

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ZA ODGOJNE I OBRAZOVNE ZNANOSTI U SLAVONSKOM BRODU

Nela Mijić

**UMJETNA INTELIGENCIJA – MODELI UČENJA**

ZAVRŠNI RAD

Slavonski Brod, 2019.



SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU  
FAKULTET ZA ODGOJNE I OBRAZOVNE ZNANOSTI U SLAVONSKOM BRODU

Sveučilišni preddiplomski studij ranoga i predškolskoga odgoja i obrazovanja, Slavonski Brod

**UMJETNA INTELIGENCIJA – MODELI UČENJA**

**ZAVRŠNI RAD**

Kolegij: Informatička pismenost

Mentor: doc. dr. sc. Vjekoslav Galzina

Student: Nela Mijić

Matični broj: 483

Slavonski Brod

rujan , 2019.

## **SAŽETAK**

U ovom radu razmotrena je primjena umjetne inteligencije (UI) u sustavu obrazovanja. Prije uvoda u umjetnu inteligenciju, istaknute su neke od metoda i stilova učenja pomoću kojih čovjek uči. Postoji više metoda učenja i svaki pojedinac odabire, za njega, primjerenu metodu učenja. Stilovi učenja su teoretski podijeljeni u tri skupine: vizualni, auditivni i kinestetički. Primarne vrste učenja koje koristi umjetna inteligencija su: strojno učenje i rudarenje podataka. Primjena UI u obrazovanju, kao sustav učenja, koristi umjetne neuronske mreže, tj. stvaranje *umjetnog mozga*, koji je sličan ljudskom. Dubokim učenjem računalo uči, a donošenje odluka odvija se pomoću sustava inteligentnih agenata. Prve zabilježene komercijalne primjene sustava s UI su industrijski sustavi upravljanja te aparati u kućanstvima. Danas su takvi sustavi zastupljeni u svim segmentima znanosti i struke, a također i u obrazovanju. Predstavnici u obrazovanju su *Wolfram Alpha*, *Mozaik education* i *Izzi*.

## **ABSTRACT**

The application of artificial intelligence (AI) in the education system is considered in this paper. Before the introduction to artificial intelligence, some of the methods and styles of learning by which one learns were highlighted. There are several learning methods and each individual chooses, for him, the appropriate learning method. Learning styles are theoretically divided into three groups: visual, auditory and kinesthetic. The primary types of learning used by artificial intelligence are machine learning and data mining. The use of AI in education, as a learning system, uses artificial neural networks, that is, the creation of an *artificial brain*, which is similar to the human. With deep learning, the computer learns and making a decision is done by intelligent agents. The first recorded commercial application of artificial intelligence systems are industrial control systems and household appliances. Today, such systems are represented in all segments of science and the profession, and also in education. Representatives in education are *Wolfram Alpha*, *Mozaik education* and *Izzi*.

## **SADRŽAJ**

<b>1 UVOD</b>	1
<b>2 O METODAMA I STILOVIMA UČENJA</b>	3
2.1 Metode poučavanja	4
2.2 Metode učenja	6
2.2.1 Stil učenja - vizualni	6
2.2.2 Stil učenja - auditivni	6
2.2.3 Stil učenja - kinestetički	7
<b>3 UMJETNA INTELIGENCIJA</b>	9
3.1 Općenito o umjetnoj inteligenciji	10
3.2 Strojno učenje	12
3.3 Rudarenje (istraživanje) podataka	14
<b>4 PRIMJENA METODA UČENJA KOD UMJETNE INTELIGENCIJE</b>	15
4.1 Umjetne neuronske mreže	16
4.2 Duboko učenje	18
4.3 Primjena inteligentnih agenata	20
<b>5 KOMERCIJALNE PRIMJENE UMJETNE INTELIGENCIJE</b>	22
5.1 Inteligentni sustavi u obrazovanju	23
5.2 Google-ov razvoj umjetne inteligencije	28
5.3 Predviđanja o primjeni umjetne inteligencije (UI)	29
<b>6 ZAKLJUČAK</b>	30
<b>7 LITERATURA</b>	31

## 1 UVOD

Učenje je složen proces usvajanja novih ili nadogradnje postojećih znanja, kroz proučavanje, iskustvo ili razne studije. Proces učenja kod osobe može potaknuti razne transformacije, u kojima razumijevanje novih informacija može dovesti do nekih promjena u ponašanju i/ili pogleda na svijet oko njih. Stilovi učenja su različiti i ovise o mogućnostima pojedinca. Pri rođenju se nesvesno kreće učiti.[1]

Od prvog udaha, prvog plača, prvog obroka, prvog koraka. Učenje je jedan od najvažnijih proces u čovjekovom životu, potreban za razvoj i unapređenje kvalitete života. Postoje dva načina na koje se može shvatiti bit učenja, kroz vlastiti proces obrazovanja i usvajanje informacija kroz životni ciklus. Cijeli život, čovjek uči kako savladati određene životne situacije u kojima se nađe, te na što lakši način pronaći odgovarajuće rješenje na to. Neki, smatraju kako je to možda nepotreban proces, koji opterećuje pojedinca. S tim se najviše suočava mlađi dio populacije u osnovnim i srednjim školama, a u nekim slučajevima i starije generacije. Svake godine postoje primjeri učenika, koji željno iščekuju početak školske godine, da po prvi puta sjednu u školske klupe sa željom da nešto nauče. Međutim, nakon određenog vremena počinje pad koncentracije i zanimanja. Uzrok tome je najčešće obrazovni sustav, koji nema prave načine podučavanja novih generacija. Početkom 20.st., dolazi treća industrijska revolucija kojom je počeo razvoj digitalizacije, koja će drastično promijeniti načine življenja čovjeka, u smislu olakšanja života. Jedna od stvari, koja se također počela koristiti krajem 20.st., je osobno računalo (PC od eng. *Personal Computer*). Ono je prвobитно koriшteno u istraživačke svrhe, danas je to svakodnevница, svako kućanstvo posjeduje bar jedno računalo. Osim njega, razvili su se još mnogi uređaji kao mobiteli, prijenosna računala (laptopi), tablet i mnoge druge stvari. Prvo elektroničko računalo konstruirano je 1943. godine u vrijeme drugog svjetskog rata. Prvi put se umjetna inteligencija primjenjuje 1959. godine u SAD-u (Sjedinjene Američke Države) na Sveučilištu Illinois. Krajem šezdesetih i početkom sedamdesetih, počinje se ostvarivati niz projekata uvođenja digitalnih računala u nastavu europskih zemalja. 1970-ih godina, u Njemačkoj je bilo 10 visokih škola koje su podučavale učenike informatici. Najjednostavniji princip rada računala u obrazovanju je bilo da učitelj postavlja pitanje, a učenik odgovara, te na kraju dobiva povratnu informaciju o uspješnosti.

Početkom 21.st., dolazi do naglog razvoja osobnih računala, nastaju novi softveri i aplikacije kako bi se olakšalo rješavanje raznih problema. Nakon osobnih računala, na *scenu* stupa umjetna inteligencija (UI).

Umjetna inteligencija (UI, prema engl. akronimu AI, od *Artificial Intelligence*), dio računalne znanosti (informatike) koji se bavi razvojem sposobnosti računala za obavljanje zadaća, za koje je potreban neki oblik inteligencije, tj. da se mogu snalaziti u novim prilikama, učiti nove koncepte, donositi zaključke, razumjeti prirodni jezik, raspoznavati prizore i dr. Naziv se, također, rabi za označivanje svojstva svakoga neživog sustava koji pokazuje inteligenciju (inteligentni sustav); obično su to računalni sustavi, dok se izraz katkad neutemeljeno primjenjuje na robote, koji nisu nužno intelligentni. Intelligentnim sustavom smatra se svaki sustav, koji pokazuje prilagodljivo ponašanje, uči na temelju iskustva, koristi velike količine znanja, pokazuje svojstva svjesnosti, komunicira sa čovjekom prirodnim jezikom i govorom, dopušta pogreške i nejasnoće u komunikaciji ili dr. Funkcije intelligentnoga sustava jesu: prikupljanje i obrada informacija, interakcija s radnom okolinom, komunikacija s čovjekom ili s drugim intelligentnim sustavima, prikupljanje i obrada znanja, zaključivanje, te planiranje. Dok se pod ljudskom inteligencijom smatraju čovjekove mogućnosti, da istodobno pokazuje različite intelligentne odlike i obavlja takve funkcije, današnji su intelligentni sustavi ponajprije specijalizirani za pojedinu mogućnost.[2]

Danas se umjetna inteligencija koristi u obrazovnom sustavu, ne u punom značenju umjetne inteligencije, već kao pomoć kod rješavanja kompleksnijih zadataka. Neki od primjera UI u školstvu bili bi:

- Primjena holograma – da učenici mogu pogledati nešto što je bilo prije njih, npr. doba dinosaure, ledeno doba, prikaz izumrlih bića kao i prikaz nekih događaja iz prošlosti, uz prethodno nabrojane prednosti, povećala bi se zainteresiranost djeteta za odlazak u školu
- Primjena robota – nakon škole uz igru sa svojim prijateljima pruža se mogućnost interaktivnog učenja uz svog *metalnog prijatelja*, osim igre i učenja djeca bi mogla razgovarati s njim o problemima koji ga muče jer obično izbjegavaju razgovore s roditeljima o takvim stvarima

Danas se može pouzdano reći da će umjetna inteligencija obilježiti sljedeća desetljeća, pokrenuti novu tehnološku revoluciju i izmijeniti živote ljudi, na način koji se u ovom trenutku ne može sasvim sagledati.[1]

## **2 O METODAMA I STILOVIMA UČENJA**

Kao prije par desetaka godina, tako i danas, glavno pitanje djece školske dobi je kako nešto najlakše naučiti, uz najmanje napore, a da se dođe do velikog uspjeha. Poznato je kako je to skoro nemoguće, za veliki uspjeh potrebno je uložiti puno vremena u učenju i proučavanju. Stručnjaci, već duže vrijeme pokušavaju odgovoriti na prethodno postavljeno pitanje te smisljavaju različite metode učenja, koje bi trebale učenje učiniti jednostavnijim. Međutim, nemaju svi pojedinci iste tehnike učenja, svatko sebi traži tehniku koja mu najviše odgovara. Većina školaraca još nije pronašla metodu koja im odgovara kako bi najlakše savladali određeno gradivo.[3]

Osim raznih metoda učenja, koje će se razraditi u dalnjem tekstu, bitno je napomenuti važnu stvar vezano za odgojitelje, a to su i metode poučavanja. Metode poučavanja su bitne u kontaktu odgojitelja s djecom. Odgojitelj mora postupati jednak sa svom djecom i poučavanje učiniti zanimljivim za cijelu skupinu kojoj se pojašnjava određena stvar. Bitna činjenica u ovome je razlikovati metode učenja od metoda poučavanja.

Tehnike učenja su alati koji omogućuju razumijevanje i shvaćanje sadržaja: mnemotehnike, flash kartice, sažetci, bilješke, vizualno razmišljanje itd. S druge strane, metode poučavanja temelje se na teoretskim osnovama koje uključuju različite tehnike ili procedure koje učitelji koriste za prijenos znanja, procedura i vrijednosti te za lakši razvoj učeničkih vještina.[4]

## **2.1 METODE POUČAVANJA**

Metode poučavanja se koriste u različitim nastavnim područjima s ciljem olakšanja i poboljšavanja metoda učenja. Najzastupljeniji način poučavanja je izravno poučavanje. Pod pojmom izravnog poučavanja podrazumijeva se da učitelj izlaže pravilo za rješavanje zadatka, a učenik ga zatim primjenjuje. Ovaj način poučavanja je prikladan kada treba učenike uputiti u novo gradivo, kada je potrebno pobuditi zanimanje kod učenika i kada treba sažeti određenu količinu gradiva iz više izvora.

Izravno poučavanje se može prikazati u pet etapa [5]:

- Prva etapa - objašnjavanje cilja i motiviranje za učenje

U prvu etapu spadaju pojmovi: entuzijazam odgojitelja, ugodna atmosfera, postavljanje izazovnog pitanja, povezivanje gradiva sa prethodnom lekcijom, povezivanje s poznatim informacijama i povezivanje s učenikovim iskustvom.

- Druga etapa - obrada novog gradiva i/ili pokazivanje vještina

Druga etapa se sastoji od tehnika pokazivanja ili modeliranja.

- Treća etapa - vođeno uvježbavanje i praćenje izvedbe

Treća etapa sadrži elemente potrebne da se održi red u sobi dnevnog boravka, a to uključuje obilazak odgojitelja oko djece i pregled naučenog, odnosno procjena napretka pojedinca.

- Četvrta etapa – provjera razumijevanja

Četvrta etapa sadrži elemente ispitivanja pojedinca, odnosno razumijevanje se provjerava postavljanjem pitanja i ravnomjernošću prozivanja i vremena čekanja na odgovor.

- Peta etapa - vođeno uvježbavanje i praćenje izvedbe

Peta etapa uključuje primjenu svakidašnjeg života u obrađivanu lekciju, uvježbavanje na slučajevima i primjerima iz stvarnog života, raznovrsnost zadatka u srodnim problemskim područjima i primjena uočenog pravila na novim primjerima.

Neke od ostalih metoda poučavanja [5]:

- Dijaloška
- Istraživačka
- Učenje putem rješavanja problema
- Metoda igre

**Dijaloška metoda** – ova metoda ima orijentacijski i motivacijski karakter. Ona omogućava da se učenici uvedu u program, da naprave plan rada i da se motiviraju za predstojeću aktivnost polazeći od značaja njenog izvršenja, odnosno cilja koji treba ostvariti. [5]

**Istraživačka metoda** – podrazumijeva samostalno traganje za činjenicama, pronalaženje relevantnih veza i odnosa među danim podacima, prestrukturiranje podataka, redefiniciju i samostalno dolaženje do novih rezultata. [5]

**Učenje putem rješavanja problema** – problemsko učenje omogućava visoku razinu kreativnosti učenika. Ovo je najviši, i domet, i oblik učenja. [5]

**Metoda igre** – se često primjenjuje u nastavi. Do izražaja dolazi učenikova inteligencija, upornost i želja za pobjedom. [5]

Tablica 2.1 Razlike između neadekvatnog i adekvatnog poučavanja [6]

Neadekvatno poučavanje	Adekvatno poučavanje
Učenje – pamćenje činjenica	Učenje – obrada važnih informacija
Predavačka nastava	Iskustvena i istraživačka nastava
Zamoran nastavni proces	Užitak u učenju
Nezadovoljni učenici	Zadovoljni učenici
Ekstrinzična motivacija	Intrinzična motivacija
Bijeg od odgovornosti	Preuzimanje odgovornosti
Nastavni sadržaj u središtu	Učenici u središtu pozornosti
Kratkotrajna reproduktivna znanja učenika	Trajna i uporabna znanja učenika

## **2.2 METODE UČENJA**

Metode učenja se koriste da bi se što lakše usvojilo potrebno znanje. U prethodnom tekstu je objašnjeno kako se svaki pojedinac koristi određenom tehnikom, tj. tehnikom koja mu najbolje pristaje da usvoji to znanje. U dalnjem tekstu nabrojat će se neke od metoda učenja koje su najčešće. Osim metoda učenja treba spomenuti i stilove učenja, koji su takođe bitni. Stilovi učenja mogu se razvrstati u tri grupe: vizualni, auditivni i kinestetički. Svaki pojedinac odabire stil učenja koji mu najviše odgovara, tj. stil učenja pomoću kojega će na najlakši način savladati određenu količinu gradiva. Svaki od prethodno nabrojanih stilova ima određene prednosti i mane vezane uz načine savladavanja gradiva.

### **2.2.1 Stil učenja – vizualni [6]**

Ovim stilom učenja djeca zapamte 65% gradiva.

- ❖ Najbolje uče gledanjem
- ❖ Vole vidjeti profesora
- ❖ Vole sjediti u prvoj klupi
- ❖ Razmišljaju u slikama
- ❖ Grafikoni
- ❖ Ilustracije
- ❖ Video

### **2.2.2 Stil učenja – auditivni [6]**

Ovim stilom učenja djeca zapamte 30% gradiva.

- ❖ Najbolje uče slušanjem
- ❖ Vole razgovarati o onome što uče s drugima
- ❖ Lakše uče čitajući naglas

- ❖ Vole snimati tekst na audio traku

### 2.2.3 Stil učenja – kinestetički [6]

Ovim stilom učenja djeca zapamte 5% gradiva.

- ❖ Najbolje uče kroz pokret, dodir i aktivnosti
- ❖ Teško im je dugo vremena sjediti na mjestu
- ❖ Vole kad mogu napraviti nešto, a ne samo čitati ili slušati



Slika 2.2 Prikaz vizualnog i kinestetičkog stila učenja [7]

Nabrojani stili učenja su prisutni u svim različitim metodama učenja, samo u određenom postotku. U sljedećim metodama učenja najzastupljeniji stil učenja jest vizualni. Neke od metoda učenja su [8]:

- Kartice za učenje – učenici sami sebi izrade kartice koje se sastoje od jednog pitanja i odgovora na to pitanje.
- Sastavljanje ispita – sami sebi sastavite ispit koji obuhvaća bitno gradivo.

- „POMODORO“ tehnika učenja – učenje u vremenskim intervalima od 45 min, te pauzama od 15 min.
- Ukrašavanje napisane lekcije – pretvaranje nekih riječi u neke stvari koje se lakše pamte.
- Mozartov efekt – slušanje glazbe za vrijeme učenja može poboljšati koncentraciju i aktivirati moždane vijuge. Stručnjaci tvrde da zbog glasnoće koja se izmjenjuje svakih 30 sekundi Mozartova glazba *zagrijava mozak* i pobuđuje kreativno i motivacijsko područje u ljudskom mozgu.
- Mentalne mape – u krugu se nalazi bitan pojam, a oko njega sve činjenice koje su bitne za to.
  
- MURDER metoda – ova metoda se sastoji od riječi: **Mood** (raspoloženje), **Understand** (razumjeti), **Recall** (podsjetiti se), **Digest** (podijeliti), **Expand** (proširiti), **Review** (preispitati). Prije učenja potrebno je stvoriti pozitivnu atmosferu, a zatim treba početi učiti s razumijevanjem. Kada se završi, trebalo bi se još jedanput podsjetiti svega proučenog. Na kraju svega treba se preispitati dosadašnji rad.
- ČPČPP metoda – sastoji se od **ČITANJA, PITAJUĆI SE** koji je dio gradiva bitan, ponovno **ČITANJE, PAMĆENJE** pročitanog i **PONAVLJANJE** svakih nekoliko sati.

### **3 UMJETNA INTELIGENCIJA**

Stvaranje UI ili umjetne inteligencije je dosta komplikiran posao. No, razumijevanje kako UI funkcioniра ne treba uopće biti komplikirano. Stvar je u tome da je velik broj strojeva, koji rade tako što koriste umjetnu inteligenciju, rade na sličan način kao ljudski mozgovi, ali ne u potpunosti.

Ipak, ono što UI ili umjetnu inteligenciju odvaja od ostatka računalnih programa jest to što se za UI ne treba točno odrediti svaki potprogram za svaki mogući scenarij, koji se može i ne mora dogoditi. Umjetnu inteligenciju može se pokušati naučiti da sama nešto novo nauči. To se zove *strojno učenje*. Isto tako, umjetnu inteligenciju se može naučiti da sama dalje uči i dolazi do novih otkrića i spoznaja. To se naziva *dubokim učenjem*. I unatoč tome što postoji cijeli niz varijacija na temu svakog od ova tri pojma, svi oni se mogu svesti pod iduće [9]:

- Umjetna inteligencija, koja je poznata pod skraćenicom *AI* ili *Artificial Intelligence*, je stroj, koji ima sposobnost oponašati ili imitirati ljudsko ponašanje.
- Strojno učenje ili *machine learning* je podsustav umjetne inteligencije unutar kojeg ljudi osposobljavaju strojeve, kako bi oni bili u mogućnosti prepoznati obrasce unutar podataka i kako bi mogli stvarati pretpostavke.
- Duboko učenje je podsustav strojnog učenja unutar kojeg svaki stroj može sam sebe trenirati ili učiti.

### **3.1 Općenito o umjetnoj inteligenciji**

Umjetna inteligencija (UI) je simulacija procesa inteligencije ljudi pomoću strojeva, posebice računalnih sustava. Ti procesi uključuju učenje (stjecanje informacija i pravila za korištenje informacija), rasudivanje (koristeći pravila za postizanje približnih ili konačnih zaključaka) i samokorekciju. Posebne primjene UI uključuju ekspertne sustave, prepoznavanje govora i strojni vid. Umjetna inteligencija se može kategorizirati kao slaba ili jaka. Slaba UI, sustav je UI koji je dizajniran i obučen za određeni zadatak. Virtualni osobni asistenti, kao što je Appleov Siri, oblik su slabe UI. Jaka UI, također poznata kao umjetna opća inteligencija, je sustav UI s generaliziranim ljudskim sposobnostima. Kada se susretne s nepoznatim zadatkom, snažan sustav UI može pronaći rješenje bez ljudske intervencije. Umjetna inteligencija kao usluga omogućuje pojedincima i tvrtkama da eksperimentiraju usvruhu obavljanja različitih poslova. Popularne usluge UI u oblaku uključuju usluge Amazon AI, IBM Watson Assistant, Microsoft Cognitive Services i Google AI usluge. [10]

Umjetna inteligencija je podjeljena u nekoliko skupina, koje su definirane po vremenu nastanka i osobinama svakog sustava, uz prikazane mogućnosti istih. [10]

- **Reaktivni strojevi** – primjer je *Deep Blue*, IBM-ov šahovski program koji je pobijedio Garryja Kasparova u 1990-ima. *Deep Blue* može identificirati dijelove na šahovskoj ploči i predvidjeti, ali nema mogućnost pamćenja i ne može koristiti

prošla iskustva kako bi informirao buduće. Analizira moguće poteze - vlastite i poteze svog protivnika - i odabire najispravniji potez. *Deep Blue* i *Google AlphaGO* dizajnirani su za uske svrhe i ne mogu se lako primijeniti na drugu situaciju.

- **Ograničena memorija** - ti sustavi umjetne inteligencije mogu koristiti prošla iskustva kako bi mogli donijeti buduće odluke. Neke od funkcija odlučivanja u automobilima, koji se samostalno voze, projektirane su na ovaj način. Zapažanja govore o akcijama koje se događaju u ne tako dalekoj budućnosti, kao što je promjena voženja automobila iz jedne prometne trake u drugu. Ta zapažanja se ne pohranjuju trajno.
- **Teorija uma** - ovaj termin psihologije odnosi se na razumijevanje da drugi imaju svoja vlastita uvjerenja, želje i namjere koje utječu na odluke koje donose. Ova vrsta UI još ne postoji.
- **Samosvijest** - u ovoj kategoriji, UI sustavi imaju osjećaj sebe, imaju svijest. Strojevi sa samosviješću razumiju svoje trenutno stanje i mogu koristiti informacije kako bi zaključili što drugi osjećaju. Ova vrsta UI još ne postoji.

Neki stručnjaci u industriji smatraju da je pojam umjetne inteligencije previše usko povezan s popularnom kulturom, zbog čega javnost ima nerealne strahove o umjetnoj inteligenciji i nevjerojatnim očekivanjima o tome kako će promijeniti radno mjesto i život općenito. Istraživači i trgovci se nadaju da će oznaka proširene inteligencije, koja ima više neutralne konotacije, pomoći ljudima da shvate kako će UI jednostavno poboljšati proizvode i usluge, a ne zamijeniti ljudi koji ih koriste.

Prije nego što se počne govoriti o dalnjem razvoju umjetne inteligencije treba napomenuti glavne razlike između čovjeka (čovjekova mozga) i računala (Von Neumannovo računalo). Tablica 3.1, opisuje glavne razlike između načina *rada* čovjekova mozga i Von Neumannovog računala.

Tablica 3.1 Razlike rada čovjekova mozga i Von Neumannovog računala [11]

ATRIBUT	MOZAK	RAČUNALO
Gradbeni element	neuron (>100 vrsta)	logička vrata
Brzina prijenosa	2 ms ciklus (milisekunda)	ns ciklus (nanosekunda)
Broj procesora	oko $10^{11}$	$\leq 32 *$
Broj veza	$10^3 - 10^4$	$\leq 32 *$
Način rada	serijski, paralelno	serijski
Signali	analogni	digitalni
Informacije	ispravne/neispravne	ispravne

### 3.2 Strojno učenje

Strojno učenje grana je umjetne inteligencije u kojoj se primjenjuje računalo u rješavanju određenih problema. U primjeni ove metode se ne koristi programirano računalo koje u svojoj memoriji ima pohranjen primjer istog ili sličnog problema, već se računalo upoznaje s tematikom problema i pronađe optimalno rješenje za proučeni problem. Najbolji primjer, koji je moguće prikazati u obrazovanju, može se najlakše povezati sa rješavanjem jednostavnih i složenih zadataka iz matematike.

Računala su u prošlosti mogla raditi samo ono za što su bila programirana. Strojno učenje omogućava računalima učiti na sličan način kako to rade ljudi: stroj prikuplja znanje bazirano na prošlom iskustvu. Umjesto da mu se stalno mora ažurirati softverski kod, stroj je, kako vrijeme prolazi, samostalno sposoban poboljšavati svoj rad [12]:

Primjeri primjene strojnog učenja vidljivi su u:

- Bioinformatici
- Prepoznavanju uzorka
- Prepoznavanju govora

- Predviđanju trendova
- Inteligentnom upravljanju
- Programima implementacije koje nije moguće riješiti klasičnim programiranjem
- Prilagodljivim programskim sustavima

Postoje tri vrste algoritama strojnog učenja [8]:

- **Nadzirano učenje** - Skupovi podataka su označeni tako da se uzorci mogu otkriti i koristiti za označavanje novih skupova podataka, nadzirano učenje je ekvivalentno učenju sa učiteljem
- **Nenadzirano učenje** - Skupovi podataka nisu označeni, nego su razvrstani prema sličnostima ili razlikama, nenadzirano učenje ekvivalent je učenju bez učitelja. U ovom načinu učenja računalo provjerava svaki ishod. Zbog stalnog provjeravanja ishoda, u svrhu da se pronađe optimalno rješenje, ova vrsta učenja više spada u kategoriju rudarenja podataka, nego u metode učenja
- **Podržano/ojačano učenje** - Skupovi podataka nisu označeni, ali nakon izvršenja radnje ili nekoliko akcija, sustav UI dobiva povratnu informaciju. Metoda učenja usvojena je u umjetnoj inteligenciji (UI) kao metoda usmjeravanja strojnog učenja bez nadzora kroz nagrade i kazne

Nema sumnje da će daljnji razvoj tehnologije i sve veća upotreba umjetne inteligencije, u narednim godinama, izazvati promjene na tržištu rada i načinu kako i koje poslove će ljudi u budućnosti obavljati. Neka predviđanja govore kako će u idućih 20-30 godina roboti zamijeniti polovicu svakodnevnih poslova, koje ljudi obavljaju danas. To ne znači da u budućnosti neće biti poslova, već će biti drugačije prirode. Tehnologija će ukinuti ili redefinirati neke od postojećih radnih mesta, ali će istodobno i kreirati nova, kojima će se ljudi morati prilagoditi i za koje će trebati razviti nove vještine. Iz radničke perspektive, između nestanka radnog mesta i bitno promijjenjenog opisa radnog mesta nije velika razlika, jer oni koji neće razviti nove kompetencije i vještine će vjerojatno ostati bez posla. Prema tome, treba stalno učiti, pratiti tehnološke trendove, spremno prihvatići promjene i fokusirati se na područja gdje će ljudski faktor i dalje biti potreban, a umjetna inteligencija će biti onakva kakvom je stvore ljudi.[8]

### **3.3 Rudarenje (istraživanje) podataka**

Rudarenje podataka može se definirati kao prikupljanje određenih znanja iz velike količine podataka, odnosno izvlačenje potrebnih informacija putem organiziranja, sortiranja ili grupiranja iz prethodno spremljenih podataka koji su nam u cijelosti dostupni. Danas, kada se ljudi nalaze u svijetu u kojem je sve više informacija i podataka, dolazi do preopterećenja ljudskih mogućnosti, stoga na snagu stupa umjetna inteligencija. Sustavi umjetne inteligencije pogodni su za *skladištenje* velike količine podataka, idealan primjer za ovu vrstu strojnog učenja može se pronaći u odgojno-obrazovnim ustanovama. Primjena rudarenja podataka može se primijeniti u predmetima koji su teorijske naravi, npr. povijest, hrvatski jezik, geografija, itd.

Primjer rudarenja podataka prikazat će se na nastavnom predmetu povijesti. Određenu količinu podataka, vezanih za nastavni predmet, unijet će se u računalo koje sadrži UI.

Računalo će učitati podatke i poredati ih po kronološkom redoslijedu događanja, te ih predočiti istim redoslijedom djeci koja prate nastavu.

Prije rudarenja podataka potrebno je poznavati parametre. U rudarstvu podataka, pravila asocijacija stvaraju se analizom podataka za učestale ako/onda obrasce, zatim korištenjem kriterija podrške i pouzdanosti za lociranje najvažnijih odnosa unutar podataka. Kriterij podrške je koliko često se stavke pojavljuju u bazi podataka, dok je kriterij pouzdanosti broj puta koliko su ako/onda obrasci točni. Ostali parametri rudarenja podataka uključuju analizu slijeda ili putanje, klasifikaciju, grupiranje i predviđanje. Parametri analize sekvenci ili putanje traže uzorke u kojima jedan događaj vodi do drugog, kasnijeg događaja. Sekvenca je uređena lista skupova stavki i to je uobičajena vrsta podatkovne strukture koja se nalazi u mnogim bazama podataka. Parametar klasifikacije traži nove obrasce i može rezultirati promjenom načina organiziranja podataka. Klasifikacijski algoritmi predviđaju varijable na temelju drugih čimbenika unutar baze podataka. [10]

## 4 PRIMJENA METODA UČENJA KOD UMJETNE INTELIGENCIJE

Moderne metode učenja baziraju se na razvoju umjetne inteligencije, tako da pristupaju problemu na isti način kako i čovjek pristupa, korištenjem vlastitog znanja, tj. uporabom mozga. Pri razvoju ovakvog načina upravljanja umjetnom inteligencijom potrebno je razjasniti tri važna pravila. Prvo i temeljno pravilo jest razmotriti princip funkcioniranja ljudskog mozga, u smislu razvoja i prilagodbe mozga tijekom vremena. Drugo pravilo je potreba za dobivanjem jednostavnih modela gradivnih elemenata mozga. Treće pravilo govori o povezivanju gradivnih elemenata mozga, povezivanje se može izvesti elektroničkim krugom ili računalnim programom, s ciljem simuliranja rada pojedinog režnja mozga. Umjetni *gradivni blokovi*, tj. režnjevi mogu se tada zajedno priključiti na različite načine, kako bi djelovali slično ljudskom mozgu. Glavni cilj je kopirati originalni mozak na neki način, ali je bitno samo traženje inspiracije za razvoj *mozga*, koji bi se koristio u modernim sustavima umjetne inteligencije.[13]

Primjena umjetne inteligencije, u odgoju, primjenjuje se kroz obrazovne softvere. Pod pojmom obrazovni softveri, podrazumijevaju se gotovi računalni programi, koji se mogu koristiti u okviru sadržaja nastave. Obrazovni softver sadrži različite nastavne programe, namijenjene određenim korisnicima. Jednu vrstu obrazovnog softvera čine intelligentni sustavi, tj. softveri umjetne inteligencije. Razvojem umjetne inteligencije pokušava se imitirati ljudsko razmišljanje. Ljudsko razmišljanje je proces koji upotrebljava inteligenciju i znanje pojedinca. Inteligencija pojedincu omogućuje stjecanje znanja, te olakšava primjenu u praksi. Umjetna inteligencija računalu daje dodatnu mogućnost procjene mogućeg kapaciteta, koji se ogleda u intelligentnom ponašanju.[14]


Metode učenja kod umjetne inteligencije su [14]:

- Umjetne neuronske mreže
- Duboko učenje
- Primjena intelligentnih agenata

#### **4.1 Umjetne neuronske mreže**

Neuron je živčana stanica koja je osnovna jedinica živčanog sustava, ujedno je najsloženija jedinica koja se nalazi u ljudskom tijelu. Broj neurona, koji se nalazi kod pojedinca je približno  $10^{11}$  međusobno povezanih neurona, ima ih više od 100 vrsta i raspoređeni su po točno određenom rasporedu. Neuron je građen od tijela u kojem se nalazi jezgra, oko tijela su dendriti, sinapse i akson. Dendriti su kratki produžetci, koji prenose živčane impulse s osjetnih organa do neurona.

Neuron prima impulse kroz dendrite, a signale koje proizvodi tijelo predaje preko aksona. Zahvaljujući paralelnom radu neurona, ljudski mozak postiže izrazito visoku brzinu i sposobnost realiziranja više raznovrsnih zadataka istovremeno. [15]



Slika 4.2 Prikaz neurona (živčane stanice) [16]

Pojam neuronskih mreža u današnje vrijeme se najviše odnosi na razvijanje umjetnih neuronskih mreža, kao i sjedinjavanje s programibilnim *mozgom* u jednu cjelinu. Umjetne neuronske mreže koriste se za proučavanje bioloških neuronskih mreža, kao i rješavanje kompleksnih problema primjenom umjetne inteligencije. Neuronske mreže imaju široku primjenu u tehničkim, a također i društvenim znanostima. Tijelo umjetnog neurona predstavlja sumator, dendriti predstavljaju ulaz u sumator, dok akson predstavlja izlaz iz sumatora.

Prilikom primjene umjetnih neuronskih mreža bitno je spomenuti razvoj umjetnog neurona, pod tim se podrazumijeva:

- ❖ proces učenja (treniranje)
- ❖ razvrstavanje *naučenih* podataka
- ❖ testiranje
- ❖ opoziv naučenih podataka po potrebi

Umjetne neuronske mreže primjenjuju se u obrazovanju, financijama, kontroli kvalitete, vojne svrhe, zdravstvu, itd. Umjetne neuronske mreže se sve više koriste u različitim kontrolama na granicama država, razvoj tehnike i sl. Najbolji primjer su mobilni uređaji, koji sadržavaju različite komponente koje imaju uključenu primjenu neuronskih mreža.

Otključavanje uređaja pomoću otiska prsta i prepoznavanja lica, kamera raspoznaće objekte i okolinu u kojoj se nalazi. To su samo neki od primjera umjetnih neuronskih mreža.

Primjeri primjene umjetne neuronske mreže su:

- pretvaranje teksta u govor i obrnuto
- prepoznavanje govora
- prepoznavanje osobe preko šarenice oka
- otključavanje otiskom prsta
- detekcija eksplozivnih sredstava na zračnim lukama
- detekcija radioaktivnih čestica
- detekcija dima u prostorijama, itd.

Bitne osobine umjetnih neuronskih mreža bitno je poznavati zbog uvođenja istih u školstvo, obrazovanje i odgoj djece. Osobine umjetnih neuronskih mreža su:

- mogu funkcionirati s nejasnim ili manjom informacijama
- mogu raditi s velikim brojem varijabli
- prilagođavaju se okolini
- sposobne su formirati znanje učeći iz iskustva

## 4.2 Duboko učenje

Duboko učenje je tema o kojoj se sve više priča. Duboko učenje predstavlja pod-kategoriju strojnog učenja, koristi se umjetnim neuronskim mrežama koje pomažu pri prepoznavanju govora, računalnog *vida* i obrade prirodnih jezika.

Duboko učenje je tehnika strojnog učenja, koja uči računala da rade ono što ljudi rade svakodnevno: učenje na primjerima. U dubokom učenju, računalni model uči izvoditi

zadatke klasifikacije izravno iz slike, teksta ili zvuka. Modeli dubokog učenja mogu postići vrhunsku točnost, ponekad premašivši performanse na ljudskoj razini. Modeli su obučeni korištenjem velikog skupa obilježenih podatkovnih i neuronskih mrežnih arhitektura, koje sadrže mnogo slojeva.[17]

Pri klasičnom strojnom učenju računalo bi kreiralo znanje kroz nadzirano iskustvo, što znači da je ljudski operater pomagao stroju u učenju dajući mu stotine ili tisuće praktičnih primjera za učenje, a greške su se ispravljale ručno. Razlika današnjih sustava sa dubokim učenjem je u tome što sada istraživači nastoje konstruirati sustav, koji sam kreira svoje osobine, koliko god je to izvedivo. Dakle, duboko učenje je uglavnom bez nadzora. Uključujući, na primjer, neuronske mreže velikih razmjera koje omogućavaju računalu i samostalno *razmišljanje* bez potrebe za izravnom ljudskom intervencijom. [1]

Velika snaga sustava dubokog učenja je omogućila revoluciju u autonomnim vozilima. Sustav za duboko učenje, zasnovan na učenju, konstantno prati cestu, promet i potencijalne opasnosti. Kombinacijom podataka senzora i prethodno stečenog znanja, sustav automatski donosi trenutačne odluke. Autonomna vozila su iz filmova znanstvene fantastike postala stvarnost. Na principu kako duboko učenje kontrolira autonomno vozilo, tako je moguće da *umjetni* profesor, nastavnik ili odgojitelj prati ponašanje djece u učionici. Prati njihove reakcije na određene nastavne cjeline i donosi odluke kako nešto učiniti zabavnije, ako se djeci to ne sviđa. Prikupljanjem podataka s nastave, mogu se prikupiti podaci o ponašanju djece, aktivnosti, zainteresiranosti za obavljanje neke aktivnosti i sl. Glavno pitanje je hoće li roboti ikad zamijeniti profesore, učitelje i odgojitelje?

Duboko učenje postiže točnost prepoznavanja na višim razinama nego ikada prije. To pomaže potrošačkoj elektronici da ispuni očekivanja korisnika, a to je ključno za sigurnosno kritične aplikacije poput automobila bez vozača. Nedavni napredak u dubokom učenju poboljšan je do točke u kojoj duboko učenje nadmašuje ljude u nekim zadacima, kao što je klasificiranje objekata na slikama.

Postoje dva glavna razloga zbog kojih je duboko učenje nedavno postalo korisno [17]:

1. Duboko učenje zahtijeva velike količine označenih podataka. Na primjer, razvoj automobila bez vozača zahtijeva milijune slika i tisuće sati videozapisa.
2. Duboko učenje zahtijeva znatnu računalnu snagu. Procesori visokih performansi imaju paralelnu arhitekturu koja je učinkovita za duboko učenje. U kombinaciji s računalstvom, razvojnim timovima omogućuje skraćivanje vremena obuke za mrežu dubokog učenja, od nekoliko tjedana do nekoliko sati ili manje.

Primjene za duboko učenje koriste se u industriji od automatske vožnje do medicinskih uređaja.

Automatizirana vožnja: Istraživači u automobilskoj industriji koriste duboko učenje kako bi automatski detektirali objekte, kao što su znakovi zaustavljanja i semafori. Osim toga, duboko učenje koristi se za otkrivanje pješaka, što pomaže u smanjenju nezgoda.

Zrakoplovstvo i obrana: Duboko učenje koristi se za identifikaciju objekata sa satelita, koji pronalaze područja od interesa, te za identifikaciju sigurnih ili nesigurnih zona za vojnike.

Medicinska istraživanja: Znanstvenici koriste duboko učenje kako bi automatski otkrili stanice raka. Izgrađen je napredni mikroskop, koji daje visokodimenzijski set podataka koji se koriste za vježbanje aplikacije za duboko učenje, kako bi se točno identificirale stanice raka.

Elektronika: Duboko učenje koristi se u automatiziranom sluhi i govoru. Primjerice, uređaji za pomoć u kući, koji odgovaraju vašem glasu i znaju vaše postavke, pokreću duboke aplikacije za učenje.

Obrazovanje: Razvoj aplikacija pomoću kojih djeca pretražuju određene nastavne cjeline, a umjetna inteligencija, u suradnji sa dubokim učenjem, prikazuje primjenu pretraženog u praksi. Na taj način djeca lakše shvaćaju određenu cjelinu.[17]

### **4.3 Primjena intelligentnih agenata**

Intelligentni agent je program koji odluke donosi samostalno ili obavlja postavljene zadatke na temelju svog okruženja, korisničkog unosa i iskustva. Ti programi se koriste za samostalno prikupljanje informacija na redovan, programiran raspored ili na zahtjev korisnika. Drugi naziv za intelligentne agente je *bot* što je skraćenica od robota. Intelligentni

agenti funkcioniraju tako što, pomoću parametara, koje je korisnik pružio, pretražuju cijeli ili dio interneta, prikupljajući informacije za koje je korisnik zainteresiran. Podatke mogu pretraživati pomoću ključnih riječi ili datuma objave. Parametri pretraživanja, koje koriste agenti uz primjenu umjetne inteligencije, mogu se unijeti pomoću senzora, kao što su mikrofon ili kamera, a izlaznu informaciju agent prikazuje na ekranu ili pomoću zvučnika.


U obrazovanju je moguće primijeniti ovakvu vrstu umjetne inteligencije, vezano za dodatni sadržaj tijekom učenja. Ako se pojedinac zainteresira za neki događaj može istražiti dodatni sadržaj o tome te apsolvirati isti. Poznata online trgovina Amazon je razvila program *Amazon assistant*, koji olakšava pretraživanje. Program funkcioniра da kupac slika proizvod koji ga zanima te program pretražuje slične rezultate u svim oglasima i na kraju daje ispis svih oglasa, koji se poklapaju u određenom postotku.

Vrste intelligentnih agenata definirane su prema njihovim sposobnostima i stupnju inteligencije [18]:

- Refleksni agenti: ti agenti funkcioniraju u trenutnom stanju, ignorirajući prošlost. Odgovori se temelje na pravilu akcije-uvjeta-akcije (ECA pravilo) gdje korisnik pokreće događaj, a agent se odnosi na popis unaprijed postavljenih pravila i unaprijed programiranih ishoda.
- Agenti zasnovani na modelu: ovi agenti odabiru radnju na isti način kao i refleksni agent, ali imaju sveobuhvatniji pogled na okoliš. Model svijeta programiran je u unutarnji sustav koji uključuje povijest agenta.
- Agenti temeljeni na cilju: ovi agenti proširuju bazu podataka agenta temeljenu na informacijskom modelu, uključujući i informacije o cilju ili informacije o poželjnim situacijama.
- Agenti temeljeni na korisnosti: ovi su agenti slični agentima koji su utemeljeni na ciljevima, ali pružaju dodatno mjerjenje korisnosti koje procjenjuje svaki mogući scenarij na željeni rezultat i bira radnju koja maksimizira ishod. Primjeri kriterija ocjenjivanja mogu biti vjerojatnost uspjeha ili potrebni resursi.

- Učeći agenti: ovi agenti imaju sposobnost postepenog poboljšanja i znanja o okolini tijekom vremena kroz dodatni element učenja. Element učenja koristit će povratne informacije, da bi odredio kako bi se elementi učinkovitosti trebali mijenjati da bi se postupno poboljšavali.

Najbolji primjer inteligentnih agenata je program koji je razvio Apple, program se zove *Siri*. *Siri* je osobni asistent za iOS, macOS, tvOS i watchOS uređaje koji koriste prepoznavanje glasa i pokretan je umjetnom inteligencijom. *Siri* odgovara na postavljena pitanja korisnika, govoreći kroz zvučnike uređaja i prezentirajući informacije na početni zaslon iz određenih aplikacija, npr. web-pretraživač ili kalendar. Usluga također korisnicima omogućuje diktiranje e-pošte i tekstualnih poruka, čitanje primljenih poruka i obavljanje raznih drugih zadataka.




Slika 4.4 „Siri“ aplikacija (čeka da joj se postavi pitanje) [19]

## 5 KOMERCIJALNE PRIMJENE UMJETNE INTELIGENCIJE

Razvojem intelligentnih sustava najveći problem bio je gdje to primijeniti, jer se nije znalo kakvo se *ponašanje* umjetne inteligencije može očekivati. Primjena umjetne inteligencije prvo bitno se

primjenjivala u sredinama gdje greška sustava neće dovesti do katastrofe. Dalnjim razvojem umjetne inteligencije, dolazi do razvoja složenijih sustava (npr. sustavi za kontrolu). Početkom 21. stoljeća, umjetna inteligencija se sve više koristi u svakodnevnom životu, počevši od jednostavnijih uređaja, pa sve do složenijih, industrijskih sustava. Prvi samostalni uređaji pogonjeni umjetnom inteligencijom korišteni su u raznim industrijama (npr. autoindustrija, proizvodnja odjevnih predmeta, itd.). U prethodnih par godina industrija proizvodnje autonomnih uređaja, koji koriste umjetnu inteligenciju, u velikom je porastu, sustavi umjetne inteligencije polako su se *ušuljali* u medicinu, obrazovanje, razne industrije i sl..

Razvoj sustava, s primjenom umjetne inteligencije, može uvelike olakšati obavljanje određenih poslova, koji su dosadni, zamorni i monotonii za pojedinca. Ovi primjeri mogu se najbolje pokazati razvojem autonomnih roboata, koji zamjenjuju usisivač, slika 5.1.



Slika 5.1 Autonomni kućni robot za usisavanje [20]

### 5.1 Inteligentni sustavi u obrazovanju

Inteligentni sustavi u obrazovanju pojavljuju se u novije vrijeme, takav način učenja, pomoću ovih sustava, nazvan je e-učenje. Ovakav način učenja odvija se tako da učenik

nakon škole ponovi gradivo, pomoću literature koja se nalazi na stranicama, koje imaju pristup elektronskim udžbenicima i ostalim pomoćnim sadržajima. Poznata je činjenica da robot nikad neće zamijeniti učitelja, profesora ili odgojitelja, tako da se ne vidi drugi način ulaska sustava umjetne inteligencije u obrazovanje. Danas, postoji velik broj ovakvih sustava koji mogu pomoći u usavršavanju određenog dijela gradiva.

Primjeri nekih sustava koji koriste umjetnu inteligenciju u obrazovanju:

- *Wolfram Alpha*
- *Mozaik education*
- *Izzi* i sl.


Inteligentni sustavi mogli bi olakšati posao učiteljima, npr. primjena intelligentnog sustava kod ocjenjivanja. Ocjenjivanje domaćih zadataka i testova može biti zamorno, čak i kad ih nastavnici podijele između sebe. Čak i u nižim razredima učitelji često otkrivaju da ocjenjivanje oduzima značajno vrijeme, vrijeme koje bi se moglo iskoristiti za interakciju s učenicima, pripremu za nastavu ili rad na profesionalnom razvoju.

Od vrtića do fakulteta, jedan od ključnih načina na koji će umjetna inteligencija utjecati na obrazovanje je kroz primjenu većih razina individualnog učenja. To se već događa kroz sve veći broj prilagodljivih programa učenja, igara i softvera. Ovi sustavi odgovaraju na potrebe učenika, stavljajući veći naglasak na određene teme, ponavljajući stvari koje studenti još nisu savladali i općenito pomažu studentima da rade vlastitim tempom.

Pomoću UI sustava, softvera i podrške, učenici mogu u bilo kojem trenutku učiti, s bilo kojeg mesta na svijetu, a s ovakvim programima koji se nalaze na mjestu određene vrste predavanja u učionici, UI može samo zamijeniti učitelje u nekim slučajevima. Obrazovni programi, koje pokreće UI, već pomažu učenicima naučiti osnovne vještine, ali kako ti programi rastu i kako programeri više uče, vjerojatno će ponuditi studentima mnogo širi spektar usluga.[14]

**Wolfram Alpha** je znanstvena tražilica koju je razvila kompanija *Wolfram Research*. *Wolfram Alpha* ne radi kao klasične tražilice, tipa *Google*, nego pomoću određenih algoritama pokušava odgovoriti na postavljeno pitanje. Korisnik može pitati određeno


pitanje, matematički zadatak ili slične stvari. Nakon pretraživanja, *Wolfram Alpha* izbacuje sve što je vezano za pretraživani pojam. Slika 5.2, prikazuje odgovor na pretraživani pojam.



Slika 5.2 Rezultat za pretraživanje pojma Slavonski Brod [21]

**Mozaik education** je kompanija, osnovana u Mađarskoj, ovo je organizacija koja je obične knjige *bacila* u prošlost i ponudila učenicima novu razinu obrazovanja. Knjige su za djecu predškolske dobi i djecu koja idu u osnovnu i srednju školu. *Mozaik education* obuhvatio je većinu predmeta koji su najbitniji (npr. fizika, matematika, geografija, povijest i dr.). Knjige,

osim zanimljivih članaka, nude dodatni sadržaj za one koji žele znati više, te sadrže puno veću kolekciju fotografija i slika da bi dočarali značenje nekog pojma. Osim slika, tu su i 3D modeli antičkih građevina i izumrlih životinja, kao i interaktivni filmovi na kojima se izvode pokusi iz kemije i fizike. Primjena ovakvih programskih sustava je sve veća, razvojem pametnih ploča otvara se nova dimenzija učenja. Osim učenja, ovaj sustav nudi provjeru znanja iz svakog područja te upozorava pristupnika koji dio gradiva bi trebao malo više vježbati.



Slika 5.3 Primjeri gradiva iz pojedinih predmeta

(a - erupcija vulkana, b - prijenos signala između neurona, c - kostur čovjeka, d - pregled mišića po tijelu, e - dišni sustav) [22]

**Izzi** (interaktivno, zanimljivo, zabavno, inkluzivno), također je sustav koji koristi umjetnu inteligenciju. Sustav je sličan prethodnom (*Mozaik education*), a razlika je što je ovaj sustav baziran na stjecanje znanja kroz igru. *Izzi* sadrži popis knjiga koje se koriste na nastavi, uz dodatne digitalne sadržaje u njima, određene cjeline imaju auditorni i animacijski zapis.

Ciljevi koji se ostvaruju spajanjem tiskanih i digitalnih sadržaja:

**Ostvarivanje ishoda** - znanja, vještina, sposobnosti

**Integrirano učenje** - jedinstvena struktura i kombiniranje tiskanog i digitalnog sadržaja


**Interaktivno učenje** - učenik je aktivan sudionik

**Istraživačko učenje** - povezivanjem različitih nastavnih područja s različitim kontekstima života

**Individualno učenje** - svaki učenik samostalno napreduje

**Poticanje** - kreativnog i kritičkog mišljenja, samovrednovanja i suradničkog vrednovanja

**Angažirane i zadovoljne učitelje, učenike i roditelje**




Slika 5.4 Učenje sadnje drveta uz pomoć IZZI sustava

Osim usavršavanja inteligentnih sustava u obrazovanju, mogućnost primjene ima i holografija. Holografija je metoda stvaranja i reproduciranja trodimenzionalnih slika na određenom prostoru, primjenom koherentne svjetlosti, tj. lasera. Reprodukcija, ovakvih zapisa, vrši se na fotografskoj ploči jer ona registrira smjerove i faze svjetlosnih zraka. Zbog

toga, holografija omogućava pohranjivanje pune trodimenzionalne strukture snimljenog objekta.

Primjena holograma u obrazovanju ima veliki potencijal, osim vjerodostojnjeg prikaza i realnog shvaćanja određene strukture, takav pristup bi nastavu učinio zabavnijom i zanimljivijom. Slika 5.5, prikazuje životinje koje su prikazane pomoću holograma, ali u stvarnoj veličini.



Slika 5.5 Hologram slona [23]

## 5.2 Google-ov razvoj umjetne inteligencije

*Google* se posebno ističe kao tvrtka koja od svojeg osnutka radi na realizaciji umjetne inteligencije. *Google* se može smatrati za jedan sustav ili projekt, koji povezuje različite

inovativne metode, ideje i inovativne ciljeve za razvoj skupa sustava umjetne inteligencije. *Google* sustav koristi tehnike strojnog učenja, kako bi automatski klasificirao i obradio veliku količinu informacija s mreže ili za razvoj *Google Glass* - računala koje se nosi. *Google Glass* sadrži optički zaslon, koji se stavlja na glavu i omogućuje trenutnu i stalnu povezanost sa internetom. [1]

Korisnici *Google* sustava pridonose stvaranju umjetne inteligencije, tako što odabiru rezultate koji im najbolje odgovaraju, a vezani su za pojam koji su unijeli u tražilicu (npr. video sadržaj, fotografije, određeni tekstovi i sl.). Ovakav sustav učenja, koji koristi ovaj sustav naziva se pojačano učenje. Pojačano učenje je ono što čini *Google* posebnim u odnosu na druge pretraživače, uz to je i najkorištenija tražilica na svijetu. Osim *Google* tražilice, imaju na milijune Gmail, You Tube i Android korisnika, svi prethodno nabrojani sustavi koriste sustav umjetne inteligencije, da bi olakšali pristup određenim stvarima (npr. pjesmama, fotografijama, komunikaciji među ljudima i sl.). U novije vrijeme, *Google* organizira sve više različitih tečajeva, radionica i sličnoga, na temu primjene umjetne inteligencije u svakodnevnom životu, a sve to da se ljudima dočara kako to neće imati negativan utjecaj, već da će olakšati život.



Slika 5.6 Google-ov razvoj autonomnih vozila [24]

### 5.3 Predviđanja o primjeni umjetne inteligencije (UI)

Daljnji razvoj umjetne inteligencije nije upitan, on je u porastu svake godine. Velike količine novčanih sredstava se ulažu u razvoj umjetne inteligencije, način na koji će se to ulagati je teško za predvidjeti. Obrazovanje je jedno od područja gdje bi se umjetna inteligencija mogla primjenjivati u velikoj količini. Kineski znanstvenici su otišli korak dalje i napravili robota, uz kojeg se djeca mogu igrati i učiti, robot je dobio naziv *BeanQ*. Ovaj robot sadrži oblike umjetne inteligencije i služi se metodom dubokog učenja, kako bi apsorbirao određeno gradivo, te da isto pojasni djetetu.



Slika 5.7 BeanQ robot odgovara na postavljeno pitanje

Na kraju, treba istaknuti kako već danas prevladava primjena umjetne inteligencije za rješavanje određenih, vrlo specifičnih zadataka, postoje i realna očekivanja kako će umjetna inteligencija zaživjeti sredinom ovog stoljeća. Mnogi znanstvenici ističu zabrinutost kako će umjetna inteligencija utjecati na čovječanstvo. Pogotovo se ističe strah od izgradnje jake, svjesne umjetne inteligencije kao nečega s čime se čovječanstvo još nije susrelo, kao i posljedica koje je nemoguće predvidjeti. Dok god postoji mala zabrinutost ili strah od umjetne inteligencije ona se ne može primjenjivati u obrazovanju, jer je to ipak rad s djecom, a poznato je da na mладима svijet ostaje.

## 6 ZAKLJUČAK

Primjena umjetne inteligencije prisutna je u područjima istraživanja i raznim industrijama. Od početka razvijanja sustava, pogonjenih umjetnom inteligencijom, pa sve do danas, istraživanja su učinila veliki pomak, jer se u današnje vrijeme mogu naći brojni primjeri uporabe umjetne inteligencije.

Čovjek kontinuirano uči, od trenutka rođenja sve do prestanka života. Do sada je čovjek morao sam razvijati metode i modele kako optimalno savladati određeno gradivo i usvojiti potrebna znanja. Razvojem umjetne inteligencije, čovjek će i dalje morati učiti, ali mu umjetna inteligencija može pružiti pomoć i ubrzati pristup potrebnim informacijama. Pojedini primjeri ovih sustava (*Mozaik education*, *Wolfram Alpha*, hologrami i sl.) mogu pomoći u boljem i bržem shvaćanju određenih materijala i pojava. Uz ljudsko vodstvo, nastaje se izraditi intelligentni sustavi, koji su kreativni i uče u interakciji s okolinom. Za istraživanja ljudskog mozga i neuromorfne računalne arhitekture, očekuje se mogućnost novih spoznaja u izgradnji umjetne inteligencije. Nagli razvoj umjetne inteligencije pokrenuo je niz pitanja o posljedicama njene primjene, kao što je utjecaj na privatnost života, sigurnost pojedinca i sl. Otkrića i proizvodnje umjetne inteligencije su za čovjeka koliko korisne toliko i zabrinjavajuće. Tek će se u dogledno vrijeme, moći predvidjeti kakve bi učinke na cijelokupno čovječanstvo mogle imati daljnje perspektive UI, a za sada ostaju samo nagađanja.

## 7 LITERATURA

- [1] Kovač, L. (2015). *Umjetna inteligencija danas*. Rijeka: Sveučilište u Rijeci, Filozofski fakultet.
- [2] *Umjetna inteligencija*. Pribavljen 1.5.2019., sa <http://www.enciklopedija.hr/natuknica.aspx?ID=63150>
- [3] Pribavljen 11.5.2019., sa <https://dev.index.hr/mame/clanak/zelim-vam-reci-dane-brinete-ako-je-vase-dijete-drugacije-od-drugih/952252.aspx>
- [4] *Suvremene metode i oblici proučavanja*. Pribavljen 11.5.2019., sa <http://www.os-kamenica.com/nastava/suvremene-metode-i-oblici-poucavanja>
- [5] Ljubin Golub, T. i Kozjak Mikić, Z.: *Psihologija učenja i poučavanja*. Zagreb, Učiteljski fakultet.
- [6] Ivanov, L.: *Poučavanje*. Zadar, Odjel za psihologiju.
- [7] *Predavanje informatike u Gani*. Pribavljen 11.5.2019., sa <https://www.24sata.hr/fun/nije-mu-lako-nastavnik-u-gani-predaje-informatiku-na-ploci-562791>
- [8] *Brzo i kvalitetno učenje*, Pribavljen 11.5.2019., sa <http://studentski.hr/zabava/zanimljivosti/brzo-i-kvalitetno-ucenje>
- [9] *Razlike između strojnog učenja, AI i "dubokog" učenja*. Pribavljen 11.5.2019., sa <https://pcchip.hr/ostalo/tech/razlike-izmedu-strojnog-ucenja-ai-i-dubokog-ucenja/>
- [10] *AI (artificial intelligence)*, Pribavljen 26.5.2019., sa <https://searchenterpriseai.techtarget.com/definition/AI-Artificial-Intelligence>
- [11] Bašić Dabelo, B.; Čupić, M., i Šnajder, J.: *Umjetne neuronske mreže*, Zagreb, Fakultet elektrotehnike i računalstva.
- [12] *Što je to "machine learning" ili strojno učenje?*, Pribavljen 26.5.2019., sa <https://pcchip.hr/helpdesk/sto-je-to-machine-learning-ili-strojno-ucenje/>

- [13] *Will Machine Learning AI Make Human Translators An Endangered Species?*, Pribavljeno 8.6.2019., sa  
<https://www.forbes.com/sites/bernardmarr/2018/08/24/will-machine-learning-ai-make-human-translators-an-endangered-species/#79ec0a913902>
- [14] Nadrljanski, M., Tomašević, M. *Obrazovni softver – inteligentni tutorski sustavi učenja*. Split: Pomorski fakultet u Splitu.
- [15] Dumančić, S. (2014). *Neuronske mreže*, Osijek, Odjel za fiziku.
- [16] *Od živčane stanice do živčanog sustava*. Pribavljeno 9.6.2019., sa  
<https://edutorij.e-skole.hr/share/proxy/alfresco-noauth/edutorij/api/proxy-guest/4f77c550-2b26-4717-b65e-82b845685f3f/biologija-8/m03/j01/index.html>
- [17] *What is deep learning?*. Pribavljeno 9.6.2019., sa  
<https://www.mathworks.com/discovery/deep-learning.html>
- [18] *Intelligent agent*. Pribavljeno 9.6.2019., sa  
<https://searchenterpriseai.techtarget.com/definition/agent-intelligent-agent?fbclid=IwAR3tIi08IBOWgC9SgAz5Na3TaR5LL6wJpF2jgqrDUaeLtIPU6jIFrwiCDeU>
- [19] *Here's how to use Google Assistant on your iPhone or iPad*. Pribavljeno 9.6.2019., sa <https://thenextweb.com/apple/2018/11/27/forget-siri-heres-how-to-use-google-assistant-on-your-iphone-or-ipad/>
- [20] Pribavljeno 11.6.2019., sa <https://smartmall.hr/trgovina/xiaomi-roborock-xiaowa-e20-robot-usisavac-2600ma-baterija-1800pa-usisavanje-640ml-velika-prasina-box-autonomno-planiranje-izdanje-bijela/>
- [21] *Slavonski Brod*. Pribavljeno 11.6.2019., sa  
<https://www.wolframalpha.com/input/?i=Slavonski+Brod>
- [22] Pribavljeno 11.6.2019., sa  
<https://www.mozaweb.com/hr/lexikon.php?cmd=getlist&let=7&sid=BIO&pg=2>
- [23] *Nemački cirkus životinje zamenio hologramima*. Pribavljeno 11.6.2019., sa <https://www.originalmagazin.com/2019/06/04/nemacki-cirkus-zivotinje-zamenio-hologramima/>
- [24] *Self-driving cars*. Pribavljeno 11.6.2019., sa  
<https://www.bbc.com/news/business-45048264>