

# Strojno autorstvo: generatori teksta i prijevoda

---

**Glavačević, Mislav**

**Master's thesis / Diplomski rad**

**2020**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **Josip Juraj Strossmayer University of Osijek, Faculty of Humanities and Social Sciences / Sveučilište Josipa Jurja Strossmayera u Osijeku, Filozofski fakultet**

*Permanent link / Trajna poveznica:* <https://um.nsk.hr/um:nbn:hr:142:023372>

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

*Download date / Datum preuzimanja:* **2024-11-26**



**FILOZOFSKI FAKULTET**  
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

*Repository / Repozitorij:*

[FFOS-repository - Repository of the Faculty of Humanities and Social Sciences Osijek](#)



Sveučilište J. J. Strossmayera u Osijeku

Filozofski fakultet

Dvopredmetni diplomski studij Nakladništva i Informacijske tehnologije

Mislav Glavačević

**Strojno autorstvo: generatori teksta i prijevoda**

Diplomski rad

Mentor: prof. dr. sc. Zoran Velagić

Osijek, 2019.

Sveučilište J. J. Strossmayera u Osijeku

Filozofski fakultet Osijek

Odsjek za informacijske znanosti

Dvopredmetni diplomski studij Nakladništva i Informacijske tehnologije

---

Mislav Glavačević

## **Strojno autorstvo: generatori teksta i prijevoda**

Diplomski rad

Društvene znanosti, informacijsko – komunikacijske znanosti, informacijski  
sustavi i informatologija

Mentor: prof. dr. sc. Zoran Velagić

Komentor: doc. dr. sc. Tomislav Jakopec

Osijek, 2020.

## IZJAVA

Izjavljujem s punom materijalnom i moralnom odgovornošću da sam ovaj rad samostalno napisao, te da u njemu nema kopiranih ili prepisanih dijelova teksta tuđih radova niti da nisu označeni kao citati s napisanim izvorom odakle su preneseni. Svojim vlastoručnim potpisom potvrđujem da sam suglasan da Filozofski fakultet Osijek trajno pohrani i javno objavi ovaj moj rad u internetskoj bazi završnih i diplomskih radova knjižnice Filozofskog fakulteta Osijek, knjižnice Sveučilišta Josipa Jurja Strossmayera u Osijeku i Nacionalno i sveučilišne knjižnice u Zagrebu.

U Osijeku, 30. 6. 2020. g., MISLAV GLAVIČEVIĆ, JMBAG: 0471210397

Mislav Glavičević

## Sažetak i ključne riječi

Cilj je ovoga diplomskog rada opisati aspekte strojnog autorstva, odnosno generatora teksta i prijevoda kao segmenta u području kreativnih industrija, specifično u polju autorstva. Rad daje pregled nastanka i razvoja strojnog autorstva te preduvjeta i čimbenika koji su pripomogli njegovom razvoju. Na početku rada opisan će se umjetna inteligencija kao preduvjet stvaranja strojnog autorstva, što je ona, kada je nastala, kako se razvijala, kako funkcionira te koje su sve grane umjetne inteligencije bitne za razvoj strojnog autorstva, odnosno generatora teksta i prijevoda. Konkretno, objasnit će se što je strojno učenje, duboko učenje, računalna lingvistika, obrada prirodnog jezika, razumijevanje prirodnog jezika te generiranje prirodnog jezika. Nakon toga slijedi detaljan opis generatora teksta, kako funkcioniraju, gdje se primjenjuju te će se navesti nekoliko aplikacija (alata) za generiranje teksta. Zatim slijedi opis i povijesni pregled nastanka i razvoja generatora prijevoda, gdje se primjenjuju, za što se koriste, kako funkcioniraju te će se navesti nekoliko najrelevantnijih organizacija i njihovih aplikacija za strojno prevođenje teksta. Na kraju će se donijeti zaključak o tome što je uvjetovalo pojavu strojnog autorstva, kako se razvijalo tijekom godina i kako izgleda danas te što se može očekivati u budućnosti od strojnog autorstva s obzirom da je tehnologija i sve ono što se veže uz nju veoma podložno velikim promjenama koje se mogu dogoditi u vrlo kratkom roku.

Ključne riječi: generatori teksta, generatori prijevoda, umjetna inteligencija, strojno autorstvo

## Sadržaj

Sažetak i ključne riječi .....	3
1. Uvod.....	1
2. Preduvjeti razvoja strojnog autorstva - računalni sustav i baze podataka .....	3
3. Preduvjeti razvoja strojnog autorstva - umjetna inteligencija.....	6
3.1. Strojno učenje.....	8
3.2. Duboko učenje.....	10
3.3. Računalna lingvistika .....	12
3.4. Obrada prirodnog jezika.....	13
3.5. Razumijevanje prirodnog jezika.....	16
3.6. Generiranje prirodnog jezika.....	17
4. Generatori teksta .....	19
4.1. Sustavi u produkciji umjetne inteligencije .....	20
4.2. Dohvaćanje dokumenata i aplikacije za grupiranje.....	22
4.3. Izvlačenje znanja.....	26
4.4. Automatsko sažimanje teksta .....	27
4.5. Analiza osjećaja.....	29
4.6. Roboti za čavrljanje i razgovorni agenti.....	31
4.7. Korisnička sučelja prirodnog jezika .....	34
4.8. Prva istraživačka knjiga napisana pomoću umjetne inteligencije .....	36
4.9. Prvi roman napisan pomoću umjetne inteligencije .....	37
5. Strojno prevođenje - definicija i pregled razvoja.....	38
5.1. Primjena i sustavi strojnog prevođenja.....	40
5.2. Vrste strojnog prijevoda .....	43
5.3. Aplikacije za strojni prijevod .....	46
6. Zaključak.....	49
7. Popis korištenih izvora i literature .....	51

## 1. Uvod

Strojno autorstvo u obliku generatora teksta i prijevoda pojavljuje se sredinom 20. stoljeća nastankom i razvojem adekvatnog računalnog sustava te bazama podataka i umjetne inteligencije koji zajedno stvaraju preduvjet njihova razvoja. Prema SpringerLinku generiranje teksta je pod-polje obrade prirodnog jezika koje koristi znanje iz računalne lingvistike i umjetne inteligencije za automatsko generiranje teksta iz prirodnog jezika kako bi udovoljio određenim komunikacijskim potrebama.<sup>1</sup> Generatori prijevoda su automatizirani programi osposobljeni za prevođenje izvornog jezika na druge, ciljne jezike bez potrebe za ljudskom intervencijom.<sup>2</sup> U prvim godinama njihova razvoja sustave za generiranje teksta i prijevoda uglavnom su koristile svjetske sile, kao što su Sjedinjene Američke Države, Sovjetski Savez ili Europska Zajednica koje su imale potrebu posjedovati takve programe u razdoblju Hladnoga rata kada su im od velike koristi bili takvi programi za prijevod, dohvaćanje i shvaćanje teksta u kojemu su se mogle nalaziti različite vrlo važne informacije.<sup>3</sup> Osnovni preduvjet njihova razvoja bilo je stvaranje radnog okruženja, odnosno računalnog sustava koji je temelj stvaranja strojnog autorstva onakvog kakav je danas. Prema Techopediji, računalni sustav je osnovno, cjelovito i funkcionalno računalo koje uključuje svu potrebnu tehničku i programsku podršku kako bi bilo u potpunosti funkcionalno za korištenje.<sup>4</sup> Tehnička podrška odnosi se na sve vanjske i unutarnje opipljive dijelove računala. Bez nje ne bi bilo moguće pokrenuti programsku podršku. Nakon toga perioda, programima strojnog generiranja teksta i prijevoda počeli su se baviti istraživači i znanstvenici koji su se bavili proučavanjem umjetne inteligencije općenito te njenim pod-poljima kao što su:

- strojno učenje,
- duboko učenje,
- računalna lingvistika,
- obrada prirodnog jezika,

---

<sup>1</sup> Zhang L., Sun JT. (2009) Text Generation. In: LIU L., ÖZSU M.T. (eds) Encyclopedia of Database Systems. Springer, Boston, MA URL: [https://link.springer.com/referenceworkentry/10.1007%2F978-0-387-39940-9\\_416](https://link.springer.com/referenceworkentry/10.1007%2F978-0-387-39940-9_416) (2019-10-12)

<sup>2</sup> What is Machine Translation? // GALA – Globalization and Localization Association. URL: <https://www.gala-global.org/what-machine-translation>

<sup>3</sup> Hutchins, John W. Machine Translation: A Brief History. // Concise History of Language Sciences: From the Sumerians to the Cognitivists, 1995. Str. 431-445. URL: <https://aymara.org/biblio/mtranslation.pdf> (2019-09-09)

<sup>4</sup> Computer System. // Techopedia. URL: <https://www.techopedia.com/definition/593/computer-system> (2019-10-26)

- razumijevanje prirodnog jezika te
- generiranje prirodnog jezika.

S obzirom da je razvoj umjetne inteligencije jedan od preduvjeta nastanka strojnog autorstva, potrebno je nju i njene grane poznavati te shvatiti kako bi se svi segmenti uspješno primijenili za razvijanje programa ili aplikacija koje omogućuje strojno generiranje teksta ili prijevoda. Prema Encyclopedia Britannici, umjetna inteligencija je sposobnost računala ili računalno upravljano robotu za obavljanje zadataka koje obično izvršavaju ljudi.<sup>5</sup> Ukratko, umjetna inteligencija je sposobnost oponašanja ljudskih aktivnosti. Umjetna inteligencija koristi se u mnogim gospodarskim granama te u mnogim programskim rješenjima za obavljanje određenih zadataka. Ona se sastoji od mnogo različitih grana koje često međusobno ne mogu komunicirati, što znači da različite grane nekada ne mogu simultano koristiti svoje funkcije pri rješavanju problema jer znaju koristiti potpuno drugačiju paradigmu prirodnog jezika ili skupove algoritama za donošenje odluka. Za potrebe strojnog autorstva važne i relevantne grane umjetne inteligencije su strojno učenje, duboko učenje, računalna lingvistika, obrada prirodnog jezika, razumijevanje prirodnog jezika te generiranje prirodnog jezika. Navedene grane umjetne inteligencije međusobno proizlaze jedna iz druge; tako je duboko učenje grana strojnog učenja, a generiranje prirodnog jezika grana obrade prirodnog jezika. Godinama se razvijaju različiti sustavi i pristupi navedenih grana umjetne inteligencije kako bi se omogućilo stvaranje proizvoda ili usluge najveće kvalitete koji su bili uvjetovani i neprekidnim istraživanjem i razvojem, kako umjetne inteligencije, tako i njenih grana. Nakon što su ostvareni navedeni preduvjeti razvoja strojnog autorstva, pojedinci i organizacije u mogućnosti su stvarati različite alate i aplikacije za generiranje teksta ili prijevoda. Primjeri aplikacija za generiranje teksta jesu dohvaćanje dokumenata i njihovo grupiranje (korisna za pretraživanje, pronalaženje i organiziranje najrelevantnijih dokumenata ili mrežnih izvora za određenu korisnikovu potrebu), aplikacija za automatsko sažimanje teksta (korisna kada korisnik ima potrebu za sažetim i konciznim sadržajem teksta određene teme, pružajući mu pri tome najbitnije informacije umjesto cijeloga teksta), aplikacije robota za čavljanje (koji oponaša karakteristike ljudskog asistenta za podršku korisnicima) te mnoge druge. Strojno autorstvo odnosi se i na stvaranje cjelovitih knjiga koje je generirala umjetna inteligencija. Prva istraživačka knjiga napisana pomoću umjetne inteligencije nosi naslov *Lithium-Ion Batteries: A Machine-Generated*

---

<sup>5</sup> Artificial Intelligence. // Encyclopedia Britannica. URL: <https://www.britannica.com/technology/artificial-intelligence> (2019-09-12)



*Summary of Current Research* koju je objavio američki nakladnik Springer Nature<sup>6</sup> dok je prvi takav roman *I the Road* Ross Goodwin, kreativni tehnolog i zaposlenik Googlea, generirao koristeći se automobilom opremljenim kamerom za snimanje, GPS-om, mikrofonom te satom koji su bili povezani prijenosnim pisaćim strojem umjetne inteligencije koji je poprimao ulazne podatke u stvarnom vremenu.<sup>7</sup> Kako je već napomenuto, generatori prijevoda počeli su se razvijati nešto ranije nego generatori teksta, no svoju potpunu funkcionalnost stječu kada i generatori teksta, a to je u razdoblju razvijanja umjetne inteligencije, sredinom 1950-ih godina. Generatori prijevoda tijekom godina svoga razvijanja koristili su različite pristupe i sustave pomoću kojih su funkcionirali. Današnje aplikacije za generiranje teksta proizvodi su ili specijaliziranih organizacija za prijevod teksta (kao što je SYSTRAN) ili velikih svjetskih IT organizacija (kao što su Google ili Microsoft). Te aplikacije mogu biti besplatne ili se naplaćivati, ovisno o politici pojedine organizacije. Neki od najpoznatijih aplikacija za generiranje prijevoda su Google Translate, Microsoft Translate, SYSTRAN, Yandex, Apertium i mnoge druge.<sup>8</sup> S obzirom da će se u radu spomenuti mnogo različitih tehničkih termina i da je većina literature prevedena s engleskog jezika, napominjem kako sam kao pomoć pri korištenju prijevoda tehničkih termina s engleskog jezika na hrvatski jezik, koristio mrežno mjesto *Stranica GNU tima za hrvatske prijevode* koja se nalazi na poveznici <http://www.gnu.org/server/standards/translations/hr/>.

## 2. Preduvjeti razvoja strojnog autorstva - računalni sustav i baze podataka

U ovome odlomku govorit će se o razvojnim preduvjetima generatora teksta i prijevoda kao što su nastanak i razvoj računalnog sustava, baze podataka i umjetne inteligencije. Svaki od navedenih preduvjeta omogućili su generatorima teksta i prijevoda funkcionalnost kakvu imaju danas, stoga ih je važno zasebno opisati. Temeljni je preduvjet razvoja strojnog autorstva nastanak računalnog sustava koji ima ulogu platforme i radnog okruženja na kojemu navedeni koncept funkcionira. Osnovni su dijelovi računalnog sustava tehnička podrška (hardware) i programska podrška (software). Tehnička podrška pri svome radu komunicira s programskom podrškom kako

---

<sup>6</sup> Vincent, James. The first AI-generated textbook shows what robot writers are actually good at. // The Verge. URL: <https://www.theverge.com/2019/4/10/18304558/ai-writing-academic-research-book-springer-nature-artificial-intelligence> (2019-09-12)

<sup>7</sup> McDowell, Kenric. *I The Road By an Artificial Neural Network*. URL: <https://www.jbe-books.com/products/1-the-road-by-an-artificial-neural> (2020-02-08)

<sup>8</sup> Best Machine Translation Software. // G2. URL: <https://www.g2.com/categories/machine-translation> (2019-09-12)

bi izvršavali različite računalne funkcije i procese.<sup>9</sup> Prema Techopediji, tehnička podrška u kontekstu računalne tehnologije odnosi se na fizičke elemente koji čine računalni ili elektronički sustav te na sve ostale elemente koji su fizički opipljivi. Osim razvoja računalnog sustava adekvatnog za primjenu strojnog autorstva, idući sustav na kojemu se temelji nastanak koncepta strojnog autorstva jest razvoj baze podataka.<sup>10</sup> Prema TechTargetu, baza podataka je skup podataka koji se organizira na način da im se može lako pristupiti, upravljati i ažurirati. Računalne baze podataka obično sadrže zbirke podataka ili datoteke koje imaju različite vrste informacija te ih koriste različite strane sile kao metodu za pohranu, upravljanje i dohvaćanje tih informacija. Postoji mnogo različitih modela baza podataka, od najprisutnijih relacijskih modela baza podataka do distribuiranih, objektno-orijentiranih, NoSQL ili baza podataka u oblaku. Baze podataka doživjele su značajan razvoj od njihova nastanka u 1960-im godinama kada su se pojavile u obliku hijerarhijskih i mrežnih baza podataka. U 1980-im godinama razvio se oblik objektno-orijentiranih baza podataka, dok se danas najčešće javljaju u sljedećim oblicima:

- SQL (Structured Query Language),
- NoSQL (Not only Structured Query Language).

Također postoji i poseban način realizacije baze podataka u oblaku (cloud databases).<sup>11</sup> U nastavku će se opisati svaki od navedenih modela baze podataka. Hijerarhijski model baze podataka jest model u kojemu su podaci organizirani u obliku nalik stablu. Podaci se pohranjuju kao zapisi koji su međusobno povezani različitim vezama. Zapis je zbirka polja, dok svako polje sadrži samo jednu vrijednost.<sup>12</sup> Nadalje, mrežna baza podataka je model baze podataka u kojemu se više članova zapisa ili datoteka može povezati s više vlasničkih datoteka i obrnuto. Ovaj model može se promatrati kao naopako stablo u kojemu je informacija svakoga člana stabla, grana povezana s vlasnikom podataka, odnosno s dnom stabla.<sup>13</sup> Relacijske baze podataka sljedeći su model baze podataka razvijen 1970-ih godina u IBM-u. Ona je tablična baza podataka u kojoj su podaci definirani tako da se mogu reorganizirati i pristupiti na više različitih načina. Relacijske baze podataka sastoje se od skupa tablica s podacima koji se uklapaju u unaprijed definiranu kategoriju. Svaka tablica ima najmanje jednu kategoriju podataka u stupcu te svaki redak u stupcu ima

---

<sup>9</sup> Remaker, Phillip. What is the difference between hardware, firmware and software? // Quora. URL: <https://www.quora.com/Whats-the-difference-between-hardware-firmware-and-software> (2019-10-19)

<sup>10</sup> Software. // Techopedia. URL: <https://www.techopedia.com/definition/4356/software> (2019-11-09)

<sup>11</sup> Database (DB). // TechTarget. URL: <https://searchsqlserver.techtarget.com/definition/database> (2019-10-26)

<sup>12</sup> Mertz, David. Putting XML in context with hierarchical, relational and object-oriented models. // IBM. URL: <https://www.ibm.com/developerworks/xml/library/x-matters8/index.html> (2019-10-26)

<sup>13</sup> Network Database. // Techopedia. URL: <https://www.techopedia.com/definition/20971/network-database> (2019-10-26)

određenu instancu podataka za kategorije koje su definirane u stupcima. Strukturirani upitni jezik (SQL) standardno je sučelje za interakciju između korisnika i aplikacijskog programa korištenog za upravljanje relacijskim bazama podataka. Idući razvijeni model baze podataka jest objektno-orijentirana baza podataka. Ona je organizirana oko objekata i podataka, nasuprot radnjama i logici. Na primjer, multimedijски zapis u relacijskoj bazi podataka je definirani podatkovni objekt, za razliku od alfanumeričke vrijednosti koju ima u objektno-orijentiranim bazi podataka. Iako se podaci kreirani pomoću objektno-orijentiranih programskih jezika često pohranjuju u relacijske baze podataka, objektno-orijentirane baze podataka također su dobro prilagođene za pohranjivanje takve vrste podataka. Distribuirane baze podataka idući je model baze podataka u kojemu se dijelovi baze podataka pohranjuju na više fizičkih mjesta i u kojima se obrada tih podataka širi ili replicira između različitih točaka u mreži. Distribuirane baze podataka mogu biti homogene ili heterogene. Sve fizičke lokacije u homogenom sustavu raspodijeljenih baza podataka imaju istu temeljnu tehničku podršku i pokreću iste operacijske sustave i aplikacije baza podataka, dok tehnička podrška, operativni sustavi ili aplikacije baze podataka u heterogenoj distribuiranoj bazi podataka mogu biti različiti na svakoj od lokacija.<sup>14</sup> NoSQL noviji je model baze podataka koji može poprimiti široki raspon oblika podataka, uključujući formate kao što su ključ-vrijednost, dokumentni format te stupčane i grafičke oblike podataka. NoSQL jest alternativa tradicionalnim relacijskim bazama podataka u kojemu se podaci smještaju u tablice te u kojemu je podatkovna shema pažljivo osmišljena prije same izrade baze podataka. NoSQL baze podataka korisne su za rad s velikim količinama podataka, a s kojima relacijske baze podataka nisu u mogućnosti učinkovito upravljati. Najkorisnije su kada organizacije trebaju analizirati velike količine nestrukturiranih podataka ili podataka koji su pohranjeni na više virtualnih poslužitelja u oblaku.<sup>15</sup> Na kraju, baza podataka u oblaku je model baze podataka koji je optimiziran ili izgrađen za virtualno okruženje bilo u hibridnom, javnom ili privatnom oblaku. Ovaj oblik baze podataka pruža prednosti poput mogućnosti plaćanja kapaciteta i propusnosti za pohranu po upotrebi, pružaju skalabilnost na zahtjev te imaju visoku dostupnost korisnicima na tržištu. Baze podataka u oblaku također pružaju tvrtkama mogućnost podrške poslovnim aplikacijama u implementaciji programske podrške kao usluge.<sup>16</sup> U ovome odlomku primarni cilj bio je opisati računalni sustav baze podataka kao osnovnu platformu koja je polazište za omogućavanje razvoja strojnog

---

<sup>14</sup> Database (DB). // TechTarget. URL: <https://searchsqlserver.techtarget.com/definition/database> (2019-10-26)

<sup>15</sup> NoSQL (Not Only SQL database). // TechTarget. URL: <https://searchdatamanagement.techtarget.com/definition/NoSQL-Not-Only-SQL> (2019-10-26)

<sup>16</sup> Database (DB). // TechTarget. URL: <https://searchsqlserver.techtarget.com/definition/database> (2019-10-26)

autorstva, a u nastavku teksta opisat će se umjetna inteligencija kao razvojni preduvjet strojnog autorstva čiji su nastanak omogućili prethodno opisani razvojni preduvjeti.

### 3. Preduvjeti razvoja strojnog autorstva - umjetna inteligencija

Nastavno na prethodni odlomak o razvijanju računalnog sustava i baze podataka, umjetna inteligencija idući je bitni preduvjet razvoja strojnog autorstva. Umjetna inteligencija područje je računalne znanosti koje naglašava stvaranje inteligentnih strojeva koji rade i koji se ponašaju poput ljudi te koja se može koristiti za rješavanje problema u stvarnome svijetu primjenom sljedećih procesa ili tehnika:

- strojnog učenja,
- dubokog učenja,
- prirodne obrade jezika,
- Robotike,
- ekspertnih sustava,
- mutne logike (fuzzy logic).<sup>17</sup>

Ona se odnosi na simulaciju ljudskog ponašanja u strojevima koji su programirani da razmišljaju poput ljudi i oponašaju njihove postupke. Pojam se također može primijeniti na bilo koji stroj koji pokazuje osobine povezane s ljudskim umom, kao što su učenje i rješavanje problema. Idealna karakteristika umjetne inteligencije jest njezina sposobnost racionalizacije i poduzimanja radnji koje imaju najveće šanse za postizanje određenog cilja. Neke od aktivnosti koje računala s umjetnom inteligencijom imaju sposobnost izvršavati su prepoznavanje govora, učenje, planiranje, rješavanje problema, a također i generiranje teksta i prijevoda. Umjetna inteligencija osnovana je kao akademska disciplina 1956. godine i od tada je doživjela nekoliko valova optimizma pri njenom razvijanju, nakon čega je uslijedilo razočaranje i značajan gubitak financijskih sredstava (poznato kao *AI winter*). Zbog toga su uslijedili novi pristupi što je dovelo do njenog uspješnog razvijanja. Većim dijelom njene povijesti, istraživanje umjetne inteligencije podijeljeno je na pod-polja koja često ne uspijevaju međusobno komunicirati. Veliki broj ljudi

---

<sup>17</sup> Lateef, Zulaikha. Types of Artificial Intelligence You Should Know. // edureka! URL: <https://www.edureka.co/blog/types-of-artificial-intelligence/#Branches%20Of%20Artificial%20Intelligence> (2019-10-27)

umjetnu inteligenciju povezuje s robotima, ponajviše zbog visokobudžetnih filmova i romana koji u svojim pričama opisuju ljude sličnim strojevima koji u većini slučajeva uništavaju Zemlju. No, to je dalek i neprecizan opis onoga što umjetna inteligencija zaista jest.<sup>18</sup> Umjetna inteligencija temelji se na načelu da se ljudska inteligencija može definirati na način da je stroj može oponašati i izvršavati različite zadatke, od onih najjednostavnijih do najsloženijih. Ciljevi umjetne inteligencije uključuju učenje, rasuđivanje i percepciju. S obzirom da je tehnologija gospodarska grana koja iznimno brzo napreduje, početna mjerila i shvaćanja koja definiraju umjetnu inteligenciju postaju zastarjela. Na primjer, strojevi koji izračunavaju osnovne funkcije ili prepoznaju tekst kroz optimalno prepoznavanje znakova više se ne smatraju umjetnom inteligencijom, budući da se ova funkcija sada uzima zdravo za gotovo kao urođena računalna funkcija. Umjetna inteligencija neprestano se razvija u korist mnogih različitih industrija. Strojevi su povezani koristeći interdisciplinarni pristup koji se temelji na matematici, računalnim znanostima, lingvistici, psihologiji i na još mnogo toga. Stoga, ona se koristi za nebrojeno velik broj aplikacija iz različitih sektora i industrija pa je tako i temelj za mogućnost pojave strojnog autorstva, odnosno za generiranje teksta i prijevoda. Umjetna inteligencija može se svrstati u tri različite vrste sustava koji je pokreću: analitičku, inspiriranu prema čovjeku i humaniziranu. Analitička umjetna inteligencija ima samo karakteristike povezane s kognitivnom inteligencijom, generira kognitivne reprezentacije okoline i koristi učenje koje se temelji na prošlom iskustvu za donošenje budućih odluka. Umjetna inteligencija inspirirana prema čovjeku ima elemente kognitivne i emocionalne inteligencije, shvaća ljudske emocije uz kognitivne elemente i koristi ih pri donošenju odluka. Humanizirana umjetna inteligencija pokazuje karakteristike svih triju vrsta kompetencija (kognitivna, emocionalna i društvena inteligencija), sposobna je biti samosvjesna te je takva i u interakciji s drugima. Nadalje, umjetna inteligencija može biti podijeljena u dvije različite kategorije: slaba i jaka umjetna inteligencija.<sup>19</sup> Slaba (ili uska) umjetna inteligencija je strojna inteligencija koja je ograničena na određeno i usko područje. Ona simulira ljudsku spoznaju i pogoduje ljudima automatiziranjem dugotrajnih zadataka i analizom podataka na načine koji ljudi ponekad ne mogu. Slaboj umjetnoj inteligenciji nedostaje ljudska svijest te ju ona može simulirati. Klasična ilustracija slabe umjetne inteligencije je eksperiment kineske misaone sobe. Ovaj eksperiment implicira da osoba izvan sobe može čuti ono što se čini kao razgovor na kineskom jeziku s osobom u sobi koja dobiva upute o tome kako sudjelovati u razgovoru na kineskom, ali

---

<sup>18</sup> Artificial Intelligence (AI). // Techopedia. URL: <https://www.techopedia.com/definition/190/artificial-intelligence-ai> (2019-08-16)

<sup>19</sup> Frankenfield, Jake. Artificial Intelligence (AI). // Investopedia. URL: <https://www.investopedia.com/terms/a/artificial-intelligence-ai.asp> (2019-08-16)

zapravo osoba u sobi ne zna i ne razumije ni jednu riječ na kineskom, osim instrukcija i informacija koje je dobila od treće osobe. To je zato što je osoba u sobi dobra u praćenju uputa, a ne u govoru na kineskom. Slaba umjetna inteligencija nema opću inteligenciju već specifičnu inteligenciju.<sup>20</sup> S druge strane, jaka umjetna inteligencija bila bi oblik strojne inteligencije koja je jednaka ljudskoj inteligenciji. Njene ključne značajke jesu sposobnost rasuđivanja, rješavanja problema, donošenja prosudbi, planiranja, učenja i komuniciranja. Također bi trebala imati svijest, objektivne misli, samosvijest, osjećajnost i mudrost. Jaka umjetna inteligencija trenutno ne postoji. Stručnjaci i znanstvenici podijeljeni su kada je u pitanju njeno razvijanje te moguća pojava. Neki stručnjaci smatraju da bi se mogla razviti između 2030. i 2045. godine, drugi smatraju da bi se mogla razviti u sljedećem stoljeću, dok treći smatraju da razvoj jake umjetne inteligencije uopće nije ni moguć.<sup>21</sup> Umjetna inteligencija, uz računalni sustav i baze podataka koje koristi kao radno okruženje, osnovni je i neophodni razvojni preduvjet strojnog autorstva, a u nastavku teksta opisat će se grane umjetne inteligencije koje su usko povezane s razvojem strojnog autorstva.

### 3.1. Strojno učenje

Prema Ng Andrew-u, strojno učenje je znanost o tome da računala djeluju bez izričite potrebe da budu programirana.<sup>22</sup> Ono se također može objasniti kao automatizacija i poboljšanje procesa učenja računala na temelju njihovih iskustava bez da zapravo budu programirana, odnosno da djeluju bez ikakve pomoći i instrukcija čovjeka. Strojno je učenje metoda analize podataka koje automatizira izgradnju analitičkog modela. Ono je grana umjetne inteligencije koja se temelji na ideji da sustavi mogu učiti iz dobivenih podataka, identificirati obrasce i donositi odluke uz minimalnu ljudsku intervenciju. Isto kao što se spomenulo za umjetnu inteligenciju, tako i zbog razvoja novih računalnih tehnologija, poimanje strojnog učenja danas nije isto kao što se smatralo u prošlosti. Razvoj ove znanosti počeo je s idejom da računala mogu učiti bez programskih instrukcija čovjeka za obavljanje različitih zadataka. Istraživači zainteresirani za umjetnu inteligenciju htjeli su vidjeti mogu li računala učiti iz prethodno dobivenih i obrađenih podataka. Arthur Samuel, jedan od prvih istraživača strojnog učenja, 1959. godine definirao je strojno učenje

---

<sup>20</sup> Frankenfield, Jake. Weak AI. // Investopedia. URL: <https://www.investopedia.com/terms/w/weak-ai.asp> (2019-08-16)

<sup>21</sup> Frankenfield, Jake. Strong AI. // Investopedia. URL: <https://www.investopedia.com/terms/s/strong-ai.asp> (2019-08-16)

<sup>22</sup> Ng, Andrew. Machine Learning. // Coursera. URL: <https://www.coursera.org/learn/machine-learning> (2019-08-17)

kao polje znanosti koje računalima daje mogućnost učenja bez čovjekove programske podrške. Samuel je učio računalni program kartaškoj igri „dama“ te mu je cilj bio naučiti ga da igra bolje od njega samoga. S time je uspio 1962. godine kada je njegov program pobijedio prvaka države Connecticut. Dio „učenje“ u sintagmi „strojno učenje“ znači da algoritmi strojnog učenja pokušavaju minimalizirati pogreške pri donošenju odluka, a maksimizirati vjerojatnost da su njihova predviđanja istinita.<sup>23</sup> Iterativni aspekt strojnog učenja vrlo je važan jer su modeli izloženi novim podacima i sposobni su se samostalno prilagoditi. Oni uče iz prethodnih proračuna da bi proizveli pouzdane, ponovljive odluke i rezultate. Strojno učenje je znanost koja nije nova, ali je dobila novi zamah pri svome razvijanju. Prema tome, koja je razlika između umjetne inteligencije i strojnog učenja? Dok je umjetna inteligencija znanost o oponašanju ljudskih sposobnosti, strojno učenje je specifična grana umjetne inteligencije koja trenira stroj kako da uči. Proces strojnog učenja započinje ubacivanjem kvalitetnih podataka u računalni sustav i zatim osposobljavanjem računala pomoću izgradnje različitih modela strojnog učenja koristeći postojeće podatke i različite algoritme. Izbor algoritma ovisi o vrsti podataka koje računalo posjeduje te kakvu vrstu zadataka pokušava automatizirati.<sup>24</sup> Postoji više metoda strojnog učenja, a dvije najkorištenije metode su nadzirano učenje i nenadzirano učenje. Nadzirani algoritmi učenja obučeni su pomoću označenih primjera, kao što je unos u kojemu je poznat željeni izlaz (rezultat). Na primjer, dio opreme može imati podatke označene sa „N“ (neuspješno) ili „U“ (upogonjeno). Algoritam učenja prima skup ulaza zajedno s odgovarajućim ispravnim izlazima kako bi pronašao pogreške te zatim modificira model u skladu s dobivenim rezultatima. Kroz metode kao što su klasifikacija i regresija nadzirano učenje koristi obrasce za predviđanje vrijednosti oznake na dodatnim neoznačenim podacima. Nadzirano se učenje obično koristi u aplikacijama gdje povijesni podaci predviđaju moguće buduće događaje. Na primjer, računalo može predvidjeti kada je vjerojatno da će doći do prevare korisnika prilikom izvršavanja transakcija kreditnim karticama ili koji će klijent vjerojatno podnijeti nekakav zahtjev u banci. S druge strane, nenadzirano se strojno učenje koristi za podatke koji nemaju povijesne oznake. U tome slučaju, sustavu nije navedeno što treba napraviti kako bi dobili željeni ishod radnje koju poduzima, već algoritam sam mora shvatiti što se prikazuje i što treba napraviti. Cilj je istražiti podatke i pronaći strukturu unutar njih. Nenadzirano učenje dobro funkcionira kod transakcijskih podataka. Na primjer, može identificirati segmente kupaca sa sličnim atributima koji se mogu tretirati na sličnom uzorku pri provođenju marketinških kampanja.

---

<sup>23</sup> Nicholson, Chris. Artificial Intelligence (AI) vs. Machine Learning vs. Deep Learning. // Skymind. URL: <https://skymind.ai/wiki/ai-vs-machine-learning-vs-deep-learning> (2019-09-17)

<sup>24</sup> Gupta, Mohit. ML |. What Is Machine Learning? // GeeksforGeeks. URL: <https://www.geeksforgeeks.org/ml-machine-learning/> (2019-08-17)

Također može pronaći glavne attribute koji međusobno odvajaju segmente korisnika. Osim ovih dviju prethodno navedenih metoda strojnog učenja, često korištene metode su i metoda polunadziranog strojnog učenja te metoda pojačanog strojnog učenja. Metoda polunadziranog učenja koristi se za iste aplikacije kao i metoda nadziranog učenja, ali za obučavanje koristi i označene i neoznačene podatke, i to najčešće malu količinu označenih podataka s velikom količinom neoznačenih podataka (zbog toga što neoznačeni podaci iziskuju manje financijske troškove te je potrebno manje truda za prikupljanje od označenih podataka). Ova vrsta učenja može se koristiti s metodama kao što su klasifikacija, regresija i predviđanje. Jedan od prvih primjera polunadziranog strojnog učenja jest prepoznavanje lica osobe na web-kameri. Pojačano strojno učenje najčešće se koristi za robotiku, igre i navigaciju. U ovoj vrsti učenja algoritam putem metode „pokušaja i pogrešaka“ poduzima akcije, odnosno radnje koje donose najbolje rezultate. Pojačano učenje sastoji se od tri primarne komponente, a one su agent (učenik ili donositelj odluke), okruženje (sve s čime agent ima interakciju) te radnja (što agent može učiniti). Cilj je da agent odabere radnje koje maksimiziraju očekivane rezultate tijekom određenog vremena.<sup>25</sup> Strojno učenje osnovna je grana umjetne inteligencije iz koje proizlaze sva ostala pod-polja koja će se opisivati u nastavku teksta. Slijedi opis pod-grane strojnog autorstva, duboko učenje.

### 3.2. Duboko učenje

Prema autorima knjige *Deep Learning: Methods and Applications*, Deng Liju i Dong Yuu, duboko učenje skup je algoritama koji se primjenjuju u strojnom učenju te koji se koriste za modeliranje apstrakcija na visokoj razini pomoću arhitekture modela koji su sastavljeni od višestrukih nelinearnih transformacija. Ono je klasa tehnika strojnog učenja koje koriste mnoge slojeve nelinearne obrade podataka za nadziranu ili nenadziranu ekstrakciju različitih obilježja u svrhu analize i klasifikacije uzoraka.<sup>26</sup> Duboko učenje je pod-polje strojnog učenja koje uči računala da rade ono što je karakteristično za ljude – a to je učiti na primjerima. U dubokom učenju, umjetne neuronske mreže i algoritmi koje su kreirali ljudi, uče iz velike količine podataka. Duboko učenje naziva se “dubokim” jer neuronske mreže imaju različite duboke slojeve koji omogućuju učenje. Gotovo svaki problem koji zahtjeva razmišljanje o njemu je problem koje duboko učenje može riješiti. Iako je duboko učenje počelo biti teoretizirano 1980-ih godina, tek je nedavno postalo korisnim. Količina podataka koja se generira svaki dan je izuzetna – trenutno se procjenjuje

---

<sup>25</sup> Machine Learning: What It Is and Why It Matters. // Sas. URL: [https://www.sas.com/en\\_us/insights/analytics/machine-learning.html](https://www.sas.com/en_us/insights/analytics/machine-learning.html) (2019-08-17)

<sup>26</sup> Deng, Li; Dong Yu. Deep Learning: Methods and Applications. URL: <https://www.microsoft.com/en-us/research/wp-content/uploads/2016/02/DeepLearning-NowPublishing-Vol7-SIG-039.pdf> (2019-08-29)



da je to oko 2,6 kvantimilijuna bajta i upravo zbog toga duboko učenje ima svoju svrhu. Budući da algoritmi dubokog učenja zahtijevaju mnoštvo podataka za učenje, ovo povećanje stvaranja podataka jedan je od razloga zašto su mogućnosti dubokog učenja porasle posljednjih godina. Uz navedeno povećanje podataka, algoritmi dubokog učenja imaju koristi od jačanja računalne snage koja je danas dostupna, kao i zbog širenja umjetne inteligencije kao usluge. Umjetna inteligencija kao usluga omogućila je manjim organizacijama pristup tehnologijama umjetne inteligencije, kao i algoritmima umjetne inteligencije potrebnim za duboko učenje, i to bez velikih početnih ulaganja. Duboko učenje omogućuje strojevima da rješavaju složene probleme čak i kada koriste skup podataka koji su vrlo raznoliki, nestrukturirani i međusobno nepovezani. Što više algoritmi dubokog učenja uče, to su bolji rezultati.<sup>27</sup> Duboko učenje u prvi plan stavlja umjetnu inteligenciju pomažući oblikovati alate koji se koriste za postizanje izuzetno velike razine točnosti. Napredak u dubokom učenju pogurao je ove alate do točke gdje duboko učenje nadmašuje ljude u nekim zadacima poput klasificiranja predmeta u slikama, tekstu ili zvuku.<sup>28</sup> Duboko učenje specifičan je pristup koji se koristi za izgradnju i obučavanje neuronskih mreža koje se smatraju vrlo pouzdanima u donošenju odluka. Smatra se da je algoritam dubok ako se ulazni podaci šalju kroz niz nelinearnosti, odnosno nelinearnih transformacija prije nego što postanu izlazni. Suprotno tome, većina modernih algoritama strojnog učenja smatraju se "plitkima" jer unos može ići samo na nekoliko razina poziva potprograma za izvršavanje radnji. Većina metoda dubokog učenja koje se danas koriste rade pomoću arhitekture neuronske mreže. Neuronska mreža niz je algoritama koji nastoje prepoznati temeljne odnose u skupu podataka kroz proces koji oponaša način rada ljudskog mozga. Glavna karakteristika neuronske mreže jest njena sposobnost stvaranja najboljih rezultata bez potrebe za mijenjanjem izlaznih kriterija. One mogu prepoznati uzorke putem podataka i na temelju njih donijeti pravilnu odluku. Svaki sloj neuronske mreže obrađuje glavne značajke te izvlači poneki vrijedan podatak.<sup>29</sup> Neki od praktičnih i poznatih primjera dubokog učenja su:

- virtualni asistenti (Cortana, Alexa, Siri),
- prevoditelji (Google Translate),
- vizija ili oči (u dostavnim kamionima, dronovima, automobilima bez vozača),

---

<sup>27</sup> Marr, Bernard. What Is Deep Learning AI? A Simple Guide With 8 Practical Examples. // Forbes. URL: <https://www.forbes.com/sites/bernardmarr/2018/10/01/what-is-deep-learning-ai-a-simple-guide-with-8-practical-examples/#7b3d0dfb8d4b> (2019-08-29)

<sup>28</sup> What Is Deep Learning? 3 things you need to know. // MathWorks. URL: <https://www.mathworks.com/discovery/deep-learning.html> (2019-08-29)

<sup>29</sup> Donovan, Alexander. What Is Deep Learning and Why Is It More Relevant Than Ever? // URL: <https://interestingengineering.com/what-is-deep-learning-and-why-is-it-more-relevant-than-ever> (2019-08-29)

- roboti za čavrljanje i servisni roboti,
- prepoznavanje objekata na slici,
- prepoznavanje lica (na pametnim telefonima, prijenosnim računalima) i još mnogi drugi.<sup>30</sup>

Strojno učenje osnovna je grana umjetne inteligencije u kontekstu strojnog autorstva, a u ovom odlomku može se zaključiti kako je duboko učenje kao pod-polje strojnog učenja jedna od polazišnih točki za omogućavanje funkcionalnosti strojnog autorstva s obzirom da su upravo generatori prijevoda jedan od praktičnih primjera dubokog učenja. U nastavku slijedi opis ostalih grana umjetne inteligencije čiji je glavni zadatak rješavanje problema pri suočavanju sa suptilnostima ljudskog jezika.

### 3.3. Računalna lingvistika

Prema Techopediji, računalna lingvistika jest znanstvena i inženjerska disciplina koja se bavi razumijevanjem pismenog i govornog jezika iz računalne perspektive te izgradnjom objekata koji korisno obrađuju i proizvode jezik, bilo skupno ili u dijalogu. Ona je pregledavanje načina na koji bi stroj postupao s prirodnim jezikom te izvršava ili konstruira modele za jezik koji mogu omogućiti ciljeve poput preciznog strojnog prijevoda jezika ili simulacije umjetne inteligencije. Općenito, računalna lingvistika uključuje uvid u prirodu jezika, njegovu morfologiju, sintaksu i dinamičku upotrebu te crtanje svih mogućih modela kako bi se strojevima moglo pomoći u upravljanju jezikom.<sup>31</sup> Ona je interdisciplinarno područje studija koje zahtijeva stručnost u strojnom učenju, dubokom učenju, umjetnoj inteligenciji, kognitivnom računalstvu i neuroznanosti.<sup>32</sup> Budući da je jezik čovjekovo najprirodnije i najsvestranije sredstvo komunikacije, jezično kompetentna računala uvelike bi olakšala ljudsku interakciju sa strojevima i svim vrstama programske podrške. Teorijski ciljevi računalne lingvistike uključuju formuliranje gramatičkih i semantičkih okvira za karakterizaciju jezika na načine koji omogućuju računalnu izvedbu implementacije sintaktičke i semantičke analize. Praktični ciljevi polja su široki i raznoliki. Neki od najistaknutijih su:

---

<sup>30</sup> Marr, Bernard. 10 Amazing Examples Of How Deep Learning AI Is Used In Practice? // Forbes. URL: <https://www.forbes.com/sites/bernardmarr/2018/08/20/10-amazing-examples-of-how-deep-learning-ai-is-used-in-practice/#4c0eb429f98a> (2019-08-29)

<sup>31</sup> Computational Linguistics. // Techopedia. URL: <https://www.techopedia.com/definition/194/computational-linguistics> (2019-08-30)

<sup>32</sup> Computational Linguistics. // SearchEnterpriseAI. URL: <https://searchenterpriseai.techtarget.com/definition/computational-linguistics-CL> (2019-08-30)

- učinkovito pretraživanje teksta o željenoj temi,
- učinkovito strojno prevođenje,
- odgovaranje na pitanja (od jednostavnih činjeničnih pitanja do pitanja koja zahtijevaju zaključke i opisne odgovore),
- sažimanje teksta,
- analiza teksta ili govornog jezika,
- agenti za dijalog koji pomažu pri izvršavanju određenih zadataka (kupovina, rješavanje tehničkih problema, planiranje putovanja...),
- stvaranje računalnih sustava koji posjeduju sposobnost oponašanja ljudske inteligencije za primjenu u dijalogu, stjecanju jezika i stjecanju znanja iz teksta te
- stvaranje robota za čavljanje sposobnih za prolazak Turingovog testa (test koji je 1950. godine izradio Alan Turing, a koji omogućava provjeru inteligencije računala ili programske potpore<sup>33</sup>).

Razvijeni su i modeli koji omogućuju upotrebu strojeva za razumijevanje kako se pojedini jezik stječe. Krajnji cilj omogućavanja strojevima da stvarno oponašaju ljudske jezične odgovore kontinuirana je evolucija koja još uvijek ostavlja puno prostora za napredak. Jedna od teorija je da će strojevi s vremenom steći sposobnost oponašanja stvarnog ljudskog razgovora, čime će postati inteligentniji koristeći heurističke modele i druge procese koji nadilaze puko prikupljanje podataka i njihovo kvantitativno izračunavanje.<sup>34</sup> Računalna lingvistika polazišna je grana umjetne inteligencije koja pomaže računalima kvalitetnu obradu i upravljanje ljudskim jezikom. S godinama se sve više razvijala te je još uvijek puno prostora za postizanje savršenog rezultata, a u nastavku će se navesti i opisati preostale grane umjetne inteligencije koje potpomažu upravo tome da računala postanu besprijekorna pri obradi, razumijevanju i generiranju ljudskim jezikom.

### 3.4. Obrada prirodnog jezika

Prema Towards Data Scienceu, obrada prirodnog jezika (Natural Language Processing) grana je umjetne inteligencije koja pomaže računalima razumjeti, interpretirati i upravljati ljudskim jezikom. Ona se temelji na mnogim disciplinama, uključujući računalnu znanost i

---

<sup>33</sup> Turing Test. SearchEnterpriseAI. URL: <https://searchenterpriseai.techtarget.com/definition/Turing-test> (2019-08-30)

<sup>34</sup> Schubert, Lenhart. Computational Linguistics. The Stanford Encyclopedia of Philosophy, Spring 2019 Edition. URL: <https://plato.stanford.edu/archives/spr2019/entries/computational-linguistics> (2019-08-30)

računalnu lingvistiku kako bi ispunila jaz između ljudske komunikacije i računalnog razumijevanja. Krajnji cilj obrade prirodnog jezika jest čitati, dešifrirati i razumjeti ljudske jezike. Obrada prirodnog jezika nije nova znanost, no njenom ubrzanom razvoju u zadnjih nekoliko godina pomogao je povećani interes za razvijanjem komunikacije između čovjeka i stroja te dostupnost velikih podataka, snažno računanje i razvoj naprednih algoritama.<sup>35</sup> "Materinji jezik računala", poznat kao strojni kod ili strojni jezik, većini je ljudi uglavnom nerazumljiv. U strojnom jeziku komunikacija se ne odvija riječima nego milijunima nula i jedinica koje proizvode logičke radnje. Razvoj NLP aplikacija izazovan je jer računala tradicionalno zahtijevaju od ljudi da im "govore" u programskom jeziku, koji je precizan, nedvosmislen i visoko strukturiran, ili kroz ograničen broj jasno izgovorenih glasovnih naredbi. Međutim, ljudski govor nije uvijek precizan, već može biti dvosmislen, a jezična struktura može ovisiti o mnogim varijablama, uključujući sleng, regionalni dijalekt i društveni kontekst. Obrada prirodnog jezika omogućuje računalima čitanje teksta, slušanje i tumačenje govora te određivanje koji su dijelovi teksta ili govora važni za određenu potrebu. Današnji strojevi mogu analizirati više podataka temeljenih na jeziku nego što to mogu ljudi, i to bez umora i na dosljedan način. S obzirom na već spomenutu jako veliku količinu nestrukturiranih podataka koji se stvaraju svaki dan, smatra se da će automatizacija biti presudna za učinkovitu analizu tekstualnih i govornih podataka.<sup>36</sup> Obrada prirodnog jezika uključuje mnogo različitih tehnika tumačenja ljudskog jezika, od statističkih i strojnih metoda do algoritamskih pristupa. Dvije glavne tehnike koje se koriste pri obradi prirodnog jezika jesu sintaksa i semantička analiza. Sintaksa je tehnika raspoređivanja riječi u rečenici kako bi imala gramatički smisao, a obrada prirodnog jezika koristi sintaksu za procjenu značenja iz jezika temeljenog na gramatičkim pravilima. Tehnike temeljene na sintaksi uključuju:

- raščlanjivanje (gramatička analiza rečenice),
- segmentaciju riječi (dijeljenje većih dijelova teksta na manje jedinice),
- razbijanje rečenica,
- morfološku segmentaciju (dijeljenje riječi u grupe) te
- korjenovanje riječi (npr. riječ "pjevanje" se suzi u korijen "pjesma").

Semantika se odnosi na upotrebu i značenje riječi. Obrada prirodnog jezika primjenjuje algoritme zbog razumijevanja značenja i strukture rečenica. Tehnike koje koristi semantikom uključuju

---

<sup>35</sup> Lopez Yse, Diego. Your Guide to Natural Language Processing (NLP) // Towards Data Science. URL: <https://towardsdatascience.com/your-guide-to-natural-language-processing-nlp-48ea2511f6e1> (2019-09-02)

<sup>36</sup> Natural Language Processing (Iot): What it is and why it matters. // SAS. URL: [https://www.sas.com/en\\_us/insights/analytics/what-is-natural-language-processing-nlp.html#world](https://www.sas.com/en_us/insights/analytics/what-is-natural-language-processing-nlp.html#world) (2019-09-02)

rašćlanjivanje smisla riječi (time riječ dobije značenje na temelju konteksta), prepoznavanje imenovanih entiteta (određivanje riječi koje se mogu grupirati, npr. "imena ljudi" ili "imena mjesta") te generiranje prirodnog jezika (korištenje baze podataka za određivanje semantike riječi i pretvorbe u ljudski jezik). Trenutni pristupi obrade prirodnog jezika temelje se na dubokom učenju. Modeli dubokog učenja zahtijevaju ogromne količine označenih podataka za osposobljavanje i prepoznavanje relevantnih korelacija te je zato sastavljanje ovakvog skupa velikih podataka jedna od glavnih prepreka s kojom se obrada prirodnog jezika suočava. Raniji pristupi obrade prirodnog jezika uključivali su pristup koji se zasniva na pravilima. U ovom se pristupu pojednostavljenim algoritmima strojnog učenja naređivalo koje riječi i izraze treba tražiti u tekstu te koje odgovore treba generirati kada ih pronade. Pristup temeljen na dubokom učenju je fleksibilniji i intuitivniji jer u njemu algoritmi na različitim primjerima uče prepoznati namjere i potrebe govornika. Obrada prirodnog jezika koristi se za kategoriziranje sadržaja, otkrivanje i modeliranje tema, kontekstualno izdvajanje, analizu osjećaja, pretvaranje govora u tekst i teksta u govor, sažimanje dokumenata, strojno prevođenje.<sup>37</sup> Neki od primjera aplikacija obrade prirodnog jezika su:

- Google Translate (prijevod jezika),
- provjera gramatičkih ispravnosti u aplikacijama za pisanje teksta poput Microsoft Word ili Grammarly,
- aplikacije za osobne asistente kao što su OK Google, Siri, Cortana i Alexa te
- aplikacije za interaktivni govorni odgovor koje se koriste u pozivnim centrima za odgovaranje na određene zahtjeve korisnika.

U svim navedenim primjerima, sveobuhvatni je cilj iskoristiti "sirovi jezik" te koristiti lingvistiku i algoritme za preoblikovanje ili obogaćivanje teksta na način da mu donese veću vrijednost i kvalitetu. Iako je nadzirano učenje i posebno duboko učenje danas u širokoj upotrebi za modeliranje ljudskog jezika, postoji potreba za sintaktičkim i semantičkim razumijevanjem koji nisu uvijek prisutni u ovim pristupima strojnog učenja. Zbog toga je obrada prirodnog jezika važna jer pomaže u rješavanju jezičnih nejasnoća te dodavanja numeričke strukture podacima za mnoge prethodno navedene aplikacije. Osim toga, kako je sve više prirodnog ljudskog jezika kao oblika informacije na Internetu, obrada prirodnog jezika omogućila je analizu i takvih podataka te učenje

---

<sup>37</sup> Natural Language Processing (NLP). // SearchBusinessAnalytics. URL: <https://searchbusinessanalytics.techtarget.com/definition/natural-language-processing-NLP> (2019-09-02)

iz većeg broja izvora podataka.<sup>38</sup> Nakon što je opisan način na koji računala obrađuju prirodni jezik, vrlo je bitno objasniti kako računala rješavaju problem razumijevanja ljudskog jezika, što slijedi u nastavku.

### 3.5. Razumijevanje prirodnog jezika

Prema Twiliju, razumijevanje prirodnog jezika (Natural Language Understanding) je računalno razumijevanje strukture i značenja ljudskog jezika omogućavajući pri tome korisnicima interakciju s računalom koristeći rečenice prirodnog jezika.<sup>39</sup> Ono je grana umjetne inteligencije koja koristi računalnu programsku podršku za razumijevanje unosa rečenica u tekstualnom ili govornom obliku, odnosno tumačenje teksta ili bilo koje druge vrste nestrukturiranih podataka. Razumijevanje prirodnog jezika može obraditi tekst, prevesti ga u računalni jezik i proizvesti rezultat na jeziku koji ljudi mogu razumjeti.<sup>40</sup> NLU je grana obrade prirodnog jezika koja pomaže računalima razumjeti i interpretirati ljudski jezik “razbijanjem” elementarnih dijelova govora. Ono uključuje modeliranje razumijevanja ljudskog čitanja, odnosno analizira i prevodi unos prema principima ljudskog jezika.<sup>41</sup> Razumijevanje prirodnog jezika i obrada prirodnog jezika često se shvaćaju kao isto polje umjetne inteligencije, no to nije slučaj. Oni su različiti dijelovi istog procesa obrade prirodnog jezika. Razumijevanje prirodnog jezika je sastavni dio obrade prirodnog jezika. Ono tumači značenje koje korisnik komunicira. Na primjer, ljudima koji govore isti jezik lako je međusobno se razumjeti čak i ukoliko se neke riječi nepravilno izgovore i zato je razumijevanje prirodnog jezika programirano sa sposobnošću razumijevanja značenja usprkos uobičajenim ljudskim greškama, kao što su primjerice pogrešni izgovori. NLU ima zadatak komunicirati s nedovoljno jasnim pojedincima i razumjeti njihove namjere i potrebe, što znači da ono nadilazi razumijevanje i tumači značenje. NLU je odgovorno za taj zadatak razlikovanja primjene različitih procesa kao što su kategorizacija teksta, analiza sadržaja i analiza osjećaja, što omogućuje strojevima rukovanje različitim ulaznim naredbama. S druge strane, obrada prirodnog jezika

---

<sup>38</sup> Garbade, Michael J. A Simple Introduction to Natural Language Processing. // Becoming Human. URL: <https://becominghuman.ai/a-simple-introduction-to-natural-language-processing-ca66a1747b32> (2019-09-02)

<sup>39</sup> Macherey, Klaus i dr. Natural Language Understanding Using Statistical Machine Translation. // Lehrstuhl für Informatik VI, 2001, str. 2. URL: [https://www.researchgate.net/publication/2371092\\_Natural\\_Language\\_Understanding\\_Using\\_Statistical\\_Machine\\_Translation](https://www.researchgate.net/publication/2371092_Natural_Language_Understanding_Using_Statistical_Machine_Translation) (2019-09-03)

<sup>40</sup> Roman, Kaia. Natural Language Understanding. // Twilio. URL: <https://www.twilio.com/docs/glossary/what-is-natural-language-understanding> (2019-09-03)

<sup>41</sup> Natural Language Understanding (NLU). // Techopedia. URL: <https://www.techopedia.com/definition/33013/natural-language-understanding-nlu> (2019-09-03)

krovni je pojam za objašnjenje čitavog procesa pretvaranja nestrukturiranih podataka u strukturirane podatke. NLP pomaže tehnologiji da se uključi u komunikaciju koristeći prirodni jezik. Kao rezultat toga, ljudi su došli u mogućnost uspostavljanja razgovora s virtualnom tehnologijom kako bi izvršili zadatke i odgovorili na pitanja.<sup>42</sup> Razumijevanje prirodnog jezika koristi algoritme za pretvorbu ljudskog govora u strukturiranu ontologiju. Glavni pokretač NLU-a je stvaranje robota za razgovor i čavljanje koji mogu učinkovito komunicirati s javnošću bez potrebe za njihovo nadziranje pri radu s ljudima. Primjeri proizvoda koji koriste razumijevanje prirodnog jezika su:

- Appleov *Siri*,
- Amazonova *Alexa*,
- Microsoftova *Cortana* ili
- razni Googleovi pomoćnici koji obavljaju posao razumijevanja prirodnog jezika u kontekstu slušanja i dešifriranja korisnikovog unosa, odnosno zahtjeva.

Sličan program za razumijevanje prirodnog jezika ugrađen je i u Amazonov *Lex*, korporativni servis za izgradnju platformi strojnog učenja. Razumijevanjem primjene NLU-a u ove aplikacije, primjećuje se kako razumijevanje prirodnog jezika uključuje i razumijevanje unosa jezika.<sup>43</sup> Obrada prirodnog jezika i njegovo razumijevanje osnovne su grane umjetne inteligencije koje se bave interakcijom stroja i čovjeka te je preostalo opisati još proces pretvaranja strukturiranih podataka u ljudski jezik, čime se bavi generiranje prirodnog jezika.

### 3.6. Generiranje prirodnog jezika

Prema Search Enterprise AI-ju, generiranje prirodnog jezika (*Natural Language Generation*) proces je programske podrške koji strukturirane podatke pretvara u prirodni jezik. NLG je povezan s računalnom lingvistikom (*Computational Linguistics*), obradom prirodnog jezika (*Natural Language Processing*) te razumijevanjem prirodnog jezika (*Natural Language Understanding*), područjima umjetne inteligencije koje se bave interakcijom čovjek-stroj i stroj-

---

<sup>42</sup> Natural Language Understanding: What is it and how is it different from NLP. // Expert System. URL: <https://www.expertsystem.com/natural-language-understanding-different-nlp/> (2019-09-03)

<sup>43</sup> Natural Language Understanding (NLU). // SearchEnterpriseAI. URL: <https://searchenterpriseai.techtarget.com/definition/natural-language-understanding-NLU> (2019-09-03)

čovjek, a koja su opisana u prethodnim poglavljima. Generiranje prirodnog jezika može se koristiti za izradu sadržaja dugačkog oblika koje koriste organizacije čiji je posao stvaranje automatizacijski prilagođenih izvješća, kao i za izradu prilagođenih sadržaja za mrežna mjesta ili mobilne aplikacije. NLG istraživanje često se usredotočuje na izgradnju računalnih programa koji podatkovnim točkama pružaju kontekst. Sofisticirana NLG programska podrška ima mogućnost rudarenja velikom količinom numeričkih podataka, prepoznavanje obrazaca i dijeljenja tih podataka na način koji je ljudima lako razumjeti. Brzina NLG programske podrške posebno je korisna za stvaranje vijesti i drugih informativnih sadržaja koji se oslanjaju na što brže pružanje informacija korisnicima. Jedna od vrlina NLG-a jest mogućnost da se rezultati generiranog teksta mogu objavljivati doslovno kao mrežni sadržaji. Sustavi za generiranje prirodnog jezika generiraju tekstove na engleskom ili drugim ljudskim jezicima iz podataka dostupnih na računalu.<sup>44</sup> Iz tehničke perspektive gotovo se svi primijenjeni NLG sustavi izvode slijedeći tri osnovna zadatka:

- određivanje sadržaja (određivanje informacije koja će biti prenesena korisniku) i planiranje teksta (kako bi te informacije trebale biti strukturirane),
- planiranje rečenica (određivanje kako će se informacije podijeliti između pojedinih rečenica i odlomaka) te
- realizacija (stvaranje pojedinačnih rečenica na gramatički ispravan način). Određivanje sadržaja i planiranje teksta obavljaju se istovremeno u većini primijenjenih NLG sustava.

Ovi se zadaci mogu obaviti na više različitih razina sofisticiranosti. Jedan od najjednostavnijih (i najčešćih) pristupa je pisanje "teško kodiranog" sadržaja ili planera teksta u standardnom programskom jeziku kao što je C++. Ovakav sustav može imati manjak fleksibilnosti, ali ako stvoreni tekst ima standardiziran sadržaj i strukturu, onda to može biti najučinkovitiji način za izvršavanje tih zadataka. Zadatak planiranja rečenica uključuje združivanje dviju ili više pojedinačnih rečenica, korištenje zamjenica i prijedloga što doprinosi tome da tekst izgleda kao da ga je napisao čovjek. Planiranje rečenica je važno ukoliko se želi da tekst bude koherentan i lagan za čitanje, posebice ako treba izgledati kao da ga je napisao čovjek. Na kraju, realizacija je zadatak koji generira pojedinačne rečenice. Ono treba poštivati sva gramatička, morfološka i ostala jezična pravila kao što je korištenje točki na kraju rečenica, korištenje zamjenica, razlikovanje jednine od množine i slično.<sup>45</sup> S generiranjem prirodnog jezika kao granom umjetne inteligencije koja se bavi

---

<sup>44</sup> Natural Language Generation (NLG). // SearchEnterpriseAI. URL:

<https://searchenterpriseai.techtarget.com/definition/natural-language-generation-NLG> (2019-08-29)

<sup>45</sup> Reiter, Ehud. Building Natural Language Systems, 1996. URL: <https://arxiv.org/pdf/cmp-lg/9605002.pdf> (2019-08-29)



interakcijom stroja i čovjeka, završeno je navođenje i opisivanje razvojnih preduvjeta pomoću kojih strojno autorstvo funkcionira, a u nastavku slijedi opis, definiranje i navođenje konkretnih primjera generatora teksta i prijevoda.

#### 4. Generatori teksta

Uzimajući u obzir sve navedene razvojne preduvjete strojnog autorstva koji omogućuju razvoj generatora teksta, u nastavku teksta slijedi opis konkretnih primjera aplikacija za generiranje teksta. Desetljećima se strojevi bore sa suptilnostima ljudskog jezika, pa čak i nedavni razvoj dubokog učenja, koji se temelji na velikim podacima i poboljšanim procesorima, nije uspio razbiti taj kognitivni izazov. No, nove metode za analizu teksta, koje su razvile gigantske svjetske tvrtke poput Googlea i OpenAI-ja, kao i neovisni istraživači, otključavaju dosad nepoznate „talente“, odnosno mogućnosti i sposobnosti koje računala zasigurno posjeduju. OpenAI je tvrtka iz San Francisca, Kalifornije u Sjedinjenim Američkim Državama osnovana 2015. godine koja se bavi istraživanjem umjetne inteligencije koja otkriva i provodi put do sigurne umjetne opće inteligencije. Istraživači OpenAI-ja proveli su test za strojno generiranje teksta kada je njihov program jezičnog modeliranja napisao uvjerljiv esej na temu s kojom se oni sami nisu slagali. Testirali su novi sustav umjetne inteligencije ubacivanjem tekstualnih uputa u program, dovodeći ga do stvaranja potpuno izmišljenih rečenica i odlomaka u tekstu. Nakon toga su tražili od računala da argumentira svoje teze i zaključke iznesene u eseju na temu *Zašto je recikliranje loše za čovječanstvo?* za koje su oni sami smatrali da su nevaljani. Istraživači OpenAI-ja razvili su algoritam nazvan GPT-2, a odlikuje ga funkcija poznata kao modeliranje jezika koja testira sposobnost programa da predvidi sljedeću riječ u danoj rečenici. Ovaj algoritam može napisati cijeli „izmišljeni“ članak ako mu se da samo naslov članka, a osim toga navest će i izmišljene citate za članak. Također, ovaj algoritam može pisati i *fan-fiction*. Iako je GPT-2 vrlo fluentan i gramatički besprijekoran pri stvaranju rečenica, njegova najveća odlika je fleksibilnost. GPT-2 je obučen za modeliranje jezika uzimanjem velikog broja članaka, blogova i mrežnih mjesta kao uzorak pri modeliranju jezika. Koristeći samo te podatke, bez ispravaka i preinaka inženjera OpenAI-ja, postigao je vrhunske rezultate na brojnim nevidljivim jezičnim testovima, što je postignuće poznato kao „učenje bez pokušaja“. Osim ovoga, GPT-2 može izvršavati i ostale zadatke vezane za generiranje teksta kao što su prevođenje teksta s jednog jezika na drugi,

sažimanje dugih članaka te odgovaranje na trivijalna pitanja.<sup>46</sup> Praktični primjeri aplikacija generatora teksta su:

- dohvaćanje dokumenata i aplikacije za grupiranje,
- izvlačenje znanja,
- automatsko sažimanje teksta,
- analiza osjećaja,
- roboti za čavrljanje i razgovorni agenti te
- korisnička sučelja prirodnog jezika.

Navedene aplikacije realiziraju se pomoću sustava u produkciji umjetne inteligencije te će se u nastavku opisati na koji način funkcionira. Isto tako navest će se opis svake od navedenih aplikacija za generiranje teksta, kako funkcioniraju te zašto su korisne.

#### 4.1. Sustavi u produkciji umjetne inteligencije

Prema Analytics India Magazineu, sustavi u produkciji mogu se definirati kao vrsta kognitivne arhitekture u kojoj se znanje prikazuje u obliku pravila. Ono je računalni program koji se obično koristi za pružanje nekog oblika umjetne inteligencije koji se uglavnom sastoji od skupa pravila o ponašanju umjetne inteligencije, ali i uključuje mehanizam potreban za praćenje tih pravila.<sup>47</sup> Glavne komponente sustavu u produkciji umjetne inteligencije jesu:

- globalna baza podataka - središnja struktura podataka koju koristi sustav u produkciji umjetne inteligencije,
- skup proizvodnih pravila – izvršavaju se na globalnoj bazi podataka; svako pravilo obično ima preduvjet kojega globalna baza podataka zadovoljava ili ne zadovoljava – ako je preduvjet zadovoljen pravilo bude zadovoljeno te primjena istoga mijenja bazu podataka, te
- sustav upravljanja – ono bira koje se primjenjivo pravilo treba primijeniti i zaustavlja računanje kada je ispunjen uvjet prekida u bazi podataka; ako se istovremeno želi aktivirati više pravila, sustav upravljanja rješava taj “sukob”.

---

<sup>46</sup> Vincent, James. OpenAI's new multitalented AI writes, translates, and slanders. // The Verge. URL: <https://www.theverge.com/2019/2/14/18224704/ai-machine-learning-language-models-read-write-openai-gpt2> (2019-08-30)

<sup>47</sup> F.R., Martin. What 's An Artificial Intelligence Production System? Here Are The Basics. // Analytics India Magazine. URL: <https://analyticsindiamag.com/ai-production-system-basic/> (2020-02-10)

Glavne značajke sustava u produkciji su:

- Jednostavnost (simplicity),
- Modularnost (modularity),
- Podesivost (modifiability) te
- Baza znanja (knowledge-intensive).

Struktura svake rečenice u sustavu u produkciji jedinstvena je i ujednačena jer koristi strukturu “if-then” rečenica koje predstavljaju situacije i njihove moguće ishode. Ta struktura pruža jednostavnost u predstavljanju znanja. Jednostavnost kao značajka sustava u produkciji poboljšava čitljivost proizvodnih pravila. Modularnost kao značajka odnosi se na proizvodno pravilo koje kodira znanje dostupno u zasebnim odjeljcima. Te informacije mogu se tretirati kao skup neovisnih činjenica koje se mogu dodavati ili brisati iz sustava bez da se njihovim brisanjem prouzroče štetne posljedice na cijeli sustav. Iduća značajka sustava u produkciji, podesivost, odnosi se na mogućnost promjene pravila u sustavu – ono najprije omogućuje izradu pravila u kosturnom obliku koja se zatim primjene ukoliko odgovaraju potrebama određene aplikacije. Na kraju, baza znanja sustava u produkciji pohranjuje čisto znanje te kao značajka ne sadrži nikakve podatke o upravljanju ili programiranju. Svako pravilo sustava u produkciji obično je napisano na engleskom jeziku, a problem semantike rješava sama struktura reprezentacije. Postoje četiri glavne klase sustava u produkciji umjetne inteligencije:

1. Monotoni sustav u produkciji (Monotonic Production System) - sustav u kojemu primjena pravila nikad ne sprječava kasniju primjenu drugog pravila nakon što se odabralo prvo primijenjeno pravilo,
2. Djelomično komutativni sustav u produkciji (Partially Commutative Production System) - vrsta sustava u kojemu primjena niza pravila pretvara stanje X u stanje Y, a zatim svaka permutacija onih pravila, koja su također dopuštena za primjenu, pretvara stanje X u stanje Y. Na primjer, dokazivanje teorema pripada ovoj vrsti sustava u produkciji umjetne inteligencije,
3. Nemonotoni sustav u produkciji (Non-Montonic Production System) - vrlo je važan s gledišta implementacije jer se može implementirati bez mogućnosti vraćanja na prethodna stanja kada se otkrije da se primijenilo pogrešno pravilo. Ono povećava efikasnost jer nije potrebno pratiti promjene u procesu pretraživanja te
4. Komutativni sustav u produkciji (Commutative Production System) - korisni su za rješavanje problema u kojima se događaju nepovratne promjene; u radu s ovakvim

sustavima redosljed izvođenja operacija vrlo je važan i stoga se moraju donijeti ispravne odluke odmah na početku rada.

Kao i svaki sustav, i sustav u produkciji ima svoje prednosti i nedostatke. Njegove glavne prednosti jesu:

- pružanje izvrsnih alata za strukturiranje programske podrške umjetne inteligencije,
- sustav je visoko modularan jer se pojedinačna pravila mogu neovisno jedno o drugom dodavati, uklanjati ili mijenjati,
- prirodno preslikavanje na podatke o državnim svemirskim istraživanjima,
- sustav koristi upravljanje temeljeno na uzorcima koje je fleksibilnije od algoritamske kontrole,
- pruža mogućnost heurističke kontrole pretraživanja,
- dobar je način za modeliranje inteligentnih strojeva te je
- vrlo koristan u realnom vremenu i aplikacijama.

S druge strane, njegovi glavni nedostaci jesu:

- Otežana analiza tijekom kontrole unutar samog sustava,
- U njemu su opisane operacije koje mogu biti izvršene u potrazi za rješavanjem problema,
- Postoji nedostatak učenja zbog sustava u produkciji temeljenog na pravilima koji ne pohranjuje rezultat problema za buduću upotrebu te
- Pravila sustava u produkciji ne bi trebala imati bilo kakvu funkciju “rješavanja sukoba” među pravilima jer kada se novo pravilo doda u bazu podataka, ono bi trebalo osigurati da nema sukoba s bilo kojim postojećim pravilom.<sup>48</sup>

Nakon što je u ovome odlomku opisan sustav u produkciji umjetne inteligencije, u nastavku teksta navest će se i opisati primjeri aplikacija za generiranje teksta koje se realiziraju upravo pomoću sustava u produkciji.

## 4.2. Dohvaćanje dokumenata i aplikacije za grupiranje

---

<sup>48</sup> Sayantini. What is Production System in Artificial Intelligence? // Edureka! . URL [https://www.edureka.co/blog/production-system-ai/ \(2020-02-10\)](https://www.edureka.co/blog/production-system-ai/ (2020-02-10))

Dohvaćanje informacija (Information retrieval) već je dugo jedna od središnjih tema informacijsko-komunikacijskih znanosti, a obuhvaća pretraživanje strukturiranih podataka koji se nalaze u relacijskim bazama podataka, kao i nestrukturiranih tekstualnih dokumenata. S obzirom da se nalazimo u dobu velike količine informacija (često nestrukturiranih), ovakve aplikacije izuzetno su korisne kako bi korisnik smanjio vrijeme potrebno za pronalazak potrebnih informacija. Isto tako, pomoću aplikacija za dohvaćanje dokumenta i aplikacija za grupiranje, olakšava se proces grupiranja i uređivanja informacija i dokumenata kako bi se kasnije mogli lakše pronalaziti. Kriteriji za pretraživanje za navedene vrste podataka nisu povezani jer je za strukturirane i nestrukturirane podatke često potrebno pretraživanje usmjereno prema sadržaju.<sup>49</sup> Tradicionalno dohvaćanje informacija imao je uobičajeni postupak – uglavnom se pojavljuje u obliku popisa knjiga u knjižnicama te u samim knjigama kao tablice sadržaja, indeksa itd. Ti popisi i tablice obično sadrže mali broj indeksa (npr. naslov, autor, podnaslov) zbog toga što je izrada i održavanje tih popisa bio dugotrajan, zahtjevan i iscrpljujući proces. Danas dohvaćanje informacija funkcionira sasvim drugačije. U modernim sustavima pretraživanja informacija postoji nekoliko modela koji predstavljaju informacije sadržane u velikoj zbirci tekstualnih dokumenata. Unutar dohvaćanja informacija, grupiranje dokumenata (Document clustering) ima nekoliko perspektivnih aplikacija koje se bave poboljšanjem učinkovitosti postupka pretraživanja dokumenata. Većina IR sustava temelji se na obrnutim indeksima koji za svaku ključnu riječ na jeziku pohranjuju popis dokumenata koji sadrže tu ključnu riječ. Grupiranje dokumenata je specifična tehnika za nenadziranu organizaciju dokumenata, automatsko izvlačenje određene teme i brzo pretraživanje informacija na tu temu. Ono je metoda grupiranja skupova apstraktnih objekata u kategorije usporedivih objekata. Grupiranje dokumenata postalo je vrlo važan oblik pretraživanja informacija pojavom *World Wide Web*-a zbog eksponencijalnog rasta dostupnih informacija u digitalnom obliku. U njemu su dostupne gotovo sve vrste željenih podataka (bibliografske zbirke, vijesti, softverske biblioteke, repozitoriji za multimediju, internetske enciklopedije itd.). Grupiranje dokumenata može pružiti strukturu za organiziranje velikih skupova teksta te njihovo učinkovito pregledavanje i pretraživanje. Grupiranje digitalnih dokumenata daje pristup korisnim podacima s internetskog sadržaja kao što su slike, tekst, zvuk, video, metapodaci i hiperveze. Ono je korisno kada je potrebno organizirati veliki broj dokumenata da bi im se lakše pristupilo. Također, korisno je i u istraživačkim analizama podataka te u podržavanju raznih aplikacija za obradu prirodnog jezika. Boolean-ov model za pronalaženje informacija jednostavan je model pretraživanja informacija zasnovan na teoriji skupa i Boolean-ovoj algebri. U svojoj osnovi,

---

<sup>49</sup> Schubert, Lenhart. Computational Linguistics. The Stanford Encyclopedia of Philosophy, Spring 2019 Edition. URL: <https://plato.stanford.edu/archives/spr2019/entries/computational-linguistics> (2019-09-04)

Boolean-ovo predstavljanje dokumenta je skup pojmova koji se nalaze unutar određenog dokumenta te koji se izvlače iz njega pomoću različitih metoda, kao npr. filtriranje.<sup>50</sup> Često korištena metoda za dohvaćanje relevantnih dokumenata je takozvana *Vector Space Model* metoda. Ovaj model pohranjuje popise parova (ključne riječi, često korištene riječi) za svaki dokument u skupu podataka. To omogućuje skupu dokumenata da se vizualiziraju kao točke u “dimenzijskom prostoru”, gdje je  $n$  ukupan broj ključnih riječi u jeziku. Aplikacije grupiranja dokumenata u dohvaćanju informacija uključuju pronalaženje sličnih dokumenata, grupiranje rezultata te brže i učinkovitije pretraživanje informacija.<sup>51</sup> Grupiranje dokumenata pokazalo se posebno korisnim u aplikacijama za sažimanje teksta, kategorizaciju teksta, pregledavanje dokumenata i filtriranje vijesti. Osim toga, grupiranje dokumenata koristi se i u drugim područjima kao što su biološka i medicinska istraživanja i epidemiologija, istraživanje tržišta, obrazovna istraživanja, analiza društvenih mreža, geološka analiza itd.<sup>52</sup>

Dohvaćanje informacija (Information retrieval) već je dugo jedna od središnjih tema informacijsko-komunikacijskih znanosti, a obuhvaća pretraživanje strukturiranih podataka koji se nalaze u relacijskim bazama podataka, kao i nestrukturiranih tekstualnih dokumenata. S obzirom da se nalazimo u dobu velike količine informacija (često nestrukturiranih), ovakve aplikacije izuzetno su korisne kako bi korisnik smanjio vrijeme potrebno za pronalazak potrebnih informacija. Isto tako, pomoću aplikacija za dohvaćanje dokumenta i aplikacija za grupiranje, olakšava se proces grupiranja i uređivanja informacija i dokumenata kako bi se kasnije mogli lakše pronalaziti. Kriteriji za pretraživanje za navedene vrste podataka nisu povezani jer je za strukturirane i nestrukturirane podatke često potrebno pretraživanje usmjereno prema sadržaju.<sup>53</sup> Tradicionalno dohvaćanje informacija imalo je uobičajeni postupak – uglavnom se pojavljuje u obliku popisa knjiga u knjižnicama te u samim knjigama kao tablice sadržaja, indeksa itd. Ti popisi i tablice obično sadrže mali broj indeksa (npr. naslov, autor, podnaslov) zbog toga što je izrada i održavanje tih popisa bio dugotrajan, zahtjevan i iscrpljujući proces. Danas dohvaćanje

---

<sup>50</sup> P.Prabhu, P. Document Clustering for Information Retrieval: A General Perspective, 2011. URL: [https://www.researchgate.net/publication/256041972\\_Document\\_Clustering\\_for\\_Information\\_Retrieval\\_-\\_A\\_General\\_Perspective](https://www.researchgate.net/publication/256041972_Document_Clustering_for_Information_Retrieval_-_A_General_Perspective) (2019-09-04)

<sup>51</sup> Davis, Nathan S. An Analysis of Document Retrieval and Clustering Using an Effective Semantic Distance Measure, 2008. URL: <https://scholarsarchive.byu.edu/cgi/viewcontent.cgi?article=2599&context=etd> (2019-09-04)

<sup>52</sup> Schubert, Lenhart. Computational Linguistics. The Stanford Encyclopedia of Philosophy, Spring 2019 Edition. URL: <https://plato.stanford.edu/archives/spr2019/entries/computational-linguistics> (2019-09-04)

<sup>53</sup> Schubert, Lenhart. Computational Linguistics. The Stanford Encyclopedia of Philosophy, Spring 2019 Edition. URL: <https://plato.stanford.edu/archives/spr2019/entries/computational-linguistics> (2019-09-04)

informacija funkcionira sasvim drugačije. U modernim sustavima pretraživanja informacija postoji nekoliko modela koji predstavljaju informacije sadržane u velikoj zbirki tekstualnih dokumenata. Unutar dohvaćanja informacija, grupiranje dokumenata (Document clustering) ima nekoliko perspektivnih aplikacija koje se bave poboljšanjem učinkovitosti postupka pretraživanja dokumenata. Većina IR-sustava temelji se na obrnutim indeksima koji za svaku ključnu riječ na jeziku pohranjuju popis dokumenata koji sadrže tu ključnu riječ. Grupiranje dokumenata specifična je tehnika za nenadziranu organizaciju dokumenata, automatsko izvlačenje određene teme i brzo pretraživanje informacija na tu temu. Ono je metoda grupiranja skupova apstraktnih objekata u kategorije usporedivih objekata. Grupiranje dokumenata postalo je vrlo važan oblik pretraživanja informacija pojavom *World Wide Weba* zbog eksponencijalnog rasta dostupnih informacija u digitalnom obliku. U njemu su dostupne gotovo sve vrste željenih podataka (bibliografske zbirke, vijesti, biblioteke programske podrške, repozitoriji za multimedije, internetske enciklopedije itd.). Grupiranje dokumenata može pružiti strukturu za organiziranje velikih skupova teksta te njihovo učinkovito pregledavanje i pretraživanje. Grupiranje digitalnih dokumenata daje pristup korisnim podacima s internetskog sadržaja kao što su slike, tekst, zvuk, video, meta-podaci i hiperveze. Ono je korisno kada je potrebno organizirati veliki broj dokumenata da bi im se lakše pristupilo. Također, korisno je i u istraživačkim analizama podataka te u podržavanju raznih aplikacija za obradu prirodnog jezika. Booleanov model za pronalaženje informacija jednostavan je model pretraživanja informacija zasnovan na teoriji skupa i Booleanovoj algebri. U svojoj osnovi, Booleanovo predstavljanje dokumenta skup je pojmova koji se nalaze unutar određenog dokumenta, a koji se izvlače iz njega pomoću različitih metoda, kao npr. filtriranje.<sup>54</sup> Često korištena metoda za dohvaćanje relevantnih dokumenata je takozvana *Vector Space Model* metoda. Ovaj model pohranjuje popise parova (ključne riječi, često korištene riječi) za svaki dokument u skupu podataka. To omogućuje skupu dokumenata da se vizualiziraju kao točke u “dimenzijskom prostoru”, gdje je  $n$  ukupan broj ključnih riječi u jeziku. Aplikacije grupiranja dokumenata u dohvaćanju informacija uključuju pronalaženje sličnih dokumenata, grupiranje rezultata te brže i učinkovitije pretraživanje informacija.<sup>55</sup> Grupiranje dokumenata pokazalo se posebno korisnim u aplikacijama za sažimanje teksta, kategorizaciju teksta, pregledavanje dokumenata i filtriranje vijesti. Osim toga, grupiranje dokumenata koristi se i u

---

<sup>54</sup> P.Prabhu, P. Document Clustering for Information Retrieval: A General Perspective, 2011. URL: [https://www.researchgate.net/publication/256041972\\_Document\\_Clustering\\_for\\_Information\\_Retrieval\\_-\\_A\\_General\\_Perspective](https://www.researchgate.net/publication/256041972_Document_Clustering_for_Information_Retrieval_-_A_General_Perspective) (2019-09-04)

<sup>55</sup> Davis, Nathan S. An Analysis of Document Retrieval and Clustering Using an Effective Semantic Distance Measure, 2008. URL: <https://scholarsarchive.byu.edu/cgi/viewcontent.cgi?article=2599&context=etd> (2019-09-04)

drugim područjima kao što su biološka i medicinska istraživanja i epidemiologija, istraživanje tržišta, obrazovna istraživanja, analiza društvenih mreža, geološka analiza itd.<sup>56</sup>

### 4.3. Izvlačenje znanja

Prema autoru članka *Automatic Information Extraction*, Hamishu, Cunninghamu, izvlačenje znanja (Knowledge extraction) jest stvaranje znanja iz strukturiranih (relacijske baze podataka, XML) i nestrukturiranih (tekst, dokument, slika) izvora podataka. Dobiveno znanje mora biti u strojno čitljivom obliku i mora predstavljati znanje na način koji olakšava učenje.<sup>57</sup> Izvlačenje znanja i izrada sažetaka iz nestrukturiranog teksta sve su važnije primjene s obzirom na mnoštvo dokumenata objavljenih u medijima, organizacijskim tvrtkama ili pojedinačno. Taj neprekidni niz informacija otežava pregledavanje relevantnih izvora za određene informacijske potrebe. Iako je metodički slično izvlačenju informacija (Information extraction) i skladištenju podataka (Data warehouse), glavni kriterij izvlačenja znanja jest dobivanje rezultata koji nadilazi stvaranje strukturiranih informacija ili pretvorba u relacijsku shemu podataka. Takav pristup zahtijeva ili ponovnu upotrebu postojećeg formalnog znanja (ponovna uporaba identifikatora ili ontologija) ili stvaranje sheme na temelju izvornih podataka. Jedna od najčešće korištenih metoda za izvlačenje znanja oslanja se na upotrebi obrazaca ekstrakcije koji su osmišljeni tako da odgovaraju vrstama uobičajenih jezičnih obrazaca koje autori obično koriste pri pružanju informacija. Na primjer, dobivanje informacija o tvrtkama može se dobiti pretraživanjem po ključnim riječima kao što su *Corp., sa sjedištem u, s godišnjim prihodom* i slično. Obrasci izvlačenja znanja obično se mogu shvatiti kao ciljanje određenih atributa u unaprijed određenim okvirnim vrijednostima (npr. okvirni podaci o tvrtkama). Razlika između izvlačenja znanja i automatskog sažimanja teksta ovisi o tekstu na koji se navedeni sustav, zasnovan na uzorku, primjenjuje. Ako se sve tražene informacije objedine u jedan prošireni tekstualni segment, tada se dobiveno znanje može smatrati kao sažetak teksta. S druge strane, ako se umjesto toga podaci selektivno izvuku iz različitih rečenica unutar velikog skupa teksta, pri čemu se većina informacija u tekstu zanemaruje jer se smatra nebitnom za traženu informacijsku potrebu, tada bi se ta aktivnost sustava smatrala kao izvlačenje informacija, a ne kao sažimanje teksta. Kada se za

---

<sup>56</sup> Schubert, Lenhart. Computational Linguistics. The Stanford Encyclopedia of Philosophy, Spring 2019 Edition. URL: <https://plato.stanford.edu/archives/spr2019/entries/computational-linguistics> (2019-09-04)

<sup>57</sup> Cunningham, Hamish. Automatic Information Extraction, 2004. URL: <https://gate.ac.uk/sale/ell2/ie/main.pdf> (2019-09-05)



određeni dokument koji treba sažeti ne može pretpostaviti pripada li nekoj unaprijed određenoj kategoriji, izvlačenje znanja se obično izvodi koristeći takozvane “središnje rečenice”. Rečenica se smatra “središnjom” ukoliko su mnoge druge rečenice u tekstu slične njoj, odnosno kada većina drugih rečenica u tekstu u sebi sadrži riječi koje sadrži središnja rečenica. Međutim, samo vraćanje dijelova središnjih rečenica u cjelini neće rezultirati odgovarajućim sažetkom. Takve rečenice u sebi mogu sadržavati nerazriješene zamjenice ili druge izraze koji se odnose na njih i čije značenje treba pronaći u rečenicama koje nisu “središnje”. Zbog toga se trebaju primijeniti heurističke tehnike obrade teksta, a izvučene informacije moraju se tečno i dosljedno kombinirati. Na primjer, odgovarajuće izvlačenje znanja u rečenici: “Tornado je odnio krov lokalne seoske kuće i smanjio zidove i sadržaj kuće na ruševine.”, moglo bi izgledati kao rečenica: “Tornado je uništio lokalnu seosku kuću.”.<sup>58</sup> Jedan od poznatih alata za izvlačenje znanja je *Text-To-Knowledge (T2K)*. Ono je platforma za automatsko izvlačenje jezičnih i specijaliziranih informacija iz zbirki dokumenata. T2K pruža strukturiranu organizaciju izdvojenog znanja i indeksira analizirane tekstove u odnosu na izvučene informacije. Oslanja se na alatima za obradu prirodnog jezika, statističke analize teksta i strojnom učenju koji su dinamički integrirani kako bi pružili precizan prikaz jezičnih informacija i sadržaja na engleskom i talijanskom jeziku.<sup>59</sup>

#### 4.4. Automatsko sažimanje teksta

Svijet se trenutno nalazi u dobu u kojemu količina tekstualnog materijala svakoga dana sve više raste. Sami Internet koji se sastoji od nebrojeno mnogo mrežnih stranica, članaka, blogova i ostalih vrsta digitalnih dokumenata, sadrži ogromnu količinu nestrukturiranih i neograničenih podataka koji nisu organizirani u tradicionalne baze podataka. Zbog toga postoji velika potreba smanjiti veliki dio ovih podataka na kraće i preciznije sažetke, koji bilježe najrelevantnije informacije, kako bi ih korisnici učinkovitije pregledavali i provjerili sadrže li dokumenti velikog opsega informacije koje traže. Automatsko sažimanje teksta jest postupak stvaranja kratke i koherentne verzije dužeg dokumenta. Cilj automatskog sažimanja teksta jest razviti tehnike pomoću kojih stroj može generirati sažetak koji uspješno oponaša sažetke koje je uradio čovjek. Nije dovoljno samo generirati riječi i izraze koji obuhvaćaju suštinu izvornog dokumenta već sažetak treba biti točan i koherentan uz očuvanje ključnih podataka sažetog teksta te treba izgledati

---

<sup>58</sup> Schubert, Lenhart. Computational Linguistics. The Stanford Encyclopedia of Philosophy, Spring 2019 Edition. URL: <https://plato.stanford.edu/archives/spr2019/entries/computational-linguistics> (2019-09-04)

<sup>59</sup> Dell’Orletta F., Venturi G., Cimino A., Montemagni S. (2014) “[T2K: a System for Automatically Extracting and Organizing Knowledge from Texts](#)”. In Proceedings of 9th Edition of International Conference on Language Resources and Evaluation (LREC 2014), 26-31 May, Reykjavik, Iceland.

kao novi samostalni dokument. Čovjek sam po sebi nije u mogućnosti kreirati vlastite sažetke teksta jer bi to iziskivalo previše vremena te zbog toga postoji velika potreba za automatskim metodama koje će obaviti taj zahtjevni posao. Autori knjige *Automatic Text Summarization* navode 6 razloga zašto su danas potrebni alati za automatsko sažimanje teksta. Prvi razlog jest taj da sažeci smanjuju vrijeme čitanja teksta što je svakako izuzetno potrebno s obzirom na “pretrpanost” informacijama s kojima se ljudi susreću zadnjih nekoliko godina. Drugi razlog jest da tijekom istraživanja pojedinog dokumenta sažeci olakšavaju postupak odabira dokumenta kao relevantnog, potrebnog i korisnog za zadovoljavanje informacijskih potreba. Kao treći razlog autori navode da automatsko sažimanje teksta poboljšava učinkovitost indeksiranja, dok za četvrti razlog ističu da su algoritmi automatskog sažimanja teksta objektivniji od sažetaka koje napravi čovjek. Za peti razlog navode da su personalizirani sažeci korisni u sustavima odgovaranja na pitanja jer pružaju personalizirane informacije te za zadnji razlog navode da korištenje automatiziranih ili polu-automatiziranih sustava sažimanja teksta omogućuje komercijalnim apstraktnim uslugama povećanje broja tekstova koje mogu obrađivati. Različiti načini sažimanja teksta mogu se općenito kategorizirati na temelju vrste unosa (jedan ili više dokumenata), svrhe (općenite, specijalizirane i upitne) te po vrsti izlaza (ekstraktivni ili apstraktivni). Dva su glavna pristupa automatskom sažimanju teksta: ekstraktivna metoda i apstraktivna metoda. Ekstraktivno sažimanje teksta uključuje identificiranje važnih dijelova teksta iz izvornog dokumenta kako bi se napravio potpuno novi dokument. Tehnike koje koristi uključuju rangiranje relevantnosti izraza kako bi se odabrale samo one najrelevantnije. Apstraktno sažimanje teksta podrazumijeva generiranje potpuno novih fraza i rečenica kako bi se stvorio novi smisleni dokument. Ovaj pristup je kompliciraniji, ali i pristup kojim se koriste ljudi pri sažimanju određenog teksta. Apstraktivni pristup koristi klasične metode koje odabiru i sažimaju sadržaj iz izvornog dokumenta. Zbog jednostavnijeg načina funkcioniranja, ekstraktivne metode pokazale su se kao najuspješniji pristup za automatsko sažimanje teksta. No, nedavno su metode dubokog učenja pokazale obećavajuće rezultate za automatsko sažimanje teksta. Ove metode mogu se smatrati apstraktnim metodama te su u stanju generirati potpuno novi opis pomoću učenja modela generiranja jezika specifičnog za izvorne dokumente. Nedavni uspjeh modela *sequence-to-sequence*, u kojemu ponavljajuće neuronske mreže (*Recurrent Neural Network*) i čitaju i slobodno generiraju tekst, potpomogao je održivosti apstraktnih metoda za automatsko sažimanje teksta.<sup>60</sup> Primjeri automatski generiranih sažetih tekstova su:

---

<sup>60</sup> Brownlee, Jason. A Gentle Introduction to Text Summarization. // Machine Learning Mastery. URL: <https://machinelearningmastery.com/gentle-introduction-text-summarization/> (2019-08-27)

- bilješke za studente,
- pregledi filmova,
- recenzije knjiga,
- biografije,
- razni bilteni vremenskih prognoza i izvješća na burzama,
- kronologije istaknutih događaja itd.

#### 4.5. Analiza osjećaja

Prema Lexalyticsu, analiza osjećaja (Sentiment Analysis) poznata je i kao rudarenje mišljenja (Opinion mining) i odnosi se na upotrebu obrade prirodnog jezika, analize teksta, računalne lingvistike i biometrije za sustavno identificiranje, izdvajanje i proučavanje afektivnih tvrdnji i subjektivnih informacija. Ove aplikacije danas pronalaze svoju svrhu u raznim modernim tvrtkama, koje imaju potrebu kontinuirano poboljšavati svoje poslovanje, omogućavajući im provođenje raznih testova i analiza nad svojim korisnicima kako bi lakše saznali njihove potrebe i mišljenje te u skladu s time nastavili razvijati svoje proizvode i usluge. Time tvrtke mogu korisniku pružiti ono što mu treba te u skladu s time svoje poslovanje učiniti učinkovitijim i unosnijim. Aplikacije za analizu osjećaja grade sustave koji pokušavaju identificirati i izvući subjektivna mišljenja iz teksta, kombinirajući obradu prirodnog jezika i tehnike strojnog učenja, kako bi procijenile autorove osjećaje o entitetima, temama i kategorijama unutar rečenice ili fraze s Interneta.<sup>61</sup> Obično, osim identificiranja mišljenja korisnika o određenoj temi, sustavi za analizu osjećaja izdvajaju attribute izraza kao što su polaritet (iznosi li korisnik pozitivno, negativno ili neutralno mišljenje), predmet (tema o kojoj se priča) i nositelj mišljenja (osoba ili subjekt koji izražava svoje mišljenje). Trenutno je analiza osjećaja tema od velikog interesa i u neprestanome razvoju s obzirom na to da ima mnogo praktičnih primjena (aplikacija). Budući da informacije na Internetu neprestano rastu na raznim mrežnim mjestima za recenziranje, forumima, blogovima i društvenim medijima, samim time dostupan je veliki broj tekstova u kojima subjekt iznosi svoje mišljenje. Pomoću sustava analize osjećaja te se nestrukturirane informacije mogu automatski pretvoriti u strukturirane podatke javnog mišljenja o proizvodima, uslugama, robnim markama, politici ili bilo kojoj drugoj temi u kojoj ljudi mogu izraziti svoje mišljenje. Analiza osjećaja

---

<sup>61</sup> Sentiment Analysis Explained. // Lexalytics. URL: <https://www.lexalytics.com/technology/sentiment-analysis> (2019.09-05)

omogućuje organizacijama praćenje popularnosti i percepcije o proizvodu ili usluzi, ugledu tvrtke i slično.<sup>62</sup> Postoji više različitih alata za analizu osjećaja koji se fokusiraju na proučavanje različitih atributa kao što su:

- polaritet, sustavi koji otkrivaju raspoloženja i osjećaje (ljuti, sretni, tužni),
- sustavi koji otkrivaju namjere (zainteresirani, nezainteresirani).

Također, postoji i više različitih metoda i algoritama za implementaciju sustava analize osjećaja kao što su:

- sustavi temeljeni na pravilima koji provode analizu osjećaja pomoću skupa ručno izrađenih pravila,
- automatski sustavi koji se oslanjaju na tehnike strojnog učenja kako bi se omogućilo učenje iz podataka te
- hibridni sustavi koji kombiniraju pristup temeljen na pravilima i automatski pristup.

S obzirom na spomenutu veliku količinu nestrukturiranih podataka (za koje se procjenjuje da ih je oko 80%), sustavi za analizu osjećaja omogućuju tvrtkama razumijevanje tih podataka automatiziranjem poslovnih procesa dobivanjem učinkovitih uvida te uštede velikog broja sati koje bi utrošili na ručnu obradu tih podataka. Drugim riječima, sustavi za analizu osjećaja čine organizacije učinkovitijima. Neke od prednosti ovih sustava jesu:

- skalabilnost,
- analiza u stvarnom vremenu (Real-time analysis) i
- dosljedni kriteriji.

Skalabilnost omogućuje obradu velike količine podataka na učinkovit način kao što su tisuće različitih "tweetova", razgovora s korisničkom podrškom ili osvrta kupaca o proizvodu ili usluzi. Analiza u stvarnom vremenu pomaže prepoznati važne informacije o trenutnoj svijesti korisnika o proizvodima i uslugama te prepoznavanje trenutnih potreba kupaca na određenom tržištu. Sustavi za analizu osjećaja sposobni su prepoznati postoji li ljutiti korisnik koji je na rubu prekida korištenja proizvoda ili usluge te time omogućuje organizaciji brzu reakciju na takve događaje i poduzimanje radnji kako bi tog korisnika zadržali. S obzirom da ljudi ne mogu imati zajedničko mišljenje za određenu temu zbog više različitih subjektivnih mišljenja, korištenjem centraliziranog

---

<sup>62</sup> Sentiment Analysis. // Techopedia. URL: <https://www.techopedia.com/definition/29695/sentiment-analysis> (2019-09-05)

sustava analize osjećaja, tvrtke mogu primijeniti jedinstvene kriterije koji će evaluirati dobivene podatke korisničkih mišljenja. To dovodi do smanjenja pogrešaka i poboljšanju dosljednosti podataka.<sup>63</sup> Postoji mnogo različitih alata za analizu osjećaja, a neki od njih jesu:

- *Quick Search* (daje trenutni pregled proizvoda ili usluge na mreži pretraživanjem društvenih medija),
- *RapidMiner* (podatkovna znanstvena platforma koja koristi rudarenje teksta kako bi pomogla organizacijama izvršavanje analize osjećaja o njihovim proizvodima ili uslugama),
- *NCSU Tweet Visualizer* (koristi se za analizu osjećaja na Twitter društvenoj mreži),
- *Sentiment Analyzer* (alat koji koristi računalnu lingvistiku i rudarenje teksta za otkrivanje osjećaja koji se kriju u tekstu) i mnogi drugi.<sup>64</sup>

Na primjer, poznata aplikacija usluge prijevoza Uber vrlo lako može napraviti analizu osjećaja korisnika o njihovim uslugama izvlačenjem informacija iz društvenih mreža, kao što su Facebook i Twitter ili čitanjem komentara članaka na raznim portalima te saznati što korisnici misle o cijeni, usluzi, načinima plaćanja, sigurnosti i ostalim parametrima njihove usluge. Kao primjer upotrebe analize osjećaja u politici, može se navesti 2012. godina kada je administracija Barracka Obama koristila alate za analizu osjećaja kako bi dobili uvid o tome što ljudi misle o novoj najavljenoj polici zaštite osobnih podataka kako bi, u skladu s dobivenim informacijama, zaključili kako trebaju djelovati u kampanji kada je u pitanju ta tema.<sup>65</sup>

#### 4.6. Roboti za čavrljanje i razgovorni agenti

Prema Expert Systemu, roboti za čavrljanje odnose se na program umjetne inteligencije koji simulira razgovor s korisnikom na prirodnom jeziku putem aplikacija za razmjenu poruka, mrežnih stranica, mobilnih aplikacija ili telefona. Oni simuliraju interaktivni ljudski razgovor koristeći unaprijed izračunate korisničke fraze i slušne ili tekstualne signale. Ovakve aplikacije izuzetno su korisne za velike IT tvrtke, kao što su Google ili Microsoft, pomoću kojih mogu

---

<sup>63</sup> Sentiment Analysis: Nearly Everything You Need to Know. // MonkeyLearn. URL: <https://monkeylearn.com/sentiment-analysis/> (2019-09-05)

<sup>64</sup> Meg. The best sentiment analysis tools. // TalkWalker. URL: <https://www.talkwalker.com/blog/best-sentiment-analysis-tools#> (2019-09-06)

<sup>65</sup> What is Sentiment Analysis and How to Do It Yourself. // Brand24. URL: <https://brand24.com/blog/sentiment-analysis/> (2019-09-06)

korisniku pružiti potrebne informacije za rješavanje određenih probleme bez potrebe za izravnom komunikacijom. Kao i gotovo sve komponente obrade prirodnog jezika i arhitektura robota za čavrljanje podijeljena je u dvije klase – sustavi temeljeni na pravilima i sustavi temeljeni na tijelu. Sustavi temeljeni na pravilima uključuju rane sustave kao što su ELIZA i PARRY. Današnji roboti za čavrljanje smatraju se potomcima ELIZE. ELIZA je program kojega je izumio Joseph Weizenbaum i koji minimalno ovisi o lingvističkoj ili kognitivnoj teoriji, namijenjen za oponašanje psihijatra. ELIZA se oslanjala na prilagođavanje korisničkih unosa na spremljenim uzorcima i vraćala jedan od skupa izlaznih predložaka povezanih s podudarnim uzorkom izlaza, instanciran s materijalom iz izlaza. S druge strane, sustavi temeljeni na tijelu rudare velike skupove podataka razgovora na relaciji *čovjek-čovjek* pomoću pretraživanja informacija ili korištenjem paradigme strojnog prevođenja ,poput neurološke mreže *sequence-to-sequence*, kako bi naučilo mapiranje korisničkog izraza u sustav za odgovore.<sup>66</sup> Roboti za čavrljanje često se opisuju kao jedan od najnaprednijih i najperspektivnijih načina interakcije ljudi i strojeva. S tehnološkog stajališta predstavlja prirodnu evoluciju sustava odgovora na pitanja putem obrade prirodnog jezika. Formuliranje odgovora na korisnikova pitanja pomoću prirodnog jezika jedan je od najtipičnijih primjera obrade prirodnog jezika koji se primjenjuje u raznim aplikacijama. Sposobnost prepoznavanja korisnikove namjere i izvlačenje podataka i relevantnih entiteta sadržanih u korisničkom zahtjevu, prvi je uvjet i najbitniji korak u radu robota za čavrljanje koji, ako nije u mogućnosti ispravno razumjeti korisnički zahtjev, neće moći dati točan odgovor. Funkcionalan robot za čavrljanje mora pružiti najprikladniji odgovor na korisnički zahtjev nakon što je uspješno identificirao njegovu potrebu. Taj odgovor može biti različitih oblika - općenit i unaprijed definiran tekst, tekst preuzet iz baze znanja koja sadrži različite odgovore, kontekstualizirani podatak na temelju informacija koje je pružio korisnik, podatak pohranjen u poslovnim sustavima ili kao rezultat radnje koje je robot za čavrljanje izveo interakcijom s jednim ili više sigurnosnih programa. Primjeri poznatih robota za čavrljanje su Microsoftov virtualni asistent Cortana, Appleov Siri ili Amazonova Alexa, koji pomažu korisniku navedenih sustava pri prilagođavanju, postavljanju i korištenju sustava te pruža podršku ukoliko se susretne s određenim problemima ili nejasnoćama prilikom korištenja sustava.<sup>67</sup> Na mrežnim stranicama veliki je broj poznatih i inovativnih robota za čavrljanja, a koriste ih gotovo sve organizacije koje se bave pružanjem proizvoda ili usluga. Na primjer, UNICEF koristi robota za čavrljanje kako bi ljudima

---

<sup>66</sup> Jurafsky, Daniel; James H. Martin. *Speech and Language Processing: An Introduction to Natural Language Processing: Computational Linguistics, and Speech Recognition*, 2018. URL: <https://web.stanford.edu/~jurafsky/slp3/ed3book.pdf> (2019-09-07)

<sup>67</sup> Chatbot: What is Chatbot? Why are Chatbots Important? // Expert System. URL: <https://www.expertsystem.com/chatbot/> (2019-09-07)

koji žive u zemljama u razvoju govorio o najnužnijim potrebama u svojoj zajednici. Roboti za čavrljanje danas su vrlo važni jer pojednostavljaju interakciju između ljudi i virtualnih usluga poboljšavajući korisničko iskustvo. Istodobno tvrtkama nude nove mogućnosti za poboljšanje procesa angažiranja kupaca i radne učinkovitosti smanjujući pritom tipične troškove za pružanje potpore kupcima. Da bi rješenja robota za čavrljanje bila učinkovita, ono bi trebalo biti u mogućnosti obavljati oba navedena zadatka. Međutim, ljudska podrška igra ključnu ulogu jer bez obzira na pristup i platformu, ljudska intervencija je presudna u konfiguriranju, obuci i optimizaciji sustava robota za čavrljanje.<sup>68</sup> S druge strane, dijaloški sustavi ili razgovorni agenti računalni su sustavi dizajnirani za koherentnu komunikaciju s ljudima putem teksta, govora, grafike ili drugih metoda. Razgovorni agenti (koji se još nazivaju i relacijski agenti) do sada su se u velikoj mjeri oslanjali na tehnike robota za čavrljanje, no cilj njihove funkcionalnosti jest nadići te tehnike stvaranjem agenata s osobinama ljudi koji su sposobni pokazati emociju i empatiju prema korisnicima. Oni bi trebali imati semantičku i epizodnu memoriju, dugoročno učiti o korisničkim potrebama i pružati korisniku usluge. Te usluge osim druženja i podrške mogu biti i pružanje savjeta (npr. o zdravlju), održavanje rasporeda, pravljenje podsjetnika, odgovaranje na pitanja i podučavanje (npr. o jezicima), igranje igara te pružanje internetskih usluga. Vizualno takvi agenti izgledaju vedro (često imaju ljudsku glavu ili druge animirane likove) te posjeduju osobine uljudnosti, diskrecije, skromnosti i dobre informiranosti.<sup>69</sup> Dijaloški sustavi temelje se na neuronskim arhitekturama, kao npr. spomenutoj LSTM arhitekturi ili neuronskoj mreži, te su pokazali sposobnost postizanja tečne komunikacije, posebice ako se izučavaju izravno na dijaloškim zapisima. Jedna od glavnih prednosti razgovornih agenata jest mogućnost rada na velikom broju podataka postojećih razgovora kako bi naučili pokriti različite domene znanja bez potrebe za stručnim znanjem. Ipak, razgovorni agenti pokazali su ograničeno angažiranje tijekom razgovora te im nedostaje dosljednost i preuzimanje proaktivne strategije angažmana kao što to čine skripte robota za čavrljanje. Kako bi riješili ograničenja sastavljenog skupa podataka, istraživači Facebooka stvorili su novi dijaloški skup podataka koji se temelji na personalizaciji te sastavljen od razgovora izvučenih iz internetske platforme Reddit. Jednostavnom heuristikom stvorili su skup podataka od preko 5 milijuna ličnosti koje obuhvaćaju više od 700 milijuna razgovora. Da bi procijenili njihovu učinkovitost, istraživači su obučili personalizirane dijaloške sustave na svom novo razvijenom skupu podataka. Sustavi obučeni na njihovom skupu podataka

---

<sup>68</sup> Shewman, Dan. 10 of the Most Innovative Chatbots on the Web. // WordStream. URL: <https://www.wordstream.com/blog/ws/2017/10/04/chatbots> (2019-09-07)

<sup>69</sup> Schubert, Lenhart. Computational Linguistics. The Stanford Encyclopedia of Philosophy, Spring 2019 Edition. URL: <https://plato.stanford.edu/archives/spr2019/entries/computational-linguistics> (2019-09-04)

bili su sposobni angažiranije voditi razgovore, nadmašujući druge razgovorne agente koji nisu imali pristup osobama, tj. njihovim osobinama tijekom svoje obuke.<sup>70</sup> Još uvijek postoje ograničenja s kojima se razgovorni agenti susreću, no navedena istraživanja velikih svjetskih organizacija ukazuju na to da bi s vremenom oni mogli postati vrlo moćan alat za pružanje korisničkih usluga i korisničke potpore.

#### 4.7. Korisnička sučelja prirodnog jezika

Prema Intellexeru, korisničko sučelje prirodnog jezika pruža prirodnu interakciju čovjeka s bilo kojom aplikacijom. Ovakve aplikacije danas su vrlo korisne jer čine rad učinkovitim te eliminira potrebu za posebnim proučavanjem sintakse. Osim toga, omogućavaju detaljan i precizan opis traženih informacija. Korisničko sučelje prirodnog jezika može pretvoriti upite u prirodnom jeziku u logičke upite, proširujući ih mogućim načinima kombiniranja i parafraziranja. Ono također može proširiti izvorne upite sinonimima, ali zbog činjenice da je ukupan broj sinonima prilično ograničen, a skup sinonima, koji se primjenjuju za određeno područje, potrebno je prilagoditi, ova funkcija ne pruža se u upitima za koje se treba dodatno promišljati i pretraživati (izvan teme ili područja s kojim se radi), ali se može dodati nakon korisnikovog zahtjeva za prilagođavanje. Rješenja sučelja prirodnog jezika mogu se učinkovito koristiti u tražilicama (korisnik može unijeti rečenice na prirodnom jeziku i dobiti precizne rezultate pretraživanja), računalnim igrama (korisnik može komunicirati s likovima u igri poboljšavajući iskustvo igranja) te u programima za upravljanje dokumentima (alati prirodnog jezika osiguravaju visokokvalitetnu analizu informacija korištenjem semantičke usporedbe dokumenata, rezimiranje dokumenata, kategorizacije i analize osjećaja).<sup>71</sup> Područje korisničkih sučelja prirodnog jezika posjeduje značajnu raznolikost u aplikacijama prirodnog jezika – od tekstualnih sustava koji minimalno ovise o razumijevanju do sustava sa značajnim razumijevanjem i zaključivanjem prilikom interakcije na osnovi teksta ili govora. Neke od njih jesu:

- tekstualno odgovaranje na pitanja,
- Front-end baze podataka,
- odgovaranje na pitanja temeljeno na znanju te

---

<sup>70</sup> Mazare, Pierre-Emmanuel i dr. Training Millions of Personalized Dialogue Agents, 2018. URL: <https://arxiv.org/pdf/1809.01984.pdf> (2019-09-07)

<sup>71</sup> Intellexer Natural Language Interface. // Intellexer. URL: [https://www.intellelexer.com/natural\\_language.html](https://www.intellelexer.com/natural_language.html) (2019-09-07)



- mrežne glasovne usluge.

Tekstualno odgovaranje na pitanja (Text-Based Question Answering) praktičan je primjer sučelja prirodnog jezika koji je sposoban odgovoriti na postavljena pitanja na temelju gotovih i spremljenih odgovora u tijelu teksta kojemu pristupa sustav odgovaranja na pitanja. Ovaj alat postao je koristan u današnjem dobu velikoga broja informacija, no postavljena pitanja i dalje trebaju biti jednostavne naravi, a ne one naravi koje zahtijevaju donošenje zaključka i promišljanja o pitanju. Tekstualno odgovaranje na pitanja započinje klasifikacijom pitanja, nakon čega slijedi pretraživanje informacija za prepoznatu vrstu postavljenog pitanja. Zatim slijedi sužavanje rezultata pretraživanja te rečenica koje mogu sadržavati odgovor na pitanje. Budući da izabrane rečenice mogu sadržavati nevažne informacije, potrebno je izvući samo one relevantne i stvoriti dobro oblikovan i prikladan odgovor na pitanje.<sup>72</sup> Front-end baze podataka korisničko su sučelje ili aplikacija koja omogućuje pristup tabličnim i strukturiranim podacima. Ono sadrži jedinstvenu uslužnu programsku podršku za programiranje podataka u kojemu zahtijeva unos podatka koji šalje natrag u bazu podataka. Primarni cilj front-end baze podataka jest pružiti sučelje za dohvaćanje, pohranjivanje i prikazivanje podataka pohranjenih u bazi podataka. Front-end dio baze podataka obično radi neovisno o svom back-end dijelu.<sup>73</sup> Za razliku od internetskog pretraživanja, odgovaranje na pitanja temeljeno na znanju (Knowledge-Based Question Answering) daje točne i sažete rezultate pod uvjetom da se pitanja prirodnog jezika mogu razumjeti i preslikati precizno na strukturirane upite preko baze podataka. Izazov ovog pristupa jest taj što čovjek može jedno pitanje postaviti na više načina i stoga ovaj pristup koristi milijunske skupove podataka kako bi imao jako veliki broj uzoraka na temelju kojih može odgovarati na veliki broj pitanja koja mogu biti postavljena na različit način.<sup>74</sup> Glasovne usluge, posebno na mobilnim uređajima, bilježe značajan rast u razvoju kao aplikacije. Ključna tehnologija u ovim je uslugama prepoznavanje govora - tehnika kojom se stvara specijalizirani program i sustavi za prepoznavanje, razlikovanje i provjeru autentičnosti glasa pojedinog izvornika. Prepoznavanje glasa procjenjuje biometriju glasa pojedinca kao što su frekvencija i tijek glasa te prirodni naglasak. Prije nego što su ovakvi alati sposobni prepoznati glas govornika, tehnike prepoznavanja glasa zahtijevaju određenu obuku u kojoj sustav nauči glas (njegov naglasak i ton) govornika. To se obično postiže

---

<sup>72</sup> Schubert, Lenhart. Computational Linguistics. The Stanford Encyclopedia of Philosophy, Spring 2019 Edition. URL: <https://plato.stanford.edu/archives/spr2019/entries/computational-linguistics> (2019-09-04)

<sup>73</sup> Database Front End. // Techopedia. URL: <https://www.techopedia.com/definition/6761/database-front-end> (2019-09-07)

<sup>74</sup> Wanyun Cui i dr. KBQA: Learning Question Answering over QA Corpora nad Knowledge Bases. Proceedings of the VLDB Endowment, 10, 5, 2017. URL: <https://arxiv.org/abs/1903.02419> (2019-09-07)

nizom tekstualnih riječi i izjava koje osoba mora izgovarati kroz ugrađeni ili vanjski mikrofoni.<sup>75</sup> Ove usluge pojavljuju se u različitim oblicima kao što su organizator (raspored sastanaka, prometni uvjeti i sl.), upravljač elektroničke pošte, biranje kontakata, financijske transakcije i slično. S korisničkim sučeljem prirodnog jezika završava se s navođenjem aplikacija za generiranje teksta, a u nastavku će se navesti prvi primjeri knjiga napisanih pomoću umjetne inteligencije.

#### 4.8. Prva istraživačka knjiga napisana pomoću umjetne inteligencije

*Springer Nature*, američki akademski nakladnik, uz blisku suradnju s istraživačima sa Sveučilišta Goethe u Frankfurtu/Mainu, izdali su prvu istraživačku knjigu generiranu strojnim učenjem naziva *Lithium-Ion Batteries: A Machine-Generated Summary of Current Research*. Knjiga je sažetak recenziranih radova na temu litijско – ionskih baterija koje je brzo rastuće znanstveno polje zadnjih nekoliko godina. Ovaj prototip namijenjen je za istraživače, magistre i doktorande, recenzente, akademske pisce i mnoge druge. Pružajući strukturirani izvadak iz potencijalno velikog supa radova, trebao bi pružiti pregled određene teme čime se štedi vrijeme i trud. Knjiga sadrži citate, hiperveze na citirani rad i automatski generirane sadržaje navedenih referenci te je besplatna, odnosno moguće ju je preuzeti s interneta.<sup>76</sup> Henning Schoenenberger, zaposlenik *Spring Naturea*, navodi kako ova njihova prva strojno generirana knjiga predlaže potencijalno učinkovito rješenje problema upravljanja velikom količinom informacija. Njihovo programsko rješenje omogućuje čitateljima da steknu pregled određenog područja istraživanja u kratkom vremenu jer time ne moraju pročitati stotine objavljenih članaka na određenu temu. Na primjer, Schoenenberger tvrdi kako je u posljednje tri godine napisano više od 53 tisuće istraživačkih članaka na temu litijско-ionskih baterija te da uz pomoć ovakve umjetne inteligencije znanstvenici i istraživači mogu uštediti značajno puno vremena pri sažimanju svih postojećih članaka. Također čitatelj, ako misli da mu je to potrebno, može kliknuti na navedeni izvor koji će ga odvesti do tražene literature te samim time dublje ući u temu kako bi nastavio detaljnije istraživati temu. Schoenenberger tvrdi da se korisnici, umjesto da koriste rezultate tražilica koji često nisu relevantni, mogu osloniti na provjerene i relevantne informacije objavljene na sadržajnoj

---

<sup>75</sup> Voice Recognition. // Techopedia. URL: <https://www.techopedia.com/definition/9961/voice-recognition> (2019-09-07)

<sup>76</sup> Vincent, James. The first AI-generated textbook shows what robot writers are actually good at. // The Verge. URL: <https://www.theverge.com/2019/4/10/18304558/ai-writing-academic-research-book-springer-nature-artificial-intelligence>

platformi *Springer Nature* imena *SpringerLink*, koja je pod znanstvenim nadzorom. Upravo je na toj platformi razvijen algoritam *Beta Writer* koji se koristio za strojno generiranje ove istraživačke knjige. Algoritam je odabirao, koristio i procesirao relevantne publikacije sa *Springer Nature* platforme. Ovakvi prototipi, Schoenenberger navodi, mogu pomoći svakome tko želi izraditi pregled literature ili treba brz i precizan uvod u određenu temu.<sup>77</sup>

#### 4.9. Prvi roman napisan pomoću umjetne inteligencije

Umjetna inteligencija sposobna je pisati tekstove različitih žanrova. U prethodnom poglavlju naveden je primjer istraživačke knjige, a u ovome će se dati primjer strojno generiranog romana. Ross Goodwin, kreativni tehnolog zaposlen u Googleu, umjetnik, haker, znanstvenik o podacima te nekadašnji *ghostwriter* (profesionalni pisac plaćen za pisanje knjiga, članaka, priča ili izvještaja koji su službeno pripisani drugoj osobi) administracije Barracka Obame, autor je prvog romana generiranog umjetnom inteligencijom *I the Road*.<sup>78</sup> Oponašajući roman Jack Kerouaca *On the Road*, Goodwin se u ožujku 2017. godine vozio od New Yorka do New Orleansa s implementiranom umjetnom inteligencijom u vlastitom prijenosnom računalu koji je na temelju primljenih *inputa* ispisivao rečenice na rolama papira u pisaču spojenim na računalo. Goodwin je koristio umjetnu inteligenciju u obliku dugoročne memorijske ponavljajuće neuronske mreže (*Long short-term memory*).<sup>79</sup> LSTM je arhitektura umjetne rekurentne neuronske mreže (*Recurrent neural network*) koja se koristi u području dubokog učenja. Za razliku od standardnih neuronskih mreža, LSTM ima povratne veze te je u mogućnosti obraditi ne samo pojedinačne podatkovne točke poput slika već i cijele sekvence podataka kao što su govor ili video. Naprimjer, LSTM je primjenjiv u zadacima poput prepoznavanja nesegmentiranog i povezanog rukopisa ili prepoznavanja govora. Uobičajena LSTM jedinica sastoji se od ćelije, ulaznih vrata, izlaznih vrata i zaboravljenih vrata. Stanica pamti vrijednosti tijekom proizvoljnih vremenskih intervala, a troja vrata reguliraju protok informacija unutar i izvan stanice.<sup>80</sup> Goodwin je postavio tri senzora koji

---

<sup>77</sup> Conrad, Lettie Y. The robots Are Writing: Will Machine-Generated Books Accelerate our Consumption os Scholarly Literature? // The Scholarly Kitchen. URL: <https://scholarlykitchen.sspnet.org/2019/06/25/the-robots-are-writing-will-machine-generated-books-accelerate-our-consumption-of-scholarly-literature/> (2019-09-12)

<sup>78</sup> Ross Goodwin. // MLconf. URL: <https://mlconf.com/speakers/ross-goodwin/> (2019-09-12)

<sup>79</sup> Horingold, Thomas. The First Novel Written by AI Is Here - and It's as Weird as You'd Expect It to Be. // SingularityHub. URL: <https://singularityhub.com/2018/10/25/ai-wrote-a-road-trip-novel-is-it-a-good-read/> (2019-09-12)

<sup>80</sup> Pranjali, Srivastava. Essentials of Deep Learning: Introduction to Long Short Term Memory // Analytics Vidhya. URL: <https://www.analyticsvidhya.com/blog/2017/12/fundamentals-of-deep-learning-introduction-to-lstm/> (2019-09-12)

su bili *input* iz stvarnoga svijeta: nadzorna kamera postavljena na prtljažniku automobila, mikroskop unutar automobila te GPS koji je pratio lokaciju automobila. Unos iz ovih izvora i vrijeme predviđeno unutarnjim satom računala ubačeni su u LSTM program koji je zauzvrat generirao rečenice i ispisivao ih na rolama papira. Goodwin je u AI-program umetnuo tri različita tekstna korpusa (veliki i strukturirani skupovi tekstova) – jedan s poezijom, jedan sa znanstvenom fantastikom i jedan s „mračnim“ tekstovima. Osim navedenoga, umetnuo je i skup podataka s *Foresquarea* (mobilna aplikacija za pronalazak i otkrivanje mjesta i lokacija diljem svijeta) i dodao im komentare o njima.<sup>81</sup> Na temelju navedenih tehnologija, AI-program generirao je roman slovo po slovo. Kontinuiranim unosom iz GPS-a i sata u računalu, u romanu se često spominju zemljopisna širina i dužina te doba dana. Tekst u romanu tiskao se neuređeno i s mnogo pogrešaka u njemu, no Goodwin nije htio prepravljati tekst jer ga je htio pokazati u njegovom „najsurovijem“ obliku. Goodwin tvrdi da je umjetna inteligencija sposobna pisati literaturu, ali da i dalje osjeća odgovornost nad napisanim tekstom jer je cijeli proces i sami program funkcionirao pod njegovim vodstvom. Navodi kako mu je glavna svrha ovog romana generiranog umjetnom inteligencijom, otkriti javnosti način na koji strojevi stvaraju riječi, rečenice i tekstove.<sup>82</sup>

## 5. Strojno prevođenje - definicija i pregled razvoja

Prema John W. Hutchinsu, autoru knjige *Machine Translation: A brief history*, strojno je prevođenje (Machine Translation) tehnologija koja automatski prevodi tekst pomoću terminskih baza i naprednih tehnika gramatičke, sintaktičke i semantičke analize. Ideja da računala prevode ljudske jezike stara je koliko i sama računala. Ono je sustav odgovoran za proizvodnju prijevoda sa ili bez ljudske pomoći. Iako je cilj strojnog prevođenja stvaranje visoko kvalitetnog prijevoda teksta, u praksi se krajnji rezultat prijevoda još dodatno uređuje. U tom pogledu, strojno prevođenje ne razlikuje se od ljudskog prevođenja jer većina napravljenih ljudskih prijevoda bude dodatno pregledana i uređena od još jednog prevoditelja kako bi taj prijevod bio što kvalitetniji i precizniji. Međutim, vrste pogrešaka koje pravi strojno prevođenje razlikuju se od onih koje naprave ljudi, primjerice dodavanje netočnih prijedloga, zamjenica, glagolskih vremena i slično. Upotreba strojnih rječnika za prevladavanje jezičnih barijera prvi se put spominje u 17. stoljeću. Međutim, tek u 20. stoljeću podneseni su prvi konkretni prijedlozi u patentima koje su kreirali

---

<sup>81</sup> Merchant, Brian. When an AI Goes Full Jack Kerouac. // The Atlantic. URL: <https://www.theatlantic.com/technology/archive/2018/10/automated-on-the-road/571345/> (2019-09-12)

<sup>82</sup> An AI and an artist go on the road. “The idea was to write a novel with a car”.// CBC. URL: <https://www.cbc.ca/radio/spark/409-1.4860495/an-ai-and-an-artist-go-on-the-road-the-idea-was-to-write-a-novel-with-a-car-1.4860760>

George Artsrouni te Petr Smirnov-Troyanskii. Artsrouni je dizajnirao uređaj za pohranu na papirnoj vrpici koji bi mogao pronaći ekvivalent bilo koje riječi na nekom drugom jeziku te je prototip toga uređaja prikazao javnosti 1937. godine. Troyanskii je osmislio tri faze strojnog prevođenja:

- u prvoj fazi urednik koji zna samo materinski jezik trebao je izvesti logičku analizu riječi u njihovom korijenskom obliku i sintaktičkim funkcijama;
- u drugoj fazi stroj je trebao pretvoriti dijelove korijenskih oblika i funkcija u ekvivalentne dijelove na ciljanom jeziku;
- u trećoj fazi dodatni prevoditelj koji razumije samo ciljani jezik trebao je pretvoriti dobivene rezultate prijevoda u uobičajene oblike svoga jezika.

Strojno autorstvo prvi se put približilo javnosti 1949. godine kada je održan Weaverov memorandum u kojemu je iznio svoje viđenje o strojnom prevođenju te predložio različite metode koje bi omogućile takvu tehnologiju (upotreba kriptografskih tehnika, statističke analize). Nekoliko godina poslije počela su prva istraživanja o strojnom prevođenju na Sveučilištu u Washingtonu, Los Angelesu te na Massachusetts Institutu za tehnologiju (MIT). Upravo je na MIT-ju 1951. godine imenovan prvi stalni istraživač strojnog prevođenja Yehoshua Bar-Hilel. Godinu dana kasnije Bar-Hilel sazvaio je prvu konferenciju o strojnom prevođenju na kojoj su postavljeni prvi uzorci budućeg istraživanja. Kako je javnosti i znanstvenom krugu bilo potrebno dokazati da je ovaj koncept moguć, prvi korak u tome napravilo je Sveučilište Georgetown Leon Doster, kada su u suradnji s IBM-om 1954. godine, napravili projekt u kojem su dali prvu demonstraciju sustava za strojno prevođenje. Za projekt su uzeli pažljivo odabran uzorak od 49 ruskih rečenica prevedenih na engleski jezik koristeći vrlo ograničen rječnik od 250 riječi i samo 6 gramatičkih pravila. Iako je taj projekt imao malu znanstvenu vrijednost, bio je dovoljno impresivan da potakne značajno financijsko ulaganje u ovu granu. U pedesetim i šezdesetim godinama 20. stoljeća istraživanja strojnog prevođenja često su bila polarizirana između empirijskog pristupa pokušaja i pogreške koje je često usvajalo statističke metode s ciljem stvaranja izravnih radnih sustava te teorijskog pristupa koji su podrazumijevali temeljna lingvistička istraživanja s ciljem stvaranja dugoročnih rješenja. U ovome razdoblju računalni resursi bili su neprikladni te se stoga velika pozornost stavljala na poboljšavanje tehničke podrške (papirne vrpce, magnetski mediji) te osmišljavanju programskih alata prigodnih za obradu jezika. Iz političkih razloga, većina američkih istraživanja bila su vezana za rusko-engleski prijevod, a većina sovjetskih istraživanja za englesko-ruski prijevod. U Kanadi i Europi potrebe su bile potpuno različite. Kanadske vlade imale su potrebu za prijevodom s engleskog na francuski jezik,

dok je u Europi postojala potreba unutar europske zajednice za prijevodom znanstvene, tehničke, administrativne i pravne dokumentacije sa i na sve jezike unutar zajednice. Tijekom osamdesetih godina strojno prevođenje doživjelo je brzi napredak koji je bio omogućen pojavom mnogih novih operativnih sustava te širenjem komercijalnog tržišta za sustave strojnog prevođenja. Značajniji sustav toga vremena bio je Systran–sustav za strojno prevođenje koji je koristilo Ratno zrakoplovstvo SAD-a za rusko-engleski prijevod te europske zajednice za englesko-francuski prijevod. Dominantni okvir istraživanja strojnog prevođenja do kraja 1980-ih zasnovan je osnovi jezičnih pravila raznih vrsta – pravila za sintaktičku analizu, leksička pravila, pravila za leksički prijenos, pravila za sintaktičko generiranje, pravila za morfologiju itd. Pristup temeljen na pravilima bio je najistaknutiji u sustavima dominantnog prijenosa kao što su Ariane, Metal, Susy, Mu i Eurotra. Međutim, od 1989. godine dominacija pristupa temeljenog na pravilima narušena je nastankom nove metode i strategije koja se danas naziva korpusna metoda. Učinkovitost ove metode iznenadila je mnoge istraživače te ih potaknula da u narednim godinama prave eksperimente sa statističkim metodama raznih vrsta.<sup>83</sup> Unatoč velikim pomacima u tehnologiji, ove besplatne usluge strojnog prevođenja upotrebljive su za povremeni prijevod te se najčešće ne koriste u komercijalne svrhe. S druge strane, komercijalni dobavljači tehnologije strojnog prevođenja radili su na poboljšanju svoje plaćene usluge, a prilagođavanje strojeva za strojni prijevod pronalazi komercijalnu upotrebu u ograničenim područjima. Međutim, izazovi razumijevanja konteksta, tonova, jezičnih registara i neformalnog izražavanja razlozi su zašto se od strojnog prevođenja ne očekuje da u bližoj budućnosti zamjeni ljudske prevoditelje. Najveća upotreba strojnog prevođenja jesu aplikacije koje zahtijevaju interakciju u stvarnom vremenu za asimilaciju tekstova i čavrljanja te kao produktivni alat koji pruža podršku ljudskim prevoditeljima. U nastavku teksta navest će se vrste sustava za strojni prijevod te područja u kojima se ono primjenjuje.

## 5.1. Primjena i sustavi strojnog prevođenja

U prethodnom poglavlju navedene su definicije i povijest razvoja strojnog prijevoda, a u ovome slijedi navođenje i opis različitih vrsta sustava pomoću kojih rade te će se navesti u kojim područjima pronalaze svoju svrhu i efikasnost. Strojno prevođenje jest potpuno automatizirani

---

<sup>83</sup> Hutchins, John W. Machine Translation: A Brief History. // Concise History of Language Sciences: From the Sumerians to the Cognitivists, 1995. Str. 431-445. URL: <https://aymara.org/biblio/mtranslation.pdf> (2019-09-09)

program koji može prevesti izvorni sadržaj na tražene jezike. Za obradu bilo kojeg prijevoda, ljudskog ili automatiziranog, značenje teksta na izvornom jeziku mora se u potpunosti vratiti na ciljni jezik. Prevoditelj mora protumačiti i analizirati sve elemente u tekstu i znati kako svaka riječ može utjecati na druge riječi. To zahtijeva opsežnu stručnost u gramatici, sintaksi (strukturi rečenica), semantici odnosno značenju itd. u izvornom i ciljnom jeziku, kao i upoznavanje sa svakom lokalnom regijom te njihovim specifičnostima u jeziku. Ljudski i strojni prijevodi nailaze na različite izazove. Na primjer, niti jedan pojedinačni prevoditelj ne može proizvesti identičan prijevod istog teksta, a može biti i više opetovanih revizija nad završnim rezultatom prijevoda kako bi se ostvarilo zadovoljstvo korisnika. Strojni prijevod susreće se s velikim izazovom stvaranja kvalitetnih prijevoda kako bi se postiglo zadovoljstvo korisnika. Alati za strojno prevođenje često se koriste za prevođenje velike količine informacija koje se sastoje od milijuna riječi koje ne mogu biti prevedene na tradicionalan način zbog prevelike količine vremena koje bi čovjek trebao utrošiti za takav rad. Kvaliteta rezultata strojnog prijevoda može se značajno razlikovati te stoga sustavi strojnog prijevoda zahtijevaju obuku za potrebno područje djelovanja kako bi povećali kvalitetu. Prevoditeljske tvrtke koriste strojni prijevod kako bi povećale produktivnost svojih prevoditelja, smanjili troškove te da bi klijentima pružili usluge naknadnog uređivanja prevedenog teksta. Upotreba strojnog prevođenja također bilježi rast i razvoj pružatelja jezičnih usluga. Godine 2016. SDL – jedna od najvećih svjetskih prevodilačkih tvrtki objavila je da prevodi 20 puta više sadržaja pomoću strojnog prevođenja nego s ljudskim timovima.<sup>84</sup> Strojni prijevod koristi se za različite potrebe te u različitim područjima znanja. Osnovne namjene strojnog prijevoda jesu:

- pružanje suštinskog prijevoda,
- “trenutni prijevod”,
- korištenje kontroliranog jezika te
- pružanje podrške ljudskom prijevodu.

Jedna od namjena strojnog prijevoda jest pružanje suštinskog prijevoda u kojemu rezultati strojnog prevođenja nisu tako dobri kao što bi ih napravili ljudi, ali su korisni za razumijevanje onoga što tekst govori. Takav prijevod može biti dovoljno dobar ovisno o namjeni i ciljanoj publici. Nadalje, strojni prijevod omogućuje zadovoljavanje korisnikove trenutne potrebe, što znači da je sposoban pružiti prijevode materijala koji trebaju biti prevedeni u kratkome roku te koji nemaju vremena čekati prijevode ljudi, primjerice rezultati iz upita u bazama podataka. Također, strojni prijevod

---

<sup>84</sup> What is Machine Translation? // GALA – Globalization and Localization Association. URL: <https://www.gala-global.org/what-machine-translation> (2019-09-10)

omogućuje korištenje kontroliranog jezika, odnosno za tekstove napisane na kontroliranom jeziku programi strojnog prijevoda mogu pružiti prijevode visoke kvalitete, kao što su prijevodi patenata ili tehničkih specifikacija. Naravno, strojni prijevod izuzetno je koristan u današnje doba stvaranja velikih količina podataka te zbog kojega ljudski prijevod često nije ekonomski ili tehnički izvediv. Na kraju, strojno prevođenje korisno je i za pružanje podrške za ljudske prevoditelje pomoću modernih alata za računalno asistirani prijevod (Computer Aided Tools) koji omogućuju korisnicima prevođenje izvornih segmenata teksta pomoću strojnog prijevoda. Time prevoditelji mogu odlučiti hoće li koristiti rezultate prijevoda takve kakvi jesu ili će ih naknadno ručno urediti što može ubrzati njihov rad.<sup>85</sup> Međutim, postoji važna razlika između strojnog prijevoda i CAT-a. Dok je danas cilj strojnog prijevoda takozvani FAHQT (potpuno automatizirani prijevod visoke kvalitete), u CAT-u se istražuju i razvijaju alati i metode koje pomažu ljudskim prevoditeljima u procesu prevođenja. Dobro poznati i široko korišten primjer CAT-a jest upotreba sustava za prijevod memorije (Translation-Memory System). TMS kombinira pretvarač prilagođenog prevoditelja s bazom podataka zajedno s bazom podataka koji sprema sve prijevode koji su napravljeni u određenom projektu (prijevodna memorija), kao i komponentu koja analizira jedinice koje trebaju tek biti prevedene zbog sličnosti s onim jedinicama u prijevodnoj memoriji. Ako je pronađena sličnost nakon određenog praga, sustav omogućuje prevoditelju mijenjanje prijevoda ili, ako je pronađeno 100% sličnosti, samo ga zamjenjuje. Pokazalo se da je ova vrsta alata izuzetno korisna za prevoditelje u područjima tehničke dokumentacije ili lokalizacije programske podrške. Međutim, CAT nije dizajniran za prijevod književnog teksta. Buduće razvijene komponente TMS-a mogle bi koristiti strojni prijevod za jedinice s manjim sličnostima, automatsku transliteraciju brojeva ili datuma te implementaciju korisničkih rječnika za upravljanje terminologijom.<sup>86</sup> Postoje tri različite vrste sustava strojnog prijevoda:

- generički,
- podesivi i
- prilagodljivi strojni prijevod.

Generički strojni prijevod obično se odnosi na platforme kao što su Google Translate, Bing, Yandex i Naver. Te platforme pružaju strojno prevođenje za *ad hoc* prijevode milijunima ljudi. Tvrtke mogu kupiti generički strojni prijevod za skupni pred-prijevod te za skupno povezivanje s vlastitim sustavima. Podesivi strojni prijevod odnosi se na program strojnog prijevoda koji ima svoju

---

<sup>85</sup> Machine Translation. // Andovar. URL: <https://www.andovar.com/machine-translation/> (2019-09-10)

<sup>86</sup> Stein, Daniel. Machine Translation: Past., Present and Future. // Language Technologies for a Multilingual Europe / Daniel Stein [et.al.]. Berlin: Language Science Press, 2018. str 5-17.



osnovnu komponentu te se može osposobiti za poboljšanje točnosti terminologije za odabrano područje (medicina, pravo, terminologija tvrtke). Na primjer, Svjetska organizacija za intelektualno vlasništvo (WIPO) koristi vlastiti specijalizirani program koji prevodi patente preciznije nego programi ostalih generičkih strojnih prijevoda. Također eBay (online usluga aukcijske kupnje i prodaje), koristi vlastito rješenje strojnog prijevoda koje može razumjeti stotine kratica s različitih jezika koje se koriste u njihovoj digitalnoj trgovini. Prilagodljivi strojni prijevod pruža prevoditeljima prijedloge dok upisuju riječi i rečenice za prijevod te uči iz njihovih unosa u stvarnom vremenu. Predstavljen od Lilt-a (platforma za interaktivno i prilagodljivo prevođenje) 2016. godine te SDL-a 2017. godine, vjeruje se da prilagodljivi strojni prijevod značajno poboljšava produktivnost i da može u budućnosti razviti tehnologiju prevoditeljske memorije koja se u usporedbi sa strojnim prijevodom, oslanja na stvarne ljudske prijevode koji su najčešće prilično točni te sadrže pravu terminologiju.<sup>87</sup> Nakon što su se u ovome potpoglavlju opisale vrste sustava pomoću kojih strojni prijevod funkcionira, navođenjem područja primjene u kojima pronalaze svoju svrhu, u nastavku teksta navest će se osnovne vrste strojnog prijevoda te kako svaki od njih funkcionira.

## 5.2. Vrste strojnog prijevoda

Strojni prijevod, kao i generatori teksta, tijekom svoga razvijanja nailazio je na različite pristupe i načine na temelju kojih je imao svoju funkcionalnost. Vrste strojnog prijevoda razvijale su se usporedno s razvojem same tehnologije, odnosno razvojem prethodno navedenih preduvjeta kao što su računalni sustav, baze podataka te umjetna inteligencija. Tako danas postoji pet osnovnih vrsta strojnog prijevoda:

- strojni prijevod temeljen na pravilima,
- statistički strojni prijevod,
- strojni prijevod temeljen na primjerima,
- neurološki te
- hibridni strojni prijevod.

---

<sup>87</sup> What is Machine Translation? // GALA - Globalization nad Localization Association. URL: <https://www.gala-global.org/what-machine-translation> (2019-09-10)

Strojni prijevod temeljen na pravilima (Rule-Based Machine Translation), razvijen prije nekoliko desetljeća, bio je prvi praktični pristup strojnom prijevodu. Ovaj pristup temelji se na bezbroj ugrađenih jezičnih pravila te milijune dvojezičnih rječnika za svaki jezični par. Program raščlanjuje tekst te stvara prijelazni prikaz iz kojeg se generira tekst na ciljnom jeziku. Ovaj postupak zahtijeva korištenje opsežnih leksikona s morfološkim, sintaktičkim i semantičkim informacijama i velike skupove pravila te zatim prenosi gramatičku strukturu izvornog jezika na ciljni jezik. Prednost je pristupa strojnog prijevoda temeljnog na pravilima u tome što stroj može prevesti širok raspon tekstova bez potrebe za velikim dvojezičnim korpusima. Međutim, razvoj sustava strojnog prijevoda temeljenog na pravilima zahtijeva mnogo vremena i mnogo rada te može potrajati nekoliko godina za jedan jezični par. Osim toga, pravila koja generiraju ljudi nisu u stanju pokriti sve moguće jezične pojave, a sukobi između postojećih pravila mogu dovesti do loše kvalitete prijevoda. Zbog toga je strojni prijevod temeljen na pravilima uvelike zamijenjen statističkim strojnim prijevodima ili hibridnim sustavima.<sup>88</sup> Statistički strojni prijevod djeluje na temelju obučavanja prevoditeljskog stroja s vrlo velikom količinom dvojezičnih (izvorni tekstovi i njihovi prijevodi) i jednojezičnih tekstualnih korpusa.<sup>89</sup> Sustav traži statističke veze između izvornih tekstova i prijevoda, kako za čitave segmente teksta, tako i za kraće izraze unutar svakog segmenta, stvarajući takozvani prijevodni model. Sustav zatim stvara rezultate pouzdanosti za vjerojatnost da će se izvorni tekst mapirati u prijevod. Sami prevoditeljski stroj ne zna jezična pravila ili gramatiku. Ključna je prednost statističkog strojnog prijevoda ta što eliminira potrebu ručnog prijevoda za svaki jezični par te potrebu za stvaranjem skupova jezičnih pravila kao što je to slučaj s pristupom temeljenog na pravilima. Uz velike skupove tekstova u stanju je osposobiti generički prevoditeljski mehanizam za bilo koji jezični par, čak i za određenu industriju ili područje znanosti. Glavni nedostatak statističkog strojnog prijevoda jest potreba za vrlo velikim i dobro organiziranim dvojezičnim korpusima za svaki jezični par. Programi statističkog prijevoda neće dobro raditi ako se od njih traži prijevod teksta koji nije sličan materijalima u korpusima za obuku. Na primjer, mehanizam za prevođenje, koji je obučen za prijevod tehničkog teksta, teško će prevesti tekst napisan u ležernom stilu. Stoga je vrlo važno program obučiti tekstovima koji su slični materijalu koji treba prevesti. Statistički pristup strojnog prijevoda koristi Google Translate i Microsoft Translate te unatoč navedenim nedostacima, najčešći je oblik strojnog prijevoda koji se danas koristi. Pristup strojnog prijevoda temeljen na primjeru koristi analogni prijevod u kojemu

---

<sup>88</sup> What is Machine Translation? Rule Based Machine Translation vs. Statistical Machine Translation. // Systran. URL: <http://www.systransoft.com/systran/translation-technology/what-is-machine-translation/> (2019-09-10)

<sup>89</sup> Post, Nicole. Different Types of Machine Translation. // Localize Blog. URL: <https://localizeblog.com/types-of-machine-translation/> (2019-09-10)

se brojni postojeći prijevodni parovi izvornih i ciljanih rečenica koriste kao primjeri. Kada treba prevesti novu izvornu rečenicu, preuzimaju se primjeri kako bi se pronašli oni slični izvoru te se onda ciljane rečenice generira oponašanjem prijevoda podudarnih primjera. Budući da je stopa učitavanja za dugačke rečenice vrlo niska, obično se primjeri i izvorna rečenica raščlanjuju na manje fragmente. Ovaj pristup može rezultirati kvalitetnim prijevodom kada se u sustavu pronađu vrlo slični primjeri prijevoda, no kada ne postoji sličan primjer prijevoda u sustavu, kvaliteta prijevoda može biti vrlo niska. Stoga pristup temeljen na primjeru nije široko implementiran kao komercijalna usluga. Neurološki strojni prijevod temelji se na paradigmi strojnog učenja te je najnoviji pristup strojnog prijevoda. Ono koristi neuronske mreže koje se sastoje od čvorova koji su konceptualno modelirani za oponašanje ljudskog mozga. Čvorovi mogu sadržavati pojedinačne riječi i izraze ili dulje segmente te se mogu međusobno povezati u složenoj mreži temeljenoj na dvojezičnim tekstovima koji se koriste za obuku sustava. Složena i dinamična priroda takvih mreža omogućava formiranje značajno obrazovanih pretpostavki o kontekstu, a samim time i značenja bilo koje riječi koju treba prevesti. Glavna prednost neurološkog strojnog prijevoda jest pružanje jedinstvenog sustava koji se može obučiti i za dešifriranje izvornog i ciljanog teksta. Kao rezultat toga ne ovisi o specijaliziranim sustavima kao što su drugi pristupi strojnog prijevoda, posebice statistički strojni prijevod. Sustavi za neurološki strojni prijevod kontinuirano se uče i prilagođavaju kako bi se ostvarilo postizanje najboljih rezultata prijevoda. Zbog toga je ovaj pristup posljednjih godina postao održiv. Kako svaki od navedenih pristupa ima svoje nedostatke, predloženi su različiti hibridni sustavi strojnog prijevoda kako bi se ti nedostaci minimalizirali. Dvije su glavne kategorije hibridnih sustava - prva se odnosi na sustavima temeljenim na pravilima koji koriste statistički prijevod za naknadnu obradu, a druga se odnosi na statističkim sustavima upravljanim programima temeljenih na pravilima. U prvom slučaju tekst prvo prevodi program temeljen na pravilima, a taj prijevod zatim obrađuje program statističkog strojnog prijevoda koji ispravlja sve pogreške u prijevodu. U drugom slučaju, program temeljen na pravilima ne prevodi tekst, ali podržava statistički strojni prijevod unošenjem metapodataka. Također, predlaže se da pri korištenju bilo koje od dvaju navedenih vrsta implementira i dio pristupa neurološkog strojnog prijevoda. Gotovo svi praktični sustavi strojnog prijevoda do određene mjere prihvaćaju hibridni pristup, kombinirajući pristup temeljen na pravilima i statistički pristup. U posljednje vrijeme se sve više sustava također koriste i prednostima neurološkog pristupa.<sup>90</sup>

---

<sup>90</sup> Machine Translation. // Andovar. URL: <https://www.andovar.com/machine-translation/> (2019-09-10)

### 5.3. Aplikacije za strojni prijevod

U prethodnom poglavlju navedene su vrste i pristupi strojnog prijevoda, a u ovome će se navesti koje su najpoznatije i najkorištenije aplikacije za strojni prijevod te koji od navedenih pristupa koriste pri svome radu. Postoji više od 100 pružatelja usluga strojnog prijevoda od kojih se neki bave isključivo razvojem tehnologija za strojni prijevod, dok su ostali prevodilačke tvrtke ili gigantske IT organizacije.<sup>91</sup> Nadovezujući se na gigantske IT organizacije, jedan je od najpoznatijih pružatelja strojnog prijevoda iz te branše Google Translate, besplatna višejezična usluga strojnog prevođenja koju je razvio Google. Ono nudi sučelje za strojni prijevod na mrežnom mjestu te u mobilnim aplikacijama za Android i iOS. Google Translate podržava preko 100 jezika na različitim razinama te od sredine 2017. godine pruža svoje prevodilačke usluge preko 500 milijuna ljudi. Google Translate pokrenut je 2006. godine u obliku statističkog strojnog prijevoda pri čemu je koristio prijevode Ujedinjenih Naroda i Europskog Parlamenta za prikupljanje jezičnih podataka.<sup>92</sup> Njegova se točnost tijekom godina vrlo često kritizirala i ismijavala. Tako je u studenom 2016. godine Google objavio da će Google Translate prijeći na pristup neurološkog strojnog prijevoda (Google Neural Machine Translation) koji prevodi cijele rečenice, a ne samo njezine dijelove. Današnja usluga Google Translatea koristi kombinacije statističkog i neurološkog strojnog prijevoda.<sup>93</sup> Još jedan IT gigant pruža uslugu strojnog prijevoda, a to je Microsoft sa svojom aplikacijom Microsoft Translate koji se od Google Translatea razlikuje po tome što svoje usluge pruža u oblaku koji je integriran u brojnim Microsoftovim proizvodima i uslugama. Ovo aplikacijsko sučelje za strojni prijevod dostupno je na mrežnom mjestu te podržava Android i iOS, a dostupan je putem pretplate te je besplatan za manje količine prijevoda i naplaćuje se za količine veće od 2 milijuna znakova mjesečno. Microsoft Translate u potpunosti koristi statistički pristup strojnog prijevoda.<sup>94</sup> Nadalje, jedna od najstarijih tvrtki za strojni prijevod, SYSTRAN, osnovana 1968. godine, za razliku od Googlea (i u nekim slučajevima Microsofta) nije besplatna usluga strojnog prevođenja, već svoje usluge naplaćuju, a cijena ovisi o tome koristi li njihove usluge pojedinac ili organizacija. U početku svoga djelovanja SYSTRAN je funkcionirao na pristupu

---

<sup>91</sup> What is Machine Translation? // GALA – Globalization and Localization Association. URL: <https://www.gala-global.org/what-machine-translation> (2019-09-10)

<sup>92</sup> Sommerlad, Joe. Google Translate: How Does the Serach Giant's Multilingual Interpreter Actually Work? // Independent. URL: <https://www.independent.co.uk/life-style/gadgets-and-tech/news/google-translate-how-work-foreign-languages-interpreter-app-search-engine-a8406131.html> (2019-09-11)

<sup>93</sup> McGuire, Nick. How Accurate Is Google Translate In 2018? // ARGO Translation. URL: <https://www.argotrans.com/blog/accurate-google-translate-2018/> (2019-09-11)

<sup>94</sup> Machine Translation. // Microsoft. URL: <https://www.microsoft.com/en-us/translator/business/machine-translation/> (2019-09-11)

temeljenim na pravilima, no izlaskom SYSTRAN Server 7, novog klijent-pružatelja 2010. godine, započeli su s korištenjem hibridnog pristupa strojnog prevođenja, kombinirajući pristup temeljen na pravilima i statistički pristup. Danas SYSTRAN, uz ovu tehnologiju, koristi i sve brže rastući pristup neurološkog strojnog prijevoda, a zanimljivost njihovih proizvoda je što osim teksta posjeduju aplikacije za prijevod čitavih dokumenata (npr. Word, Power Point) i prijevod mrežnih stranica.<sup>95</sup> Jedan je od većih pružatelja strojnog prijevoda u Europi Yandex, ruska međunarodna organizacija specijalizirana za Internet servise i proizvode, koja svojom aplikacijom Yandex Translate pruža usluge strojnog prijevoda teksta ili mrežnih stranica. Ova aplikacija koristi samoupravljeni statistički pristup strojnog prijevoda koji je razvio Yandex, ali su 2017. godine počeli koristiti i neurološki pristup strojnog prijevoda kako bi ostali konkurentni na tržištu. Sustav Yandex Translatea koristi ruska Wikipedia za pružanje usluga prijevoda s ruskog na engleski. Postoji još jedna ruska organizacija, PROMT, koja se bavi razvijanjem aplikacije za strojni prijevod, osnovana 1991. godine. PROMT pruža usluge prijevoda za engleski, njemački, francuski, španjolski, talijanski, portugalski i ruski jezik. Kao i većina organizacija koje se bave razvijanjem sustava za strojni prijevod, i PROMT je u svojim počecima koristio pristup temeljen na pravilima, no on je zamijenjen 2010. godine prijelazom na statistički pristup strojnog prijevoda. Danas, PROMT je prešao na neurološki pristup strojnog prijevoda kako bi bili u mogućnosti pružiti kvalitetnije usluge strojnog prijevoda.<sup>96</sup> Jedna od najutjecajnijih platformi za pružanje usluga strojnog prijevoda smještena u Europi jest Apertium, razvijena uz pomoć sredstava španjolske i katalonske vlade na Sveučilištu u Alicanteu. Apertium je besplatan program dostupan na mrežnom mjestu, objavljen pod GNU GPL licencom (GNU General Public License). Iako je u početku razvijen za prevođenje bliskih jezika, njegove mogućnosti su u međuvremenu poboljšane pa je sada sposoban prevoditi različite jezične parove te primjerice podržava strojni prijevod za srpsko-hrvatski jezik. Svaki novi jezični par kreira se pripremom jezičnih podataka u obliku rječnika i pravila u dokumentiranom XML formatu. Apertium za strojni prijevod koristi pristup temeljen na pravilima te i dalje uspješno pronalaze svoje korisnike te razvijaju svoje poslovanje.<sup>97</sup>

Tablica 1. Najpoznatiji svjetski pružatelji strojnog prijevoda.

Naziv	Pružatelj
-------	-----------

<sup>95</sup> SYSTRAN Translate. // SYSTRAN. URL: <http://www.systransoft.com/systran/> (2019-09-11)

<sup>96</sup> About the Company. // PROMT Automated Translation Solutions. URL: <https://www.promt.com/company/profile/> (2019-09-11)

<sup>97</sup> Apertium: A free/open-source machine translation platform. // Apertium. // <https://www.apertium.org/index.eng.html?dir=cat-por#translation> (2019-09-11)

Google Translate	Google
Microsoft Translate	Microsoft
Systran Translate	Systran
Prompt.One	Prompt
Yandex	Yandex
Apertium	Apertium

U posljednjih nekoliko desetljeća tehnologija strojnog prevođenja napredovala je zajedno s naprecima ostvarenim u različitim srodnim područjima kao što su informatika, lingvistika te mobilna tehnologija. S obzirom da ne postoji način da se predvidi kako će se i kojom brzinom sama tehnologija razvijati u budućnosti, teško je predvidjeti kako će se i što će se u budućnosti dogoditi s tehnologijom strojnog prevođenja. Međutim, vjeruje se da će neke teme i pravci koji su se pojavili u posljednjih nekoliko godina i utjecali na njegov razvoj, i dalje imati znatan utjecaj na daljnje razvijanje, što uključuje:

- globalizaciju prijevoda,
- stvaranje raznovrsnosti,
- redefiniranje prijevoda,
- umrežavanje pedagogije,
- modernizaciju profesionalizma,
- formulaciju koncepata,
- savršenstvo automatizacije,
- poduzetnost prevođenja,
- naglasak na praktičnost,
- preusmjeravanje u istraživanju,
- promjenu pristupa.<sup>98</sup>

---

<sup>98</sup> Chan, Sin-wai. The future of Translation Technology: Towards a World without Babel. London i New York: Routledge, 2017.

## 6. Zaključak

U ovome radu opisano je strojno autorstvo u obliku generatora teksta i prijevoda, odnosno njihov razvoj, preduvjeti za razvoj te primjena i primjeri. Može se reći kako je ovaj oblik autorstva istovremeno star i nov s obzirom da se prvi put pojavio prije više od 60 godina, ali se neprestano razvija i poprima nove značajke i funkcionalnosti što je uvjetovano brzim razvojem tehnologije općenito. Upravo je taj brzi razvoj tehnologije, konkretno umjetne inteligencije i njenih grana, omogućio nastanak različitih pristupa i sustava korištenih za omogućavanje i stvaranje alata ili aplikacija za strojno generiranje teksta ili prijevoda. Vrlo je bitna raznolikost u pristupima i sustavima jer se tijekom godina na temelju korištenja jednog pristupa moglo prepoznati njegove prednosti i što je još bitnije, njegove nedostatke kako bi se omogućilo razvijanje i implementiranje novih pristupa koji su omogućili brže, jednostavnije te posljedično, kvalitetnije strojno generiranje teksta ili prijevoda. Generatori teksta i prijevoda sastoje se od više različitih vrsta te se koriste za više različitih polja primjene, no krajnji cilj i jednoga i drugoga jest pružiti kvalitetan proizvod ili uslugu te biti konkurentan na tržištu kontinuiranim razvijanjem i praćenjem tehnoloških dostignuća. Ako se zanemari razvoj tehnologije i ostane na zastarjelim sustavima ili pristupima, vrlo su velike šanse da će to dovesti do propasti organizacije koja se time bavi. Današnje su aplikacije za generiranje teksta i prijevoda vrlo raznolike i inovativne, no to je područje u kojemu se u bilo kojemu trenutku može proizvesti konkurentan i jak proizvod ili usluga, bio on potpuno nov na tržištu ili jednostavno bolja verzija postojećih aplikacija. Trenutno, tržište strojnog autorstva vode ili velike IT organizacije kao što su Google i Microsoft ili organizacije koje se bave specifičnim područjem umjetne inteligencije kao što je OpenAI i SYSTRAN. Istraživanje kojega su proveli Colin Lovrinovic i Holger Volland u kojemu su raspravljali o budućem utjecaju umjetne inteligencije u nakladničkoj industriji donosi nekoliko vrlo zanimljivih rezultata. Prvo, očekuje se da umjetna inteligencija neće zamijeniti čovjeka kao autora te da će zapravo omogućiti snažnije poslovanje u nakladničkoj industriji. Također, rezultati istraživanja su pokazali kako ulaganje u umjetnu inteligenciju neće utjecati na čovjekov obujam posla u svakodnevnom radu. Osim toga, istraživanje je pokazalo kako nakladničke tvrtke koje su uložile u razvijanje umjetne inteligencije (zapošljavanjem novih stručnih radnika ili obukom postojećih) bilježe primjetno povećanje u prihodima pri prodaji svojih proizvoda. Međutim, istraživanje također pokazuje kako trenutno postoji bojazan od značajnijeg ulaganja u razvoj umjetne inteligencije. Vjeruje se da će taj bojazan s vremenom nestati jer nakladničke tvrtke koje ulažu u njen razvoj bilježe porast u prihodima te

planiraju daljnje ulaganje u nju.<sup>99</sup> Tema ovoga diplomskog rada u neprestanom je razvoju, stoga se u narednih nekoliko godina može očekivati pojava novih značajki strojnog autorstva, što znači da će se otvoriti još puno novog prostora za daljnje istraživanje i proučavanje ovoga polja.

---

<sup>99</sup> Lovrinovic, Colic; Volland, Holger. The Future Impact of Artificial Intelligence on the Publishing Industry. Gould Finch; Frankfurter Buchmesse. Listopad, 2019.



## 7. Popis korištenih izvora i literature

1. About the Company. // PROMT Automated Translation Solutions. URL: <https://www.promt.com/company/profile/> (2019-09-12)
2. An AI and an artist go on the road. “The idea was to write a novel with a car”// CBC. URL: <https://www.cbc.ca/radio/spark/409-1.4860495/an-ai-and-an-artist-go-on-the-road-the-idea-was-to-write-a-novel-with-a-car-1.4860760> (2019-09-12)
3. Apertium: A free/open-source machine translation platform. // Apertium. URL: <https://www.apertium.org/index.eng.html?dir=cat-por#translation> (2019-09-11)
4. Artificial Intelligence. // Encyclopedia Britannica. URL: <https://www.britannica.com/technology/artificial-intelligence> (2019-09-12)
5. Artificial Intelligence (AI). // Techopedia. URL: <https://www.techopedia.com/definition/190/artificial-intelligence-ai> (2019-08-16)
6. Best Machine Translation Software. // G2. URL: <https://www.g2.com/categories/machine-translation> (2019-09-12)
7. Brownlee, Jason. A Gentle Introduction to Text Summarization. // Machine Learning Mastery. URL: <https://machinelearningmastery.com/gentle-introduction-text-summarization/> (2019-08-27)
8. Chan, Sin-wai. The future of Translation Technology: Towards a World without Babel. London i New York: Routledge, 2017.
9. Chatbot: What is Chatbot? Why are Chatbots Important? // Expert System. URL: <https://www.expertsystem.com/chatbot/> (2019-09-07)

10. Computational Linguistics. // SearchEnterpriseAI. URL:  
<https://searchenterpriseai.techtarget.com/definition/computational-linguistics-CL> (2019-08-30)
11. Computational Linguistics. // Techopedia. URL:  
<https://www.techopedia.com/definition/194/computational-linguistics> (2019-08-30)
12. Computer System. // Techopedia. URL:  
<https://www.techopedia.com/definition/593/computer-system> (2019-10-26)
13. Conrad, Lettie Y. The robots Are Writing: Will Machine-Generated Books Accelerate our Consumption os Scholarly Literature? // The Scholarly Kitchen. URL:  
<https://scholarlykitchen.sspnet.org/2019/06/25/the-robots-are-writing-will-machine-generated-books-accelerate-our-consumption-of-scholarly-literature/> (2019-09-12)
14. Cunningham, Hamish. Automatic Information Extraction, 2004. URL:  
<https://gate.ac.uk/sale/ell2/ie/main.pdf> (2019-09-05)
15. Database (DB). // TechTarget. URL:  
<https://searchsqlserver.techtarget.com/definition/database> (2019-10-26)
16. Database Front End. // Techopedia. URL:  
<https://www.techopedia.com/definition/6761/database-front-end> (2019-09-07)
17. Davis, Nathan S. An Analysis of Document Retrieval and Clustering Using an Effective Semantic Distance Measure, 2008. URL:  
<https://scholarsarchive.byu.edu/cgi/viewcontent.cgi?article=2599&context=etd> (2019-09-04)
18. Dell’Orletta F., Venturi G., Cimino A., Montemagni S. (2014) “[T2K: a System for Automatically Extracting and Organizing Knowledge from Texts](#)“. In Proceedings of 9th Edition of International Conference on Language Resources and Evaluation (LREC 2014), 26-31 May, Reykjavik, Iceland. URL: <http://www.italianlp.it/demo/t2k-text-to-knowledge/> (2019-09-05)

19. Deng, Li; Dong Yu. Deep Learning: Methods and Applications. URL:  
<https://www.microsoft.com/en-us/research/wp-content/uploads/2016/02/DeepLearning-NowPublishing-Vol7-SIG-039.pdf> (2019-08-29)
20. Donovan, Alexander. What Is Deep Learning and Why Is It More Relevant Than Ever?  
// URL: <https://interestingengineering.com/what-is-deep-learning-and-why-is-it-more-relevant-than-ever> (2019-08-29)
21. F.R., Martin. What 's An Artificial Intelligence Production System? Here Are The Basics. // Analytics India Magazine. URL: <https://analyticsindiamag.com/ai-production-system-basic/>(2020-02-10)
22. Frankenfield, Jake. Artificial Inteligence (AI). // Investopedia. URL:  
<https://www.investopedia.com/terms/a/artificial-intelligence-ai.asp> (2019-08-16)
23. Frankenfield, Jake. Strong AI. // Investopedia. URL:  
<https://www.investopedia.com/terms/s/strong-ai.asp> (2019-08-16)
24. Frankenfield, Jake. Weak AI. // Investopedia. URL:  
<https://www.investopedia.com/terms/w/weak-ai.asp> (2019-08-16)
25. Garbade, Michael J. A Simple Introduction to Natural Language Processing. // Becoming Human. URL: <https://becominghuman.ai/a-simple-introduction-to-natural-language-processing-ea66a1747b32> (2019-09-02)
26. Gupta, Mohit. ML |. What Is Machine Learning? // GeeksforGeeks. URL:  
<https://www.geeksforgeeks.org/ml-machine-learning/> (2019-08-17)
27. Horingold, Thomas. The First Novel Written by AI is Here – and It's as Weird as You'd Expect It to Be. // Singularity hub. URL:  
<https://www.theverge.com/2019/4/10/18304558/ai-writing-academic-research-book-springer-nature-artificial-intelligence> (2019-09-12)

28. How to write with artificial intelligence. // Medium. URL: <https://medium.com/deep-writing/how-to-write-with-artificial-intelligence-45747ed073c> (2019-08-30)
29. Hutchins, John W. Machine Translation: A Brief History. // Concise History of Language Sciences: From the Sumerians to the Cognitivists, 1995. Str. 431-445. URL: <https://aymara.org/biblio/mtranslation.pdf> (2019-09-09)
30. Intellexer Natural Language Interface. // Intellexer. URL: [https://www.intellexer.com/natural\\_language.html](https://www.intellexer.com/natural_language.html) (2019-09-07)
31. Jurafsky, Daniel; James H. Martin. Speech and Language Processing: An Introduction to Natural Language Processing: Computational Linguistics, and Speech Recognition, 2018. URL: <https://web.stanford.edu/~jurafsky/slp3/ed3book.pdf> (2019-09-06)
32. Lateef, Zulaikha. Types of Artificial Intelligence You Should Know. // edureka! URL: <https://www.edureka.co/blog/types-of-artificial-intelligence/#Branches%20of%20Artificial%20Intelligence> (2019-10-27)
33. Lopez Yse, Diego. Your Guide to Natural Language Processing (NLP) // Towards Data Science. URL: <https://towardsdatascience.com/your-guide-to-natural-language-processing-nlp-48ea2511f6e1> (2019-09-02)
34. Lovrinovic, Colic; Volland, Holger. The Future Impact of Artificial Intelligence on the Publishing Industry. Gould Finch; Frankfurter Buchmesse. Listopad, 2019.
35. Macherey, Klaus i dr. Natural Language Understanding Using Statistical Machine Translation. // Lehrstuhl für Informatik VI, 2001, str. 2. URL: [https://www.researchgate.net/publication/2371092\\_Natural\\_Language\\_Understanding\\_Using\\_Statistical\\_Machine\\_Translation](https://www.researchgate.net/publication/2371092_Natural_Language_Understanding_Using_Statistical_Machine_Translation) (2019-09-03)

36. Machine Learning: What It Is and Why It Matters. // Sas. URL: [https://www.sas.com/en\\_us/insights/analytics/machine-learning.html](https://www.sas.com/en_us/insights/analytics/machine-learning.html) (2019-08-17)
37. Machine Translation. // Andovar. URL: <https://www.andovar.com/machine-translation/> (2019-09-10)
38. Machine Translation. // Microsoft. URL: <https://www.microsoft.com/en-us/translator/business/machine-translation/> (2019-09-11)
39. Marr, Bernard. 10 Amazing Examples Of How Deep Learning AI Is Used In Practice? // Forbes. URL: <https://www.forbes.com/sites/bernardmarr/2018/08/20/10-amazing-examples-of-how-deep-learning-ai-is-used-in-practice/#198d922ef98a> (2019-08-29)
40. Marr, Bernard. What Is Deep Learning AI? A Simple Guide With 8 Practical Examples. // Forbes. URL: <https://www.forbes.com/sites/bernardmarr/2018/10/01/what-is-deep-learning-ai-a-simple-guide-with-8-practical-examples/#6bda34aa8d4b> (2019-08-29)
41. Mazare, Pierre-Emmanuel i dr. Training Millions of Personalized Dialogue Agents, 2018. URL: <https://arxiv.org/pdf/1809.01984.pdf> (2019-09-07)
42. McDowell, Kenric. 1 The Road By an Artificial Neural Network. URL: <https://www.jbe-books.com/products/1-the-road-by-an-artificial-neural> (2020-02-08)
43. McGuire, Nick. How Accurate Is Google Translate In 2018? // ARGO Translation. URL: <https://www.argotrans.com/blog/accurate-google-translate-2018/> (2019-09-11)
44. Merchant, Brian. When an AI Goes Full Jack Kerouac. // The Atlantic. URL: <https://www.theatlantic.com/technology/archive/2018/10/automated-on-the-road/571345/> (2019-09-12)

45. Mertz, David. Putting XML in context with hierarchical, relational and object-oriented models. // IBM. URL: <https://www.ibm.com/developerworks/xml/library/x-matters8/index.html> (2019-10-26)
46. Meg. The best sentiment analysis tools. // TalkWalker. URL: <https://www.talkwalker.com/blog/best-sentiment-analysis-tools> (2019-09-05)
47. Natural Language Generation (NLG). // SearchEnterpriseAI. URL: <https://searchenterpriseai.techtarget.com/definition/natural-language-generation-NLG> (2019-08-29)
48. Natural Language Processing (Iot): What it is and why it matters. // SAS. URL: [https://www.sas.com/en\\_us/insights/analytics/what-is-natural-language-processing-nlp.html#world](https://www.sas.com/en_us/insights/analytics/what-is-natural-language-processing-nlp.html#world) (2019-09-02)
49. Natural Language Processing (NLP). // SearchBusinessAnalytics. URL: <https://searchbusinessanalytics.techtarget.com/definition/natural-language-processing-NLP> (2019-09-02)
50. Natural Language Understanding (NLU). // SearchEnterpriseAI. URL: <https://searchenterpriseai.techtarget.com/definition/natural-language-understanding-NLU>(2019-09-03)
51. Natural Language Understanding (NLU). // Techopedia. URL: <https://www.techopedia.com/definition/33013/natural-language-understanding-nlu> (2019-09-03)
52. Natural Language Understanding: What is it and how is it different from NLP. // Expert System. URL: <https://www.expertsystem.com/natural-language-understanding-different-nlp/> (2019-09-03)
53. Network Database. // Techopedia. URL: <https://www.techopedia.com/definition/20971/network-database> (2019-10-26)

54. Ng, Andrew. Machine Learning. // Coursera.  
URL:<https://www.coursera.org/learn/machine-learning> (2019-08-17)
55. Nicholson, Chris. Artificial Intelligence (AI) vs. Machine Learning vs. Deep Learning. // Skymind. URL: <https://skymind.ai/wiki/ai-vs-machine-learning-vs-deep-learning> (2019-08-17)
56. NoSQL (Not Only SQL database). // TechTarget. URL:  
<https://searchdatamanagement.techtarget.com/definition/NoSQL-Not-Only-SQL> (2019-10-26)
57. Post, Nicole. Different Types of Machine Translation. // Localize Blog. URL:  
<https://localizeblog.com/types-of-machine-translation/> (2019-09-10)
58. P.Prabhu, P. Document Clustering for Information Retrieval: A General Perspective, 2011. URL:  
[https://www.researchgate.net/publication/256041972\\_Document\\_Clustering\\_for\\_Information\\_Retrieval\\_-\\_A\\_General\\_Perspective](https://www.researchgate.net/publication/256041972_Document_Clustering_for_Information_Retrieval_-_A_General_Perspective) (2019-09-04)
59. Pranjal, Srivastava. Essentials of Deep Learning: Introduction to Long Short Term Memory // Analytics Vidhya. URL:  
<https://www.analyticsvidhya.com/blog/2017/12/fundamentals-of-deep-learning-introduction-to-lstm/> (2019-09-12)
60. Reiter, Ehud. Building Natural Language Systems, 1996. URL:  
<https://arxiv.org/pdf/cmp-lg/9605002.pdf> (2019-08-29)
61. Remaker, Phillip. What is the difference between hardware, firmware and software?// Quora. URL: <https://www.quora.com/Whats-the-difference-between-hardware-firmware-and-software> (2019-10-19)

62. Roman, Kaia. Natural Language Understanding. // Twilio. URL: <https://www.twilio.com/docs/glossary/what-is-natural-language-understanding> (2019-09-03)
63. Ross Goodwin. // MLconf. URL: <https://mlconf.com/speakers/ross-goodwin/> (2019-09-12)
64. Sayantini. What is Production System in Artificial Intelligence? // Edureka! . URL <https://www.edureka.co/blog/production-system-ai/> (2020-02-10)
65. Schubert, Lenhart. Computational Linguistics. The Stanford Encyclopedia of Philosophy, Spring 2019 Edition. URL: <https://plato.stanford.edu/archives/spr2019/entries/computational-linguistics/> (2019-08-30)
66. Sentiment Analysis. // Techopedia. URL: <https://www.techopedia.com/definition/29695/sentiment-analysis> (2019-09-05)
67. Sentiment Analysis Explained. // Lexalytics. URL: <https://www.lexalytics.com/technology/sentiment-analysis> (2019-09-05)
68. Sentiment Analysis: Nearly Everything You Need to Know. // MonkeyLearn. URL: <https://monkeylearn.com/sentiment-analysis/> (2019-09-05)
69. Shewman, Dan. 10 of the Most Innovative Chatbots on the Web. // WordStream. URL: <https://www.wordstream.com/blog/ws/2017/10/04/chatbots> (2019-09-07)
70. Software. // Techopedia. URL: <https://www.techopedia.com/definition/4356/software> (2019-11-09)
71. Sommerlad, Joe. Google Translate: How Does the Serach Giant’s Multilingual Interpreter Actually Work? // Independent. URL: <https://www.independent.co.uk/life->



[style/gadgets-and-tech/news/google-translate-how-work-foreign-languages-interpret-app-search-engine-a8406131.html](https://style/gadgets-and-tech/news/google-translate-how-work-foreign-languages-interpret-app-search-engine-a8406131.html) (2019-09-11)

72. Stein, Daniel. Machine Translation: Past, Present and Future. // Language Technologies for a Multilingual Europe / Daniel Stein [et.al.]. Berlin: Language Science Press, 2018. str 5-17.
73. SYSTRAN Translate. // SYSTRAN. URL: <http://www.systransoft.com/systran/> (2019-09-11)
74. Turing Test. SearchEnterpriseAI. URL: <https://searchenterpriseai.techtarget.com/definition/Turing-test> (2019-08-30)
75. Vincent, James. OpenAI's new multitalented AI writes, translates, and slanders. // The Verge. URL: <https://www.theverge.com/2019/2/14/18224704/ai-machine-learning-language-models-read-write-openai-gpt2> (2019-08-30)
76. Vincent, James. The first AI-generated textbook shows what robot writers are actually good at. // The Verge. URL: <https://www.theverge.com/2019/4/10/18304558/ai-writing-academic-research-book-springer-nature-artificial-intelligence> (2019-09-12)
77. Voice Recognition. // Techopedia. URL: <https://www.techopedia.com/definition/9961/voice-recognition> (2019-09-07)
78. Wanyun Cui i dr. KBQA: Learning Question Answering over QA Corpora nad Knowledge Bases. Proceedings of the VLDB Endowment, 10, 5, 2017. URL: <https://arxiv.org/abs/1903.02419> (2019-09-07)
79. What Is Deep Learning? 3 things you need to know. // MathWorks. URL: <https://www.mathworks.com/discovery/deep-learning.html> (2019-08-29)

80. What is Machine Translation? // GALA – Globalization and Localization Association.  
URL: <https://www.gala-global.org/what-machine-translation> (2019-09-10)
81. What is Machine Translation? Rule Based Machine Translation vs. Statistical Machine Translation. // Systran. URL: <http://www.systransoft.com/systran/translation-technology/what-is-machine-translation/> (2019-09-10)
82. What is Sentiment Analysis and How to Do It Yourself. // Brand24. URL: <https://brand24.com/blog/sentiment-analysis/> (2019-09-06)
83. Zhang L., Sun JT. (2009) Text Generation. In: LIU L., ÖZSU M.T. (eds) Encyclopedia of Database Systems. Springer, Boston, MA URL: [https://link.springer.com/referenceworkentry/10.1007%2F978-0-387-39940-9\\_416](https://link.springer.com/referenceworkentry/10.1007%2F978-0-387-39940-9_416) (2019-10-12)