

Konekcijonizam u filozofiji jezika

Belaj, Paula

Undergraduate thesis / Završni rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Croatian Studies / Sveučilište u Zagrebu, Fakultet hrvatskih studija**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:111:920409>

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

Download date / Datum preuzimanja: **2024-07-24**



Repository / Repozitorij:

[Repository of University of Zagreb, Centre for Croatian Studies](#)





SVEUČILIŠTE U ZAGREBU
HRVATSKI STUDIJI

Paula Belaj

**KONEKCIONIZAM U FILOZOFIJI
JEZIKA**

ZAVRŠNI RAD

Zagreb, 2019.



SVEUČILIŠTE U ZAGREBU
HRVATSKI STUDIJI
ODSJEK ZA FILOZOFIJU

PAULA BELAJ

**KONEKCIONIZAM U FILOZOFIJI
JEZIKA**

ZAVRŠNI RAD

Mentor: doc.dr.sc., Sandro Skansi

Zagreb, 2019.

Sažetak

U ovom završnom radu prikazan je pristup koji se naziva konekcionizam. Konekcioniističke mreže, odnosno umjetne neuronske mreže koriste se u strojnom učenju ali mogu se primijeniti i u drugim područjima. U filozofiji konekcionizam se uglavnom razmatra kao alternativa simboličkom pristupu i to najčešće u filozofiji uma. Ispituje se način na koji se umjetne neuronske mreže mogu koristiti za rješavanje problema u filozofiji jezika. Za analizu uzimaju se Wittgensteinov kontekstualizam i referencijalna i atributivna upotreba određenih opisa.

Ključne riječi: obrada prirodnog jezika, konekcionizam, umjetne neuronske mreže, jezik, filozofija jezika.

Abstract:

In this paper we present an approach called connectionism. Connectionist networks or artificial neural networks are used in machine learning but can be applied to other fields as well. In philosophy connectionism is usually regarded as an alternative to symbolic approach, mainly advocated in philosophy of mind. We examine in what way artificial neural networks can be used to target problems in philosophy of language. We examine Wittgenstein's contextualism and referential and attributive use of definite descriptions as study cases.

Keywords: natural language processing, connectionism, artificial neural networks, philosophy of language

Sadržaj

Sadržaj.....	4
1. Uvod.....	5
2. Razvoj umjetne inteligencije.....	6
2.1. Obrada prirodnog jezika, model vreće riječi.....	8
2.2. Neuronske mreže bez povratnih veza.....	10
2.3. Backpropagation.....	11
2.4. Autoenkoder.....	12
2.5. Prikazivanje riječi pomoću brojeva: Word2vec, CBOW.....	13
3. Filozofija jezika i konekcionizam.....	14
3.1. Kontekstualizam.....	15
3.2. Referencijalna i atributivna upotreba.....	16
3.3. Razumijevanje teksta i zaključivanje.....	17
4. Zaključak.....	19
Bibliografija.....	20
Popis priloga.....	21
Popis tablica.....	21

1. Uvod

U filozofiji jezika je moguće povući razliku između dva pristupa, koji se mogu nazvati klasicizam i konekcionizam. Konekcionizam kao pristup koji se bavi ljudskom kognicijom više je zastupljen u filozofiji uma. U ovom radu naglasak je na pronalaženju i opisivanju konekcionističkih modela kao alternative logičkim opisima u filozofiji jezika. Na početku rada povezuju se pojmovi umjetne inteligencije, konekcionizma i kognitivne znanosti. Rad sadrži i povijesne činjenice u mjeri potrebnoj da se shvati kada se uopće ideje koje su utjecale na razvoj konekcionizma javljaju i koja su najvažnija imena u kontekstu razvoja konekcionizma, kako u računalnoj znanosti tako i u filozofiji.

Nakon pregleda razvoja umjetne inteligencije opisane su umjetne neuronske mreže, navode se neki od primjera tih mreža koji su važni za filozofiju jezika. Opisuju se algoritmi koji služe za obradu prirodnog jezika, a ti su vreća riječi i word2vec. Elaboriraju se i neuronske mreže bez povratnih veza. Neki od algoritama dodatno su objašnjeni uz pomoć primjera. Središnji dio ovog završnog rada sadrži objašnjenje dvaju koncepata u filozofiji jezika, a ti su kontekstualizam Ludwiga Wittgensteina i referencijalna i atributivna upotreba određenih opisa Keitha Donnellana. Svaki od koncepata povezuje se s konekcionističkim učenjem. Cilj je završnog rada predstaviti pristup rješavanju spomenutih problema filozofije jezika koji je svojevrsna alternativa tradicionalnim logičkim rješenjima odnosno istražiti prisutnost konekcionizma u filozofiji jezika. Također jedan od ciljeva jest i upoznati studente s pristupom umjetnih neuronskih mreža jer se one vrlo malo spominju na studiju filozofije. Tema je u ovom radu obrađena uz korištenje literature o umjetnim neuronskim mrežama i literature iz filozofije jezika i filozofije uma. Na kraju rada dan je zaključak i popis korištene literature te je razmotrena mogućnost daljnjeg istraživanja ove teme.

2. Razvoj umjetne inteligencije

Ideje o postojanju strojeva koji mogu procesirati jezik, računati i izvoditi slične radnje nisu nove, one postoje i prije nego što dolazi do razvoja računalne tehnologije, a pronalaze se i u filozofiji¹, prema tome i sam pojam umjetne inteligencije (engl. *artificial intelligence*) u svom najjednostavnijem obliku javlja se upravo u filozofiji. Danas je umjetna inteligencija područje čijim se proučavanjem uglavnom bave kognitivne znanosti. Jedan od izazova umjetne inteligencije jest razumijevanje procesa rezoniranja i onoga što je za čovjeka neformalno i intuitivno (Goodfellow, Bengio, & Courville, 2017). Dolaskom nove, kognitivističke paradigme u dvadesetom stoljeću naglasak je na promatranju mehanizma ljudskog mozga kao modela pomoću kojih se dolazi do novih saznanja na području kognitivnih znanosti². Računalnu znanost zanima kako konstruirati algoritme koji mogu obrađivati empirijske podatke i učiti iz njih, područje koje se time bavi naziva se strojno učenje. Algoritmi strojnog učenja svoju primjenu imaju u računalnoj lingvistici, obradi podataka, računalnom vidu i slično. U okviru strojnog učenja razlikuju se tri vala-kibernetika, konekcionizam, duboko učenje (Goodfellow, Bengio, & Courville, 2017). Duboko učenje jest grana strojnog učenja čije su metode primjenjive u umjetnoj inteligenciji, primjerice kod obrade prirodnog jezika. U umjetnoj inteligenciji strojno učenje dijeli se na: nadzirano, nenadzirano i podržano učenje. Duboko učenje bavi se svim načinima učenja i primjenjuje ih na probleme koji nisu tipični u umjetnoj inteligenciji poput planiranja, rezoniranja i slično (Skansi, 2018).

Konekcionizam je prema autorima val razvoja dubokog učenja, prvi puta javlja se u kognitivnim znanostima, a glavna ideja jest da veliki broj jedinica koje su združene u jednoj mreži postiže inteligentno ponašanje (Goodfellow, Bengio, & Courville, 2017). Još jednostavnije može se opisati da se konekcionističko učenje zasniva na postojanju umjetnih neuronskih mreža koje su inspirirane onim neuronima kakvi postoje kod ljudi, pri tom je važno naglasiti da postoje mehanizmi živčanog sustava koji nisu implementirani u neuronskim mrežama, ali isto tako i da umjetni neuroni imaju brojne karakteristike po kojima se razlikuju od bioloških neurona.

¹ U 17. stoljeću, njemački filozof i matematičar Gottfried W Leibniz promišlja o postojanju univerzalnog jezika (*characteristica universalis*) za metafiziku, matematiku i znanost. (Skansi, 2018)

² Kognitivne znanosti, odnosno jednakopravne komponente jedinstvene kognitivne znanosti su: psihologija, antropologija, filozofija, lingvistika, računarstvo i neuroznanost.

Konekcijonizam se može opisati i u odnosu na simbolički sustav³. U simboličkom sustavu računalo procesira informacije na način da manipulira simbolima, odnosno sintaksa sadrži pravila o tome kako simbole treba sastavljati. Umjetna inteligencija koja uvažava takav pristup naziva se još i GOF AI (engl. *Good Old-Fashioned Artificial Intelligence*), dok konekcijonizam inspiriran znanjem o ljudskom živčanom sustavu uvodi ideju umjetnih neuronskih mreža⁴, mreža je dinamički sustav koji prima informacije iz okoline, te se informacije procesiraju i nove informacije poslone su ponovno u okolinu (Bechtel & Abrahamsen, 2002). Također, drugi spomenuti autori (Goodfellow, Bengio, & Courville, 2017) napominju da u simboličkim sustavima čovjek svojom intervencijom mora formalizirati znanje dok u strojno učenju računalo samo obrađuje ono što mu se zadaje, premda je ovo netočno, jer strojno učenje zahtjeva anotaciju odnosno označavanje podataka, koju uglavnom rade ljudi, tako da i ovdje postoji ljudska komponenta. Kao prednost simboličkog sustava može se navesti to da on sam može savladati logičke operacije, dok konekcijonistički tek to mora naučiti.

Prema autoru (Skansi, 2018) umjetna inteligencija želi otkriti načine na koje se mišljenje može oponašati u stroju odnosno računalu s logičkim pravilima, a umjetne neuronske mreže počinju s pitanjem može li se mišljenje prikazati kao ljudski mentalni proces s logičkim pravilima. Početak umjetnih neuronskih mreža vezujemo uz logičara Waltera Pittsa i psihologa, filozofa i neurologa Warrena McCullocha⁵. Walter Pitts i Warren McCulloch umjetni neuron nazivaju *Threshold Logic Unit* (skraćeno TLU), te razlikuju dvije vrste neurona-ulazni i izlazni neuroni. Također pokazuju da neuroni mogu biti u pobuđenom stanju i u stanju mirovanja. Danas su umjetni neuroni puno razvijeniji od onog kojeg opisuju Pitts i McCulloch, ali važno ih je spomenuti jer od njihovog modela kreće razvoj umjetnih neuronskih mreža. Neke od sposobnosti ovih mreža su: učenje na temelju iskustva, prepoznavanje uzoraka, sposobnost apstrakcije i poopćavanja. Autor (Waskan) opisuje da konekcijonizam pristupa ljudskoj spoznaji uz pomoć matematičkih modela, a ti su modeli umjetne neuronske mreže.

³ Knjiga *Connectionism and the Mind* sadrži sažetu kritiku upućenu konekcijonizmu i obranu simboličkog pristupa. Kritiku upućuju Steven Pinker i Alan Prince.

⁴ David Rumelhart umjetne neuronske mreže predstavlja pod imenom konekcijonizma.

⁵ Warren McCulloch i Walter Pitts objavljuju članak pod nazivom *A Logical Calculus of Ideas Immanent in Nervous Activity* 1943. godine

2.1. Obrada prirodnog jezika, model vreće riječi

Intuitivno je shvaćanje da su dva tekstualna dokumenta slična ako se u njima pojavljuju slične riječi. U računalnoj obradi podataka tekst je najčešći oblik u kojem se pojavljuju informacije i obrada prirodnog jezika zato uključuje različite načine na koje se tekst može kvantificirati kako bi mogao biti spreman za daljnju obradu računalom. Jedan od jednostavnijih modela za obradu prirodnog jezika naziva se vreća riječi (engl. *bag of words*). Model osim što se koristi za procesiranje prirodnog jezika (engl. *Natural language processing*) koristi se i za traženje informacija (engl. *information retrieval*). Traženje informacija nije ograničeno samo na tekstualne informacije, primjenjuje se za vizualne informacije i druge, a smatra se dijelom informacijskih znanosti, za razliku od obrade prirodnog jezika koja se smatra interdisciplinarnim područjem lingvistike i računarstva, uz obilne primjene i korištenja metoda filozofijske logike. Vreća riječi može se objasniti i uz pomoć skupova, to je model koji pamti ponavljanje, ali ne i redoslijed svojih članova. Kada bi govorili o vreći riječi kao o vektoru onda bismo imali podatak o položaju i ponavljanju riječi (Skansi, 2018). Primjenom ovog modela dobivaju se informacije o tome kakva je distribucija riječi u promatranom tekstu, također olakšava pronalazak drugih dokumenata ili tekstova koji imaju sličnu distribuciju riječi i omogućuje ekstrahiranje tekstualnih informacija. Postoji nekoliko pojmova koje je potrebno objasniti prije nego što na primjeru pokažemo model. Korpus označava sveukupni tekst kojim se raspolaže, a fragment je dio teksta, vreća riječi nastaje na način da se svaka riječ iz korpusa promatra kao svojstvo (engl. *feature*) i u svaki stupac ispod te riječi broji se koliko se puta ona pojavila u fragmentu (Skansi, 2018). Ovakav način procesiranja prirodnog jezika omogućuje stvaranje svojstava koja se unose u algoritam strojnog učenja (Skansi, 2018). Uzmimo primjerice dvije rečenice (dva fragmenta) koje čine korpus:

Danas nije padala kiša, ali sutra će padati.

Sutra donosim knjige jer danas imam obaveza.

Korpus se sastoji od ukupno 15 riječi, na temelju korpusa kreiran je rječnik sa slijedećim riječima : kiša, danas, knjige ,sutra, imam, padati, ali, obaveza, nije, donosim jer, će. Nakon toga svaka rečenica prikazuje se u obliku binarnog vektora. Dobiva se slijedeća tablica :


	Danas nije padala kiša ali sutra će padati.	Sutra donosim knjige jer danas imam obaveza.
Kiša	1	0
Danas	1	1
Knjige	0	1
Sutra	1	1
Imam	0	1
Padati	1	0
Ali	1	0
Obaveza	0	1
Nije	1	0
Donosim	0	1
Jer	0	1
Će	1	0

Tablica 1 : Primjer vreće riječi

Model vreće riječi osim što se koristi u obradi prirodnog jezika svoju primjenu ima i u okviru računalnog vida. Nedostatak ovog modela jest u tome što u analizi teksta ne zahvaća značenje. Primjerice, kada bi se u jednom dokumentu pojavila dva različita termina koja imaju kontekstualno isto značenje (npr. "doktor" i "liječnik") algoritam to ne bi mogao prepoznati. U strojnom učenju ovaj se model najčešće koristi za procesiranje prirodnog jezika, a u dubokom učenju (iako se vreća riječi primjenjuje i u dubokom učenju) postoje drugačiji modeli koji u svojoj obradi zahvaćaju značenje, a oni će biti opisani u drugim poglavljima ovog rada.

2.2. Neuronske mreže bez povratnih veza

Umjetne neuronske mreže razlikuju se po arhitekturi i načinu učenja. Jedan od pokazatelja arhitekture mreže jest njena dubina, a ona se određuje na temelju brojeva slojeva u mreži. Mreže koje imaju više od tri sloja jesu duboke, s druge strane ako umjetna neuronska mreža ima najviše tri sloja ona je plitka, za takvu mrežu koristi se termin jednostavna neuronska mreža bez povratnih veza (engl. *Simple feedforward neural network*). Važno je naglasiti da nije tako da su sve plitke neuronske mreže one koje su bez povratnih veza (Skansi, 2018). Samo ime govori da u takvim mrežama veze isključivo idu prema slijedećem sloju i nemaju jednostruke veze, odnosno neuron u takvoj mreži može biti povezan s više njih u slijedećem sloju. U ulaznom sloju prihvaća se određeni input koji prolazi kroz skriveni sloj do izlaznog sloja. Neuroni u istom sloju nisu međupovezani. Output koji neki neuron odašilje ima istu vrijednost neovisno o smjeru. U ovakvoj neuronskoj mreži postoji *forward pass*, to je zbroj svih kalkulacija koje se događaju kada input putuje kroz mrežu. (Skansi, 2018).



Prikaz 1. Arhitektura jednostavne mreže bez povratnih veza

Na prikazu je vidljivo da je svaki neuron u ulaznom sloju povezan sa svim neuronima u skrivenom sloju, na ulazu mreža dobiva ulazne vrijednosti, najčešće se denotiraju sa x_1 i

x_2 , te vrijednosti ulaze u skriveni sloj koji radi jednostavni matematički izračun i prosljeđuje te vrijednosti do izlaznog sloja (vrijednosti su sada y_1, y_2), objašnjenje nije potpuno ako ne uključimo pojmove težine, prijenosne funkcije i praga. Koncept težine (engl. *weight*) sličan je konceptu sinapse u biološkom neuronu, signali koji putuju kroz mrežu imaju određene numeričku vrijednost, ti signali na ulazu u neuron množe se težinskim faktorom (označava se sa w , $w_1 \dots w_n$) pomnoženi signali zatim se zbrajaju i ako je zbroj iznad određenog praga (engl. *bias*) neuron daje izlazni signal. Prag je vrijednost koja je sadržana u svakom neuronu i ona se može mijenjati. Osim funkcije praga, neuron ima i prijenosnu funkciju (engl. *activation function*). Težine mogu smanjiti ili povećati vrijednost i one se kreću u intervalu od 0 do 1 (Skansi, 2018).

2.3. Backpropagation

U radu s umjetnim neuronskim mrežama razlikuju se dva procesa - proces učenja i proces obrade podataka. Učenje je proces u kojem se mijenjaju težine i on se ponavlja. U ovom poglavlju više će biti govora o nadziranom učenju jer je *backpropagation* upravo algoritam nadziranog učenja. U nadziranom učenju mreži se daju primjeri ulaznih signala i željenih izlaznih signala za neki zadatak, dani su da nadziru proces učenja, podaci u umjetnim neuronskim mrežama mogu biti iz uzorka koji se koristi za treniranje i iz uzorka koji se koristi za testiranje (Skansi, 2018). Mreže je potrebno je trenirati kako bi one mogle proizvesti željeni output, odnosno izvršiti zadatak koji se njima zadaje. U prethodnom poglavlju spominje se *forward pass*, a proces suprotan njemu naziva se *backpropagation*. Backpropagation algoritam služi za širenje pogreške unazad i najčešće se koristi za učenje mreža. Način na koji algoritam širi pogrešku unazad kroz slojeve moguć je uz primjenu metode gradijentnog spusta koji služi za optimizaciju (Skansi, 2018). U suštini, mjeri se pogreška u mreži koja radi klasifikaciju i modificiraju se težine, ako promjena težina rezultira smanjenjem pogreške onda se ona zadrži i taj proces se nastavlja (Skansi, 2018).

2.4. Autoenkoder

Performanse algoritma strojnog učenja ovise o tome kako su podaci prezentirani. Primjerice ako algoritam dobiva informacije koje su prikazane na način da se iz njih ne može izvesti određeni zaključak onda je potrebno promijeniti način na koji su informacije prezentirane. U strojnom učenju dio informacije uključen u nekoj reprezentaciji naziva se svojstvo (engl. *feature*). U prethodnom poglavlju spomenuto je nenadzirano učenje, a uz autoenkoder vezuje se nenadzirano učenje, odnosno učenje reprezentacija. Naučene reprezentacije omogućuju inteligentnim sustavima da se prilagode novim zadacima i to u kratkom vremenskom roku uz minimalnu ljudsku intervenciju (Goodfellow, Bengio, & Courville, 2017). Po svojoj arhitekturi autoenkoder je troslojna mreža koja je bez povratnih veza. Enkoder i dekoder sastavni su dijelovi u mreži, dekoder nema doticaj s ulaznim vrijednostima, on koristi samo kod koji dobiva od enkodera. Ova mreža ima i dvije različite funkcije - funkciju kodiranja, u kojoj se ulazni signali pretvaraju u drugačiju reprezentaciju i funkciju dekodiranja, nova reprezentacija pretvara se u originalni format (Goodfellow, Bengio, & Courville, 2017). Autoenkoder primjenjuje se za predprocesiranje informacija koje će se koristiti za jednostavnu mrežu bez povratnih veza, informacije koje su predprocesirane rezultat su aktivnosti skrivenog sloja (Skansi, 2018). Kod autoenkodera nije toliko važan output koji on daje jer je on samo kopija inputa. Kod ovih neuronskih mreža vrijedi da u izlaznom sloju postoji jednak broj neurona kao i u ulaznom sloju. U skrivenom sloju autoenkodera sadržane su bitne informacije o ulaznim vrijednostima, i to je pravi output autoenkodera.

Postoji još nekoliko vrsta autoenkodera, autoenkoder koji otklanja šum u podacima naziva se *denoising autoencoder*, on na ulazu prima primjerice sliku koja sadrži šum, a output je inicijalna slika bez šuma.

Ono što je još važno za autoenkodere jest to da se oni mogu i slagati kako bi se predprocesirane informacije koristile kao input u drugoj mreži. Slaganje se provodi na način da se uzimaju srednji slojevi više autonekodera, rezultat takvog slaganje je distribuirana reprezentacija srednjih slojeva (Skansi, 2018).

2.5. Prikazivanje riječi pomoću brojeva: *Word2vec*, *CBOW*

Na prethodnim stranicama ovog rada spomenuli smo da se za obradu prirodnog jezika računalo može služiti različitim modelima. Potrebno je konstruirati rječnik koji je strojno razumljiv, a da pri tom ostane očuvana semantika. Vreća riječi, model koji se koristi uglavnom u strojnom učenju u svojoj obradi ne zahvaća značenje, ali primjerice *Word2vec* model može na temelju poznavanja konteksta prepoznati slične riječi odnosno one koje i mogu imati slično značenje. U engleskom jeziku susrećemo termin *word embeddings* pod kojim podrazumijevamo modele koji su naučeni da riječi iz određenog rječnika prikazuju u obliku vektora koji imaju numeričku vrijednost (Skansi, 2018). Autor (Skansi, 2018) ističe da se ideja o značenju kao kontekstu pogrešno pripisuje Z. Harrisu, jer tu ideju prvi puta susrećemo u djelu *Filozofska istraživanja* čiji je autor Ludwig Wittgenstein. U nastavku ćemo pobliže opisati *Word2vec* model kao jedan od najpoznatijih za prikazivanje riječi u obliku vektora. *Word2vec*, skraćemo od *word to vector* omogućuje da se pronađu riječi koje su semantički slične i to na temelju udaljenosti između tih riječi.

Primjer klasične mjere sličnosti riječi je Hammingova udaljenost, s kojom se može izračunati sličnost između dvije riječi koje su jednake duljine. Uzmimo za primjer riječi pisac i autor, obje imaju pet slova, a Hammingova udaljenost iznosi 4 jer od ukupno 5 samo im je jedno slovo zajedničko. Bitno je naglasiti da pomoću ove udaljenosti nikada ne možemo prepoznati sličnosti u značenju pa se koriste vektori za koje je potrebna drugačija mjera za udaljenost (Skansi, 2018), kakvu može pružiti *Word2vec*.

Word2vec model može se sagraditi pomoću skip-grama ili pomoću *word2vec* modela. Skip-gram omogućuje predviđanje riječi iz konteksta ako je dana središnja riječ i definirana je veličina konteksta, a *CBOW* pretpostavi veličinu konteksta uzima 2 riječi iz konteksta (ako je veličina jednaka 1) i njih koristi za predviđanje (Skansi, 2018).

CBOW (engl. *continuous bag of words*) omogućuje da se predvidi koja riječ nedostaje u određenom kontekstu. Pomoću vreće riječi mi možemo govoriti o tome koji su dokumenti slični, ali samo ako su riječi koje se nalaze u oba dva dokumenta iste.

3. Filozofija jezika i konekcionizam

Filozofiju jezika isto kao i umjetnu inteligenciju zanimaju načini na koje se obrađuje prirodni jezik, istražuju pojam značenja i odnos između stvarnosti i jezika. Kao što je već spomenuto ideja o umjetnoj inteligenciji, ali i neke druge ideje svoje izvorište imaju u filozofiji, ali naglasak ovdje nije samo ukazati na povijesne činjenice već i razmotriti kako saznanja iz računalne obrade prirodnog jezika mogu pridonijeti rješavanju problema u filozofiji jezika. U logici se pomoću simbola označava određena propozicija, uz pomoć koje se događa zaključivanje i to simboličkim pravilima-na temelju početnih simbola se pravilima pretvorbe dolazi do novih simbola. Ovdje je naglasak na formi neovisno o tome što određeni simbol reprezentira. U svojim počecima umjetna inteligencija jest vođena idejom da su kognitivni procesi zapravo procesi logičkog načina zaključivanja (Bechtel & Abrahamsen, 2002). Postavljaju se pitanja- treba li manipulaciju simbolima pripisati ljudskom ili računalnom načinu zaključivanja ili i jednom i drugom i postoji li možda drugačije objašnjenje. Prema autorima (Bechtel & Abrahamsen, 2002) konekcionizam donosi sasvim drugačije razumijevanje komputacije, više se usredotočuje na kauzalni proces i dinamiku nego na već prije pohranjene simbole i pravila odnosno strukturu. Autori (Bechtel & Abrahamsen, 2002) također u svojoj knjizi upućuju na primjere koji pokazuju da konekcionistički sustavi mogu savladati neke kognitivne zadatke koje savladavaju ljudi.⁶

⁶ David Rumelhart i James McClelland primjerice pokazuju da mreža može naučiti kako formirati prošlo glagolsko vrijeme u engleskom jeziku.

3.1. Kontekstualizam

Teoriju značenja Ludwiga Wittgensteina upoznajemo pod nazivom kontekstualizam. Značenje neke riječi ovisno je o ulozi koju ta riječ ima u određenom kontekstu, odnosno jezičnoj igri. Pojam jezične igre središnji je u Wittgensteinovoj filozofiji, a ideju za nju vrlo vjerojatno dobiva promatrajući svakodnevnu situaciju, nogometnu utakmicu koja se izvodi krajnje konvencionalno isto kao što se odvija i jezična aktivnost (Lycan, 2011). Značenje neke riječi prema tome nije samo stvar relacije koju ta riječ ima s predmetom koji denotira već značenje ovisi o kontekstu u kojem se određena riječ pojavljuje. Vrijedno je zapitati se je li značenje riječi iscrpljeno upotrebom u određenom kontekstu ili značenje neke riječi uključuje i druge aspekte, primjerice gramatičko ustrojstvo u rečenici, pripadnost idiomu i slično. U modelu Word2vec ako dvije riječi imaju malu udaljenost u vektorskom prostoru one imaju i slično značenje, a u Wittgensteinovoj filozofiji kontekst služi za dohvaćanje značenja. Također, Wittgenstein se bavi i načinom na koji ljudi definiraju koncepte. On ne govori o tome kako pripadnost određenoj kategoriji može biti određena razmatrajući nužna i dovoljna svojstva već da kategorije nemaju jasne granice i uvodi obiteljske sličnosti jer postoje pojmovi za koje je teže odrediti kojoj kategoriji pripadaju. Način na koji članovi sebe međusobno razlikuju ne temelji se na jednoj značajki već na više njih koje neki članovi obitelji posjeduju (Wittgenstein, 1998). U članku autor (Waskan) ukazuje na sličnost između konceptata kako ih smatra Wittgenstein i informacija koje skrivenom sloju umjetne neuronske mreže. Konekcionistički modeli, kada se od njih traži da odrede pripada li neki pojam određenoj kategoriji mogu prepoznati gotovo neznatne razlike između pojmova. Način na koji Wittgenstein shvaća obiteljske sličnosti sličan je teoriji grozda kod Johna Searla (Lycan, 2011) ,ime nije jednako s jednim opisom kao kod Betrandu Russella već se na ime "vješaju" opisi.

3.2. Referencijalna i atributivna upotreba

Teoriji određenih opisa Bertranda Russella upućene su kritike. Između ostalih, američki filozof Keith Donnellan piše članak pod nazivom *Reference and Definite Descriptions* kako bi presudio sporu između Russella i Strawsona. Donnellan naime ukazuje na referencijalnu upotrebu određenih opisa koji Russell zanemaruje (Lycan, 2011). Ono što je važno jest to da u upotrebi određenih opisa postoje slučajevi kada se želi istaknuti konkretni predmet i slučajevi kada se želi istaknuti atributi pojedinačne osobe ili predmeta (Lycan, 2011). Donnellan pokazuje da dvije iste rečenice mogu imati različite upotrebe. Prije nego što pokažemo kako bi umjetne neuronske mreže mogle prepoznati referencijalnu, odnosno atributivnu upotrebu-opisati ćemo obje upotrebe. Atributivna upotreba kako samo ime kaže, koristi se kada se žele naglasiti atributi, odnosno kada se želi označiti točan identitet a u referencijalnoj upotrebi opis je sročan da pokuša referirati (Donnellan, 1966). U referencijalnoj upotrebi izdvaja se ono o čemu se govori. Referencijalna jest upotreba kada je opis stekao velika početna slova te se zapravo koristi kao naslov (Sveto Rimsko Carstvo) (Donnellan, 1966). U članku autor navodi primjer : *Smithov ubojica je lud* – istinito ako je optuženik lud, bez obzira je li počinio zločin ili ne, ovo je atributivna upotreba, nadalje, zamislimo kontekst u kojem se zna da je za ubojstvo kriv Jones, u tom kontekstu Smithov ubojica referira upravo na Jonesa (Donnellan, 1966).

Da bismo pokazali kako ovdje umjetne neuronske mreže mogu pomoći, moramo opisati u grubim crtama kako se umjetne neuronske mreže koriste za analizu sentimenta (Cambria, Das, Bandyopadhyay, & Feraco, 2017.). Sentiment je "osjećaj" iza teksta, a to je nešto vrlo intuitivno ljudima, ali komplicirano za formalizirati. Na primjer rečenica "odi u onu stvar" izražava izrazito negativan sentiment, makar po nijednoj riječi pojedinačno se to ne može naslutiti. Ali ljudima je to očito. Pravo pitanje je kako logički to formalizirati da bude i strojevima jasno kako ga prepoznati, no logička formalizacija (skup pravila) je ovdje skoro pa nemoguća. No pristup pomoću strojnog učenja je vrlo uspješan (Ribeiro, Araújo, Gonçalves, Gonçalves, & Benevenuto, 2016). U oba slučaja temeljni zadatak nije toliko formalizacija koliko predikcija: svaki logički sustav je algoritam, ali ovdje želimo umjesto logičkog sustava staviti drugačiji algoritam, algoritam strojnog učenja, odnosno umjetnu neuronsku mrežu. Klasični logički pristup objašnjenju

odnosno predikciji (čini se da to moramo poistovjetiti) je: $\text{input} + \text{pravila} = \text{output}$. Algoritmi strojnog učenja rade drugačije, i to: $\text{input} + \text{output} = \text{pravila}$ (Kharkovyna, 2019). Umjetne neuronske mreže, kako smo ranije objasnili uče pravila tako da dobiju input tekst i ljudskom rukom definiran output. Podatci za sentiment se tako sastoje od rečenica i oznaka. Rečenice su skupljene od nekud, a oznake su napravili ljudi. Takvi podatci se pretvaraju ili kroz vreću riječi ili kroz Word2vec, i daju umjetnoj neuronskoj mreži, i to predstavlja treniranje. Nakon što je mreža obradila sve podatke, daje joj se nova rečenica, ali ovaj put bez oznake, i mreža generira oznaku, na primjer POS, kojim želi reci da je ta rečenica pozivnog sentimenta.

To što je atributivna a što je referencijalna upotreba zapravo je neformalna teorija kao i sentiment jer pokazali smo da iste rečenice mogu imati različitu upotrebu određenih opisa. Neuronske mreže kao što je u više navrata pokazano upravo su prikladne za rješavanje problema koji su za ljude intuitivni a računala ih moraju naučiti, prepoznavanje referencijalne odnosno atributivne upotrebe upravo je jedan od takvih problema. Način na koji ovaj problem možemo prikazati u neuronskim mrežama jest da kreiramo skup podataka. Taj skup podataka sadržala bi rečenice i u nekima od njih bilo bi označeno kada je prisutna referencijalna a kada atributivna a određeni dio podataka ne bi imao tu oznaku (svojstvo). Mreža bi na temelju tih primjera naučila prepoznati kada je korištena koja upotreba i kada bi joj dali rečenice bez oznaka ona bi ponudila rješenje.

3.3. Razumijevanje teksta i zaključivanje

Postoje neuronske mreže koje su po svojoj arhitekturi kompleksnije od onih koje su opisane na prethodnim stranicama. Neuronske mreže koje imaju povratne veze (engl. *Reccurent neural networks*) koriste se za prepoznavanje govora i prevođenje tekstova. Primjer ovakve mreže je LSTM mreža (engl. *Long-short term memory*). U članku autori (Weston, i dr., 2016) opisuju model, nazvan MemNN (engl. *memory networks*) koji se sastoji od nekoliko LSTMova i koristi se za razumijevanje teksta i zaključivanje. U članku su prikazani zadaci na kojima se mjeri može li računalo odgovarati na jednostavna pitanja. Metoda odgovaranja na pitanja na najlakši način omogućuje ocjenjivanje sposobnosti računala da razumije tekst (Weston, i dr., 2016). U zadacima je pokazano da mreža može

prepoznati jednostavnu dedukciju ili negaciju i dati točan odgovor na pitanje, što ukazuje na to da su jednostavni zadatci u obradi prirodnog jezika već uvelike riješeni i da je sada vrijeme za istraživati kompleksne zadatke kakve nudi filozofija jezika.

4. Zaključak

Cilj ovog završnog rada bio je ispitati prisutnost konekcionizma u filozofiji jezika i pokazati kako se problemima u filozofiji jezika može pristupiti metodom umjetnih neuronskih mreža. Iako je konekcionizam u filozofiji više bio zastupljen 1980.-ih godina nije pokazano da se o njemu mnogo piše u filozofiji danas i da svjedočimo njegovom povratku već je ovim radom ostvaren prethodno navedeni cilj.

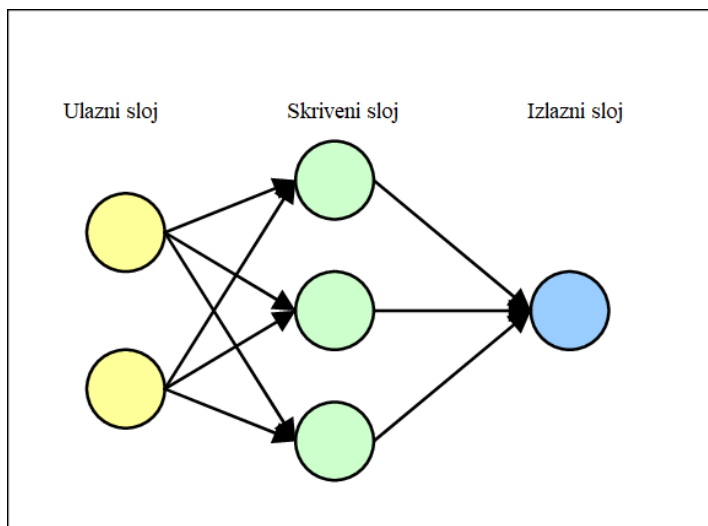
Rasprava oko toga je li u filozofiji prihvatljiviji simbolički ili konekcionistički pristup može služiti kao polazna točka za buduća istraživanja. Sigurno je da ne možemo zanemariti važnost logike posebice u filozofiji jezika, ali uvažavanje alternativnog pristupa također ne može biti zanemareno. Neuronske mreže donose drugačiji pogled na razumijevanje procesa obrade informacija i dolaženja do određenih saznanja kako u računalnoj znanosti tako i u filozofiji. Također, konekcionizam podrazumjeva jednostavnost u rješavanju problema kojima pristupa i njegova je posebnost upravo u tome. Mreža ne operira na temelju ustanovljenih pravila već sama na temelju danih informacija ustanovi obrazac pomoću kojeg nudi rješenje na probleme koji su joj zadani. Istraživanje mogućnosti neuronskih mreža u filozofiji jezika može ići i u smjeru konstruiranja baze podataka na kojoj bi mreža mogla naučiti prepoznati referencijalnu i atributivnu upotrebu u rečenici. Teorija grozda koju u filozofiji jezika vezujemo uz Johna Searla također može poslužiti za istraživanje o ovoj temi. Konekcionizam se u velikoj mjeri koristi za obradu prirodnog jezika koja zanima filozofiju jezika i u tome je ključ njegove implementacije.

Bibliografija

- Bechtel, W., & Abrahamsen, A. (2002). *Connectionism and the Mind: Parallel Processing, Dynamics, and Evolution in Networks*. Blackwell Publishing.
- Cambria, E., Das, D., Bandyopadhyay, S., & Feraco, A. (2017.). *A Practical Guide to Sentiment Analysis*. Springer.
- Donnellan, K. (1966). Reference And Definite Descriptions. *Philosophical Review*, str. 281-304.
- Goodfellow, I., Bengio, Y., & Courville, A. (2017). *Deep Learning*. Cambridge: MIT Press.
- Kharkovyna, O. (22. April 2019). *Machine Learning vs Traditional Programming*. Dohvaćeno iz Towards Data Science: <https://towardsdatascience.com/machine-learning-vs-traditional-programming-c066e39b5b17>
- Lycan, W. G. (2011). *Filozofija jezika: Suvremeni uvod*. Zagreb: Sveučilište u Zagrebu-Hrvatski studiji.
- Ribeiro, F. N., Araújo, M., Gonçalves, P., Gonçalves, M. A., & Benevenuto, F. (2016). SentiBench - a benchmark comparison of state-of-the-practice sentiment analysis methods. *EPJ Data Science*.
- Skansi, S. (2018). *Introduction to Deep Learning :From Logical Calculus to Artificial Intelligence*. Springer.
- Waskan, J. (n.d.). *Connectionism*. Dohvaćeno iz The Internet Encyclopedia of Philosophy: <https://www.iep.utm.edu/>
- Weston, J., Bordes, A., Chopra, S., Rush, A. M., Merriënboer, B. v., Joulin, A., & Mikolov, T. (2016). Towards AI-Complete question answering: A set of prerequisite toy tasks. *ICLR*. New York.
- Wittgenstein, L. (1998). *Filozofijska istraživanja*. (I. Mikecin, Trans.) Zagreb: Nakladni zavod Globus.
- Wittgenstein, L. (2009). *Plava i smeđa knjiga*. Zagreb: Nakladni zavod Globus.

Popis priloga

Prilog 1. Arhitektura jednostavne mreže bez povratnih veza



Popis tablica

Tablica 1 : Primjer vreće riječi