i tehnologija bez koje takvo nešto ne bi bilo moguće.

Na kraju djeluju i Istraživački instituti visokog obrazovanja, kao najslabiji od 4 navedene skupine. Kao dobar primjer ozbiljnosti i predanosti radu i nastojanju poboljšanja tehnologije i edukativnog sektora je MIT[15] i njihova investicija od milijardu dolara 2018. godine u razvitak Sveučilišta umjetne inteligencije (engl. *AI college*) (Beylo, B., 2020). Sveučilište Harvard [16] pokreće UI Inicijativu (engl. *AI Initiative*), kojoj je primarna funkcija da nadgleda razvoj UI tehnologija koje se sve više vežu uz ljudsku svakodnevicu, kako bi se sačuvalo dobrostanje svih ljudi (Tiell, S. 2019). Razlog zaostajanja ove četvrte skupine za ostalima je da prvi sa liste, tehnološki divovi, vrlo često zapošljavaju ljude koji se nalaze na sveučilištima, ili kao profesori ili kao studenti. Između 2004. i 2009., tehnološki divovi uspjeli su pridobiti 26 sveučilišnih profesora, a samo 2018. godine je 41 sveučilišnih profesora napustilo radno mjesto i otišlo raditi u industriju za tehnološke divove (Beylo, B., 2020).

[15] MIT - Massachusetts Institute of Technology. Sveučilište u Cambridgeu, Massachusetts.
[16] Sveučilište u Cambridgeu, Massachusetts.

3. Umjetna inteligencija u edukaciji

Umjetna inteligencija danas se može pronaći u gotovo svakoj tehnologiji i aktivnostima. Toliko je rasprostranjena da ju se uzima zdravo za gotovo i koristi bez razmišljanja.

Umjetnu inteligenciju možemo pronaći na brojnim mjestima, npr. kao sastavni dio automobila koji funkcioniraju bez vozača, a i ugrađuje se u dronove koji u skladištima tvrtke Amazon omogućavaju neposredni kontakt sa zaposlenicima u svrhu ubrzanja procesa primanja, pakiranja i slanja paketa. Nadalje, umjetna inteligencija svoju primjenu nalazi i u pametnim mobilnim uređajima, npr. u ugrađenoj kameri na način da vrši prepoznavanje lica i ljudskih osmijeha. Koristi se i u GPS sustavima, u obliku digitalnih pomoćnika u pametnim uređajima, kao npr. Siri, Cortana i sl. koji su sposobni izvršavati naredbe korisnika ili davati odgovore na upite.

Osim što je umjetna inteligencija prisutna u svakodnevnim životnim aktivnostima, osoba koje posjeduju pametan uređaj, a njihov broj je, prema O'Deinom istraživanju koje je provedeno od 2016. do 2019. godine, iznosio gotovo 50% cjelokupne svjetske populacije, tako je posljedično našla svoju primjenu i u obrazovnom sustavu.

O'Deino istraživanje pokazuje kontinuirani rast broja korisnika pametnih mobilnih uređaja. Iz istraživanja koje je provela tvrtka Markets And Markets[17] vidljivo je da će investicije u umjetnu inteligenciju u edukaciji porasti na 3.7 milijardi dolara do 2023. u odnosu na 537.3 milijuna dolara koliko su iste iznosile 2018. godine.

Takav porast, od gotovo 700%, dobar je pokazatelj u kojem smjeru ide umjetna inteligencija u obrazovnom sustavu. S većim brojem investicija i većom zainteresiranosti ona će postati jača, bolja i pametnija te će kroz godine privući druge brojne investitore i znanstvenike.

Umjetna inteligencija u edukaciji usmjerena je na istraživanje razvijanja i evaluacije računalnog softvera, kojem je namjena da poboljša predavanje i učenje. Ciljevi implementacije umjetne inteligencije u edukaciji su da se interpretiraju kompleksni studentski odgovori i da se nauči na koji način studenti djeluju, da se razumije zašto neki studenti pokazuju slabije rezultate te da se na temelju ostvarenih rezultata tijekom studiranja pruži studentima pomoć, u obliku natuknica ili simuliranja ponašanja ljudskog predavača (Woolf, P.B. 2015). Još jedan cilj je da se tehnike umjetne inteligencije iskoriste kako bi se bolje razumio proces

[17] Najveća tvrtka na svijetu koja se bavi utjecajem prihoda.

učenja i poučavanja, kako bi se doprinijelo tim procesima te ih se učinilo što djelotvornijima i boljima (Woolf, P.B., 2015).

Tehnologija ne može samostalno utjecati na edukacijski sustav, već je potrebna suradnja između tehnologije i nastavnika, kako bi se ostvarili najbolji mogući rezultati (Woolf, P.B. 2015). Tehnologija ne predstavlja problem ili prijetnju edukativnom sustavu i nastavničkoj profesiji, ona je tu da ponudi moguća rješenja na određene probleme i pitanja, a najbolji će rezultati, kako je Woolf navela u svom članku, proizaći iz suradnje tehnologije i nastavnika.

Mnoge sastavnice inteligentnih nastavnih sustava svoj početak mogu naći u umjetnoj inteligenciji. U trenutku kada se te sastavnice počnu pojavljivati kao sastavnice u većim sustavima, one se prestaju smatrati umjetnom inteligencijom i jednostavno se zaboravlja da su ikada bili dio ili potekli od nje (Woolf, P.B., 2015). Tako Nick Bostrom[18] objašnjava: „Mnogo se vrhunskih umjetnih inteligencija implementiralo u opće programe, često bez da se nazivaju umjetnim inteligencijama, jer kada nešto postane korisno i dovoljno često, više se ne označava kao umjetna inteligencija“ (Woolf, P.B., 2015).

3.1. Revolucije edukacije

Prva revolucija edukacije se veže uz vizionara Horace Manna, koji je osmislio sustav poučavanja u školama. Ideja se zasnivala na jednakosti, odnosno na načelu jednakog obrazovanje za sve. To je značilo da bi nastavnici u školama predavali svim učenicima osnovno gradivo po jedinstvenom kurikulumu. Takav standard se održao dugo vremena, od 1837. kada je bio ustanovljen, da bi danas, razvojem tehnologije, nastavnih planova i programa i vještina poučavanja, bio preferirani individualni pristup, koji nažalost nije uvijek ostvariv bez implementacije inteligentnih sustava za poučavanje, kao pomoć nastavnicima tijekom nastave.

Razvojem digitalnih tehnologija poput računala, mobilnih uređaja, digitalnih medija, alata za distribuciju, video igara i društvenih stranica počinje druga revolucija edukacije. Pojava ovih tehnologija je utjecala na percepciju školskog sustava te na učenje i poučavanje. Studenti, ali i nastavnici koriste navedene tehnologije kako bi što kvalitetnije upravljali svojim profesionalnim i akademskim životom (Collins A. i Halverson R., 2010). Međutim, pojava tehnologije nije omogućila samo brže i bolje usvajanje znanja. Studenti više nisu bili ograničeni prostorno, odnosno nisu morali boraviti u mjestu gdje se nalazi njihovo sveučilište, već su

[18] Nick Bostrom (Šve. Niklas Boström) Fiozof rođen u Švedskoj poznat je po svom radu i proučavanju egzistencijalne krize, rizika superinteligencije, testa preokreta i dr. 2011. godine osnovao je Oxford Martin Program koji se bavi utjecajima tehnologije budućnosti.

mogli učiti, upisivati kolegije i polagati ispite neovisno o lokaciji na kojoj su se nalazili. Istraživanje iz 2007. godine, koje su proveli Pew Internet i American Life Project pokazalo je da 55% mladih ljudi koriste društvene stranice za komunikaciju, pri čemu 48% koristi društvene mreže više od jedanput dnevno. Prema Heroldu (2018), odnosno 11 godina kasnije od prethodnog istraživanja, je broj mladih koji koriste društvene stranice na dnevnoj bazi porastao na preko 70%. Usporedbom spomenutih istraživanja možemo prepoznati trend koji ukazuje na rast popularnosti tehnologija i društvenih mreža. Bilo je samo pitanje vremena kada će se te platforme implementirati u obrazovni sustav jer i one, kao i sama tehnologija, napreduju iz godine u godinu te postaju korisnije i gotovo ih je nemoguće ignorirati. Prvo od dva spomenuta istraživanja ukazuje na to da su se studenti osjećali ugodno koristeći društvene mreže u kontekstu određenih predavanja te kako su aktivnije sudjelovali u samom izvođenju nastave, napominjući pritom kako bi bili skloniji upisati kolegije nastavnika koji nastavu predaju uz pomoć društvenih mreža.

U trećoj revoluciji edukacije je neizostavna umjetna inteligencija, iako je još uvijek u gotovo početnoj fazi. Glavni faktor koji je omogućio razvitak i početak treće revolucije edukacije je porast broja, inteligencije, kompetentnosti i prisutnosti pametnih strojeva (NAIS, 2018.). U narednih par godina više sustava učenja preselit će se online, a od nastavnika i studenata će se očekivati da kontinuirano uče, dok će umjetna inteligencija i virtualna realnost unaprijediti te sustave učenja. S obzirom na to da se ne može ignorirati činjenica da je za podučavanje potreban ljudski kontakt kako bi se razvile vještine neovisne o onima koje se podučavaju na sveučilištima, tradicionalni edukativni sustavi će imati jedinstvenu ulogu u poučavanju studenata, ali će se kroz te naredne godine razviti nekoliko novih i efikasnijih modela poučavanja kroz suradnju ljudi i pametnih strojeva (NAIS, 2018.). Kao ključne vještine 21. stoljeća navode se: emocionalna inteligencija, kreativnost, prilagođavanje, otpornost i kritičko razmišljanje (NAIS, 2018.).

Iz slike 3. je vidljivo da ne postoji sustav s umjetnom inteligencijom koji objedinjuje sve navedene ključne vještine 21. stoljeća. Jedino su ljudska bića sposobna primijeniti sve ključne vještine u poučavanju budućih generacija u cilju njihova obrazovanja, osposobljavanja i opremanja vještinama koje su potrebne za uspjeh, napredovanje i kontinuirano prilagođavanje okolini u kojoj se nalaze, a općenito i svijetu.

	Expert Systems	Analytical AI	Human-Inspired AI	Humanized AI	Human Beings
Cognitive Intelligence	×	✓	✓	✓	✓
Emotional Intelligence	×	×	✓	✓	✓
Social Intelligence	×	×	×	✓	✓
Artistic Creativity	×	×	×	×	✓
		Supervised Learning, Unsupervised Learning, Reinforcement Learning			

Slika 3. Tipovi sustava UI

Izvor: Kaplan, A., i Haenlein, M. (2018).

Nadalje, Koman i Wolff (2008) tvrde kako je izvanredno obavljanje nekog posla povezano s tri vještine tj. tri tipa inteligencije:

1. kognitivna inteligencija koja objedinjuje sposobnosti povezane s prepoznavanjem uzoraka i sistematično razmišljanje,
2. emocionalna inteligencija u koju spadaju prilagodljivost, samopouzdanje i usmjerenost prema ostvarivanju ciljeva,
3. socijalna inteligencija koja objedinjuje suosjećanje, funkcionalan rad unutar timova i vodstvo koje inspirira druge.

Općeprihvaćeno razmišljanje u psihologiji je to da je inteligencija nešto s čime se ljudi rađaju, a ne nešto što se može naučiti. Međutim, emocionalna i socijalna inteligencija povezane su sa specifičnim vještinama koje spadaju u tu emocionalnu i socijalnu sferu inteligencije, a te vještine su nešto što individualne osobe mogu naučiti, i u skladu s tim nešto što sustavi umjetne inteligencije mogu oponašati (Kaplan A., i Haenlein M., 2018). Strojevi ne mogu doživljavati tj. iskusiti osjećaje, ali mogu biti istrenirani tako da ih prepoznaju i preko tih spoznaja mogu adekvatno reagirati na njih i davati povratne informacije.

Kao što je vidljivo iz Slike 3, analitička umjetna inteligencija ima jedino karakteristike kognitivne inteligencije. Većina takvih sustava umjetne inteligencije danas se koristi u tvrtkama u svrhu otkrivanja prevara u djelatnostima pružanja usluga u oblasti financija, za prepoznavanje slika ili u samovozećim automobilima (Kaplan A., i Haenlein M., 2018). Umjetna inteligencija inspirirana ljudima, ima karakteristike kognitivne i emocionalne inteligencije. Osim što ti sustavi, kao i prethodno navedeni, mogu obavljati već navedene zadatke, oni imaju još jednu novu razinu, a to je prepoznavanje ljudskih emocija te na taj način

mogu iskoristiti te nove informacije kako bi donosili odluke. Te sustave također koriste tvrtke na brojne druge načine, npr. za prepoznavanje emocija kupaca kako bi poboljšali uslugu ili tijekom razgovora s potencijalnim kandidatom za posao kako bi ustanovili da je ta osoba upravo ta koju žele za svoje poduzeće (Kaplan A., i Haenlein M., 2018).

Treća, a ujedno i posljednja umjetna inteligencija, je ona koja je razvijena po uzoru na čovjeka. Takva umjetna inteligencija objedinjuje sve kompetencije, tj. inteligencije, ali nije sposobna biti kreativna jer je umjetna inteligencija u svojim korijenima ipak zasnovana na prepoznavanju uzoraka (Kaplan A., i Haenlein M., 2018). U kontekstu obrazovanja, nijedan ovaj sustav ne bi mogao funkcionirati kao individualna jedinica, niti preuzeti posao nastavnika jer će uvijek nedostajati taj jedan faktor koji samo predavač osobno može imati, što mu daje veliku prednost nad strojevima. Kako bi se buduće generacije razvijale te kako bi razvijale sve tri prethodno navedene inteligencije, potrebna je ljudska ruka koja će ih voditi jer kako Albert Einstein navodi, „kreativnost je inteligencija koja se zabavlja“, a umjetna inteligencija nije sposobna iskusiti zabavu i prave ljudske emocije.

Umjetna inteligencija je u posljednjih par desetljeća doživjela velike pomake u okviru obrazovanja. Učenici su već prije surađivali, a još uvijek i surađuju s računalima, npr. kada uče matematiku ili fiziku kako bi riješili zadatke korak po korak. Pokazalo se da je to jedna od mogućih metoda poučavanja, ali da nije dobra jer nedostaje ljudskog doticaja. Kroz suradnju s nastavnicima učenici razvijaju i druge vještine, iako ne nužno povezane uz znanstvenu disciplinu koju proučavaju. Učenici kroz kontakt s nastavnicima razvijaju kritičko razmišljanje, metakogniciju [19]i suradnju (Roll, I., Wylie R., 2016).

3.2. Utjecaj umjetne inteligencije na studente

Nije upitno utječe li umjetna inteligencija na studente, već koliko utječe na njih i na koji način. Istraživanje koje je proveo Markets And Markets dobar je indikator da će taj utjecaj, kakav god on danas bio, postati samo jači. Nije tajna da brojna sveučilišta koriste umjetnu inteligenciju kako bi poboljšali iskustvo studiranja te pomogli svojim studentima u što boljem i uspješnijem ispunjavanju studentskih obveza.

Na umjetnu se inteligenciju, u kontekstu edukacije i općenito obrazovnog sustava, generalno gleda na pozitivan način. Ona je tu da studentima olakša studiranje te da im pruži pomoć u slučaju potrebe, uz napomenu da to nije jedini oblik u kojem se umjetna inteligencija

[19] Spoznajni procesi o vlastitim spoznajnim procesima.

pojavljuje. Ona vrlo često djeluje i neposredno, bez da studenti ili budući studenti znaju za nju. Također, sveučilišta vrlo često i rudare podatke i prikupljaju informacije o svojim studentima i prije nego što se prijave na fakultet ili počnu studirati na njemu. Zbog povećanog broja zainteresiranih učenika za određena sveučilišta, ona prikupljaju informacije kako bi došli do podataka koje im se studente isplati prihvatiti, a koje ne (Belkin, D., 2019). Tako se prikupljaju razne informacije, npr. koliko dugo su budući studenti čitali e-mail, da li su otvarali poveznice koje su bile unutar tog e-maila, a sveučilišta čak znaju i je li potencijalni student rekao da će doći na određeni događaj organiziran od strane sveučilišta, a na kraju nije prisustvovao (Belkin, D., 2019).

Takav način korištenja tehnologije nije dobar za buduće studente jer na temelju prikupljenih informacija, osobe zadužene za primanje studenata, mogu stvoriti profil studenta čak i prije nego što se on službeno prijavi za studiranje te ga na temelju njega mogu i odbiti. National Association for College Admission Counseling (NACAC) u istraživanju provedenom 2017. navodi kako 13% sveučilišta smatra da je demonstrirana zainteresiranost potencijalnog studenata vrlo bitna za sveučilište kada se donosi odluka hoće li će se student biti primljen ili ne, a 32% sveučilišta smatra kako je demonstrirana zainteresiranost jednako bitna kao i preporuka nastavnika, intervju i prethodno obrazovanje (Clinedinst M., i Patel, P, 2018). S obzirom na činjenicu da puno studenata ne zna da ostavljaju toliko upečatljiv internetski otisak, dio njih otpadne i prije nego što se prijave. Obrazovne institucije mogu kupiti softver koji prati i rudari podatke potencijalnih studenata. Jedna od najvećih tvrtki koja prodaje takvu tehnologiju je Technolutions Inc[20]., a izvršni direktor tvrtke Alexander Clark[21] navodi kako njihov proizvod koristi preko 850 škola (Belkin, D., 2019).

Umjetna inteligencija u obrazovanju ima i druge primjene, neke s kojima su studenti upoznati ili je barem svjesno koriste. Tehnologija je tu da poboljša iskustvo studiranja i da im pomogne u boljem, bržem i efikasnijem ispunjavanju obveza. Kako je već prije spomenuto, s obzirom na porast količine novca koji se investira u ove tehnologije, one postaju sve bolje, a zbog činjenice da je ovo vrlo mlada znanost, iskorišten je tek dio mogućnosti.

Jedan od popularnijih i poznatijih računalnih programa koji se koristi na sveučilištima i koji koristi umjetnu inteligenciju je Chatbot[22]. U ranijim verzijama su Chatbotovi bili vrlo

[20] Trvtka osnovana 1994. godine. Bavi se razvijanjem specijaliziranog softvera za istraživanje, dizajn i razvijanje sustava za upravljanje informacijama koji se služe u industriji visokog obrazovanja.
[21] Osnivač tvrtke Technolutions i njen izvršni direktor.
[22] Računalni program koji oponaša ljudski način razgovora. On omogućuje interakciju između stroja i čovjeka, koja se odvija putem pisanih poruka ili glasa.

primitivni i ograničeni na jednostavne fraze i pitanja. Davali su vrlo šture i osnovne odgovore, zbog čega komunikacija s „botovima“ nije bila toliko privlačna (Michael, 2018). Chatbotovi koriste obradu prirodnog jezika koja ima svoje početke u umjetnoj inteligenciji, a samom konceptu Chatbotova može se ući u trag već 1950. godine kada je Alan Turing postavio pitanje „Mogu li strojevi misliti?“ (Boiano, Borda, Gaia i sur. 2018). S napretkom tehnologije napredovali su i Chatbotovi, te se prepoznala njihova korisnost i mogućnost implementiranja u obrazovni sustav. Danas oni igraju važnu ulogu u edukaciji i nalaze se u raznim dijelovima visokog školstva. Koriste se kao inteligentni predavači koji sadrže znanje preuzeto iz literature te su u mogućnosti davati odgovore na generalna pitanja vezana uz određeno znanstveno područje. U slučaju postavljanja kompleksnih pitanja ili postavljanja pitanja koja zahtijevaju kompleksni odgovor, odgovor će morati dati nastavnik (Ciolacu, M., Tehrani, A.F., Binder, L. i sur., 2018).

Korištenje Chatbotova nije ograničeno samo na nastavni proces i na sam čin predavanja, on je implementiran i u administraciju, te ima brojne druge zadaće: od komuniciranja sa studentima o njihovim iskustvima, željama i potrebama, do slanja podsjetnika za događaje, ispite itd. Kada je riječ o komunikacijskim platformama koje pokreće umjetna inteligencija u višem obrazovanju, AdmitHub se javlja kao prva tvrtka koja je razvila takvu vrstu komunikacijske platforme. Njihova baza podataka ima preko 4 milijuna pitanja koja prekrivaju preko 6000 tema (AdmitHub, 2019). Njihovi Chatbotovi odmah odgovaraju na preko 80% pitanja studenata koristeći obradu prirodnog jezika (AdmitHub, 2019).

Softveri koji koriste umjetnu inteligenciju sada su sposobni komunicirati sa studentima i na temelju tih razgovora i općenito prikupljanja podataka o studentima tijekom njihovog obrazovanja, poput podataka o ostvarenim uspjesima ili prisustvovanju na nastavi, sposobni su stvoriti individualizirani pristup podučavanja. Na temelju prikupljenih informacija može se stvoriti plan i program za svakog studenta posebno, ali ako student pokazuje slabiji ili bolji napredak u nekom području za njega se posebno stvara plan učenja u obliku dodatne pomoći tijekom rješavanja zadataka, kao što je postavljanje više pitanja koja služe kako bi se znanje bolje utvrdilo ili preporuke za upis kolegija u budućnosti (Worobec, A. i Schorsch, B., 2019).

3.3. Utjecaj umjetne inteligencije na nastavnike

Utjecaj umjetne inteligencije nisu osjetili samo studenti, već i nastavnici. Dok s jedne strane razni softveri prikupljaju podatke o studentima, kako bi se predložio najbolji pristup podučavanju, nastavnici, s druge strane, imaju uvid u te podatke te na koncu oni donose odluke

o tome kako će se te informacije iskoristiti. Jedna od glavnih značajki ove tehnologije je da je napravljena za suradnju s nastavnicima, kako bi se postigla veća efikasnost i personalizacija, te kako bi se nastavnicima omogućilo više vremena i slobode da pruže razumijevanje te da se bolje mogu prilagoditi studentima, a to je nešto što strojevi ne mogu (Marr, B., 2019).

Stephen Cox, nastavnik iz Finske, navodi kako se umjetna inteligencija mora iskoristiti kao most u prelasku preko prepreka jer će ona pomoći u razumijevanju ogromnih količina podataka i pomoći će nastavnicima da ih razumiju (Cox, S., 2020). S obzirom na to da se ne može za svakog studenta posebno uzeti osobni instruktor, nove tehnologije omogućuju premošćivanje tog problema. Corbett i Koedinger (2006) navode 5 bitnih aspekata koje računala moraju biti u mogućnosti ispuniti, kako bi potencijalno mogli obavljati ulogu instruktora:

1) mora biti u mogućnosti riješiti probleme koristeći znanje iz tog područja
2) mora razumjeti krivulje učenja, pogrešnog shvaćanja problema i neformalnog znanja
3) mora biti u mogućnosti korak po korak pratiti napredak studenta i razumjeti u kojem dijelu pokazuje slabije rezultate ili neshvaćanje i razlog iza toga
4) mora moći pružiti povratne informacije
5) treba moći pružiti individualizirane smjernice za iduće potencijalne zadatke.

Kroz godine je umjetna inteligencija napredovala i nastavit će napredovati, ali je ona uglavnom primjenjiva na administrativne usluge, a korištenje umjetne inteligencije u sferi poučavanja i učenja, pogotovo u višem obrazovanju, predstavlja brojne izazove (Popenici, S., 2017).

S obzirom na veliki broj studenata, nastavnicima je često problem pratiti individualni rad svakog studenta. Moderne tehnologije, ne nužno na osnovi umjetne inteligencije, su pomogle olakšati proces poučavanja. Mckinsey & Company, 2018. godine su proveli istraživanje nad 2000 nastavnika iz država s visokom razinom tehnologije u obrazovnom sustavu o tome kako koriste svoje vrijeme, od planiranja nastave i predavanja do ocjenjivanja i održavanja studentskih evidencija (Bryant J., Heitz C., Sanghvi S. i sur.). Istraživanje je pokazalo kako nastavnici u prosjeku troše manje od 50% svog vremena na izravnu interakciju sa studentima, što je u jednu ruku indikator nepostojanja ili slabog pristupa individualnom poučavanju. Još jedna bitna stavka istraživanja pokazala je, kako bi se implementacijom tehnologije omogućilo nastavnicima da posvete više vremena interakciji sa studentima, npr. nastavnici u prosjeku provedu 11 sati pripremajući se za nastavu, a ono bi se moglo skratiti na 6 sati, odnosno dodatnih 5 sati bi se moglo iskoristiti za izravnu interakciju sa studentima (Bryant J., Heitz C., Sanghvi S. i sur.). U slučaju da nastavnici i dalje odluče provesti jednako vremena na pripremu

nastave, tehnologija bi im omogućila bolju organiziranost, odnosno bolju pripremljenost za nastavu u smislu boljih zadataka, nastavnog plana i pristupa predavanju. Takvom tehnologijom otvaraju se vrata za bolju suradnju s drugim nastavnicima i administrativnim tijelom, što vodi ka efikasnijem traženju i pronalasku relevantnih materijala (Bryant J., Heitz C., Sanghvi S. i sur.).

Predavanje nije jedino što spada u sferu nastavničkih obveza. Uz te obveze nastavnici moraju davati i povratne informacije te vršiti evaluaciju nad studentima kako bi se što bolje pripremili za iduće predavanje. Takve obveze se također mogu olakšati implementacijom softvera, npr. softver za pisanje, koji može sagledati trendove pisanja više eseja, te na temelju tih prikupljenih informacija pružiti povratne informacije za svakog pojedinog studenta koje nastavnik može pregledati i prilagoditi. (Bryant J., Heitz C., Sanghvi S. i sur.).

S obzirom na to da tehnologija napreduje, ona će moći bolje i efikasnije pomagati nastavnicima u ispunjavanju njihovih zadataka. Efikasnije ispunjavanje zadataka omogućava kvalitetnije izvođenje nastavu, što će na kraju krajeva od najveće koristi biti samim studentima. Ovakav način izvedbe nastave, uz pomoć raznih novih tehnologija, je najprisutniji u visokom obrazovanju jer se sveučilišni nastavnici najviše bave područjem umjetne inteligencije. S obzirom na viši stupanj obrazovanja i na veće kompetentnosti kojima raspolažu polaznici sveučilišta, oni su u boljoj poziciji da zajedno s nastavnicima, kroz interakciju i rad s njima sudjeluju u poboljšavanju tih sustava.

4. Inteligentni sustavi za poučavanje

Inteligentni sustavi za poučavanje su instrukcionalni sustavi koji koriste umjetnu inteligenciju kako bi mogli poučavati (Padayachee, I. 2002). Cilj ovih sustava je korisnicima, odnosno studentima, dati personalizirane upute i povratne informacije nerijetko bez ljudskih nastavnika (Robot, R. 2020). Unatoč činjenici da studenti mogu dobiti povratne informacije od samih sustava, poželjno je da ljudski nastavnik bude prisutan i da kontrolira rad, jer poučavanje funkcionira najbolje kada postoji i socijalna komponenta. Ovakvi sustavi su dobili više pažnje u posljednjih par godina, kako zbog njihovog napretka tako i zbog činjenice da su sposobni pružiti individualnu nastavu, odnosno jedan na jedan kurikulum, krojen prema potrebama svakog studenta zasebno. Novitet ovakvih sustava je da nastavnici sada mogu naučiti računalo da poučava studente. Nastavnik može pokazati sustavu sve potrebne korake, tako da sam nastavnik riješi zadatak korak po korak, što će sustav pohraniti te će naposlijetku i sam pokušati imitirati nastavnika u rješavanju zadatka. Ukoliko sustav riješi krivo, nastavnik će grešku ispraviti i pokazati iznova kako se dolazi do točnog rješenja. Veliki napredak se dogodio kada je sustav uspio riješiti probleme koje nije bio naučen, već ih je riješio preko generaliziranja, odnosno kad je uz sve prikupljene informacije počeo donositi vlastite zaključke. Na taj način se dogodio pomak, od toga da ljudi pišu upute i pravila za umjetnu inteligenciju inteligentnih sustava, do toga da inteligentni sustavi sami pišu svoja pravila (Robot, R. 2020).

Prema Freedman, Ali i Mcroy (2000) inteligentni sustavi za poučavanje sastoje se od 4 komponente:

a) model domene

b) studentski model

c) model poučavanja

d) okruženje za učenje ili korisničko sučelje

Model domene baziran je na teoriji učenja, odnosno ovaj model sadrži pravila, koncepte i strategije za rješavanje problema. Može imati nekoliko uloga, može procijeniti uspješnost studenta, otkrivati greške u radu ili može služiti kao izvor stručnog znanja.

Studentski model blisko prati napredak studenta i njihov proces rješavanja zadataka (Freedman R., Ali S., Mcroy S. 2000). Studentski model i model domene usko su povezani, tako da kada student krene rješavati zadatak na način na koji nije ispravan ili dobije krivo rješenje, studentski model će to usporediti s pravilima, konceptima i strategijama za rješavanje problema koje se

nalaze u modelu domene te će u slučaju neslaganja dati upozorenje (Freedman R., Ali S., Mcroy S. 2000).

Model poučavanja kao i studentski model, blisko prati studenta, tj. njegov rad tijekom rješavanja zadataka. Ako model poučavanja primijeti da student odstupa od strategije rješavanja, dat će mu pravovremeno upozorenje u stvarnom vremenu. Na temelju riješenih zadataka model poučavanja se ažurira te pohranjuje nove informacije o sposobnostima studenta za rješavanja određenog problema (Freedman R., Ali S., Mcroy S. 2000). Kada sustav procijeni da je vjerojatnost uspješnog rješavanja određenog zadatka studenta veća od 95%, odnosno da je sustav gotovo u potpunosti siguran da će student samostalno moći riješiti određeni zadatak, prijeći će na idući. Na njemu će po istom principu prolaziti kroz zadatak sa studentom sve dok vjerojatnost uspješnog samostalnog rješavanja ne pređe tu granicu od 95%. Na kraju, korisničko sučelje objedinjuje već prije spomenute tri domene i omogućuje studentu komunikaciju s inteligentnim sustavima za poučavanje.

Prema Luckin, Holmes, Griffiths i Forcieru (2016) postoje 3 kategorije softverskih aplikacija, tj. inteligentnih sustava za poučavanje, s obzirom na način na koji se primjenjuju u obrazovanju, a to su:

a) inteligentni osobni tutori

b) inteligentna potpora za kolaborativno učenje

c) inteligentna virtualna realnost

Pod osobnim tutorima se misli na imitaciju instruktora koji daje individualne instrukcije nekom studentu. Ovakve aplikacije funkcioniraju na bazi studentskih modela, algoritama i neuronskih mreža. Studentski modeli prikaz su sposobnosti, vještina, razina znanja i nedostataka kod studenata. Na temelju tih informacija dobiva se uvid u to koliko je neki student sposoban usvojiti gradivo, te koje su mu jačine i slabosti u znanstvenim područjima. Nadalje, algoritmi uz veliku količinu podataka prema Sennaar (2019) postaju jači i sposobniji, odnosno u mogućnosti su obavljati zadatak za koji su zaduženi, točnije, efikasnije i brže. Kroz kombinaciju i kolaboraciju studentskih modela, algoritama i neuronskih mreža inteligentni sustavi za poučavanje sposobni su vjerodostojno imitirati ljude u poučavanju. Takvi sustavi donose odluke o usmjerenju u kojem bi student trebao ići, na temelju njegovih jačina i slabosti u određenim znanstvenim područjima. U slučaju da je studentu potrebna pomoć, mogu je pružiti, te su čak sposobni i inicirati dijalog sa studentom kako bi proces učenja i poučavanja bio što bolji i efikasniji (Zawacki-Richter i sur.,2019).

Potencijal ovakvih inteligentnih aplikacija prividno je neograničen, a njihovu pravu vrijednost i moć vidimo kada je potrebno poučavati veliki broj studenata na udaljenosti. S obzirom na to da je 2020. godinu obilježila bolest COVID-19, javila se potreba za online nastavom tj. poučavanjem na daljinu. Tisuće učenika i studenata bili su primorani pohađati nastavu iz vlastitog doma, jer se nastava odvijala na daljinu i preko interneta. Zbog velikog broja studenata koji uče na vlastiti način, vlastitom brzinom i imaju različitu brzinu usvajanja znanja, nastavnicima je potrebna pomoć kako bi poučavanje bilo što efikasnije, a taj problem je riješen putem inteligentnih sustava za poučavanje.

Šturo poučavanje nije dovoljno studentima, već je potrebna jedna razina socijalizacije. Ljudi, kao socijalna bića, uglavnom uspijevaju najbolje u svojim naumima i naukama kroz kolaboraciju i pomoć drugih. Zbog ljudske potrebe za kolaboraciju vrlo je bitno online kolaborativno učenje, ali se takav način učenja mora nadgledati i mora biti moderirano i vođeno. Umjetna inteligencija je sposobna nadgledati što se događa u takvom okruženju, i na temelju prikupljenih informacija donositi odluke kako bi se proces učenja olakšao i poboljšao (Zawacki-Richter i sur., 2019). Umjetna inteligencija pridonosi kvaliteti kolaborativnog online učenja, tako da olakšava i pruža pomoć tijekom komunikacije studenata, na kraju sve diskusije sumira i predstavi ih tako ljudskom predavaču, koji te informacije može iskoristiti kako bi ih vodio dalje i usmjerio na pravi put.

Na kraju, inteligentna virtualna realnost, kao što i samo ime ove tehnologije kaže, stvara virtualnu realnost kroz koje studenti mogu biti u okolini prikladnoj za poučavanje. U takvim autentičnim okolinama virtualne realnosti, virtualni agenti mogu predstavljati nastavnike, moderatore ili čak vršnjake studentima koji pohađaju nastavu kroz virtualnu realnost (Zawacki-Richter i sur., 2019). Prema Troconis-Rodell (2019) virtualni agenti su računalno generirani i animirani virtualni likovi, koji raspolažu umjetnom inteligencijom i koji služe kao predstavnici službe ili institucije. Takvi virtualni agenti se ne koriste samo u kontekstu obrazovanja, već su rasprostranjeni i mogu se naći i u drugim područjima, npr. u Microsoftu predstavljaju prodajne predstavnike. Virtualni agenti su u mogućnosti prikupljati podatke i analizirati ih, a u kontekstu obrazovanja preko analiziranih podataka donositi zaključke i davait preporuke studentima što bi trebali napraviti, kako bi bili uspješniji. Nadalje, te informacije mogu prenijeti i samim nastavnicima, koji na temelju njih također mogu donijeti odluke za koje smatraju da su najbolje za određenog student u tom trenutku.

Primjeri takvih sustava jesu: *Algebra Tutor, eTeacher, Mathematics Tutor, Smart Tutor, AutoTutor* i dr. Navedeni inteligentni sustavi za poučavanje funkcioniraju na istom principu,

na način da pomažu studentima i nastavnicima kako bi nastava bila što kvalitetnija. Sustavi uzimaju postojeće podatke o znanju studenata, i na temelju njih se prilagođavaju na način da će studentima dati primjerene zadatke, pomoći im ako naiđu na problem koji ne mogu riješiti i nadgledati njihov cjelokupni rad. Nastavnici, s druge strane, imaju pristup svim informacijama te kroz kolaborativni rad s inteligentnim sustavima za poučavanje osmišljavaju najbolji i najefikasniji plan i program provođenja nastave, kako bi studenti dobili najbolju moguću obuku.

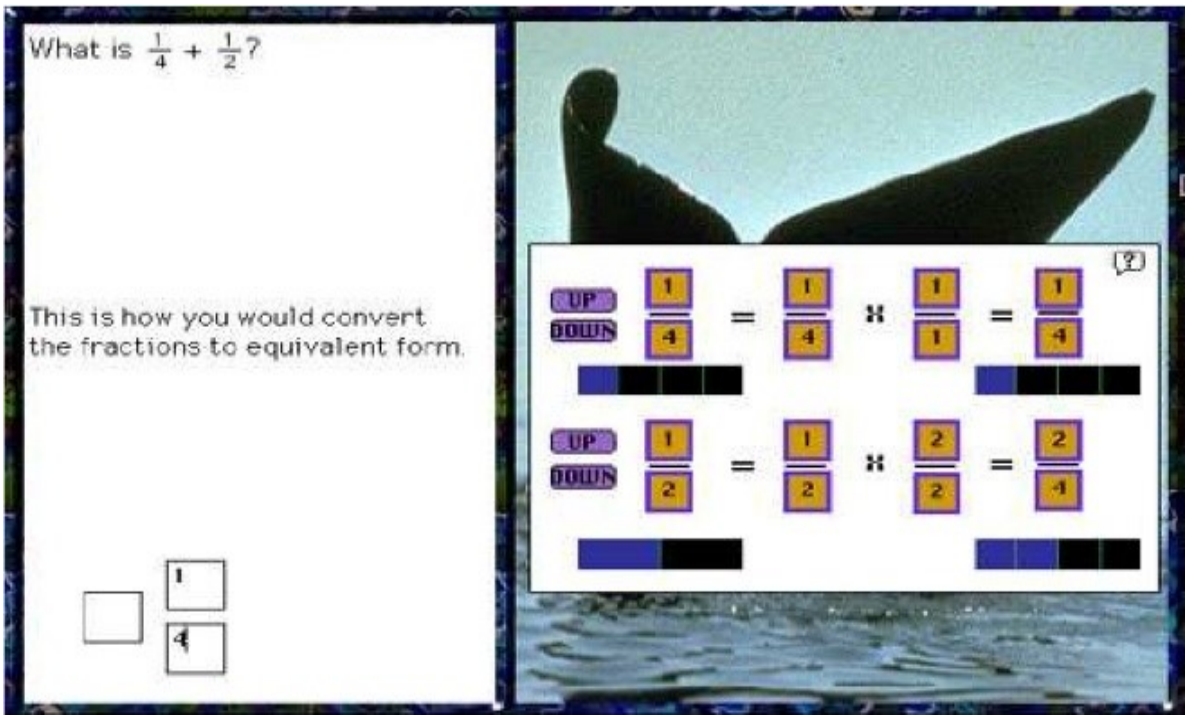
U devedesetim godinama prošlog stoljeća pojavio se veliki interes za razvitak inteligentnih sustava za poučavanje, no taj interes je brzo nestao jer ih je vrlo teško napraviti (Reeves T. C., 1998). Ipak, u 2010. godini, opet se javio interes za razvoj inteligentnih sustava za poučavanje zato što se preko statističke umjetne inteligencije, baziranoj na neuronskim mrežama, uspjelo izvući veliku količinu uzoraka iz velike količine podataka što je omogućilo sustavima da npr. daju savjet na temelju analize prikupljenih podataka (Reeves T. C., 1998).

4.1. Primjeri inteligentnih sustava za poučavanje

WhaleWatch je inteligentni sustav za poučavanje, napravljen od strane Beal Beck Wolf i suradnika, i specifično je dizajniran kako bi budućim generacijama koje se namjeravaju obrazovati u STEM području, pogotovo u matematici i inženjerstvu, približio matematiku. Sustav je dizajniran za podučavanje razlomaka (Beal, Beck Wolf, 1998). Ovaj inteligentni sustav za poučavanje se dinamički ažurira kako bi pratio potrebe i napredak tj. zaostatke studenata. WhaleWatch odabire probleme koji odgovaraju po težini učenicima, te na temelju prikupljenih podataka o uspješnosti ili neuspješnosti pruža pomoć i daje upute. S obzirom na to da je sustav razvijen prije više od dva desetljeća, uvelike je bio baziran na tome da učenicama približi matematiku i inženjerstvo jer su tadašnja istraživanja pokazala da je manje vjerojatno da se učenice opredijele za STEM područje (Beal, Beck Wolf, 1998). WhaleWatch je dobio ime po primjeru koji se koristio pri podučavanju razlomaka, tj. rješavanje razlomaka se postavilo u kontekstu da je student biolog koji nastoji spasiti ugroženu vrstu kitova tj. Right Whalea. Ovakav je primjer iskorišten jer su autori sustava smatrali kako će time razviti veći interes za matematiku kod studentica.

WhaleWatch je zamišljen tako da studentu ponudi određeni zadatak. Ako student riješi zadatak bez problema, prelazi na teži, ali ako 2 puta za redom unese pogrešan odgovor sustav će pitati „želite li vidjeti primjer?“. U slučaju da student odgovori da želi, sustav će studentu pustiti kratak video u kojem prikazuje postupak rješavanja. Ako student ne razumije ključan koncept,

onda će sustav sa studentom prolaziti korak po korak kroz zadatak sa sve detaljnijim objašnjenjima u slučaju da je potrebno.

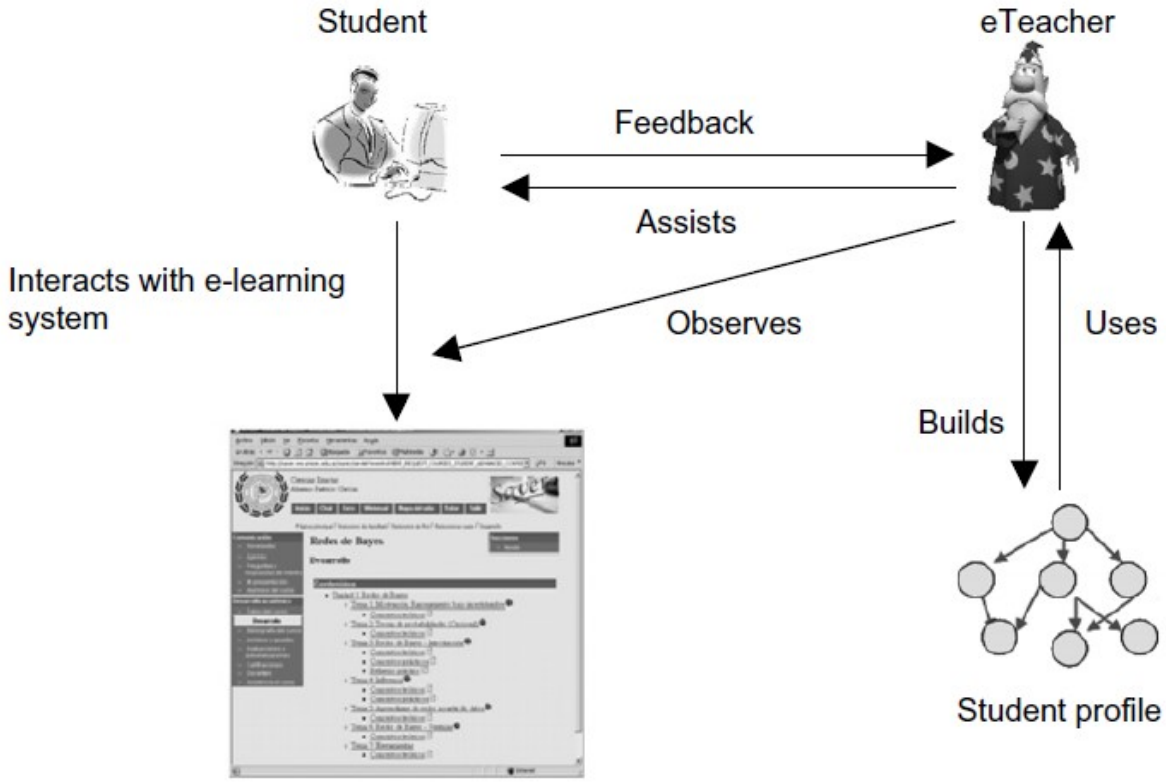


Slika 4. WhaleWatch inteligentni sustava za poučavanje

Izvor: Beal, Beck, Wolf i sur. (1999).

eTeacher, inteligentni sustav za podučavanje razvijen od strane Schiaffino, Garcie i Amandia, nudi individualni pristup podučavanju, odnosno adaptira se prema potrebama studenata kako bi im olakšao usvajanje znanja i doprinio boljem i kvalitetnijem izvođenju nastave. Ovakvi tipovi sustava uče kako njihovi korisnici funkcioniraju, koje su njihove preference, navike i interesi, te na temelju prikupljenih informacija daju svakom studentu proaktivnu, personaliziranu pomoć (Schiaffino, Garcia, Amandi 2008). Način na koji eTeacher funkcionira je da prvo napravi profil studenta koji je većinom baziran oko stila učenja studenta. Takav model raspoređuje studente prema tome gdje se uklapaju na nekoliko ljestvica, koje su indikator kako student prima i obrađuje informacije (Schiaffino, Garcia, Amandi 2008). Vrlo je bitno da se ostvari individualni pristup na ovoj razini, jer su svi studenti različiti, neki usvajaju znanje brže a neki sporije, neki studenti preferiraju kompleksne i apstraktne zadatke, dok drugi preferiraju koncizne. Kako bi svi mogli učiti i pratiti gradivo približno jednakom brzinom, gradivo tj. način na koji se gradivo predstavlja mora biti prilagođen svakom studentu

posebno, a s obzirom na to da se nerijetko radi o velikom broju studenata, sustav mora biti optimiziran popratiti potrebe svih studenata.



Slika 5. Pregled eTeachera

Izvor: Schiaffino, Garcia, Amandi, 2008.

Student koristi sustav eTeacher koji zatim prikuplja informacije i asistira studentu u rješavanju problema. Student daje povratne informacije sustavu, kroz rad na nekom problemu, koji zatim koristi te informacije kako bi stvorio profil studenta u svrhu približavanja individualnom modelu poučavanja.

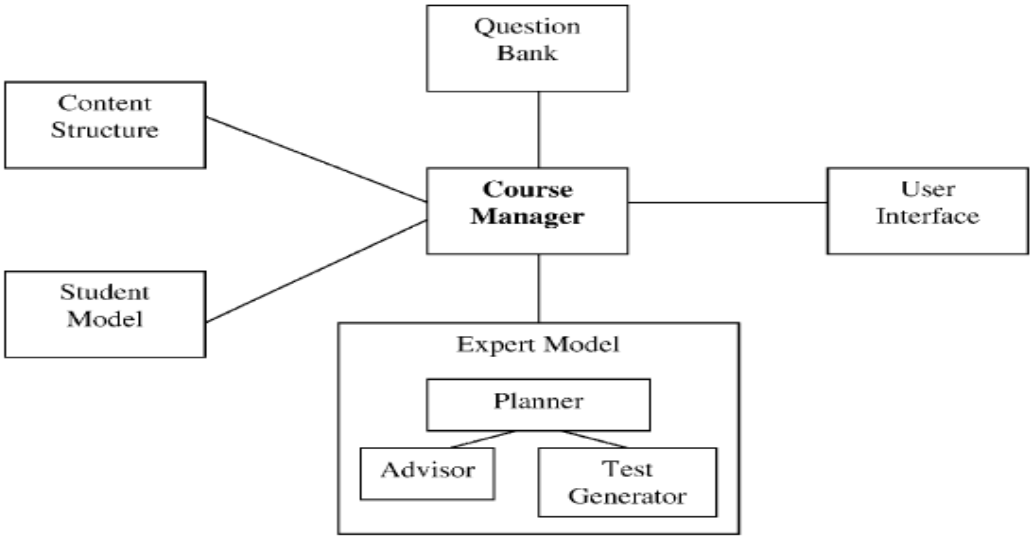
Algebra Tutor, odnosno PAT (PUMP [23]Algebra Tutor) je inteligentni sustav za poučavanje, razvijen sredinom devedesetih godina od strane Koedingera, Andersona, Hadleya i Mark. Sustav je implementiran u školi u Pittsburghu, gdje se pokazao vrlo efikasnim. Naime, učenici koji su sudjelovali u program, koji je bio baziran oko PAT kurikuluma, ostvarili su 15% bolje rezultate na standardiziranim testovima nego što su njihovi vršnjaci koji su bili dio standardnog kurikuluma (Koedinger, Anderson, Hadley i sur. 1997). Sustav je koncipiran tako da nastavnici matematike surađuju sa sustavom, kako bi matematičke zadatke učinili pristupačnijima svojim

[23] Pittsburgh Urban Mathematics Project

učenicima. Sustav umjesto tradicionalnog načina predstavljanja zadataka, zadatke daje kroz simulacije stvarnoga svijeta kao način da se matematika učini značajnijom i da se pokaže njena primjena u „stvarnom svijetu“ (Koedinger, Anderson, Hadley i sur. 1997). Učenici rade na malim projektima, poput toga da uspoređuju kojim intenzitetom raste drveće u Americi i kojom brzinom se sječe, te im se postavljaju pitanja poput „kada će sve drveće koje je do tog trenutka izraslo nestati?“ (Koedinger, Anderson, Hadley i sur. 1997). Osim što sustav nudi novi način rješavanja problema i razmišljanja, služi i za razvijanje moralne svijesti kod učenika, potiče ih da razmišljanju o planeti i kako ju očuvati za buduće generacije.

Smart Tutor, inteligentni sustav za poučavanje implementiran za poučavanje na daljinu u Hong Kongu, razvijen na School of Professional and Continuing Education[24], The University of Hong Kong[25] (HKU SPACE). Ovaj inteligentni sustav za poučavanje, napravljen je kako bi omogućio tečajeve starijim studentima i onima koji nisu studenti, a danas ima preko 30 000 korisnika. Pruža cjeloživotno učenje kako bi omogućilo ljudima da prate svoje interese i da se razvijaju i treniraju u području vlastitih interesa (Cheung, Hui, Zhang i sur. 2002). Smart Tutor je sastavljen od šest komponenata: voditelj tečaja, baza pitanja, studentski model, struktura sadržaja, stručni model i korisničko sučelje (Cheung, Hui, Zhang i sur. 2002). Zadatak voditelja tečaja je da koordinira ostale komponente kako bi funkcionirale bolje, struktura sadržaja održava odnos između sadržaja predmeta što omogućava voditelju tečaja da kreira individualne strukturne mape za studente kako bi svaki imao individualni pristup poučavanju. Baza pitanja sadržava pitanja koja su relevantna za određeni predmet koji se predaje, a studentski model sadrži profile studenata kako bi se omogućio individualni pristup poučavanju koji će kreirati stručni model.

[24] Hrv. Škola za stručno i trajno obrazovanje
[25] Hrv. Sveučilište u Hong Kongu, osnovano 1911.



Slika 6. Arhitektura Smart Tutora

Izvor: Cheung, Hui, Zhang i sur. 2002

Za razliku od drugih inteligentnih sustava za poučavanje, ovaj je primjenjiv na više znanstvenih područja i pruža obrazovanje i starijim generacijama koje žele nastaviti svoje učenje. S obzirom na to da je cjeloživotno učenje neizostavni dio života, ovakav sustav nudi brojne mogućnosti i otvara mnoga vrata budućim generacijama, kako bi mogli nastaviti raditi efikasno u novom razdoblju koje se konstantno mijenja, adaptirajući se na promjene koje u 21. stoljeću postaju sve brže i češće.

4.2. Problemi koje rješava umjetna inteligencija

Područje umjetne inteligencije koristi napredak računalnih znanosti, kako bi stvorilo strojeve koji izvršavaju zadane zadatke i donose odluke, na onaj način kako bi to učinio i čovjek (Becker, Brown, Dahlstrom i sur. 2018). Kroz prilagodbu sustava koji koriste umjetnu inteligenciju da reagiraju na postavljene zadatke i prepreke na takav način da bude što vjerodostojniji i da što bolje imitira ljudsku ruku, ostvaruje se mogućnost visoke i profitabilne suradnje ljudi i umjetne inteligencije, odnosno ljudi i strojeva. Razvitak umjetne inteligencije doprinio je tome da se ona implementira u različita područja, tj. u različite industrije, kao što su zdravstveni sustav, financijske usluge i u sve razine obrazovanja. Potencijal umjetne inteligencije je prividno beskrajan, a u kontekstu edukacije kojim se ovaj rad bavi umjetna inteligencija ima sposobnosti poboljšati gotovo sve aspekte edukacije. Umjetna inteligencija ima mogućnost poboljšati online učenje na način da bi ga moglo dovesti na razinu kvalitete koja dosad nije bila dostupna. Obzirom na činjenicu da u vrijeme pisanja ovog rada traje epidemija bolesti COVID-19, mnogi studenti su primorani pohađati i slušati predavanja na

računalima na sigurnoj udaljenosti. Takav način obrazovanja dovodi do umora izazvanog korištenjem Zooma (eng. Zoom Fatigue[26]) (Lee, J., 2020). Zoom Fatigue, kao pojava se u globalnom aspektu prvi puta javlja 2020. godine kao posljedica korištenja platformi za online komunikaciju. S obzirom na to da je 21. stoljeće doba inovacija, ideja i rješenja, tako je pronađeno i rješenje za ovaj novi globalni problem, odnosno tzv. umor izazvan korištenjem platformi za online komunikaciju.

Umjetna inteligencija razvija nove pristupe učenju i daje nova rješenja na probleme koji se mogu pojaviti tijekom učenja. Nije neuobičajeno da student ne razumije materijal koji se obradio tijekom nastave, i nekada je vrlo izazovno za studenta da sustigne svoje akademske vršnjake u obradi i razumijevanju gradiva. Predavaonice, odnosno kolegiji koje studenti pohađaju na sveučilištima su vrlo često popunjeni te nastavnici nemaju prostora ni vremena za individualno poučavnje svakog studenta, odnsono ne mogu svakom studentu posvetiti pažnju koja im je potrebna u određenim situacijama. I sam manjak nastavnika na sveučilištima dodatno otežava situaciju, odnosno nastavnici su primorani vršiti nadzor nad velikim brojem kolegija, a u skladu s tim i nad velikim brojem studenata, te vrlo često nisu u mogućnosti pružiti studentima pažnju i pomoć koja im je potrebna.

Kao pomoć nastavnicima javljaju se sustavi umjetne inteligencije koji su prilagođeni nastavnom okruženju te koji mogu popuniti potencijalne rupe koje se mogu javiti u akademskom životu studenata, ali i nastavnika. Takvi inteligentni sustavi koji bi davali instrukcije studentima ne bi zamijenili nastavnike, već bi poboljšali njihove sposobnosti kako bi što bolje i efikasnije mogli prilagoditi gradivo svakom studentu (Avery, A., 2020). Takvi sustavi su sposobni primiti veliku količinu podataka i analizirati ih na taj način da nastavnici dobiju uvid u to gdje kojem studentu treba pomoć u obradi gradiva. Također, i sami sustavi su sposobni prilagoditi gradivo studentima i dati im naputke čemu trebaju posvetiti više vremena. Takve tehnologije neće zamijeniti nastavnike već će im kao potpora omogućiti veću razinu suradnje sa studentima, odnosno priuštit će nastavnicima više vremena da se posvete stvarima koje su bitne, poput interakcije i razvijanje odnosa sa studentima. Umjetna inteligencija je u mogućnosti vršiti evaluacije nad radom i napretkom ili zaostatkom studenata te na temelju prikupljenih informacija osigurati sigurniji akademski put. Socijalni aspekt nastave je jako bitan jer diže samopouzdanje studentima te ih motivira na rad što uvjetuje pozitivnim promjenama (ASAP, 2017). U idealnom slučaju, prema Luckin, profesorici na sveučilištu u

[26] Zoom Fatigue je osjećaj umora, brige ili jednostavno ne mogućnosti korištenja više platformi za online komunikaciju zbog pretjeranog korištenja.

Londonu „Zadržavate dio u kojem su ljudi posebno dobri, a zatim pokušavate automatizirati podršku unutar tog sustava“.

Osim što inteligentni sustavi mogu primiti informacije o studentima i analizirati ih, inteligentni sustavi mogu također uzeti i nastavni materijal te ga predstaviti svakom studentu posebno u manjim i lakše probavljivim dijelovima (Lynch, M., 2018). Studentima se daje i prilagođeni obrazovni tijek i program, te svaki student može učiti svojim tempom. Sustavi koji koriste umjetnu inteligenciju mogu prepoznati, analizom podataka, i ima li neki student problema u učenju. Sustavi koji se trenutno testiraju u mogućnosti su precizno identificirati ako student ima disleksiju ili diskalkuliju, što omogućuje nastavnicima efikasnije korištenje dostupnih sredstava kako bi studentima pomogli u obrazovanju (Lynch, M., 2018).

S obzirom na to da inteligentni sustavi pomažu studentima da budu uspješniji tijekom obrazovanja, to donosi i određene novčane dobitke, odnosno bolje rečeno uštedu. Vrlo često studenti koji zaostaju za svojim vršnjacima moraju uzeti instrukcije iz određenog kolegija kako ne bi zaostali za svojim kolegama. S obzirom na to da instrukcije znaju biti dosta skupe, a nemaju svi mogućnost platiti individualno podučavanje, studenti koji pohađaju kolegije koji se predaju u suradnji s inteligentnim sustavima, mogu se njima obratiti za pomoć. Takvi sustavi su smišljeni na način da studenti mogu rješavati zadatke više puta sve dok ne dođu sami do odgovora ili im to može ponudit sustav, mogu dobiti povratne informacije od sustava u obliku pitanja ili savjeta, i na kraju sustav može donijeti općenitu procjenu učenikova znanja što studenti i nastavnici mogu iskoristiti kako bi proširili znanje studenta (Beylo, B., 2020).

Vrlo često učenici ne znaju koje sveučilište i usmjerenje odabrati, a često i nakon upisa ne znaju točno u kojem smjeru nastaviti. Tradicionalno su studenti odlučivali što bi htjeli uzimajući u obzir svoje želje, želje drugih, financijsku sigurnost koje nudi određeno znanstveno području, savjeti roditelja, nastavnika i drugih. No kao što je spomenuto, na želje studenata tj. budućih studenata vrlo često utječu drugi ljudi te odluka nerijetko nije njihova osobna. Prema Nazerian (2018) studenti mogu dobiti uvid u sveučilišta koja bi im odgovarala prema tzv. pasivnim podacima kao što su npr. videozapisi koje gledaju na YouTubeu. Dobar odabir sveučilišta bi doprinijeo uspješnosti ispunjavanja akademskih obveza, motiviranosti za rad, općenito sreći i zadovoljstvu studenta, a potencijalno i uštedu jer bi bila manja vjerojatnost od mijenjanja sveučilišta.

5. Istraživanje studentskog stava u vezi umjetne inteligencije

U sklopu diplomskog rada provedeno je istraživanje, u anketnom obliku, pod istoimenim nazivom kao i diplomski rad, tj. „Umjetna inteligencija u visokom obrazovanju“. Anketa je ispitivala razinu doticaja koju studenti imaju s umjetnom inteligencijom, u kojem smjeru vide njen razvoj i smatraju li da je korisna u okviru visokog obrazovanja.

Anketa je bila provedena nad studentima svih znanstvenih usmjerenja u Republici Hrvatskoj, kako bi se dobio opći dojam o razini doticaja s umjetnom inteligencijom studenata u privatnom i u akademskom životu. Anketom je prikupljeno 150 odgovora. Sudionici ankete su prije početka bili upoznati s njezinim ciljem, te je istraživanje u cijelosti bilo anonimno.

Anketom su se prikupljali sljedeći podaci:

- **Opći podaci o studentima** (spol i godina rođenja)
- **Znanstveno područje studija studenata**
- **Smatrate li da je razvoj umjetne inteligencije (UI) brži nego razvoj drugih tehnologija?**
    - Mišljenja studenata o brzini razvoja umjetne inteligencije – s obzirom na to da je umjetna inteligencija tehnologija s kojom veliki broj studenata nije dovoljno dobro upoznat, bili su upitani da li smatraju da je razvoj brz u odnosu na druge tehnologije.
- **U kojoj mjeri smatrate da je umjetna inteligencija dio Vašeg svakodnevnog života?**
    - Razina doticaja s umjetnom inteligencijom u privatnom životu – studenti su upitani što smatraju, u kojoj mjeri je umjetna inteligencija dio njihovog svakodnevnog života. Cilj ovog pitanja je bilo vidjeti da li su studenti svjesni zapravo što sve spada u sferu umjetne inteligencije.

- **U kojoj mjeri je umjetna inteligencija dio Vašeg akademskog života?**
    - Razina doticaja s umjetnom inteligencijom u akademskom životu – isto kao i prethodno pitanje, cilj je bio vidjeti u kojoj mjeri je umjetna inteligencija dio njihovog života, ali u ovom slučaju u kontekstu obrazovanja.
- **Označite u kojoj mjeri smatrate da umjetna inteligencija može pomoći u poboljšanju obrazovanja?**
    - Smatraju li studenti da umjetna inteligencija može biti koristan alat u poboljšavanju obrazovanja. Često se javlja averzija kod ljudi pri korištenju novih tehnologija zbog nedovoljno razumijevanja.
- **Smatrate li da je nastava jednako kvalitetna online u usporedbi s tradicionalnim oblikom nastave u učionici?**
    - S obzirom na to da je u svijetu, u trenutku pisanja ovog rada, situacija vrlo ozbiljna zbog pandemije uzrokovanom Covid – 19, studenti su bili upitani što misle o online nastavi s obzirom na to da su se mnogi morali prebaciti u potpunosti na online oblik nastave, koji prije pandemije nije bio naveliko implementiran i korišten.
- **Smatrate li da je umjetna inteligencija dovoljno razvijena da bi se mogla implementirati u nastavu?**
    - Samom činjenicom da je s novijim tehnologijama i znanstvenim područjima upoznat tek manji broj ljudi, cilj ovog pitanja je bilo dobiti mišljenje studenata o implementaciji umjetne inteligencije u nastavu u svrhu njenog poboljšanja.
- **Jeste li upoznati s inteligentnim sustavima koji su sposobni davati odgovore na pitanja?(Chatbot)**
    - Jesu li studenti upoznati s inteligentnim sustavima za davanje odgovora.
- **Smatrate li da bi se inteligentni sustavi za davanje odgovora trebali implementirati na sveučilišta u sklopu administracije?**
    - S obzirom na to da je jedan od najčešćih razloga za prigovaranje studenata o fakultetu sama administracija, ovim putem se htjelo dobiti uvid u to da li bi studenti imali dovoljno povjerenja da se umjetna inteligencija implementira u sklopu administracije kako bi se olakšao proces dobivanja odgovora na pitanja.

- **Da Vaše sveučilište posjeduje inteligentni softver koji bi Vam mogao odgovoriti na pitanja, biste li ga koristili ili biste ipak komunicirali s administrativnim osobljem?**

- Nastavno na prethodno pitanje, u slučaju da sveučilište posjeduje jedan takav softver, da li bi imali dovoljno povjerenja da će dobiti točan odgovor putem takvog sustava ili bi ipak išli tradicionalnim putem i pitali osobno administrativno osoblje.

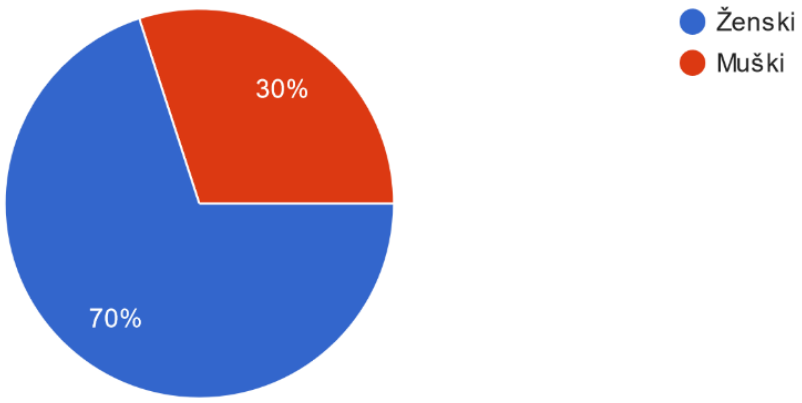
- **Mislite li da su inteligentni sustavi koji analiziraju prikupljene podatke o radu studenata u sklopu obrazovanja na sveučilištu, sposobni donijeti ispravne zaključke o općenitom stanju studenta?**
  - Jedna od glavnih značajki inteligentnih sustava je upravo ta da prikupljaju podatke o studentima, na temelju kojih donose zaključke. Pitanje je da li studenti misle da je takva tehnologija dovoljno dobra da donese zaključak o studentu, koji bi potencijalno mogao donijeti i velike promjene za samog studenta, što se tiče načina na koji mu se predstavlja gradivo.
- **Smatrate li da bi nastavnici uz korištenje inteligentnih sustava za poučavanje bili u mogućnosti pružiti bolje obrazovanje studentima?**
  - Ukoliko bi se student našao na predavanju nastavnika koji u sklopu nastave koristi i inteligentni sustav za poučavanje, smatraju li da bi znanje koje bi stekli bilo bolje od onog kojeg bi stekli da nema takvog sustava.
- **U kojoj mjeri smatrate da su inteligentni sustavi za poučavanje sposobni imitirati rad nastavnika?**
  - Puno puta se moglo čuti da će jednog dana strojevi zamijeniti ljude. Ovim pitanjem se htjelo vidjeti stajalište studenata misle li da su inteligentni sustavi za poučavanje sposobni imitirati rad nastavnika.
- **Odaberite godinu studija (ili više) na kojoj smatrate da bi inteligentni sustavi bili najkorisniji.**
  - S obzirom na to da je sveučilište „samo“ obrazovna institucija u usporedbi s osnovnom i srednjom školom koje su kako obrazovne tako i odgojne, često zna biti šok kada se prelazi na viši stupanj obrazovanja zbog manjka odgojnog aspekta. Ovim pitanjem se htjelo saznati što studenti smatraju, kada bi bilo korisno implementirati inteligentne sustave na sveučilišta s obzirom na to da na ranijim godinama studenti nisu priviknuti na novu okolinu i drugačiji sustav rada, dok su na višim godinama već prikupili neko iskustvo te je u tom slučaju potencijalno potrebna i manja razina vodstva.
- **S obzirom na to da se većina nastave održava(la) online za vrijeme pandemije bolesti COVID-19, smatrate li da je dosadašnji model dostatan ili bi se trebao poboljšati implementacijom umjetne inteligencije?**

- Većina studenata je morala u jednom obliku preći na online nastavu, s obzirom na to da je takav oblik naišao na svojevrsne izazove i probleme, htjelo se vidjeti smatraju li student da bi takav oblik nastave mogao biti unaprijeđen uvođenjem sustava koji koriste umjetnu inteligenciju.

- **Označite probleme za koje smatrate da bi se djelomično ili potpuno mogli riješiti implementacijom inteligentnih sustava na sveučilištu.**
  - Studiranje zna biti vrlo izazovno vrijeme koje zna doći sa određenim problemima. Htjelo se vidjeti smatraju li studenti da li inteligentni sustavi mogu pomoći u rješavanju nekih problema.
- **Prema Vašoj osobnoj procjeni od 1 do 5, mislite li da biste se brzo priviknuli na novi oblik nastave koji bi koristio inteligentne sustave za poučavanje?**
  - Htjelo se vidjeti mišljenje studenata, u slučaju implementacije inteligentnih sustava, u kojoj mjeri smatraju da bi se uspjeli priviknuti na takav novi način poučavanja s obzirom na to da bi to donijelo znatne promjene u načinu na koji se ishodi nastava.
- **Smatrate li da bi se trebalo nastaviti investirati u razvoj umjetne inteligencije?**
  - S obzirom na to da je to jedna vrlo brzo rastuća znanost koja ima mogućnost poboljšanja brojnih aspekata, ali isto tako vodi sa sobom i brojne nedoumice i brige, htjelo se vidjeti da li studenti smatraju kako bi investiranje u to područje bilo korisno ili nepotrebno.

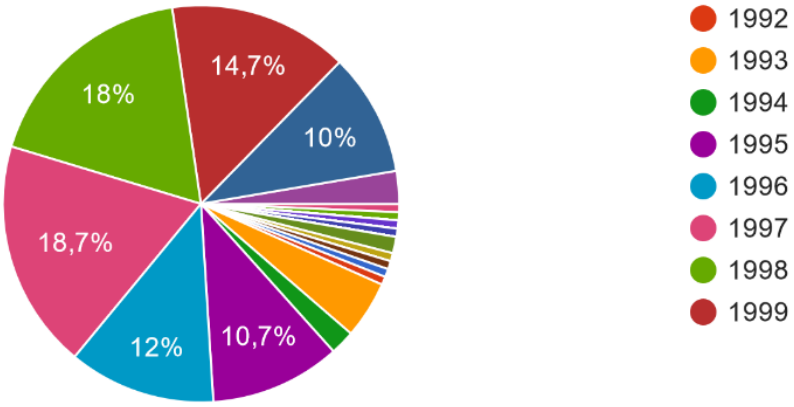
5.1. Opći podaci

Anketu je sveukupno ispunilo 150 studenata od kojih 70% studentica, tj. njih 105, dok su studenti bili u manjem broju s 30%, odnosno 45.



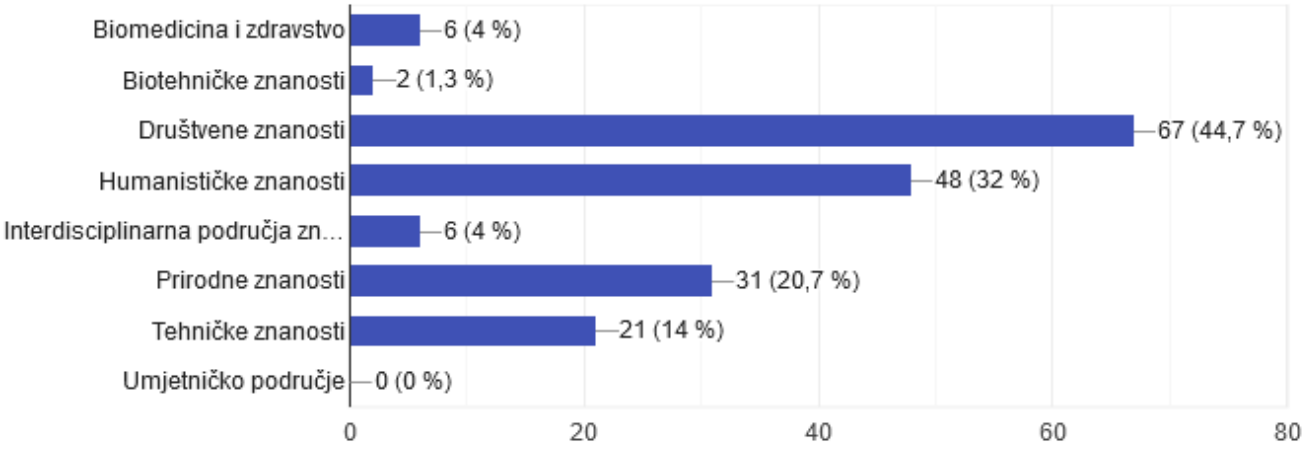
Graf 1. Ispitanici prema spolu

Na grafu 2. prikazana su je raspodjela ispitanika prema godištima. Najveći broj ispitanika rođen je 1997. godine, točnije njih 28, odnosno 18.7%.



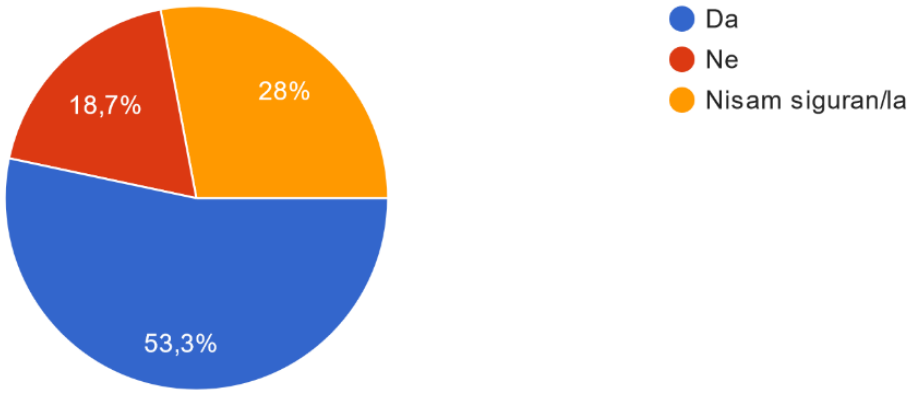
Graf 2. Ispitanici prema godini rođenja

Iz grafa 3. vidljivo je kako je najveći postotak studenata, odnosno 44.7%, studira u području društvenih znanosti. Nakon društvenih znanosti, iduće po broju ispitanika su humanističke znanosti s 32%, odnosno 48 ispitanika. Najmanje je studenata s područja biotehničkih znanosti, dok iz umjetničkog područja nitko nije ispunio anketu.



Graf 3. Ispitanici prema području studija

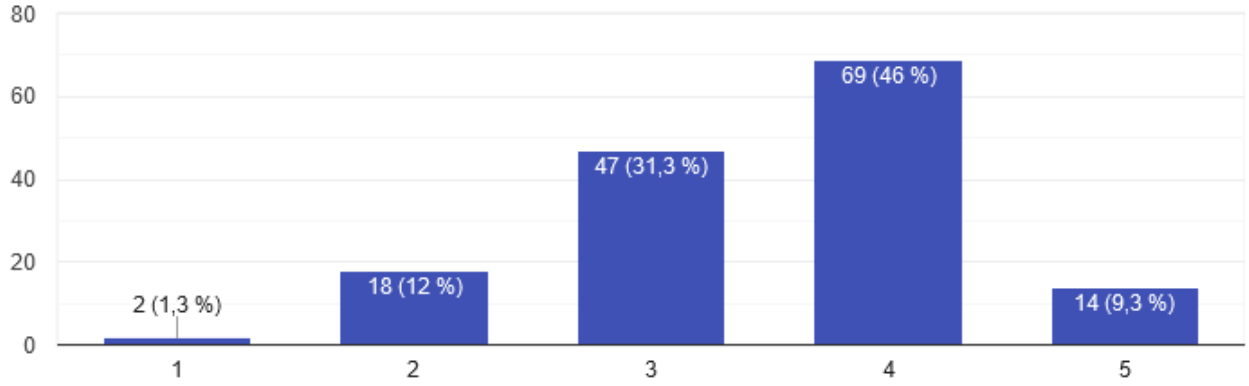
5.2. Razvoj umjetne inteligencije



Graf 4. Mišljenje studenta o brzini razvoju umjetne inteligencije

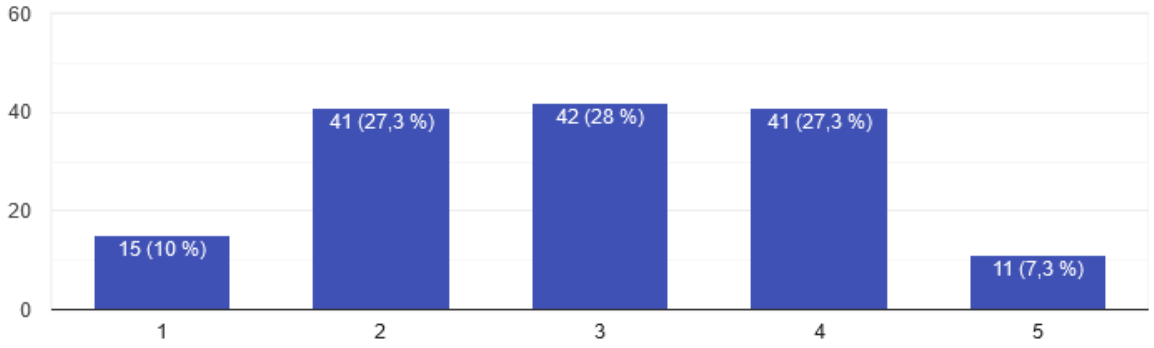
Studenti su bili upitani što misle koliko je brz razvoj umjetne inteligencije u odnosu na druge tehnologije. Većinom su studenti (53,3%) mišljenja da je razvoj umjetne inteligencije brži nego što je razvoj drugih tehnologija, dok njih 18,7% smatra kako nije brži. Gotovo trećina studenata (28%) je odgovorila kako nije sigurna da li je razvoj brži ili ne.

Na pitanje u kojoj mjeri studenti smatraju da je umjetna inteligencija dio njihovog svakodnevnog života, na skali od 1 do 5, gdje je 1 „Nije uopće dio mog života“, a 5 „Veliki je dio mog života“, većina je označila 4 (njih 46%), a najmanji broj studenata je označilo 1 tj. 1.3% studenata smatra da nije u nikakvoj mjeri dio njihovog života.



Graf 5. Mišljenje studenata o razini doticaja s umjetnom inteligencijom u njihovom privatnom životu

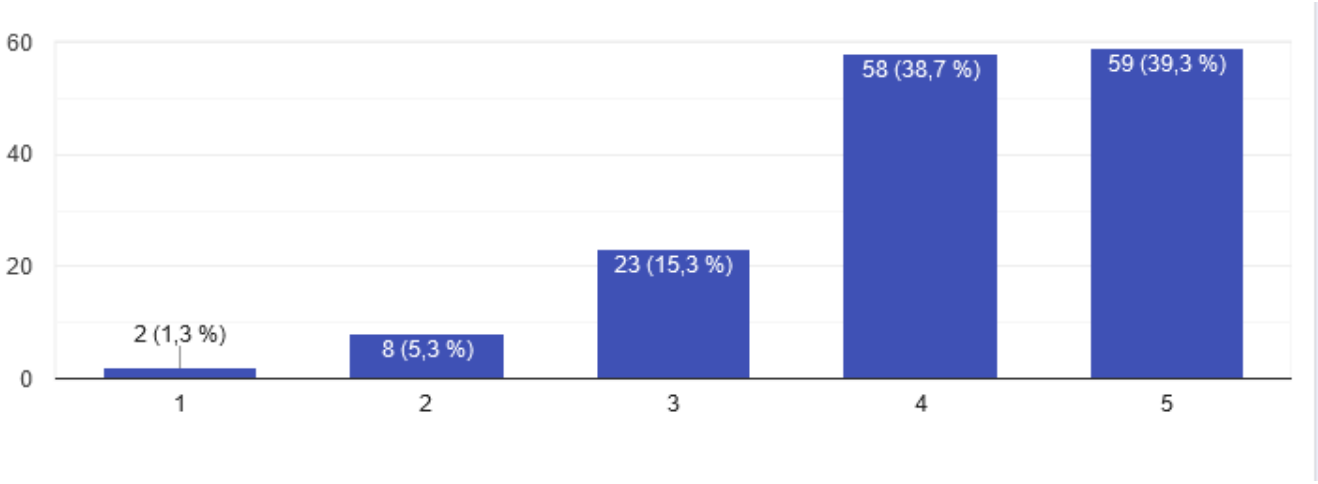
Nastavno na analizu odgovora 5. pitanja odnosno petog grafa, graf 6 daje uvid u kojoj mjeri studenti smatraju da je umjetna inteligencija dio njihovog akademskog života, na skali od 1 do 5, gdje je 1 „Nije uopće dio mog života“, a 5 „Veliki je dio mog života“. Većina odgovora spada u sredinu te nema dominantnog odgovora. Najveći broj glasova je ipak dobio odgovor 3, odnosno da studenti smatraju da je donekle umjetna inteligencija dio njihovog akademskog života. Da umjetna inteligencija nije uopće dio njihovog akademskog života, smatra 10% studenata, dok nešto manje, 7,3% smatra da je u potpunosti dio njihovog akademskog života.



Graf 6. Mišljenje studenata o razini doticaja s umjetnom inteligencijom u njihovom akademskom životu

Sljedeći graf, daje odgovor na pitanje u kojoj mjeri studenti smatraju da bi umjetna inteligencija mogla pomoći u poboljšanju obrazovanja. Velikom većinom studenti smatraju da bi ona mogla puno ili u potpunosti pomoći u poboljšanju obrazovanja (38,7 i 39,3%), dok samo mali broj

smatra da ne bi bila jako ili uopće korisna (1,3 i 5,3%) u poboljšanju obrazovanja. Neutralni stav je zadržalo 15,3% studenata.



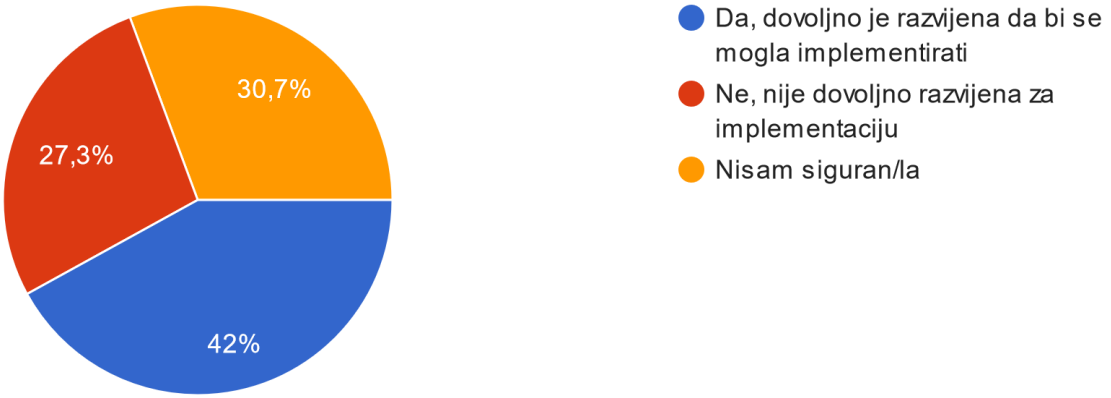
Graf 7. Mišljenje studenata o tome koliko umjetna inteligencija može pomoći poboljšanju obrazovanja

U idućem pitanju, pitalo se studente za mišljenje o online nastavi. Smatraju li studenti da je online nastava jednako kvalitetna kao i nastava koja se odvija tradicionalnim putem u učionici. Odgovor na pitanje može se dobiti uvidom u graf 8 koji prikazuje kako apsolutna većina od 66,7% studenata smatra da nastava nije jednako kvalitetna kao i ona koja se odvija u učionici. Manji dio od 20,7% smatra da je nastava jednako kvalitetna, dok 6% studenata ne može prosuditi.



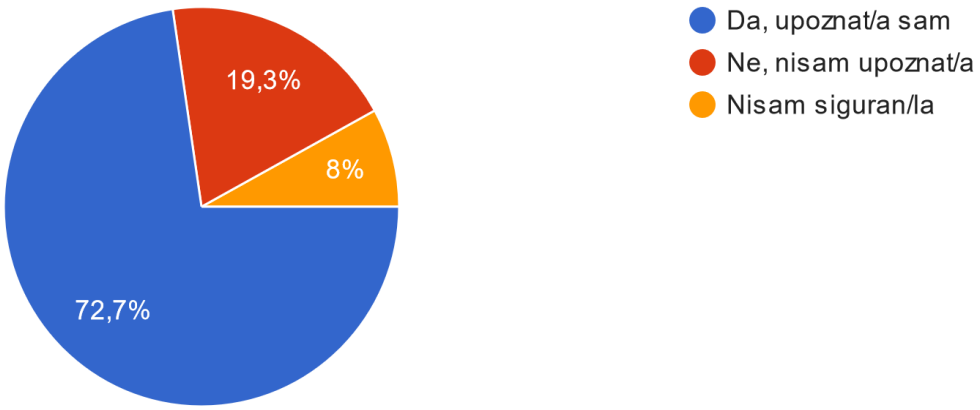
Graf 8. Mišljenje studenata o kvaliteti online nastave

Studenti su na pitanje o implementaciji umjetne inteligencije u nastavi dali odgovore vidljive u grafu 9: njih 42% smatra da je umjetna inteligencija dovoljno razvijena, odnosno da je adekvatna te da se može implementirati u nastavu, 30,7% studenata nije sigurno, a najmanji dio smatra kako umjetna inteligencija nije podobna za implementaciju u nastavu.



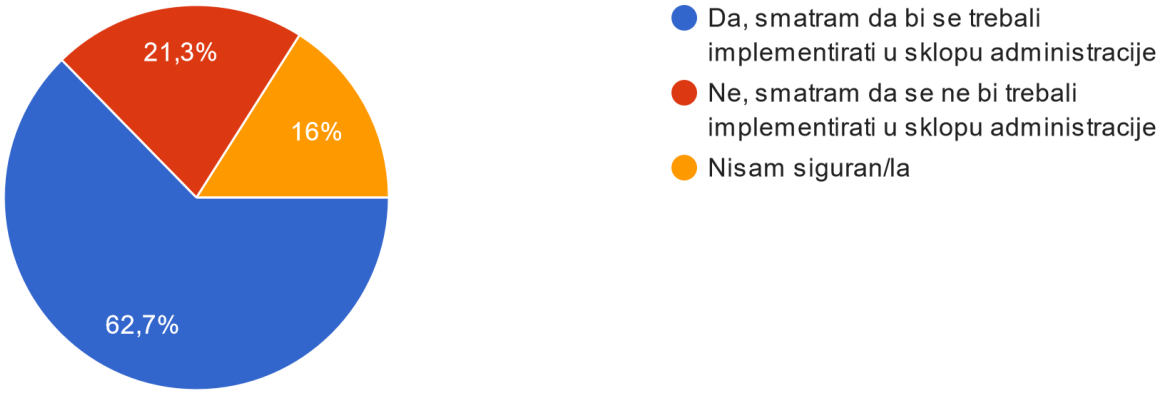
Graf 9. Mišljenje studenata o tome da li se UI može implementirati u nastavu s obzirom na stupanj razvijenosti

U 10. pitanju, studenti su upitani da li su upoznati s Chatbotom, inteligentnim sustavom za davanje odgovora. Velika većina, odnosno 72,7% studenata je upoznata, dok samo jedan manji dio nije upoznat.



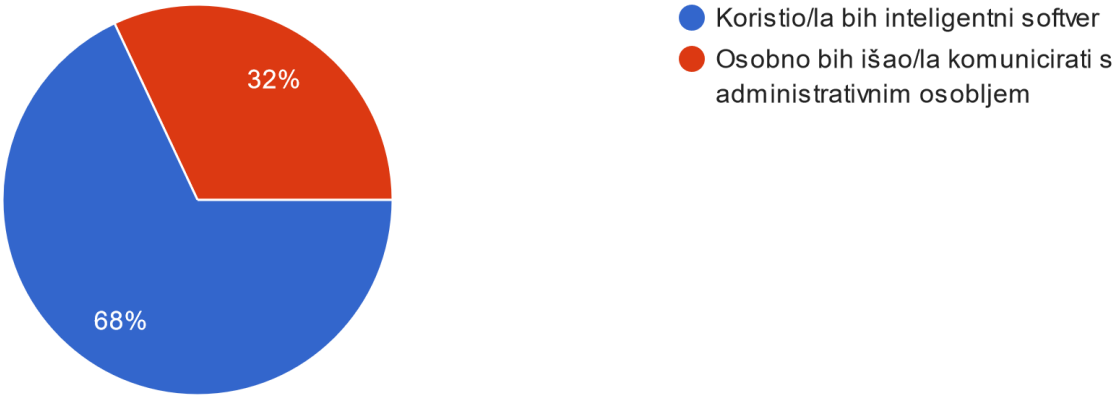
Graf 10. Upoznatost studenata s Chatbotom, inteligentnim sustavima sposobnima za davanje odgovora

Nadalje, 11. pitanje, povezano s 9. daje uvid u mišljenje studenata da li bi se umjetna inteligencija trebala implementirati u administraciju sveučilišta. Većina studenata, njih 62,7%, smatra kako bi se trebala implementirati. S druge strane postotak studenata koji smatra da se umjetna inteligencija ne bi trebala implementirati u administraciju iznosi 21,3, što je bliže prethodnoj brojki od 27,3% studenata koji smatraju da se umjetna inteligencija ne treba implementirati u nastavu. 16% studenata nije moglo dati odgovor na to pitanje.



Graf 11. Mišljenje studenata o tome da li se UI može implementirati u administraciju sveučilišta s obzirom na stupanj razvijenosti

U sljedećem, 12. pitanju, studenti su upitani da li bi prije koristili inteligentni sustav koji bi im mogao odgovoriti na pitanja ili bi ipak pričali s administrativnim osobljem. Pozitivan odgovor na pitanje je dala velika većina sa 68% dok je manji dio (32%) rekao da bi radije pričao s administrativnim osobljem.



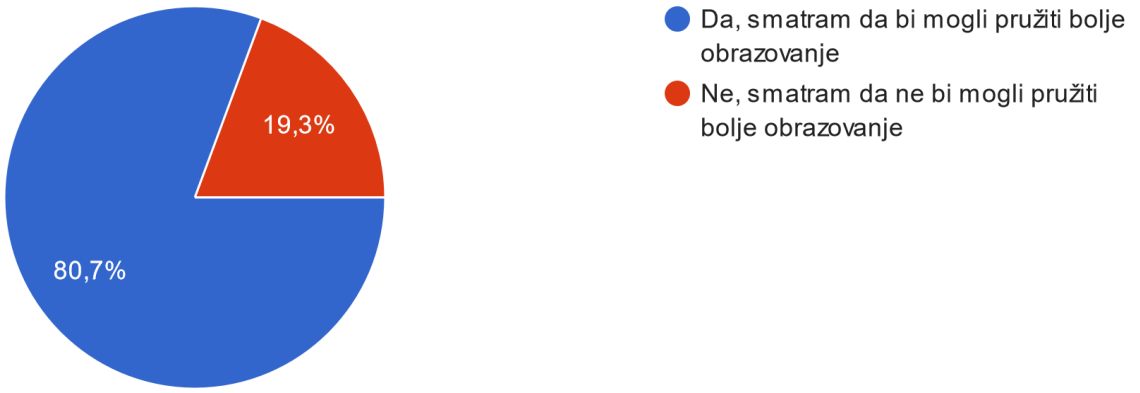
Graf 12. Postotak studenata koji bi koristili inteligentni sustav za dobivanje odgovora na pitanja odnosno razgovarali s administrativnim osobljem

U trinaestom pitanju, student su upitani smatraju li da su inteligentni sustavi za poučavanje sposobni donositi ispravne zaključke o općenitom stanju studenta. Kod ovog pitanja su odgovori podjednaki, uz neznatno više studenata (54%) koji smatraju kako inteligentni sustavi nisu sposobni analizirati stanje studenata adekvatno kako bi donijeli zaključke o općenitom stanju studenata. Nešto manji postotak od 46% smatra kako su takvi sustavi sposobni na temelju prikupljenih informacija donijeti zaključak o općenitom stanju studenta.



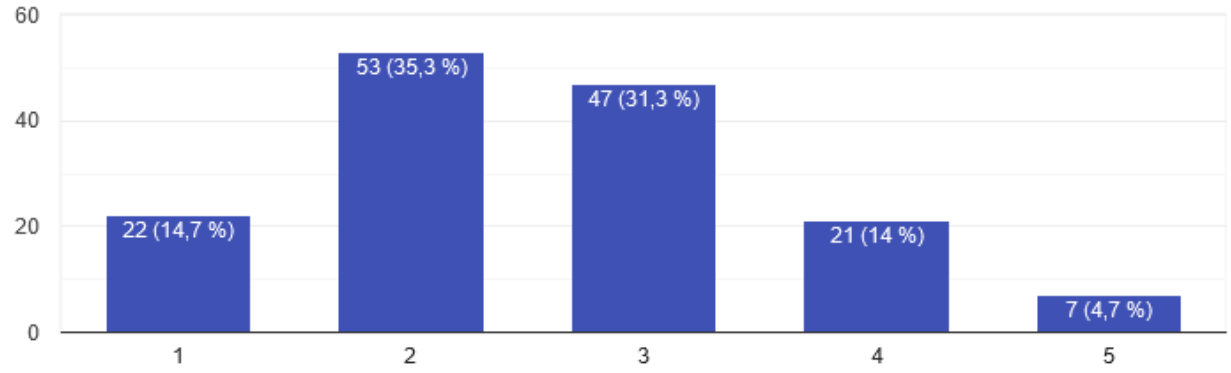
Graf 13. Postotak studenata koji smatra da su inteligentni sustavi sposobni, odnosno nisu sposobni donositi zaključke o općenitom stanju studenata na temelju prikupljenih informacija

Ispitanici koji smatraju da bi nastavnici korištenjem inteligentnih sustava za poučavanje bili u mogućnosti pružiti bolje obrazovanje svojim studentima su u većini sa 80,7%. Dok samo jedan manji dio studenata, točnije njih 19,3% smatra kako inteligentni sustavi ne bi doprinijeli poboljšanju obrazovanja



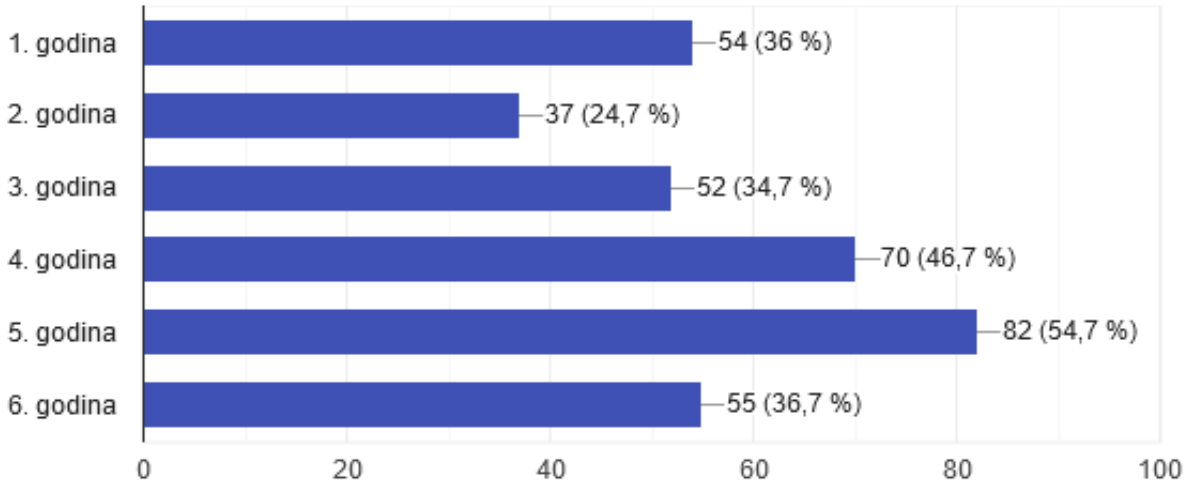
Graf 14. Mišljenje studenata o mogućnosti poboljšanja obrazovanja kroz nastavnikovo korištenje inteligentnih sustava za poučavanje

Studenti su u idućem pitanju upitani da li smatraju da je jedan inteligentan sustav za poučavanje sposoban imitirati rad nastavnika. Studenti su mogli dati svoj odgovor na skali od 1 do 5, gdje 1 predstavlja "nisu sposobni imitirati rad ljudskog nastavnika", a 5 "u potpunosti su sposobni imitirati rad ljudskog nastavnika". Većina studenata (35,3%) je odgovorila s 2, odnosno da smatra da gotovo uopće takvi sustavi nisu sposobni imitirati rad nastavnika, nakon toga u gotovo jednakom postotku, njih 31,3% je odgovorilo s 3, odnosno da smatra da su takvi sustavi donekle sposobni imitirati rad nastavnika. Najmanji postotak smatra kako su u potpunosti sposobni imitirati rad nastavnika (4,7%) dok je nešto veći postotak na drugoj strain skale, 14,7% studenata smatra kako sustavi nisu uopće sposobni imitirati rad nastavnika.



Graf 15. postotak studenata koji smatra da su inteligentni sustavi za poučavanje sposobni, odnosno nisu sposobni imitirati rad nastavnika

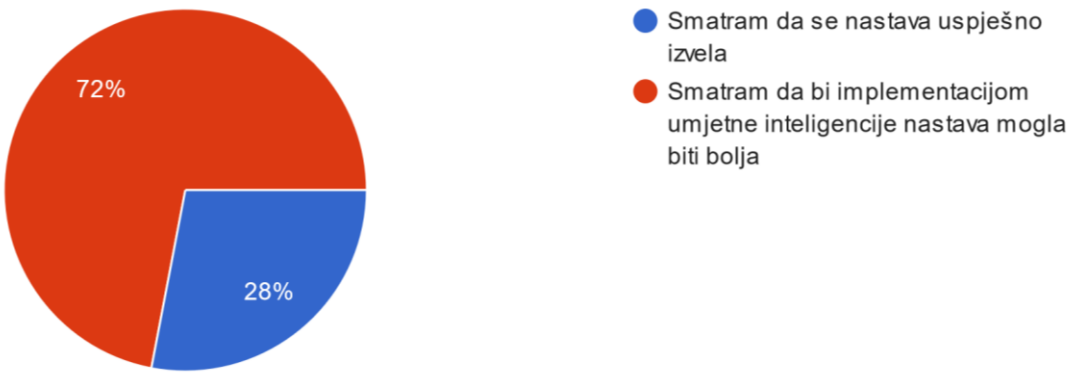
U 16. pitanju studenti su upitani što smatraju, na kojoj godini studija bi inteligentni sustavi bili najkorisniji. Studentima je za ovo pitanje dana mogućnost odabira više odgovora. Iz grafa 16 je vidljivo kako većina studenata smatra da bi takvi inteligentni sustavi bili najkorisniji na kasnijim godinama, odnosno na 5. godini (54,7%) i na 4. godini (46,7%). Tek jedan manji broj studenata smatra kako bi inteligentni sustavi bili korisniji na ranijim godinama, za 2. godinu (24,7%).



Graf 16. mišljenje studenata o inteligentnim sustavima prema studijskim godinama

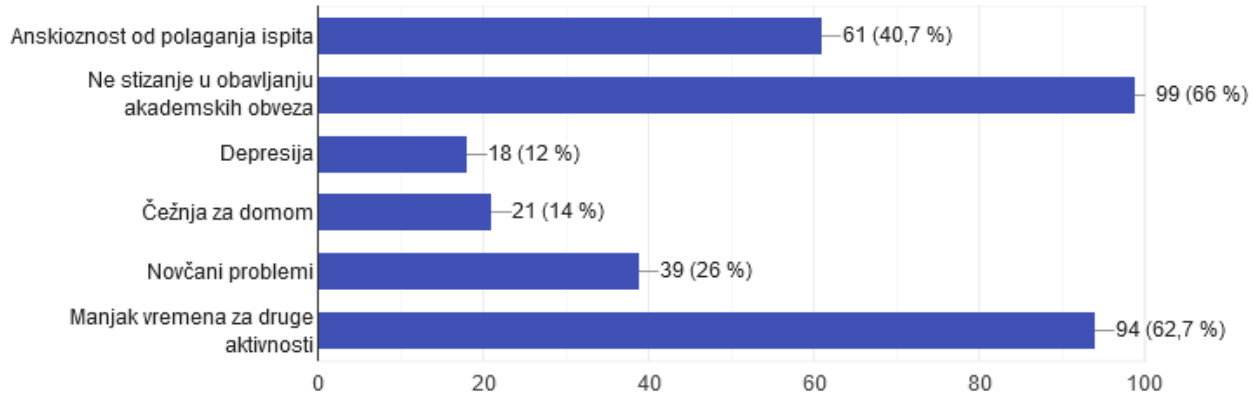
S obzirom na to da se trenutno svijet nalazi u stanju pandemije, bilo je postavljeno iduće 17. pitanje. Većina studenata (72%) smatra kako bi nastava mogla biti poboljšana kroz

implementaciju umjetne inteligencije, dok tek jedan mali dio smatra kako je nastava uspješno izvedena.



Graf 17. Mišljenje o uspješnosti izvođenja/potencijalnom poboljšanju online nastave

S obzirom na to da se gotovo svaki student za vrijeme studija barem jednom susretne s jednom od problema navedenih u anketi, bili su upitani, što smatraju koji bi se problemi mogli riješiti implementacijom inteligentnih sustava na sveučilištima. Na ovo pitanje su student također imali mogućnost odabira više odgovora.

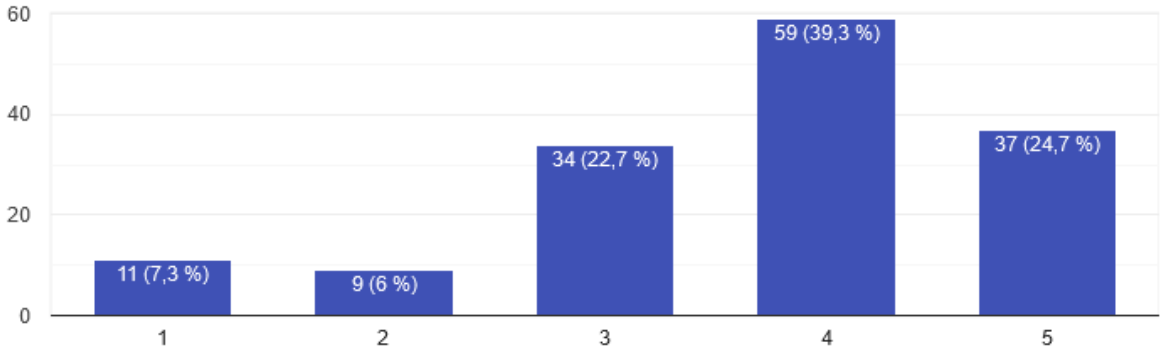


Graf 18. Koje probleme inteligentni sustavi mogu potencijalno riješiti

Graf 18. prikazuje kako većina studenata smatra kako bi inteligentni sustavi pomogli u obavljanju akademskih obveza (66%), a popratno tome i omogućilo više vremena za druge aktivnosti (62,7%). Ova dva odgovora idu jedno s drugim pa je za pretpostaviti da su studenti

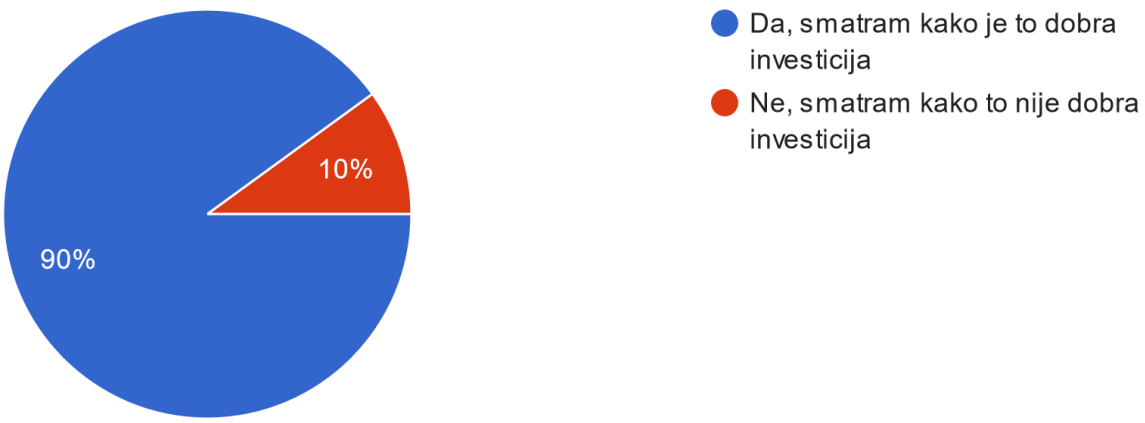
većinom, odabirali ta dva odgovora. Najmanji dio studenata smatra kako bi inteligentni sustavi mogli pomoći kada je u pitanju depresija (12%).

S obzirom na to da se svijet nalazi u nesigurnim vremenima, bilo je postavljeno pitanje u kojoj mjeri studenti smatraju da bi se uspjeli priviknuti na novi oblik nastave koji bi koristio inteligentne sustave za poučavanje. Iz grafa 19. vidljivo je kako većina studenata (39,3%) smatra kako bi se vrlo dobro priviknula na novi oblik nastave (odgovor 4) koji bi koristio inteligentne sustave za poučavanje. Nešto malo manje studenata je označilo odgovor 5, odnosno da bi se vrlo odlično priviknulo na novi oblik nastave (24,7%). Najmanje studenata je označilo odgovore 1 (7,3%) i 2 (6%), odnosno kako smatraju da se uopće ne bi priviknuli na novi oblik nastave ili bi se vrlo teško priviknuli.



Graf 19. brzina privikavanja na novi oblika nastave koji koristi inteligentne sustave za poučavanje

Posljednje, dvadeseto pitanje, zahtijevalo je mišljenje studenata da li smatraju kako bi se trebalo nastaviti investirati u umjetnu inteligenciju. S najvećim postotkom pozitivnih odgovora na nekom pitanju do sada, 90% studenata smatra kako bi se trebalo nastaviti investirati u umjetnu inteligenciju te da je to dobra investicija. Tek jedan mali postotak od 10% studenata smatra kako se ne bi trebalo više investirati u umjetnu inteligenciju, odnosno da je to loša investicija.



Graf 20. Treba li se investirati u umjetnu inteligenciju?

5.3. Rasprava

Na temelju rezultata je vidljivo kako je većina studenata iz društvenog (44,7%) i humanističkog (32%) područja. Prirodne i tehničke su na 3. i 4. mjestu po broju studenata koji su ispunili anketu, a ostatak ispitanika pripada biomedicinskim i zdravstvenim te biotehničkim znanostima.

Iduće pitanje, „Smatrate li da je razvoj umjetne inteligencije (UI) brži nego razvoj drugih tehnologija?“ s više od pola pozitivnih odgovora, odnosno „Da“ odgovora pokazuje kako su studenti generalno upoznati s tematikom i s tehnologijom umjetne inteligencije. Manji broj je odgovorio kako smatra da razvoj nije brži ili da nije siguran da li je u odnosu na druge tehnologije razvoj umjetne inteligencije brži, što s druge strane pokazuje kako je to tema o kojoj se ne priča u velikoj mjeri na fakultetima ili je zainteresiranost za tu temu mala.

Iz grafa 5, prema ostvarenim rezultatima, može se doći do zaključka kako je tek manji broj studenata svjestan prisutnosti umjetne inteligencije u privatnom životu kao dio njihove svakodnevice. S obzirom na to da je tehnologija umjetne inteligencije svugdje prisutna, npr. u pametnim mobitelima ili računalima, a prema istraživanju provedenom od strane Pew Reasearch Centera (2021), koje pokazuje kako je 89% studenata vlasnik pametnog mobitela, može se donijeti zaključak kako studenti ipak nisu najbolje upućeni u to što sve pripada tehnologiji umjetne inteligencije i koliko je ona integralni dio njihovih života.

Nastavno na prethodno pitanje, analizom grafa 6 i pomaku rezultata gdje je većina studenata odgovorila kako smatra da umjetna inteligencija nije u velikoj mjeri dio njihovog akademskog života, pokazalo se kako studenti smatraju da je umjetna inteligencija slabo zastupljena na fakultetima i da nije u velikoj mjeri iskorištena u kontekstu studiranja, bilo to od strane fakulteta ili od strane studenata.

Kroz analizu grafa 7, na čije su pripadajuće pitanje studenti u velikoj mjeri (78%) odgovorili pozitivno, može se doći do zaključka kako studenti smatraju da umjetna inteligencija može pomoći u poboljšanju obrazovanja. Također se može zaključiti kako studenti imaju povjerenja u tehnologiju umjetne inteligencije i kako ona nije samo prolazna faza u kontekstu studiranja već njena budućnost.

Na 8. pitanje, studenti su uglavnom odgovorili kako online nastava nije jednako kvalitetna kao i tradicionalni oblik nastave u učionici. Nešto manji broj studenata smatra kako su online oblik

i tradicionalni oblik nastave podjednako kvalitetni, što dovodi do zaključka kako je nastava u određenoj mjeri bila zadovoljavajuća, te je ispunjavala zahtjeve i potrebe studenata.

S obzirom na to da su studenti relativno ravnomjerno podijeljeni po pitanju umjetne inteligencije i njene upotrebljivosti u nastavi, kao što je vidljivo iz grafa 9 gdje 27,3% studenata smatra kako umjetna inteligencija nije dovoljno razvijena za implementaciju u nastavu, 30,7% nije sigurna, a 42% smatra kako je dovoljno razvijena, dolazi se do zaključka kako studenti nisu najbolje upućeni u tehnologiju umjetne inteligencije. Naime, studenti koji su sudjelovali u nastavi potpomognutoj inteligentnim sustavom za poučavanje, ostvarili su 15% bolje rezultate na testovima nego što su njihovi vršnjaci koji su pohađali standardni oblika nastave (Koedinger, Anderson, Hadley i sur. 1997). Taj eksperiment se proveo prije više od dva desetljeća koji je već tad pokazao vrlo obećavajuće rezultate. S obzirom na to da je tehnologija jako napredovala u posljednjih 20 godina, nema sumnje da bi takvo nešto bilo vrlo korisno i studentima i nastavnicima danas.

Iz grafa 10 vidljivo je da je preko 72% studenata upoznato inteligentnim sustavima koji su sposobni davati odgovore na pitanja, odnosno Chatbotovima. Odgovori na ovo pitanje pokazuju kako su studenti u većoj mjeri upoznati s tehnologijom. Uzimajući u obzir istraživanje provedeno od strane Blackboard and University Business, većina ispitanika (76%) smatra kako bi ovakav sustav pomogao administrativnom osoblju u efikasnijem obavljanju posla (Woodcock, D. 2020), može se zaključiti kako otprilike u istoj mjeri studenti koji su sudjelovali u anketi ovog rada prepoznaju potencijal takvih sustava.

Graf 11 pokazuje kako 62,7% studenata smatra kako bi se umjetna inteligencija trebala implementirati na sveučilišta u sklopu administracije, dok tek 21,3% smatra da ne bi trebala. Ovakav omjer pozitivnih i negativnih odgovora pokazuje kako su studenti spremni na promjene u administraciji sveučilišta, te kako smatraju da bi ona mogla doprinijeti boljem funkcioniranju administracije.

Na 12. pitanje studenti su većinom odgovorili pozitivno. Iz grafa 12, vidljivo je, kako bi 68% studenata koristilo inteligentni softver da dobije odgovor na pitanje umjesto traženja odgovora kroz komunikaciju s administrativnim osobljem. Ovakav omjer odgovora pokazuje kako su studenti spremni koristiti softvere kao kanal za dobivanje odgovora na pitanja jer smatraju kako bi to bilo efikasnije nego da idu tradicionalnim putem i odgovor traže u referadi tj. od administrativnog osoblja. Takva modernizacija nije željena samo od strane studenata, već i

nastavnika i administrativnog osoblja što je također vidljivo u već navedenom istraživanju provedenog od strane Blackboard and University Businessa.

Iz grafa 13 vidljivo je kako 54% studenata smatra kako inteligentni sustavi nisu sposobni donijeti ispravne zaključke o općenitom stanju studenata, što pokazuje kako su studenti uglavnom ravnomjerno podijeljeni po pitanju stavljanja svog povjerenja u takve sustave. Kao što je već navedeno u pokusu provedenom nad studentima (Koedinger, Anderson, Hadley i sur. 1997), zaključci koje donosi sustav, uglavnom su se pokazali kao dobri i doprinijeli su boljem akademskom radu studenata. Činjenica da većina ispitanika smatra kako takvi sustavi nisu sposobni donositi odluke, govori o tome kako nisu dobro upućeni u tu temu. Rješenje na ovakav trend odgovora i manjak povjerenja u tehnologiju umjetne inteligencije bi se mogao riješiti kroz podučavanje opsežnijeg gradiva koje se tiče ove teme.

Graf 14 pokazuje kako preko 80% studenata smatra kako bi nastavnici, uz korištenje inteligentnih sustava za poučavanje, bili u mogućnosti pružiti bolje obrazovanje studentima, što ukazuje na to kako studenti prepoznaju potencijal ovakve tehnologije i koliko ona može doprinijeti poboljšanju kvalitete nastave.

Graf 15 pokazuje kako tek jedan manji broj studenata, nešto više od 18%, smatra kako su inteligentni sustavi sposobni imitirati rad nastavnika. Iz odgovora se vidi, da 50% studenata smatra kako inteligentni sustavi za poučavanje nisu sposobni imitirati rad nastavnika uopće ili u velikoj mjeri, što pokazuje kako je ipak potrebna „ljudska ruka“ tj. vodstvu u poučavanju.

Iz grafa 16 je vidljivo kako studenti uglavnom smatraju da bi inteligentni sustavi za poučavanje bili najkorisniji na kasnijim godinama, što pokazuje, da studenti misle kako je na ranijim godinama, tj. na početku studija potreban veći kontakt s nastavnikom nego što je na kasnijim godinama kada su studenti u većoj mjeri osamostaljeni.

Studenti su svoje mišljenje, o tome smatraju li da je model online nastave dostatan ili da li bi se trebao poboljšati implementacijom umjetne inteligencije, iznijeli u sedamnaestom pitanju. Graf 17 pokazuje kako 72% studenata smatra da online model nastave nije dostatan, odnosno da bi se mogao poboljšati implementacijom umjetne inteligencije, što pokazuje kako bi studenti pristali na promjene, te da online nastava u sadašnjem obliku nije dostatna da zadovolji njihove akademske potrebe, te da im pomogne u uspješnom obavljanju akademskih obveza.

Iz idućeg grafa, grafa 18, može se vidjeti kako studenti, njih 66%, smatra kako bi inteligentni sustavi na sveučilištu mogli pomoći pri rješavanju problema ne stizanja obavljanja akademskih obveza i u oslobođenju vremena za više izvannastavnih aktivnosti (62,7%). Ovakvi rezultati su

pokazatelj kako studenti smatraju da im studiranje oduzima previše vremena, te da uz sve vrijeme koje alociraju na rješavanje akademskih obveza i dalje ne stižu obaviti sve pravovremeno. Isto tako su mišljenja da bi inteligentni sustavi omogućili, da imaju više vremena za obveze, bilo u kontekstu studiranja ili privatnog života.

Predzadnji graf, graf 19, pokazuje kako otprilike trećina studenata (39.3%) smatra da bi se uglavnom brzo priviknula na novi oblik nastave, dok tek jedan manji dio smatra da se ne bi uopće brzo privikli na novi oblik nastave (7,3%). Jedan dobar dio ispitanika koji je ispunio ovu anketu je rođen nakon 2000. godine, a mlađe generaciju su uglavnom informatički pismene već od malih nogu. Kada se ta činjenica poveže s rezultatima vidljivima na grafu 19, može se zaključiti kako mlađi studenti imaju povjerenja u svoje sposobnosti brze adaptacije na nove tehnologije i oblike učenja.

Iz 20., ujedno i posljednjeg grafa, vidljivo je da 90% studenata smatra da je investicija u umjetnu inteligenciju dobra investicija, što pokazuje da su studenti upućeni u prednosti umjetne inteligencije, te kako bi onda mogla doprinijeti u razvitku tj. u poboljšanju nastave, ali i administrativnog sustava u sklopu sveučilišta.

6. Zaključak

Umjetna inteligencija je od samih njenih početka bila interesantno područje sa stalnim i brzim promjenama. Od Turinga, McCarthyja, Samuela i ostalih pionira pa sve do danas ulaganje u umjetnu inteligenciju, bilo to novčano ili radnom snagom, nije prestalo. Očiti je trend u kojem se kreće, ali za sada nije moguće predvidjeti smjer. Izvjesno je da razvoj umjetne inteligencije nema kraja, a kako sada stvari stoje, čini se da je ona još uvijek u svojoj početnoj fazi.

Velike tvrtke su prepoznale vrijednost umjetne inteligencije, što je vidljivo iz brzo rastućeg ulaganja u tu tehnologiju, bilo da je to ulaganje novaca ili akvizicija od strane velikih tvrtki.

U sklopu ovog rada provedena je i anketa u kojoj su studenti ispitani o stajalištu prema umjetnoj inteligenciji i o njihovoj razini korištenja. Anketa je pokazala kako veći dio studenata vjeruje u tu tehnologiju i spreman je na promjene koje bi došle s njenom implementacijom u obrazovni sustav. Iako je broj studenata koji je sudjelovao u anketi relativno mali, iz tog uzorka se može zaključiti kako se ne protive uvođenju nove tehnologije, ali i da nisu najsigurniji što misle kada je u pitanju umjetna inteligencija, bilo da je to zbog nezainteresiranosti ili nedostatka informacija.

Inteligentni sustavi za poučavanje koji bi bili izvrstan dodatak u obrazovanju, tj. u nastavi, nisu koncipirani tako da zamijene nastavnike, već da im budu korisno pomagalo u izvođenju nastavu, kako bi se sama nastava učinila boljom i pristupačnijom.

7. Literatura

1. AdmitHub (2019) How does artificial intelligence work in chatbots?, https://www.admithub.com/blog/how-does-artificial-intelligence-work-in-chatbots/ (pristupljeno 04. studenog 2020.)
2. Alkhalisi, Z. (2019). Abu Dhabi startup is using AI to transform how kids learn, https://edition.cnn.com/2019/03/05/tech/alef-education-ai-uae/index.html (pristupljeno 29. prosinca 2020.)
3. Beal, Beck, Wolf i sur. (1999), WhaleWatch: An Intelligent Multimedia Math Tutor https://www.researchgate.net/publication/2635924_WhaleWatch_An_Intelligent_Multimedia_Math_Tutor (pristupljeno 13 svibnja 2021.)
4. Becker, Brown, Dahlstrom i sur. (2018). Horizon Report 2018 Higher Education Edition, https://www.learntechlib.org/p/184633/ (pristupljeno 28. prosinca 2020.)
5. Belkin, D. (2019). Colleges Mine Data on Their Applicants, https://www.wsj.com/articles/the-data-colleges-collect-on-applicants-11548507602 (pristupljeno 17. studenog 2020).
6. Beylo, B. (2020). Where We're Finding AI Investment Opportunities: Education, https://macro-ops.com/where-were-finding-ai-investment-opportunities-education/ (pristupljeno 28. prosinca 2020).
7. BootstrapLabs (2017) A Brief History of Artificial Intelligence, https://www.youtube.com/watch?v=056v4OxKwlI (pristupljeno 12. svibnja 2021.)
8. Brendza M. (2017) Introduction to Artificial Intelligence, https://www.storyfit.com/blog/intro-to-ai (pristupljeno 12. svibnja 2021.)
9. Bryant J., Heitz C., Sanghvi S. i sur. (2020). How artificial intelligence will impact K-12 teachers, https://www.mckinsey.com/industries/public-and-social-sector/our-insights/how-artificial-intelligence-will-impact-k-12-teachers (pristupljeno 11. studenog 2020.)
10. Cheung B., Hui L., Zhang J. i sur. (2002), SmartTutor: An intelligent tutoring system in web-based adult education, https://www.sciencedirect.com/science/article/abs/pii/S0164121202001334 (pristupljeno 13. svibnja 2021.)
11. Ciolacu, M., Tehrani, A.F., Binder, L. i sur. (2018). Education 4.0 - Artificial Intelligence Assisted Higher Education: Early recognition System with Machine Learning to support Students' Success,

https://ieeexplore.ieee.org/abstract/document/8599203 (pristupljeno 04. studenog 2020.)

12. Clinedinst M., i Patel, P. (2018). State of college admission, URL: https://www.nacacnet.org/globalassets/documents/publications/research/2018_soca/soca18.pdf (pristupljeno 04. studenog 2020.)
13. Cognii (2020). Mission, https://www.cognii.com/about (pristupljeno 29. prosinca 2020.)
14. Collins A. i Halverson R., (2010). The second educational revolution: rethinking education in the age of technology, URL: https://onlinelibrary.wiley.com/doi/epdf/10.1111/j.1365-2729.2009.00339.x (pristupljeno 11. studenog 2020.)
15. Collins H. (2019) Turing Test: why it still matters, https://theconversation.com/turing-test-why-it-still-matters-123468 (pristupljeno 12. svibnja 2021.)
16. Columbus L. (2018). 10 Charts That Will Change Your Perspective on Artificial Intelligence's Growth, https://www.business2community.com/business-innovation/10-charts-will-change-perspective-artificial-intelligences-growth-01996373 (pristupljeno 16. svibnja 2021.)
17. Computer Business Review (CBR) (2020). What is Nvidia?, https://www.cbronline.com/what-is/what-is-nvidia-4956361/ (pristupljeno 17. studenog 2020.)
18. Copeland J. (2000) What is artificial intelligence?, http://www.alanturing.net/turing_archive/pages/Reference%20Articles/what_is_AI/What%20is%20AI04.html (pristupljeno 12. svibnja 2021.)
19. Corbett T. A. i Koedinger, R. K. (2006) Cognitive Tutors: Technology Bringing Learning Science to the Classroom, https://www.researchgate.net/publication/255519934_Cognitive_Tutors_Technology_Bringing_Learning_Science_to_the_Classroom (pristupljeno 05. studenog 2020.)
20. Council of Europe Portal (2017). *History of Artificial Intelligence*, https://www.coe.int/en/web/artificial-intelligence/history-of-ai (pristupljeno 01. studenog 2020).
21. Cox, S. (2020) Using AI to Support the Teacher, https://www.wise-qatar.org/using-ai-to-support-the-teacher/ (pristupljeno 05. studenog 2020.)

22. European Commission (2018). Share of Jobs Requiring AI Skills - Indded.com, https://knowledge4policy.ec.europa.eu/visualisation/share-jobs-requiring-ai-skills-inddedcom_en (pristupljeno 16. svibnja 2021.)
23. Freedman R., Ali S.S. i Mcroy S., (2000) Links: what is an intelligent tutoring system?, https://www.researchgate.net/publication/220098051_Links_what_is_an_intelligent_tutoring_system (pristupljeno 27. prosinca 2020.)
24. Herold B. (2018). Teen Social Media Use Is Skyrocketing. But Don't Panic, New Research Says, https://blogs.edweek.org/edweek/DigitalEducation/2018/09/teen_social_media_skyrocketing.html (pristupljeno 11. studenog 2020.)
25. Kambria (2019). How Facebook Uses Artificial Intelligence, https://kambria.io/blog/how-facebook-uses-artificial-intelligence/ (pristupljeno 15. studenog 2020.)
26. Koedinger R. K., Anderson R. J., Hadley H. W. i Mark A. M. (1997) Intelligent Tutoring Goes To School in the Big City, https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKEwjapaSOhsfwAhUx_rsIHWcdAdwQFjAAegQIBBAD&url=http%3A%2F%2Fctat.pact.cs.cmu.edu%2Fpubs%2FKoedinger-Anderson.pdf&usg=AOvVaw35-0-Acfwj57Ts-Gmi1FdZ (pristupljeno 13. svibnja 2021.)
27. Lee J. (2020). A Neuropsychological Exploration of Zoom Fatigue https://www.psychiatrictimes.com/view/psychological-exploration-zoom-fatigue (pristupljeno 28. prosinca 2020.)
28. Markets and Markets (2018). AI in Education Market by Technology (Deep Learning and ML, NLP), Application (Virtual Facilitators and Learning Environments, ITS, CDS, Fraud and Risk Management), Component (Solutions, Services), Deployment, End-User, and Region - Global Forecast to 2023, https://www.marketsandmarkets.com/Market-Reports/ai-in-education-market-200371366.html (pristupljeno 01. studenog 2020)
29. Marr, B. (2019) How Is AI Used In Education -- Real World Examples Of Today And A Peek Into The Future, https://bernardmarr.com/default.asp?contentID=1541 (pristupljeno 05. studenog 2020.)
30. McCarthy, J. (2004) What Is Artificial Intelligence?, https://homes.di.unimi.it/borghese/Teaching/AdvancedIntelligentSystems/Old/Intellig

entSystems_2008_2009/Old/IntelligentSystems_2005_2006/Documents/Symbolic/04_McCarthy_whatisai.pdf (pristupljeno 12. svibnja 2021.)

31. McKinsey Global Institute (2018) Deep learning's origins and pioneers, https://www.mckinsey.com/featured-insights/artificial-intelligence/deep-learnings-origins-and-pioneers (pristupljeno 12. svibnja 2021.)
32. Michael (2018). How Chatbots Use Artificial Intelligence to Satisfy Customers Faster & Easier than Ever Before, https://freshdesk.com/customer-support/customer-satisfaction-ai-chatbots-blog/ (pristupljeno 04. studenog 2020.)
33. National Association of Independent Schools (NAIS) (2018). The Third Education Revolution, URL: https://www.nesacenter.org/uploaded/conferences/FLC/2018/handouts/DonnaOrem_ThirdEdRevolution2018.pdf (pristupljeno 12. studenog 2020.)
34. Nazerian, T. (2018). Can AI Help Students—and Colleges—Determine the Best Fit?, https://www.edsurge.com/news/2018-04-11-can-ai-help-students-and-colleges-determine-the-best-fit (pristupljeno 28. prosinca 2020).
35. Padayachee I. Intelligent tutoring system: Architecture and characteristics https://www.researchgate.net/publication/228921731_Intelligent_tutoring_systems_Architecture_and_characteristics (pristupljeno 27. prosinca 2020.)
36. Pew Research Center, (2021)., Mobile Fact Sheet, https://www.pewresearch.org/internet/fact-sheet/mobile/ (pristupljeno 18. svibnja 2021.)
37. Reeves T.C., (1998). The Impact of Media and Technology in Schools A Research Report prepared for The Bertelsmann Foundation, https://www.researchgate.net/publication/237429044_The_Impact_of_Media_and_Technology_in_Schools_A_Research_Report_prepared_for_The_Bertelsmann_Foundation (pristupljeno 27. prosinca 2020.)
38. Robot R., (2020). How Intelligent Tutoring Systems are Changing Education, https://medium.com/@roybirobot/how-intelligent-tutoring-systems-are-changing-education-d60327e54dfb (pristupljeno 27. prosinca 2020.)
39. Rogers, C., (2019). UK government announces £18.5m investment in AI training, https://edtechnology.co.uk/latest-news/uk-government-announces-18-5m-investment-in-ai-training/ (pristupljeno 29. prosinca 2020.)

40. Roll, I. i Wylie R., (2016). Evolution and Revolution in Artificial Intelligence in Education, https://link.springer.com/article/10.1007/s40593-016-0110-3#Sec9 (pristupljeno 11. studenog 2020.)
41. Schiaffino S., Garcia P. i Amandi A. (2008). eTeacher: Providing personalized assistance to e-learning students, https://www.sciencedirect.com/science/article/abs/pii/S036013150800078X (pristupljeno 13 svibnja 2021.)
42. Schorsch B. i Worobec A. (2019). Microsoft's Artificial Intelligence for Higher Education, https://www.youtube.com/watch?v=od0h3IABP9Y&t (pristupljeno 05. studenog 2020.)
43. Technolutions (2020). About Technolutions - Empowering Higher Education with Innovative Technology, https://technolutions.com/about (pristupljeno 04. studenog 2020.)
44. Tiell, S., (2019). Create an Ethics Committee to Keep Your AI Initiative in Check, https://hbr.org/2019/11/create-an-ethics-committee-to-keep-your-ai-initiative-in-check (pristupljeno 29. prosinca 2020.)
45. Turing A. M. (1950). I.—COMPUTING MACHINERY AND INTELLIGENCE, https://academic.oup.com/mind/article/LIX/236/433/986238 (pristupljeno 12. studenog 2020.)
46. Wiederhold G. i McCarthy J. (1992), "Arthur Samuel: Pioneer in Machine Learning," u IBM Journal of Research and Development, vol. 36, no. 3, pp. 329-331, doi: 10.1147/rd.363.0329 (pristupljeno 12 svibnja 2021.)
47. Woodcock D., (2020), Survey Results: Higher Ed Leaders Say AI Can Improve the Student Experience, https://www.timeshighereducation.com/hub/blackboard/p/survey-results-higher-ed-leaders-say-ai-can-improve-student-experience (pristupljeno 14. svibnja 2021)
48. Woolf, P.B. (2015). AI and Education: Celebrating 30 years of Marriage. URL: http://ceur-ws.org/Vol-1432/ai_ed_pap5.pdf (pristupljeno 17. studenog 2020.)
49. Yin, D., (2020). Learner Motivation: Making Learning on Your Product an Addiction, https://medium.com/@diana_56307 (pristupljeno 29. prosinca 2020.)

Popis slika

Slika 1. Vremenski prikaz porasta udjela poslova koji zahtjevaju vještine u području UI Izvor: Artificial Intelligence Index, 2017 Annual Report, p 19 6
Slika 2. Prikaz porasta investicija ulagača u razvojne tvrtke koje se bave umjetnom inteligencijom Izvor: Columbus L. (2018) 7
Slika 3. Tipovi sustava UI 13
Slika 4. WhaleWatch inteligentni sustava za poučavanje 23
Slika 5. Pregled eTeachera 24
Slika 6. Arhitektura Smart Tutora 26

Popis grafova

Graf 1. Ispitanici prema spolu....32
Graf 2. Ispitanici prema godini rođenja....33
Graf 3. Ispitanici prema području studija....34
Graf 4. Mišljenje studenta o brzini razvoju umjetne inteligencije....34
Graf 5. Mišljenje studenata o razini doticaja s umjetnom inteligencijom u njihovom privatnom životu....35
Graf 6. Mišljenje studenata o razini doticaja s umjetnom inteligencijom u njihovom akademskom životu....35
Graf 7. Mišljenje studenata o tome koliko umjetna inteligencija može pomoći poboljšanju obrazovanja....36
Graf 8. Mišljenje studenata o kvaliteti online nastave....36
Graf 9. Mišljenje studenata o tome da li se UI može implementirati u nastavu s obzirom na stupanj razvijenosti....37
Graf 10. Upoznatost studenata s Chatbotom, inteligentnim sustavima sposobnima za davanje odgovora....37
Graf 11. Mišljenje studenata o tome da li se UI može implementirati u administraciju sveučilišta s obzirom na stupanj razvijenosti....38
Graf 12. Postotak studenata koji bi koristili inteligentni sustav za dobivanje odgovora na pitanja odnosno razgovarali s administrativnim osobljem....39
Graf 13. Postotak studenata koji smatra da su inteligentni sustavi sposobni, odnosno nisu sposobni donositi zaključke o općenitom stanju studenata na temelju prikupljenih informacija....39
Graf 14. Mišljenje studenata o mogućnosti poboljšanja obrazovanja kroz nastavnikovo korištenje inteligentnih sustava za poučavanje....40
Graf 15. postotak studenata koji smatra da su inteligentni sustavi za poučavanje sposobni, odnosno nisu sposobni imitirati rad nastavnika....41
Graf 16. mišljenje studenata o inteligentnim sustavima prema studijskim godinama....41
Graf 17. Mišljenje o uspješnosti izvođenja/potencijalnom poboljšanju online nastave....42
Graf 18. Koje probleme inteligentni sustavi mogu potencijalno riješiti....42
Graf 19. brzina privikavanja na novi oblika nastave koji koristi inteligentne sustave za poučavanje....43
Graf 20. Treba li se investirati u umjetnu inteligenciju?....44

Umjetna inteligencija u visokom obrazovanju

Sažetak

Ovaj rad nastoji prikazati način na koji je umjetna inteligencija implementirana u obrazovni sustav, te načine na koji umjetna inteligencija doprinosi poboljšanju kvalitete nastave. Obrađen je način na koji je umjetna inteligencija implementirana u obrazovni sustav, te na koje sve ona načine doprinosi poboljšanju kvalitete nastave. U radu je prikazano na koji način umjetna inteligencija utječe na studente i kako utječe na nastavnike. Anketa koja će biti provedena u sklopu ovog rada će provjeriti da li studenti smatraju da bi inteligentni sustavi mogli biti pomoć u sklopu njihovog obrazovanja. Na sveučilištima postoje inteligentni sustavi za poučavanje, no još uvijek nisu globalno rašireni, tj. ne predstavljaju globalni standard, ali analiza uloženih investicija i porast broja zaposlenih u području umjetne inteligencije, pokazuje kako će takvi, već prije spomenuti inteligentni sustavi, u obrazovanju postati standard. Kada je riječ o velikim poduzećima, oni su vodeći u svemu što se tiče razvoja umjetne inteligencije i njenog dijela znanog kao umjetna inteligencija u obrazovanju. Neosporna je činjenica, da velika poduzeća raspolažu skoro pa neiscrpnim količinama resursa (oprema, novac, stručnjaci…), te su u mogućnosti najviše napraviti za područje umjetne inteligencije.

Ključne riječi: umjetna inteligencija, digitalni mediji, Chatbot, investicijski i razvojni trendovi, inteligentni sustavi za poučavanje

Artificial intelligence in higher education

Summary

The paper deals with the artificial intelligence that is implemented in the educational system, and in all ways that contribute to improving the quality of teaching. The paper shows how artificial intelligence affects students and how it affects teachers. The survey that will be presented as part of this paper will check if students think intelligent systems could be an aid to their education. There are intelligent teaching systems in universities, but they are not yet globally spread or a global standard, but the analysis of investments and the increase in the number of employees in the field of artificial intelligence shows that the intelligent systems will become the standard in education. When it comes to large companies, they are leaders in everything related to artificial intelligence and its development, and thus its branches, i.e., artificial intelligence in education. It is an indisputable fact that large companies have large amounts of resources and are able to do the most for the field of artificial intelligence.

Key words: artificial intelligence, digital media, Chatbot, investment and development trends, intelligent tutoring systems